



**FORECASTING MENGGUNAKAN METODE *GENERALIZED* SARIMA
DENGAN PENDEKATAN IRLS UNTUK DATA PUAB DI JAKARTA**

Skripsi

disusun sebagai salah satu syarat
untuk memperoleh gelar Sarjana Sains
Program Studi Matematika

oleh

Hevi Rochmadiyah Wulandari

4111412044

**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI SEMARANG**

2017

PERNYATAAN KEASLIAN TULISAN

Saya menyatakan bahwa skripsi ini bebas plagiat kecuali yang secara tertulis ditunjuk dalam skripsi ini dan disebutkan dalam daftar pustaka. Apabila dikemudian hari terbukti terdapat plagiat dalam skripsi ini, maka saya bersedia menerima sanksi sesuai ketentuan perundang-undangan.

Semarang, Agustus 2017



Hevi Rochmadiyah Wulandari

4111412044

UNNES
UNIVERSITAS NEGERI SEMARANG

PENGESAHAN

Skripsi yang berjudul

Forecasting Menggunakan Metode *Generalized SARIMA* Dengan Pendekatan IRLS Untuk Data PUAB Di Jakarta

disusun oleh

Hevi Rochmadiyah Wulandari

4111412044

Telah dipertahankan di hadapan sidang Panitia Ujian Skripsi FMIPA UNNES pada tanggal Agustus 2017.



Prof. Dr. Zaenuri, S.E., M.Si., Akt.
NIP. 196412231988031001

Sekretaris

Drs. Arief Agoestanto, M.Si
NIP. 196807221993031005

Ketua Penguji

Drs. Sugiman, M.Si
NIP. 196401111989011001

Anggota Penguji/
Pembimbing I

Dr. Nurkaromah Dwidayati, M.Si
NIP. 196605041990022001

Anggota Penguji/
Pembimbing II

Dr. Scolastika Mariani, M.Si
NIP. 196502101991022001

MOTTO DAN PERSEMBAHAN

MOTTO

“Jika seseorang berpergian dengan tujuan mencari ilmu, maka Allah SWT akan menjadikan perjalanannya bagaikan perjalanan menuju surga.”

(Nabi Muhammad SAW)

Hidup ini seperti sepeda. Agar tetap seimbang, kau harus terus bergerak.

(Albert Einstein)

Doing all right into others as do good to yourself.

(Penulis)

PERSEMBAHAN

- ❖ Untuk kedua orang tua tercinta, Bapak Sunardi (Alm.) yang selalu memberikan doa terbaik dari surga dan Ibu Lestari yang selalu memberi dukungan baik materil maupun nonmateril.
- ❖ Untuk kakak dan adikku tersayang, Ari Hermawan Apriyanto dan Teguh Irawan Avianto yang selalu memberikan semangat dan motivasi kepadaku.
- ❖ Untuk keluarga besar tercinta, kakak ipar Fitri, ponakan tersayang Arlen Azkayra Arfy Hermawan.
- ❖ Untuk Ibu Dr. Nur Karomah Dwidayati, M.Si, dan Ibu Dr. Scolastika Mariani, M.Si, terimakasih atas bimbingan dan masukan yang telah diberikan selama penulisan skripsi.
- ❖ Untuk sahabat-sahabat Matematika 2012, Ayuk, Bayu, Ratih dkk yang telah membantu penyusunan skripsi ini dan selalu memberi semangat.

KATA PENGANTAR

Alhamdulillah Segala Puji Syukur atas kehadiran Allah SWT yang telah melimpahkan Rahmat dan Hidayah-Nya sehingga penyusunan skripsi dengan judul **“Forecasting Menggunakan Metode *Generalized* SARIMA Dengan Pendekatan IRLS Untuk Data PUAB di Jakarta”** dapat terselesaikan. Penyusunan skripsi ini bertujuan untuk memenuhi sebagian persyaratan guna memperoleh gelar sarjana pada program studi Matematika di Fakultas Matematika dan Ilmu Pengetahuan Alam di Universitas Negeri Semarang.

Penulis menyadari bahwa berkat bantuan, kerjasama, dan sumbangan pikiran dari berbagai pihak, maka skripsi ini dapat tersusun. Oleh karena itu, pada kesempatan ini penulis menyampaikan rasa terima kasih dan penghargaan yang sebesar-besarnya kepada:

1. Prof. Dr. Fathur Rokhman M.Hum, Rektor Universitas Negeri Semarang.
2. Prof. Dr. Zaenuri, S.E., M.Si., Akt., Dekan FMIPA Universitas Negeri Semarang.
3. Drs. Arief Agoestanto, M.Si., Ketua Jurusan Matematika FMIPA Universitas Negeri Semarang.
4. Drs. Mashuri, M.Si., Ketua Prodi Matematika FMIPA Universitas Negeri Semarang.
5. Dr. Nurkaromah Dwidayati, M.Si., selaku Dosen Pembimbing I yang telah memberikan bimbingan, pengarahan, nasihat, dan saran selama penyusunan skripsi ini.

6. Dr. Scolastika Mariani, M.Si., selaku Dosen Pembimbing II yang telah memberikan bimbingan, pengarahan, nasihat, dan saran selama penyusunan skripsi ini.
7. Drs. Sugiman, M.Si., selaku Dosen Penguji yang telah memberikan penilaian dan saran dalam perbaikan skripsi ini.
8. Prof. Dr. St. Budi Waluya, M.Si., selaku Dosen Wali saya yang telah memberikan bimbingan dan arahan.
9. Dosen-dosen Matematika Universitas Negeri Semarang yang telah membekali penulis dengan berbagai ilmu selama mengikuti perkuliahan sampai akhir penulisan skripsi ini.
10. Ibu saya tercinta dan Bapak saya tercinta (Alm.) atas segala dukungan dan doanya.
11. Untuk kakak dan adikku tersayang, Ari Hermawan Apriyanto dan Teguh Irawan Avianto yang selalu memberikan semangat dan motivasi kepadaku.
12. Teman-teman Matematika 2012 yang selalu memberikan semangat.
13. Semua pihak yang telah membantu dalam penelitian ini.

Semoga skripsi ini dapat memberikan manfaat bagi semua pihak yang berkepentingan.

Semarang, Agustus 2017

Penulis

ABSTRAK

Wulandari, Hevi.R. 2017. *Forecasting Menggunakan Metode Generalized SARIMA Dengan Pendekatan IRLS Untuk Data PUAB Di Jakarta*. Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang. Pembimbing Utama Dr. Nur Karomah Dwidayati, M.Si. dan Pembimbing Pendamping, Dr. Scolastika Mariani, M.Si.

Kata Kunci : Peramalan Data Jumlahan, GSARIMA, IRLS, negatif binomial, SARIMA

Salah satu pengembangan model stokastik untuk data distribusi non-Gaussian adalah model *generalized seasonal autoregressive integrated moving average* (GSARIMA) yaitu model GARMA yang melibatkan efek musiman dan order *differencing*. Estimasi model GSARIMA menggunakan pendekatan *iteratively reweighted least square* (IRLS). Yang dalam penelitian ini, model GSARIMA diterapkan pada data Nilai Transaksi Pasar Uang Antarbank di Jakarta dan membandingkan tingkat akurasi peramalan model tersebut dengan model *seasonal autoregressive moving average* (SARIMA) dengan bantuan program R.

Estimasi pertama model SARIMA digunakan sebagai estimasi awal parameter GSARIMA. Diperoleh model terbaik *Seasonal ARIMA* (1,1,1)(0,1,1)₁₂, dengan nilai $\sigma^2 = 8,441$, $\log \text{likelihood} = -128,6$ dan $AIC = 265,2$. Estimasi GSARIMA dimulai dengan uji regresi negatif binomial yang dibuktikan bahwa distribusi negatif binomial merupakan bilangan bulat positif dan terjadi kasus overdispersi pada data. Estimasi parameter GSARIMA menggunakan IRLS dengan fungsi pembobot Huber. Perhitungan estimasi GSARIMA dan SARIMA menggunakan Microsoft Excel dan Program R. Model terbaik GSARIMA adalah model GSARIMA (1,1,1)(0,1,1)₁₂. Sehingga persamaan model GSARIMA (1,1,1)(0,1,1)₁₂ adalah sebagai berikut $\log(\mu_t) = \log(-4,72B + 4,72B^2 - 4,72B^{12} + 15,67B^{13} - 4,72B^{14}) + 2,14 \log(y_{t-1}) - 0,56 \log(y_{t-2}) - 1,56 \log(y_{t-3}) + 0,64 \log(y_{t-4}) + 1,91 \log(y_{t-12}) + 0,82 \log(y_{t-13}) - 4,8 \log(y_{t-14}) + 4,6 \log(y_{t-15}) - 1,28 \log(y_{t-16}) + 1,91 \log(y_{t-24}) - 4,87 \log(y_{t-25}) + 5,36 \log(y_{t-26}) - 3,04 \log(y_{t-27}) + 0,64 \log(y_{t-28}) + 1,91 \log(\alpha_t) + 2,73 \log(\alpha_{t-1}) - 0,82 \log(\alpha_{t-3}) + 3,82 \log(\alpha_{t-12}) + 1,91 \log(\alpha_{t-13}) - 1,91 \log(\alpha_{t-14}) + 1,91 \log(\alpha_{t-24}) - 0,82 \log(\alpha_{t-25}) - 1,91 \log(\alpha_{t-26}) + 0,82 \log(\alpha_{t-27}) + 4,28 \log\left(\frac{y_{t-1}}{\mu_{t-1}}\right) - 0,99 \log\left(\frac{y_{t-2}}{\mu_{t-2}}\right) - 1,363 \log\left(\frac{y_{t-3}}{\mu_{t-3}}\right) + 0,002 \log\left(\frac{y_{t-4}}{\mu_{t-4}}\right) + 3,82 \log\left(\frac{y_{t-12}}{\mu_{t-12}}\right) - 2,53 \log\left(\frac{y_{t-13}}{\mu_{t-13}}\right) + 0,984 \log\left(\frac{y_{t-14}}{\mu_{t-14}}\right) + 1,365 \log\left(\frac{y_{t-15}}{\mu_{t-15}}\right) - 0,002 \log\left(\frac{y_{t-16}}{\mu_{t-16}}\right) - 0,003 \log\left(\frac{y_{t-25}}{\mu_{t-25}}\right) +$

$0,003 \log \left(\frac{y_{t-26}}{\mu_{t-26}} \right) - 0,002 \log \left(\frac{y_{t-27}}{\mu_{t-27}} \right) + 3,82 \log \left(\frac{\alpha_t}{\mu_t} \right) + 5,57 \log \left(\frac{\alpha_{t-1}}{\mu_{t-1}} \right) + 1,747 \log \left(\frac{\alpha_{t-2}}{\mu_{t-2}} \right) +$
 $0,003 \log \left(\frac{\alpha_{t-3}}{\mu_{t-3}} \right) + 3,82 \log \left(\frac{\alpha_{t-12}}{\mu_{t-12}} \right) + 5,567 \log \left(\frac{\alpha_{t-13}}{\mu_{t-13}} \right) + 1,744 \log \left(\frac{\alpha_{t-14}}{\mu_{t-14}} \right) - 0,003 \log \left(\frac{\alpha_{t-15}}{\mu_{t-15}} \right) -$
 $0,003 \log \left(\frac{\alpha_{t-25}}{\mu_{t-25}} \right) - 0,003 \log \left(\frac{\alpha_{t-26}}{\mu_{t-26}} \right)$ Berdasarkan analisis, hasil perbandingan model menunjukkan bahwa model GSARIMA relatif lebih baik jika dibandingkan dengan model SARIMA dengan menggunakan nilai AIC terkecil. Model GSARIMA memiliki nilai AIC=207,37 yang lebih kecil dari model SARIMA yaitu 265,2.



DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
PERNYATAAN KEASLIAN TULISAN	ii
HALAMAN PENGESAHAN.....	iii
MOTTO DAN PERSEMBAHAN	iv
KATA PENGANTAR	v
ABSTRAK	vii
DAFTAR ISI	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	xiv
BAB 1 PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Batasan Masalah	4
1.3 Rumusan Masalah	4
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	5
1.6 Sistematika Penulisan	5
BAB 2 LANDASAN TEORI	
2.1 Tinjauan Pustaka	7
2.1.1 <i>Forecasting</i>	7
2.1.2 Analisis Runtun Waktu	8
2.1.3 Runtun Waktu Stasioneritas dan Non-Stasioneritas.....	11
2.1.3.1 Operator <i>Backshift</i>	11
2.1.3.2 Stasioner dan Non-stasioner Dalam Mean	12

2.1.3.3 Stasioner dan Non-stasioner Dalam Variansi	15
2.1.3.4 ACF dan PACF	16
2.1.4 Asumsi <i>White Noise</i>	19
2.1.4.1 Residu Bersifat Acak	19
2.1.4.2 Residu Bersifat Normal	20
2.1.5 Seasonal (Musiman)	21
2.1.6 Model Runtun Waktu Musiman	22
2.1.6.1 Proses AR	22
2.1.6.2 Proses MA	24
2.1.6.3 Proses <i>Autoregressive Moving Average</i> (ARMA)	26
2.1.6.4 Proses <i>Autoregressive Integrated Moving Average</i> (ARIMA)	30
2.1.6.5 Model <i>Seasonal Autoregressive Integrated Moving Average</i>	32
2.1.7 Model Negatif Binomial Data Jumlahan	36
2.1.8 Model GSARIMA	37
2.1.9 Algoritma IRLS	39
2.1.10 Kriteria Pemilihan Model Terbaik	41
2.1.11 Pasar Uang Antar Bank	42
2.1.12 Software R	46
2.2 Penelitian Terdahulu	47
2.3 Kerangka Berpikir	48
BAB 3 METODE PENELITIAN	
3.1 Identifikasi Masalah	51
3.2 Perumusan Masalah	51
3.3 Pengumpulan Data	52
3.4 Tahapan Penelitian	52
3.5 Kesimpulan	53

BAB 4 HASIL PENELITIAN DAN PEMBAHASAN

4.1 Hasil Penelitian	56
4.1.1 Tahap Pengambilan Data	56
4.1.2 Identifikasi Data	57
4.1.2.1 Pemeriksaan Kestasioneran	57
4.1.3 Estimasi Model Peramalan	59
4.1.3.1 Estimasi Parameter SARIMA	59
4.1.3.2 <i>Diagnostic Checking</i>	62
4.1.3.3 Estimasi Parameter GSARIMA	64
4.1.4 Peramalan GSARIMA	74
4.2 Pembahasan	77
BAB 5 PENUTUP	
5.1 Kesimpulan	81
5.2 Saran	83
Daftar Pustaka	84
Lampiran	86



DAFTAR TABEL

Tabel	Halaman
Tabel 2.1 Bentuk Transformasi	15
Tabel 2.2 Pola ACF dan PACF Tidak Musiman	34
Tabel 2.3 Pola ACF dan PACF Musiman	35
Tabel 4.1 Estimasi Model <i>Seasonal</i> ARIMA	60
Tabel 4.2 Iterasi IRLS	69
Tabel 4.3 Hasil Peramalan Nilai Transaksi Pasar Uang Antarbank di Jakarta Tahun 2015 dengan model GSARIMA	75
Tabel 4.4 Perbandingan Nilai AIC Model SARIMA dan GSARIMA	76



DAFTAR GAMBAR

Gambar	Halaman
Gambar 2.1 Plot Horizontal	9
Gambar 2.2 Plot Musiman	9
Gambar 2.3 Plot Siklis	9
Gambar 2.4 Plot Trend	10
Gambar 2.5 Contoh Grafik Fungsi autokorelasi untuk data yang dipengaruhi pola <i>Trend</i>	21
Gambar 2.6 Contoh grafik fungsi autokorelasi untuk data yang dipengaruhi pola musiman bulanan.....	21
Gambar 2.7 Pola ACF dan PACF model AR(1)	24
Gambar 2.8 Pola ACF dan PACF model MA(1)	26
Gambar 2.9 Pola ACF dan PACF model ARMA(1)	29
Gambar 2.10 Kerangka Berfikir	50
Gambar 2.11 Bagan Alir Penelitian	55
Gambar 4.1 Plot Data Pasar Uang Antarbank	56
Gambar 4.2 Plot Data Time Series Pasar Uang Antarbank	57
Gambar 4.3 Plot ACF dan PACF data Pasar Uang Antarbank	58
Gambar 4.4 Plot ACF dan PACF dari data PUAB yang telah didifferencing	59
Gambar 4.5 Uji Q-Ljung-Box Residual ARIMA $(1,1,1)(0,1,1)_{12}$	62
Gambar 4.6 Nilai <i>P-value</i> Box-Ljung Test	63
Gambar 4.7 Uji Kolmogorov-Smirnov	63
Gambar 4.8 Uji Kolmogorov-Smirnov	64
Gambar 4.9 Perbandingan Data Aktual dan Hasil Ramalan Nilai Transaksi Pasar Uang Antarbank di Jakarta Tahun 2010-2015	76

DAFTAR LAMPIRAN

Lampiran	Halaman
Lampiran 1. Data Aktual Nilai Transaksi Pasar Uang AntarBank di Jakarta Tahun 2010 sampai dengan Tahun 2014 (Miliar Rupiah)	86
Lampiran 2. Perhitungan Estimasi GSARIMA Menggunakan IRLS Iterasi 1	87
Lampiran 3. Iterasi ke-2	89
Lampiran 4. Iterasi ke-3	91
Lampiran 5. Iterasi ke-4	93
Lampiran 6. Iterasi ke-5	95
Lampiran 7. Iterasi ke-6	97
Lampiran 8. Iterasi ke-7	99
Lampiran 9. Iterasi ke-8	101
Lampiran 10. Iterasi ke-9	103
Lampiran 12. Iterasi ke-10	105
Lampiran 13. Iterasi ke-11	107
Lampiran 14. Iterasi ke-12	109
Lampiran 15. Koding <i>script</i> Estimasi Parameter Model SARIMA pada Program R	111
Lampiran 16. Output Estimasi Parameter Metode SARIMA Program R.....	113

Lampiran 17. Perhitungan Signifikansi Parameter SARIMA	119
Lampiran 18. Koding <i>script</i> dan Output Regresi Negatif Binomial pada Program R	121
Lampiran 19. Koding <i>script</i> Estimasi Parameter Model GSARIMA pada Program R	124



BAB 1

PENDAHULUAN

1.1. Latar Belakang

Kemajuan ilmu pengetahuan telah mengembangkan berbagai metode peramalan *time series*. Dalam perencanaan tentunya diperlukan ketepatan dalam pemilihan metode. Hal ini untuk meminimumkan kesalahan dalam meramal. Salah satu metode peramalan yang dapat digunakan adalah metode runtun waktu. Analisis runtun waktu merupakan suatu metode analisis peramalan berbentuk kuantitatif yang mempertimbangkan waktu, dimana data dikumpulkan secara periodik berdasarkan urutan waktu untuk menentukan pola data masa lampau yang telah dikumpulkan secara teratur (Makridakis dan Wheelwright, 1999).

Peramalan data jumlahan (*count data*) merupakan salah satu topik utama dalam kajian pemodelan peramalan deret waktu (*time series*). Hal ini telah berkembang dalam kurun waktu tiga decade terakhir ini. Perkembangan model peramalan data jumlahan banyak didasari oleh metode *single exponential smoothing* (SES), diantaranya peramalan data permintaan berselang (*intermittent demand forecasting*) seperti yang ditunjukkan oleh Taunter dan Sani (2009).

Peramalan data jumlahan dengan pendekatan Gaussian (normal) telah dilakukan oleh Direktorat Kampanye Anti Malaria, Menteri Kesehatan di Sri Lanka. Model yang digunakan adalah *seasonal autoregressive integrated moving average* (SARIMA) yang mengasumsikan bahwa transformasi logaritma yang digunakan adalah transformasi pendekatan distribusi Gaussian yang diaplikasikan

pada data malaria bulanan. Pendekatan ini juga telah dilakukan oleh Hu, Tong, Mengersen, dan Connell (2007). Hu *et al.* membandingkan antara model Poisson deret waktu dengan model SARIMA pada kasus variabilitas cuaca dari *cryptosporidiosis*.

Dalam penelitian yang dilakukan oleh Yu, Chen, dan Wen (2002) bahwa ada dua pendekatan yang sering digunakan untuk memodelkan data deret waktu non-Gaussian. Pendekatan pertama telah menggunakan kombinasi linear pada variabel acak distribusi non-Gaussian dan pendekatan yang kedua adalah mentransformasi data deret waktu Gaussian ke dalam distribusi marginal yang lebih spesifik sehingga mampu digunakan untuk pendekatan non-Gaussian. Hal ini juga digunakan oleh Benjamin, Rigby, dan Stasinopoulos (2003) yang mengembangkan model stokastik untuk data-data yang mengikuti distribusi non-Gaussian seperti distribusi Poisson dan Negatif Binomial. Model tersebut adalah model *generalized autoregressive moving average* (GARMA).

Model GARMA menghubungkan komponen ARMA dengan variabel prediktor ke transformasi parameter rata-rata dari distribusi data dengan menggunakan fungsi link (*link function*). Fungsi link ini digunakan untuk memastikan bahwa distribusi data tetap dalam domain bilangan riil positif, sehingga memiliki ketepatan prediksi yang lebih akurat. Model GARMA sangat fleksibel untuk memodelkan data jumlahan dengan struktur *autoregressive* dan atau *moving average*. Akan tetapi, hanya dapat diaplikasikan pada data yang dianggap stasioner dan tidak musiman. Benjamin *et al.* (2003) menggunakan

pendekatan *iteratively reweighted least square* (IRLS) untuk mengestimasi parameter-parameter model GARMA.

Briet, Amerasinghe, dan Vounatsou (2013) mengembangkan suatu model *generalized seasonal autoregressive integrated moving average* (GSARIMA) dengan melibatkan efek musiman dan order *differencing* yang diterapkan pada data malaria di Sri Lanka. Briet *et al.* menggunakan satu variabel prediktor, yaitu curah hujan (*rainfall*) dan mengasumsikan bahwa data malaria mengikuti distribusi Negatif Binomial karena datanya berada pada domain diskrit dan merupakan bilangan bulat positif serta telah dibuktikan bahwa terjadi kasus overdispersi.

Briet *et al.* (2013) mengidentifikasi beberapa model yang sesuai, diantaranya model GSARIMA dan *generalized autoregressive integrated moving average* (GARIMA) yang tidak memasukkan efek musiman. Model-model tersebut diestimasi menggunakan pendekatan Bayesian dan menghasilkan bahwa model GSARIMA lebih baik dibandingkan dengan model GARIMA dengan menggunakan kriteria *deviance information criterion* (DIC) meskipun kedua model tersebut belum mampu memprediksi secara tepat distribusi residualnya.

Berdasarkan uraian di atas maka dalam penelitian akan dilakukan kajian tentang estimasi model GSARIMA dengan menggunakan IRLS dan membandingkan tingkat akurasi peramalan model GSARIMA dan SARIMA dengan prediktor dan tanpa prediktor yang akan diaplikasikan pada data Pasar Uang Antar Bank di Jakarta.

1.2. Batasan Masalah

Dalam penulisan penelitian ini, penulis menggunakan pendekatan *iteratively reweighted least square* (IRLS) dalam mengestimasi parameter GSARIMA. Jenis distribusi keluarga eksponensial yang digunakan adalah Negatif Binomial sehingga model yang akan diestimasi yaitu Negatif Binomial GSARIMA $(p,d,q)(P,D,Q)^S$. Penulis menggunakan data Pasar Uang Antar Bank di Jakarta dengan periode waktu Januari 2010 sampai dengan Desember 2014 dengan alat ukur untuk menghitung keakuratan ramalan yaitu AIC.

1.3. Rumusan Masalah

Berdasarkan latar belakang di atas, permasalahan pada penelitian ini yaitu:

- 1) Bagaimana estimasi parameter model GSARIMA dengan menggunakan pendekatan *iteratively reweighted least square* (IRLS) ?
- 2) Bagaimana *forecasting* data pasar uang antarbank menggunakan metode GSARIMA dan SARIMA ?
- 3) Bagaimana bentuk peramalan terbaik yang dapat digunakan untuk memprediksi data pasar uang antar bank pada periode yang akan datang ?

1.4. Tujuan Penelitian

- 1) Mengkaji estimasi parameter model GSARIMA menggunakan pendekatan *iteratively reweighted least square* (IRLS).
- 2) Mengetahui *forecasting* data pasar uang antarbank menggunakan GSARIMA dan SARIMA.
- 3) Mendapatkan model peramalan terbaik yang dapat digunakan untuk memprediksi data pasar uang antar bank pada periode yang akan datang.

1.5. Manfaat Penelitian

Manfaat yang ingin dicapai dalam penelitian ini sebagai berikut:

- 1) Mengembangkan wawasan keilmuan dan pengetahuan tentang model GSARIMA untuk peramalan data jumlahan.
- 2) Memberikan gambaran pengetahuan tentang cara menaksir parameter GSARIMA dengan menggunakan *iteratively reweighted least square* (IRLS).

1.6. Sistematika Penulisan

Sistematika penulisan skripsi disusun untuk memudahkan pemahaman tentang struktur dan isi skripsi. Penulisan skripsi ini dibagi menjadi tiga bagian, yaitu bagian awal, bagian isi, dan bagian akhir yang masing-masing diuraikan sebagai berikut.

1) Bagian Awal

Dalam penulisan ini, bagian awal berisi halaman judul, halaman pengesahan, motto dan persembahan, kata pengantar, abstrak, daftar isi, daftar tabel, daftar gambar, dan daftar lampiran.

2) Bagian Isi

Bagian isi dari penulisan skripsi ini terdiri atas lima bab, yaitu:

a. BAB 1 PENDAHULUAN

Bab ini membahas tentang latar belakang, pembatasan masalah, rumusan masalah, tujuan penelitian, manfaat penelitian, dan sistematika penulisan skripsi.

b. BAB 2 LANDASAN TEORI

Bab ini berisi tentang konsep-konsep yang dijadikan tinjauan pustaka seperti peramalan metode SARIMA dan GSARIMA, model Negatif Binomial data jumlahan, algoritma IRLS dan beberapa teori yang mendukung penelitian ini. Selain itu, dikemukakan beberapa penelitian yang telah dilakukan sebelumnya dan contoh aplikasi serta kerangka berfikir.

c. BAB 3 METODE PENELITIAN

Bab ini berisi tentang langkah-langkah yang dilakukan dalam penelitian ini meliputi fokus penelitian, pengumpulan data, penyelesaian masalah dan penarikan kesimpulan.

d. BAB 4 HASIL PENELITIAN DAN PEMBAHASAN

Bab ini berisi tentang hasil perhitungan peramalan menggunakan metode GSARIMA dan SARIMA yang menggunakan algoritma IRLS untuk mengetahui estimasi parameter GSARIMA.

e. BAB 5 SIMPULAN DAN SARAN

Bab ini berisi tentang simpulan hasil penelitian dan saran yang berkaitan dengan hasil penelitian yang diperoleh.

3) Bagian Akhir

Bagian ini berisi daftar pustaka yang memberikan informasi tentang buku sumber serta literatur yang digunakan dan lampiran-lampiran yang melengkapi uraian pada bagian ini.

BAB 2

LANDASAN TEORI

2.1. Tinjauan Pustaka

2.1.1 *Forecasting*

Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien (Makridakis, 1999: 3). Sedangkan menurut Martiningtyas (2004:100), peramalan (*forecasting*) adalah kegiatan untuk memperkirakan apa yang akan terjadi pada masa yang akan datang. Pengumpulan data yang relevan berupa informasi dapat menghasilkan peramalan yang akurat disertai pemilihan teknik peramalan yang tepat maka pemanfaatan informasi data akan diperoleh secara optimal. Peramalan nilai-nilai yang akan datang didasari dengan data historis dan pengalaman. Peramalan sering digunakan pada bidang ekonomi, perencanaan produksi, peramalan penjualan, dan kontrol stok. Meramal juga dapat didasarkan pada keahlian *judgement*, yang ada pada gilirannya didasarkan pada data historis dan pengalaman (Makridakis, 1999: 519).

Peramalan adalah prediksi nilai-nilai sebuah peubah berdasarkan kepada nilai yang diketahui dari peubah tersebut atau peubah yang berhubungan dengan cara memproyeksikan nilai-nilai di masa lampau (nilai yang diketahui) ke masa yang akan datang dengan cara menggunakan model matematika maupun perkiraan yang subjektif meskipun akan terdapat sedikit kesalahan yang disebabkan oleh adanya keterbatasan kemampuan manusia (Makridakis, dkk, 1999).

2.1.2 Analisis Runtun Waktu


Analisis runtun waktu pertama kali diperkenalkan dan dikembangkan pada tahun 1970 oleh Box dan Jenkins. Runtun waktu adalah himpunan observasi terurut dalam waktu atau dalam dimensi lain. Waktu antara dua observasi yang berurutan biasanya adalah konstan misalnya bulan kalender. Menurut sejarah niali observasinya, runtun waktu dibedakan menjadi dua yaitu runtun waktu deterministik dan runtun waktu stokastik. Runtun waktu deterministik adalah suatu runtun waktu dimana keadaan yang akan datang dapat diramalkan secara pasti dan tidak perlu penyelidikan kembali. Runtun waktu stokastik adalah suatu runtun waktu dimana keadaan yang akan datang bersifat probabilistik, menurut observasi yang di masa lampau. (Soejoeti, 1987 : 2.2).

Data *time series* yaitu data yang dikumpulkan dari waktu ke waktu untuk melihat perkembangan suatu kegiatan (misal perkembangan penjualan, produksi, harga dan lain sebagainya), bila data digambarkan akan menunjukkan fluktuasi dan dapat digunakan untuk dasar penarikan trend yang dapat digunakan untuk dasar peramalan yang berguna untuk dasar perencanaan dan penarikan kesimpulan (Supranto, 2001:15).

Menurut Makridakis dan Wheelwright (1999:21), pola data *time series* dapat dibedakan menjadi empat jenis, yaitu:

1) Pola Horizontal (H)


Terjadi apabila nilai dari data mengalami fluktuasi di daerah nilai rata-rata konstan. (Nilai rata-ratanya stasioner). Misal suatu produk yang nilai penjualannya tidak mengalami peningkatan atau penurunan dalam waktu tertentu.



Gambar 2.1 Plot Horizontal

2) Pola Musiman (S)


Terjadi apabila suatu deret dari data dipengaruhi oleh faktor musiman yang ditunjukkan oleh adanya pola yang teratur yang bersifat musiman. Misal data penjualan produk yang dicatat secara tahunan, bulanan atau harian.



Gambar 2.2 Plot Musiman

3) Pola Siklis (C)

Terjadi apabila pola data deret waktu mengalami fluktuasi ekonomi jangka panjang berhubungan dengan siklus bisnis. Misal penjualan produk seperti mobil dan peralatan lainnya.



Gambar 2.3 Plot Siklis

4) Pola *Trend* (T)

Terjadi apabila pola data mengalami kenaikan atau penurunan, pola data seperti ini bervariasi tak beraturan. Misal penjualan banyak perusahaan, produk nasional bruto (GNP) dan berbagai indikator sektor ekonomi atau bisnis lainnya mengikuti suatu pola *trend* selama perubahan sepanjang waktu.



Gambar 2.4 Plot Trend

Jika observasi runtun waktu dilambangkan dengan Z_t , dimana $t \in A$, dengan A himpunan bilangan asli, maka runtun waktu ini dinamakan runtun waktu diskrit. Jika $t \in R$ dengan R himpunan riil maka runtun waktu tersebut dinamakan runtun waktu kontinu (Soejoeti, 1987: 2.2).

Ciri yang menonjol dari analisis runtun waktu adalah bahwa deretan observasi pada suatu variabel dipandang sebagai realisasi dari variabel random berdistribusi bersama, yaitu dianggap bahwa adanya fungsi probabiliti bersama pada variabel random Z_1, \dots, Z_n , misal $f_1, \dots, n(Z_1, \dots, Z_n)$ (Soejoeti, 1987:1.9).

Dasar pemikiran *time series* adalah pengamatan sekarang (X_t) tergantung pada satu atau beberapa pengamatan yang dilakukan sebelumnya X_{t-1} . Dengan kata lain, model *time series* dibuat karena secara statistik terdapat korelasi antar deret pengamatan. Untuk melihat adanya korelasi antar pengamatan, dapat dilakukan uji korelasi antar pengamatan yang sering dikenal dengan *Autocorrelation Function* (ACF).

2.1.3 Runtun Waktu Stasioneritas dan Non-Stasioneritas

2.1.3.1 Operator *Backshift*

Operator *backshift* yang dinyatakan dengan B merupakan sebuah operator dengan penggunaan sebagai berikut:

(2.1)

$$BX_t = X_{t-1}$$

Dengan kata lain, notasi B yang dipasang pada X_t mempunyai pengaruh menggeser data satu periode ke belakang.

Operator *backshift* sering digunakan untuk menggambarkan proses differencing (*differencing*) untuk membuat data yang rata-ratanya tidak stasioner menjadi lebih dekat ke bentuk stasioner. Berikut ini gambaran *differencing* menggunakan operator *backshift*.

Misalkan X'_t merupakan *differencing* pertama dari X_t

(2.2)

$$X'_t = X_t - X_{t-1}$$

$$X'_t = X_t - BX_t = (1 - B)X_t$$

Perhatikan bahwa *differencing* pertama dinyatakan dengan $(1 - B)$.

Untuk *differencing* orde kedua perhatikan penggambaran berikut:

(2.3)

$$\begin{aligned} X''_t &= X'_t - X'_{t-1} \\ &= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \\ &= X_t - 2X_{t-1} + X_{t-2} \\ &= (1 - 2B + B^2)X_t = (1 - B)^2X_t \end{aligned}$$

Perhatikan bahwa *differencing* orde kedua dinyatakan dengan $(1 - B)^2$, hal ini penting untuk memperlihatkan bahwa *differencing* orde kedua tidak sama dengan *differencing* kedua.

2.1.3.2 Stasioner dan Non-stasioner dalam Mean

Suatu data runtun waktu dikatakan stasioner dalam mean adalah jika rata-rata tetap pada keadaan waktu yang kondusif atau jika tidak ada unsur *trend* dalam data dan apabila suatu diagram *time series* berfluktuasi secara lurus. *Time series plot* dapat membantu secara visual yaitu dengan jalan membuat plot terhadap data runtun waktu. Jika hasil plot tidak menunjukkan gejala trend maka dapat diduga bahwa data sudah stasioner. Perlu diperhatikan bahwa *time series plot* sangat sensitif terhadap perubahan skala sumbu X dan Y .

Apabila data tidak stasioner dalam mean, maka untuk menghilangkan ketidakstasioneran melalui penggunaan metode *differencing*. Notasi yang sangat bermanfaat adalah operator shift mundur (*backward shift*) B , yang penggunaanya sebagai berikut:

(2.4)

$$BX_t = X_{t-1}$$

UNNES
UNIVERSITAS NEGERI SEMARANG

Dengan: B = Pembeda

X_t = nilai X pada orde ke t

X_{t-1} = nilai X pada orde ke $t - 1$

Notasi B yang dipasang pada X_t , mempunyai pengaruh menggeser data 1 periode ke belakang. Dua penerapan B untuk X_t akan menggeser data tersebut 2 periode ke belakang, sebagai berikut:

(2.5)

$$B(BX_t) = B^2X_t = X_{t-2}$$

Dengan: X_{t-2} = nilai X pada orde ke $t - 2$

Apabila suatu runtun waktu tidak stasioner, maka data tersebut dapat dibuat lebih mendekati stasioner dengan melakukan pembedaan (*differencing*) pertama.

Differencing pertama

(2.6)

$$X'_t = X_t - X_{t-1}$$

dengan: X'_t = *differencing* pertama

Menggunakan operator *shift* mundur, maka persamaan di atas dapat ditulis kembali menjadi:

Differencing pertama

(2.7)

$$\begin{aligned} X'_t - X'_{t-1} &= X_t - BX_t \\ &= (1 - B)X_t \end{aligned}$$

Differencing pertama dinyatakan oleh $(1 - B)$ sama halnya apabila *differencing* orde kedua (yaitu *differencing* pertama dari *differencing* pertama sebelumnya) harus dihitung, maka:

Differencing orde kedua

(2.8)

$$\begin{aligned} X''_t &= X'_t - X'_{t-1} \\ &= (X_t - X_{t-1}) - (X_{t-1} - X_{t-2}) \end{aligned}$$

$$\begin{aligned}
 &= X_t - 2X_{t-1} + X_{t-2} \\
 &= (1 - 2B + B^2)X_t \\
 &= (1 - B)^2 X_t
 \end{aligned}$$

dengan: $X_t'' = \text{differencing orde kedua}$

Differencing orde kedua diberi notasi $(1 - B)^2$. *Differencing* orde kedua tidak sama dengan *differencing* kedua yang diberi notasi $(1 - B)^2$, sedangkan *differencing* pertama $(1 - B)$ sama dengan *differencing* orde pertama $(1 - B)$.

Differencing kedua

(2.9)

$$\begin{aligned}
 X_t^2 &= X_t - X_{t-2} \\
 &= (1 - B^2)X_t
 \end{aligned}$$

dengan: $X_t^2 = \text{differencing kedua}$

Tujuan menghitung *differencing* adalah untuk mencapai stasioneritas dan secara umum, apabila terdapat *differencing* orde ke-d untuk mencapai stasioneritas, ditulis sebagai berikut:

$$\text{Differencing orde ke-d} = (1 - B)^d X_t$$

Sebagai deret yang stasioner dan model umum ARIMA (0,d,0) akan menjadi:

ARIMA (0,d,0)

(2.10)

$$(1 - B)^d X_t = e_t$$

dengan: $(1 - B)^d X_t : \text{differencing orde ke-d}$

e_t : nilai kesalahan

2.1.3.3 Stasioner dan Non-stasioner dalam Variansi

Suatu data runtun waktu dikatakan stasioner dalam variansi jika struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah, atau tidak ada perubahan variansi dalam besarnya fluktuasi secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan *time series plot* yaitu dengan melihat fluktuasi data dari waktu ke waktu.

Apabila ketidakstasioneritas dalam variansi terjadi, maka dapat dihilangkan dengan melakukan perubahan untuk menstabilkan variansi. Misalkan $T(X_t)$ adalah fungsi transformasi dari X_t dan untuk menstabilkan variansi, kita dapat menggunakan transformasi kuasa:

$$T(X_t) = \frac{x_t^\lambda - 1}{\lambda}, \text{ dengan } \lambda \text{ disebut parameter transformasi. Beberapa nilai}$$

λ yang umum digunakan sebagai berikut:

Tabel 2.1. Bentuk Transformasi

λ	Bentuk Transformasi
-1	$\frac{1}{X_t}$
-0,5	$\frac{1}{\sqrt{X_t}}$
0	$\ln X_t$
0,5	$\sqrt{X_t}$
1	X_t (tidak ditransformasikan)

Namun dalam banyak penerapan, jenis transformasi yang digunakan untuk menanggulangi data yang tidak stasioner dalam variansi adalah transformasi logaritma, ditulis: $\ln (X_t)$.

2.1.3.4 ACF dan PACF

1) *ACF (Autocorrelation Function)*

Koefisien autokorelasi runtun waktu dengan selisih waktu (lag) 0,1,2 periode atau lebih, autokorelasi menghitung dan membuat plot nilai autokorelasi dari suatu data *time series*. Untuk menghitung koefisien korelasi antara dua variabel X dan Y yang dinotasikan sebagai r_{xy} untuk n pasangan observasi $(X_i, Y_i), i = 1, 2, 3, \dots, n$ digunakan rumus sebagai berikut:

(2.11)

$$r_{xy} = \frac{Cov_{xy}}{\sqrt{Cov_{xx}Cov_{yy}}} = \frac{Cov_{xy}}{S_x S_y}$$

dengan: $S_x = \sqrt{Cov_{xx}} = \sqrt{Var_x}$ dan $S_y = \sqrt{Cov_{yy}} = \sqrt{Var_y}$ adalah deviasi standar X dan Y .

Autokorelasi adalah korelasi antara suatu variabel dengan variabel tersebut dengan lag 1,2,3 periode atau lebih misalnya antara X_t dan X_{t-1} . Menurut Makridakis et.al (1999) koefisien autokorelasi untuk lag 1,2,3, ..., k , dengan banyak pengamatan n . Data X_t diasumsikan stasioner, jadi kedua nilai tengah X_t dan X_{t-k} dapat diasumsikan bernilai sama dan dua nilai variansi (atau deviasi standar) dapat diukur satu kali saja yaitu dengan menggunakan seluruh data X_t yang diketahui sebagai berikut:

(2.12)

$$\gamma_k = Cov(X_t, X_{t-1})$$

$$\gamma_0 = VarX_t = Var X_{t-k} = S_{X_t} \times S_{X_{t-k}}$$

$$r_k = \frac{\gamma_k}{\gamma_0}$$

$$\begin{aligned}
 r_{X_t, X_{t-k}} &= \frac{\text{Cov}(X_t, X_{t-1})}{S_{X_t} \times S_{X_{t-k}}} \\
 &= \frac{\sum_{t=2}^n (X_t - \bar{X}_t)(X_{t-1} - \bar{X}_{t-1})}{\sqrt{\sum_{t=1}^n (X_t - \bar{X}_t)^2} \sqrt{\sum_{t=2}^n (X_{t-1} - \bar{X}_{t-1})^2}} \\
 &= \frac{\sum_{t=2}^n (X_t - \bar{X})(X_{t-1} - \bar{X})}{\sum_{t=2}^n (X_t - \bar{X})^2}
 \end{aligned}$$

Dengan menggunakan asumsi-asumsi di atas, maka persamaan di atas dapat disederhanakan menjadi:

(2.13)

$$r_k = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^n (x_t - \bar{x})^2}$$

Dengan:

r_k = koefisien autokorelasi lag ke k , dimana $k = 0, 1, 2, \dots, k$

n = jumlah data

X_t = nilai x orde ke t

\bar{x} = nilai rata-rata (mean)

Menurut (Mulyana, 2004), karena r_k merupakan fungsi terhadap lag ke- k maka hubungan antara autokorelasi dengan lagnya dapat disebut sebagai fungsi autokorelasi.

Untuk memeriksa apakah suatu r_k berbeda secara nyata dari nol, dapat digunakan rumus kesalahan standar dari r_k yaitu $se_{r_k} = 1/\sqrt{n}$. Sehingga seluruh nilai korelasi dari barisan data yang random (tidak berautokorelasi signifikan) akan terletak di dalam daerah nilai tengah nol ditambah atau dikurangi nilai z -score pada taraf signifikansi 95% yakni 1,96 kali kesalahan standar.

2) *PACF (Partial Autocorrelation Function)*

Fungsi Autokorelasi Parsial (PACF) adalah himpunan autokorelasi parsial untuk berbagai lag k yang ditulis dengan $(a_{kk}; k = 1, 2, 3, \dots, k)$ yakni himpunan autokorelasi parsial untuk berbagai lag k . Fungsi autokorelasi parsial digunakan untuk mengukur tingkat keamatan antara X_t dan X_{t-k} , apabila pengaruh dari selisih waktu $1, 2, 3, \dots, k - 1$ dianggap terpisah, didefinisikan :

(2.14)

$$a_{kk} = \frac{|\rho_{\sim k}^*|}{|\rho_{\sim k}|}$$

dengan: $\rho_{\sim k}$ adalah matrik autokorelasi $k \times k$

$\rho_{\sim k}^*$ adalah $\rho_{\sim k}$ dengan kolom terakhir diganti dengan $\begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix}$, sehingga:

$$a_{11} = \rho_1$$

$$a_{12} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$

$$= \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}$$

$$a_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

$$= \frac{\rho_1^3 - 2\rho_1\rho_2 + \rho_1\rho_2^2 - \rho_1^2\rho_3 + \rho_3}{1 - 2\rho_1^3 + 2\rho_1^2\rho_1 - \rho_2^2}$$

⋮

$$a_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}}$$

$$= \frac{\rho_k - \sum_{j=1}^{k-1} a_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} a_{k-1,j} \rho_{k-j}}$$

$$a_{kj} = a_{k-1,j} - a_{kk} a_{k-1,k-j} \text{ untuk } j = 1, 2, \dots, k-1$$

Nilai estimasi \hat{a}_{kk} dapat diperoleh dengan mengganti ρ_i dengan r_i untuk selisih waktu yang cukup besar, dimana fungsi autokorelasi parsial menjadi kecil sekali (tidak signifikan berbeda dengan nol), Quenouille memberikan rumus variansi a_{kk} sebagai berikut:

$$\text{Var}(a_{kk}) \approx \frac{1}{N}$$

Disini juga untuk N sangat besar, a_{kk} dapat dianggap mendekati distribusi normal.

2.1.4 Asumsi *White Noise*

Suatu model yang baik akan memiliki sifat *white noise*, yaitu memenuhi asumsi residual yang bersifat acak dan berdistribusi normal.

2.1.4.1 Residu Bersifat Acak

Keacakan sekumpulan barisan residu dapat diperiksa dengan memerhatikan fungsi autokorelasi dari barisan residu tersebut. Barisan residu dikatakan acak apabila tidak terdapat autokorelasi yang signifikan untuk setiap *lag*

yang ditentukan. Untuk lebih formal, keacakan residu dari suatu model dapat diuji menggunakan uji statistik Q Box-Pierce dengan hipotesis sebagai berikut:

$$H_0: r_1 = r_2 = \dots = r_k = 0 \text{ (residu bersifat acak)}$$

$$H_1: \exists r_i \neq r_j = 0 \text{ (residu tidak bersifat acak)}$$

Dengan $\alpha = 0.05$ dan statistik uji:

$$Q = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}$$

Serta kriteria uji:

Terima H_0 jika nilai $Q > X_{(\alpha, db)}$ atau $p\text{-value} > \alpha$. Artinya secara keseluruhan, autokorelasi dari barisan residu yang diuji tidak berbeda dari nol, atau dengan kata lain residu bersifat acak.

2.1.4.2 Residu Bersifat Normal

Untuk memeriksa apakah residu bersifat normal atau tidak, dapat dilakukan uji normalitas Kolmogorov-Smirnov dengan hipotesis sebagai berikut:

$$H_0 : \text{residu berdistribusi normal}$$

$$H_1 : \text{residu tidak berdistribusi normal}$$

Dengan $\alpha = 0.05$ dan statistik uji:

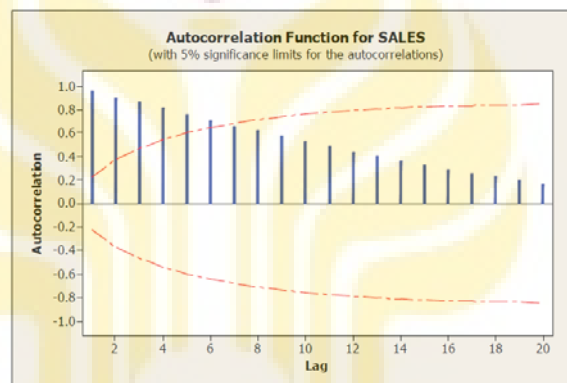
$$D = \text{maksimum } |F_0(X) - S_N(X)|$$

Serta kriteria uji:

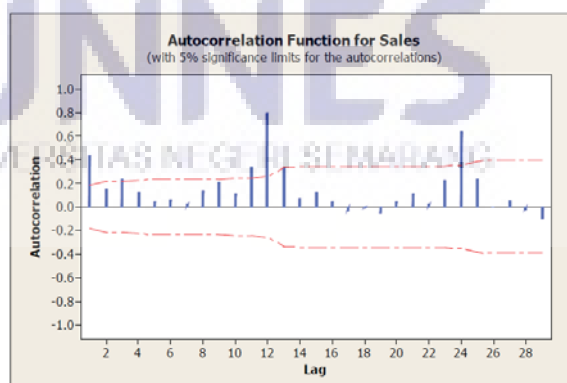
Tolak H_0 jika $D_{hit} < D_{tabel}$ atau $p\text{-value} > \alpha$. Artinya residu bersifat normal.

2.1.5 Seasonal (Musiman)

Pola musiman merupakan pola yang berulang-ulang dalam selang waktu yang tetap dan umumnya tidak lebih dari satu tahun. Apabila dalam data hanya terdapat pola musiman, adanya faktor musim dapat dilihat dari grafik fungsi autokorelasinya atau dari perbedaan *lag* autokorelasinya. Namun, jika data tidak hanya dipengaruhi pola musiman, tetapi juga dipengaruhi pola *trend*, maka pola musiman tidak mudah untuk diidentifikasi.



Gambar 2.5. Contoh grafik fungsi autokorelasi untuk data yang dipengaruhi pola *trend* (Santoso, 2009: 174)



Gambar 2.6. Contoh grafik fungsi autokorelasi untuk data yang dipengaruhi pola musiman bulanan (Hanke dan Wichern, 2005: 415)

Apabila pola *trend* lebih kuat dibandingkan dengan pola musiman, maka autokorelasi dari data asli akan membentuk garis, seperti contoh Gambar 3.5. Sedangkan, jika data dipengaruhi pola musiman, maka koefisien autokorelasi pada *lag* musiman berbeda nyata dari nol (baris melebihi garis putus-putus), seperti pada Gambar 2.6.

2.1.6 Model Runtun Waktu Musiman

2.1.6.1 Proses AR

Bentuk umum dari proses *moving average* musiman untuk periode S tingkat P atau $AR(P)^S$ didefinisikan sebagai berikut :

(2.15)

$$Z_t = \Theta_1 Z_{t-S} + \Theta_2 Z_{t-2S} + \dots + \Theta_P Z_{t-PS} + \alpha_t$$

dengan α_t adalah independen yang berdistribusi normal dengan rata-rata 0 dan variansi α_a^2 . Persamaan (3.12) dapat ditulis juga dalam bentuk

(2.16)

$$\Theta(B)Z_t = \alpha_t$$

dengan $\Theta(B) = 1 - \Theta_1(B)^S - \Theta_2(B)^{2S} - \dots - \Theta_P(B)^{PS}$ yang dikenal sebagai operator dari $AR(P)^S$.

Sebagai contoh untuk model-model $AR(P)^S$ akan diperlihatkan $AR(1)^{12}$ yaitu suatu proses $\{Z_t\}$ dikatakan mengikuti model $AR(1)^{12}$. Jika $\{Z_t\}$ mengikuti model

(2.17)

$$Z_t = \alpha_t Z_{t-12} + \alpha_t$$

dengan $E(Z_t) = 0$ untuk semua k .

Dengan demikian diperoleh :

(2.18)

$$E(Z_t, Z_{t-k}) = E[(\Theta_1 Z_{t-12} + \alpha_t)(\phi_1 Z_{t-12-k} + \alpha_{t-k})]$$

Jika persamaan (2.18) dibagi dengan γ_0 , maka diperoleh

$$\rho_k = \Phi_1 \rho_{k-12}, \quad k \geq 1.$$

Dengan demikian

(2.19)

$$\rho_{12} = \Phi_1 \rho_0$$

Dan

$$\rho_{24} = \Phi_1 \rho_{24} = \Phi_1^2$$

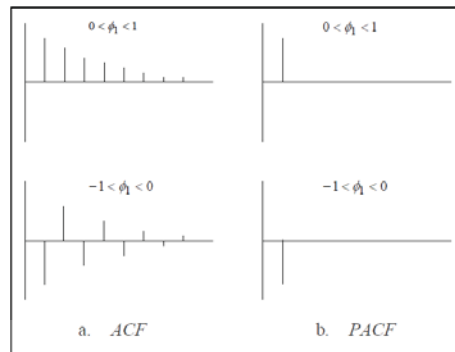
Sehingga secara umum diperoleh

(2.20)

$$\rho_{12k} = \Phi_1^k$$

untuk $k = 1, 2, \dots$

Selanjutnya, untuk $k = 1$ dan $k = 11$, dan dengan menggunakan rumus $\rho_k = -\rho_k$ akan memberikan $\rho_{11} = \Phi_1 \rho_{11}$ dan $\rho_{11} = \Phi_1 \rho_1$ yang berimplikasi bahwa $\rho_1 = \rho_{11} = 0$. Dengan cara yang sama dapat pula ditunjukkan bahwa $\rho_k = 0$ untuk k selain lag-lag musiman $12, 24, 36, \dots$ atau secara umum lag $s, 2s, 3s, \dots$ untuk $AR(1)^S$.



Gambar 2.7. Pola *ACF* dan *PACF* model $AR(1)$ (Suhartono, 2005: 37)

Untuk keperluan identifikasi model, jika suatu deret waktu memiliki grafik fungsi autokorelasi yang turun secara eksponensial dan fungsi autokorelasi parsial terputus pada *lag* ke- p , maka deret waktu tersebut dapat dimasukkan kedalam proses $AR(p)$.

2.1.6.2 Proses MA

Bentuk umum dari proses MA (*moving average*) musiman untuk periode S tingkat Q atau $MA(Q)^S$ didefinisikan sebagai berikut:

(2.21)

$$Z_t = \alpha_t - \theta_1 \alpha_{t-s} - \theta_2 \alpha_{t-2s} - \dots - \theta_Q \alpha_{t-Qs}$$

dengan α_t adalah independent yang berdistribusi normal dengan rata-rata 0 variansi σ_a^2 . Persamaan (2.21) dapat ditulis dalam bentuk

(2.22)

$$Z_t = \Theta(B)\alpha_t$$

dengan $\Theta(B) = 1 - \Theta_1(B)^s - \Theta_2(B)^{2s} - \dots - \Theta_Q(B)^{Qs}$ yang dikenal sebagai operator dari $MA(Q)^S$.

Sebagai contoh dari model-model $MA(Q)^S$ akan diperlihatkan $MA(1)^{12}$. Suatu proses $\{Z_t\}$ dikatakan mengikuti model $MA(1)^{12}$. Jika $\{Z_t\}$ mengikuti model

(2.23)

$$Z_t = \alpha_t - \Theta \alpha_{t-12}$$

Terlihat rata-rata Z_t , yaitu $E(Z_t) = 0$ untuk semua k . Dengan demikian diperoleh:

(2.24)

$$E(Z_t, Z_{t-k}) = E[(\alpha_t - \Theta_1 \alpha_{t-12})(\alpha_{t-k} - \Theta_1 \alpha_{t-12-k})]$$

Dalam hal ini $E(z, Z_t - k) = 0$ untuk $k \neq 12$, artinya proses tidak mempunyai korelasi diluar lag 12. Sebagai ringkasan, untuk suatu deret yang mengikuti proses $MA(1)^{12}$, maka:

$$\gamma_0 = \text{var}(Z_t) = \alpha_a^2(1 + \Theta_1^2)$$

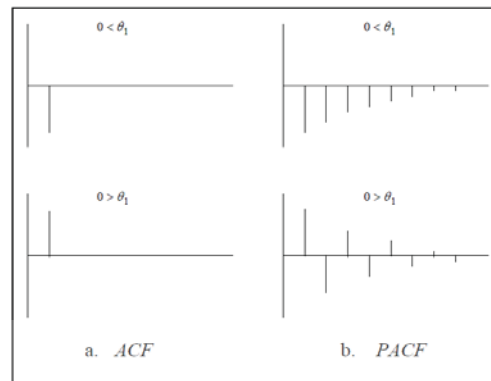
$$\gamma_{12} = -\Theta_1 \alpha_a^2$$

$$\rho_{12} = \frac{-\Theta_1}{1 + \Theta_1^2}$$

Dan

$$\gamma_k = \rho_k = 0$$

untuk $k \neq 12$



Gambar 2.8. Pola *ACF* dan *PACF* model *MA(1)*

(Suhartono, 2005: 50)

Sekali lagi, untuk keperluan identifikasi, jika suatu deret waktu memiliki grafik fungsi autokorelasi yang terputus pada *lag* ke- q dan fungsi autokorelasi parsial turun secara eksponensial, maka deret waktu tersebut dapat dimasukkan kedalam proses *MA(q)*.

2.1.6.3 Proses *Autoregressive Moving Average (ARMA)*

Model *ARMA(p,q)* merupakan kombinasi dari model *AR(p)* dan *MA(q)*, yaitu

$$(2.25) \quad Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Persamaan (2.25) dapat ditulis dalam bentuk

$$(2.26) \quad (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \alpha_t$$

atau

(2.27)

$$\phi_p(B)Z_t = \theta_q(B)a_t$$

Apabila kedua ruas pada persamaan (3.24) dikalikan dengan Z_{t-k} , hasilnya

(2.28)

$$\begin{aligned} Z_{t-k}Z_t &= \phi_1 Z_{t-k}Z_{t-1} + \dots + \phi_p Z_{t-k}Z_{t-p} + \\ &Z_{t-k}a_t - \theta_1 Z_{t-k}a_{t-1} - \dots - \theta_q Z_{t-k}a_{t-q} \end{aligned}$$

Jika memasukkan nilai harapan (*expected value*) pada kedua ruas persamaan (2.28), maka persamaan tersebut akan menjadi

(2.29)

$$\begin{aligned} \gamma_k &= \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p} + E(Z_{t-k}a_t) - \\ &\theta_1 E(Z_{t-k}a_{t-1}) - \dots - \theta_q E(Z_{t-k}a_{t-q}) \end{aligned}$$

Karena $E(Z_{t-k}a_{t-i}) = 0$ untuk $k > i$, maka

(2.30)

$$\gamma_k = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p}, \quad k \geq (q+1)$$

dan fungsi autokorelasinya adalah

(2.31) 

$$\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p}, \quad k \geq (q+1)$$

Karena proses *ARMA* merupakan kasus khusus dari proses *MA*, maka fungsi autokorelasi parsialnya juga merupakan pemulusan eksponensial dan/atau gelombang sinus tergantung dari akar-akar $1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q = 0$.

Sebagai contoh, model *ARMA*(1,1) dinyatakan sebagai berikut

(2.32)

$$Z_t = \phi_1 Z_{t-1} + a_t - \theta_1 a_{t-1}$$

Fungsi autokovarians diperoleh dengan mengalikan persamaan (2.32) dengan Z_{t-k} , hasilnya

$$Z_{t-k} Z_t = \phi_1 Z_{t-k} Z_{t-1} + Z_{t-k} a_t - \theta_1 Z_{t-k} a_{t-1}$$

dan nilai harapannya adalah

(2.33)

$$\gamma_k = \phi_1 \gamma_{k-1} + E(Z_{t-k} a_t) - \theta_1 E(Z_{t-k} a_{t-1})$$

Untuk $k = 0$, sedangkan $\gamma_{-1} = \gamma_1$ persamaan (2.33) menjadi

$$\gamma_0 = \phi_1 \gamma_1 + E(Z_t a_t) - \theta_1 E(Z_t a_{t-1})$$

Jika $E(Z_t a_t) = \sigma_a^2$, maka $E(Z_t a_{t-1})$ dapat dijabarkan sebagai berikut

$$\begin{aligned} E(Z_t a_{t-1}) &= \phi_1 E(Z_{t-1} a_{t-1}) + E(a_t a_{t-1}) \\ &\quad - \phi_1 E(\sigma_{t-1}^2) \\ &= (\phi_1 - \theta_1) \sigma_a^2. \end{aligned}$$

Oleh karena itu,

(2.34)

$$\gamma_0 = \phi_1 \gamma_1 + \sigma_a^2 - \theta_1 (\phi_1 - \theta_1) \sigma_a^2$$

Untuk $k = 1$, persamaan (2.33) menjadi

(2.35)

$$\gamma_1 = \phi_1 \gamma_0 - \theta_1 \sigma_a^2$$

Jika persamaan (2.35) disubstitusikan ke persamaan (2.34), maka

(2.36)

$$\gamma_0 = \phi_1^2 \gamma_0 - \phi_1 \theta_1 \sigma_a^2 + \sigma_a^2 - \phi_1 \theta_1 \sigma_a^2 + \theta_1^2 \sigma_a^2$$

$$= \frac{(1+\theta_1^2-2\phi_1\theta_1)}{(1-\phi_1^2)} \sigma_a^2$$

Substitusikan persamaan (2.36) ke persamaan (2.35) sehingga

(2.37)

$$\begin{aligned} \gamma_1 &= \frac{(1+\theta_1^2-2\phi_1\theta_1)}{(1-\phi_1^2)} \phi_1 \sigma_a^2 - \theta_1 \sigma_a^2 \\ &= \frac{(\phi_1-\theta_1)(1-\phi_1\theta_1)}{(1-\phi_1^2)} \sigma_a^2. \end{aligned}$$

Untuk $k = 2$, persamaan (2.33) menjadi

$$\gamma_k = \phi_1 \gamma_{k-1}, \quad k \geq 2.$$

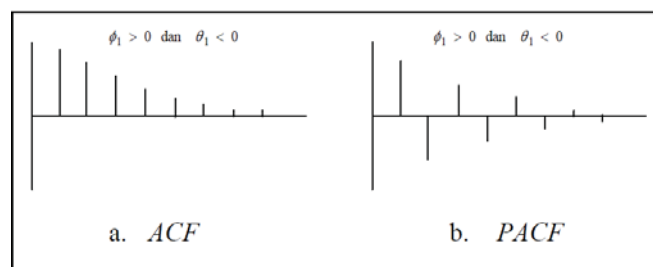
Oleh karena itu, fungsi autokorelasi dari model $ARMA(1,1)$ adalah

(2.38)


$$\rho_k = \begin{cases} 1, & k = 0, \\ \frac{(\phi_1-\theta_1)(1-\phi_1\theta_1)}{(1-\phi_1^2)} \sigma_a^2, & k = 1, \\ \phi_1 \gamma_{k-1}, & k \geq 2. \end{cases}$$

Bentuk umum fungsi autokorelasi parsial dari model ini cukup rumit sehingga tidak diperlukan. Hal yang perlu diketahui bahwa model $ARMA(1,1)$ merupakan kasus khusus dari model $MA(1)$.

Pola ACF dan $PACF$ model $ARMA(1,1)$ ditunjukkan oleh Gambar 2.9 berikut ini



Gambar 2.9. Pola ACF dan $PACF$ model $ARMA(1,1)$



Lanjutan Gambar 2.9. Pola *ACF* dan *PACF* model *ARMA*(1,1)

2.1.6.4 Proses *Autoregressive Integrated Moving Average* (*ARIMA*)

Model *ARMA*(p, q) pada persamaan (2.39), yaitu

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(Z_t - \mu) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t$$

dapat juga ditulis

(2.40)

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)Z_t = \theta_0(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t$$

UNNES
UNIVERSITAS NEGERI SEMARANG

dengan

(2.41)

$$\theta_0 = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)\mu = (1 - \phi_1 - \phi_2 - \dots - \phi_p)\mu$$

Dari persamaan (2.40), model *AR*(p) menjadi

(2.42)

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t = \theta_0 + a_t$$

dan model $MA(q)$ menjadi

(2.43)

$$Z_t = \theta_0 + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t$$

Dalam proses $MA(q)$, $\theta_0 = 0$.

Model *ARIMA* dilakukan pada data stasioner atau data yang *didifferencing* sehingga data telah stasioner. Secara umum, model *ARIMA* dinotasikan sebagai berikut

$$ARIMA(p, d, q)$$

dengan p = orde model *autoregressive*

q = orde model *moving average*

d = banyaknya *differencing*

Model ini merupakan gabungan dari model $ARMA(p, q)$ dan proses *differencing*, yaitu

(2.44)

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

dengan $\phi_p(B) = 1 - \phi_1(B) - \phi_2 B^2 - \dots - \phi_p B^p$ dan $\theta_q(B) = 1 - \theta_1(B) - \theta_2 B^2 - \dots - \theta_q B^q$.

Parameter θ_0 mempunyai peran yang berbeda untuk $d = 0$ dan $d > 0$. Untuk $d = 0$, data asli telah stasioner dan seperti persamaan (2.41) bahwa θ_0 merupakan rata-rata proses, yaitu $\theta_0 = (1 - \phi_1 - \phi_2 - \dots - \phi_p)\mu$. Sedangkan

untuk $d \geq 1$, data asli nonstasioner dan θ_0 merupakan istilah *trend deterministic* yang biasanya dihilangkan.

2.1.6.5 Model *Seasonal Autoregressive Integrated Moving Average*

Secara umum, model *Seasonal ARIMA* dinotasikan sebagai berikut

$$ARIMA(p,d,q)(P,D,Q)_s$$

dengan (p,d,q) = bagian tidak musiman dari model

(P,D,Q) = bagian musiman dari model

P = orde musiman untuk *AR*

Q = orde musiman untuk *MA*

D = banyaknya *seasonal differencing*

s = jumlah periode per musim.

Suatu deret $\{X_t\}$ tidak diketahui periode variasi musiman dan tidak musiman, bentuk model *ARIMA* untuk deret itu adalah

(2.45)

$$\phi_p(B)(1-B)^d X_t = \theta_q(B)b_t$$

Jika terdapat $\{b_t\}$ tidak *white noise* dengan korelasi antar periode musiman, maka fungsi autokorelasi untuk $\{b_t\}$ adalah

(2.46)

$$\rho_{j(s)} = \frac{E(b_{t-js} - \mu_b)(b_t - \mu_b)}{\sigma_b^2}, \quad j = 1, 2, 3, \dots$$

Untuk lebih mudah melihat korelasi antar periode, dapat direpresentasikan sebagai model *ARIMA* berikut

(2.47)

$$\Phi_P(B^s)(1 - B^s)^D b_t = \Theta_Q(B^s) a_t$$

dengan $\Phi_P(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}$ dan $\Theta_Q(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}$

adalah persamaan polinomial dalam B^s . Jika akar-akar dari polinomial-polinomial tersebut berada di luar lingkaran unit dan $\{a_t\} = 0$, maka proses tersebut adalah proses *white noise*.

Dengan mengkombinasikan persamaan (2.35) dan persamaan (2.37), diperoleh model *Seasonal ARIMA*, yaitu

(2.48)

$$\Phi_P(B^s)\phi_p(B)(1 - B)^d(1 - B^s)^D Z_t = \theta_q(B)\Theta_Q(B^s)a_t$$

dengan $Z_t = \begin{cases} X_t - \mu, & d = 0 \text{ atau } D = 0 \\ X_t, & \text{lainnya} \end{cases}$

$\phi_p(B)$ = faktor *AR* tidak musiman

$\theta_q(B)$ = faktor *MA* tidak musiman

$\Phi_P(B^s)$ = faktor *AR* musiman

$\Theta_Q(B^s)$ = faktor *MA* musiman

μ = rata-rata X_t

Untuk melakukan peramalan dengan metode *ARIMA* terdapat empat tahapan yaitu identifikasi pola data, estimasi model, *diagnostic checking* dan peramalan (Firdaus, 2006).

1) Melakukan proses identifikasi pola data

Data yang akan digunakan dalam model *ARIMA* harus stasioner. Identifikasi kestasioneran data dihitung dengan *Autocorrelation Function (ACF)* pada grafik korrelogram. Jika nilai *ACF* mendekati nol pada lag dua dan tiga maka data tersebut sudah stasioner, jika belum maka data tersebut harus di *differencing* sampai menjadi stasioner.

Dari grafik korrelogram ini dapat diduga model *ARIMA* yang akan digunakan. Garis yang menjorok keluar dari selang kepercayaan (berwarna biru) dapat dijadikan tolak ukur. Jika garis yang keluar dari selang kepercayaan ada satu buah pada korrelogram *ACF*, maka modelnya adalah *AR(1)*. Jika yang menjorok keluar ada dua buah pada korrelogram *ACF* maka modelnya *AR(2)* dan seterusnya. Sedangkan untuk garis yang menjorok keluar pada *PACF* digunakan untuk meramalkan model *MA*. Jika garis yang menjorok keluar garis error sebanyak satu buah maka modelnya *MA(1)*, jika garis yang menjorok keluar dua buah maka *MA(2)* dan seterusnya.

Tabel 2.2. Pola *ACF* dan *PACF* Tidak Musiman

No.	Model	<i>ACF</i>	<i>PACF</i>
1.	<i>AR(p)</i>	<i>Dies down</i> (menurun secara eksponensial)	<i>Cut off</i> (terputus) setelah lag <i>p</i>
2.	<i>MA(q)</i>	<i>Cut off</i> (terputus) setelah lag <i>q</i>	<i>Dies down</i> (menurun secara eksponensial)
3.	<i>ARIMA(p,q)</i>	<i>Dies down</i> (menurun secara eksponensial) setelah lag <i>(q-p)</i>	<i>Dies down</i> (menurun secara eksponensial) setelah lag <i>(p-q)</i>

Tabel 2.3. Pola *ACF* dan *PACF* Musiman dengan s Periode Per Musim

No.	Model	<i>ACF</i>	<i>PACF</i>
1.	$AR(p)$	<i>Dies down</i> (menurun secara eksponensial) pada <i>lag</i> musiman	<i>Cut off</i> (terputus) setelah <i>lag</i> P_s
2.	$MA(q)$	<i>Cut off</i> (terputus) setelah <i>lag</i> Q_s	<i>Dies down</i> (menurun secara eksponensial) pada <i>lag</i> musiman
3.	$ARIMA(p,q)$	<i>Dies down</i> (turun cepat secara eksponensial) pada <i>lag</i> musiman	<i>Dies down</i> (turun cepat secara eksponensial) pada <i>lag</i> musiman

2) Melakukan proses estimasi model

Proses estimasi merupakan proses pendugaan parameter untuk model *ARIMA*. Untuk mempermudah, proses estimasi biasanya dilakukan dengan program komputer, salah satunya dengan program R.

3) Melakukan proses diagnostik

Pada tahap ini dilakukan diagnosa secara mendetail terhadap model yang kita hasilkan untuk mengetahui apakah model tersebut sudah baik atau belum. Terdapat enam kriteria dalam uji diagnosa (Firdaus, 2006) yaitu:

- a. Residual error bersifat acak, dapat dilihat dari indikator *Ljung-Box Statistic*. Jika nilainya lebih dari 0,05 maka residual atau errornya sudah acak. Jika kurang dari 0,05 maka residualnya belum acak. Selain itu, jika *ACF* dan *PACF* residualnya berpola *cut off* maka residualnya sudah acak.
- b. Model parsimonius, artinya model sudah dalam bentuk yang paling sederhana.

- c. Parameter yang diestimasi berbeda nyata dengan nol. Dapat dilihat nilai P_{value} pada *Final Estimates of Parameters*, jika nilainya kurang dari 0,05 maka sudah berbeda nyata dengan nol. Jika lebih dari 0,05 maka parameter belum berbeda nyata dengan nol.
- d. Kondisi invertibilitas ataupun stasioneritas harus terpenuhi. Hal ini ditunjukkan dari nilai *Coefficient AR, SAR, MA, dan SMA* kurang dari satu.
- e. Proses iterasi sudah *convergence*, hal ini dapat dilihat dari pernyataan “*realitive change in each estimate less than 0,0010*”.
- f. Model memiliki *AIC* yang paling kecil

4) Peramalan

Setelah mendapatkan model yang layak atau sesuai, langkah terakhir dalam analisis runtun waktu adalah melakukan peramalan.

2.1.7 Model Negatif Binomial Data Jumlahan

Regresi Negatif Binomial merupakan salah satu model regresi terapan dari GLM Distribusi Negatif Binomial memiliki tiga komponen yaitu komponen random, komponen sistematis dan fungsi link. Adapun bentuk fungsi massa peluang Negatif Binomial adalah:

(2.49)

$$f(y_t, \mu, \alpha) = \frac{\Gamma(y_t + \frac{1}{\alpha})}{\Gamma(\frac{1}{\alpha}) y_t!} \left(\frac{1}{1 + \alpha\mu_t}\right)^{1/\alpha} \left(\frac{\alpha\mu_t}{1 + \alpha\mu_t}\right)^{y_t}$$

dengan $y_t = 0, 1, 2, \dots, N$, $E(y_t) = \mu_t$ dan $Var(y_t) = \mu_t + \frac{\mu_t^2}{\alpha}$.

Saat $\alpha \rightarrow 0$ maka distribusi negatif binomial memiliki variansi μ_t . Distribusi negatif binomial akan mendekati suatu distribusi Poisson yang mengasumsikan *mean* dan variansi sama yaitu $E(y_t) = Var(y_t) = \mu_t$.

Kontribusi variabel prediktor dalam model regresi Negatif Binomial dinyatakan dalam bentuk kombinasi linear antara parameter (η) dengan parameter regresi yang akan diestimasi yaitu:

$$\eta_t = \beta_0 + \beta_1 x_{t-1} + \dots + \beta_k x_{t-k}$$

Atau dalam matriks dituliskan dalam bentuk

$$\eta = X^T \beta$$

Dengan η adalah vektor ($n \times 1$) dari observasi, X adalah matriks ($n \times c$) dari variabel bebas, β adalah matriks ($n \times 1$) dari koefisien regresi, dengan $c = p + 1$. Nilai ekspektasi dari variabel respon Y adalah diskrit dan bernilai positif. Maka, untuk mentransformasikan nilai η_t (bilangan riil) ke rentang yang sesuai dengan rentang pada respon y_t diperlukan suatu fungsi link $g(\cdot)$ yaitu:

(2.50)

$$g(\mu_t) = \ln \mu_t = X^T \beta$$

2.1.8 Model GSARIMA

Model GSARIMA dikembangkan berdasarkan model GARMA dengan melibatkan efek musiman dan *differencing*. Diberikan $y^T = (y_t, y_{t+1}, \dots, y_{t+n})$ adalah model data deret waktu. Misalkan $y_t \sim \text{Negbin}(\mu_t, \psi)$ dengan $E(y_t) = \mu_t$ dan $V(y_t) = \mu_t + \frac{\mu_t^2}{\psi}$. Jika $\psi \rightarrow \infty$ maka y_t akan mengikuti distribusi Poisson.

Adapun model GARMA (p, q) dapat dilihat pada model (2):

(2.51)

$$g(\mu_t) = \phi_p(B)[X_t^T \beta - g(y_t)] + g(y_t) - \theta_q(B)[X_t^T \beta - g(y_t)] + g(y_t) - g(\mu_t)$$

Dimana $g(\cdot)$ adalah fungsi link, $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ dan $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$. B merupakan operator *backshift* dengan $B^d y_t = y_{t-d}$ dan vektor $\beta^T = (\beta_0, \beta_1, \beta_2, \dots, \beta_v)$ adalah koefisien untuk vektor $X_t^T = (x_0, x_{1,t}, \dots, x_{v,t})$ dengan x_0 merupakan *intercept* yang biasanya digunakan nilai $x_0 = 1$. Pada kasus GARMA, data jumlahan dimodelkan dengan menggunakan sebuah fungsi link *logarithmic* atau *identity*. Jika y_t mengikuti distribusi Poisson dengan nilai *mean* sebagai berikut:

$$\mu_t = E(y_t | y_{t-1}) = \mu [1 + \exp(-\beta_0 - \beta_1 y_{t-1})], \beta_i > 0$$

Maka ada dua metode transformasi sebagai berikut yang dapat digunakan:

a. Transformasi ZQ1 yang mempunyai bentuk:

$$\log(\mu_t) = X_t^T \beta + \sum_{i=1}^q \theta_i [\log(y_{t-1}^T) - X_{t-i}^T \beta]$$

Dimana $y_t^T = \max(y_t, c)$, $0 < c \leq 1$.

b. Transformasi ZQ2 yang mempunyai bentuk:

$$\log(\mu_t) = X_t^T \beta + \sum_{i=1}^q \theta_i [\log(y_{t-1} + c) - \log[\exp(X_{t-i}^T \beta + c)]]$$

Sehingga model GSARIMA binomial negatif untuk ZQ1 diberikan persamaan berikut:

(2.52)

$$\log(\mu_t) = \phi_p(B)(1 - B)^d (1 - B^S)^D \Phi_p(B^S) \{X_t^T \beta - \log(y_t^T)\} + \log(y_t^T) - \theta_q(B) \Theta(B^S) \log\left(\frac{y_t^T}{\mu_t}\right) + \log\left(\frac{y_t^T}{\mu_t}\right)$$

Sedangkan untuk ZQ2 adalah

(2.53)

$$\log(\mu_t) = \phi_p(B)(1-B)^d(1-B^S)^D \Phi_p(B^S) \{ \log[\exp(X_t^T \beta) + c] - \log(y_t + c) \} + \log(y_t + c) - \theta_q(B) \Theta(B^S) \log\left(\frac{y_t + c}{\mu_t + c}\right) + \log\left(\frac{y_t + c}{\mu_t + c}\right)$$

2.1.9 Algoritma IRLS

Model GARMA menggunakan IRLS telah dilakukan oleh Benjamin *et.al.* berdasarkan proses yang dilakukan oleh Green. Misalnya parameter yang akan diestimasi dinotasikan sebagai berikut $\gamma^T = (\beta^T, \phi^T, \theta^T)$. Ketiga parameter tersebut diestimasi menggunakan MLE sehingga *log-likelihood* untuk data observasi (y_1, y_2, \dots, y_N) , dan $\eta_t = g(y_t)$. Adapun fungsi *log-likelihood* model GARMA dapat dilihat pada persamaan

(2.54)

$$l = \sum_{t=m+1}^n \log f(y_t | D_t)$$

Berdasarkan fungsi *score* persamaan $U(\gamma) = \frac{\partial l}{\partial \gamma} = \left(\frac{\partial l}{\partial \beta^T}, \frac{\partial l}{\partial \phi^T}, \frac{\partial l}{\partial \theta^T} \right)$ yang diberikan sebagai berikut:

(2.55)

$$U(\gamma) = \sum_{t=m+1}^n \frac{\partial \mu_t}{\partial \eta_t} \frac{\partial \eta_t}{\partial \gamma} \frac{1}{v_t} (y_t - \mu_t)$$

Dengan $v_t = \text{Var}(y_t | D_t) = \phi \text{Var}(\mu_t) = \phi b''(\theta_t)$, (McCullagh & Nelder, 1989). Kemudian langkah selanjutnya adalah memaksimumkan fungsi *log-likelihood* l dengan menggunakan algoritma Fisher Scoring yaitu:

(2.56)

$$\gamma^{(k+1)} = \gamma^{(k)} + \alpha l^{-1}(\gamma^{(k)}) U(\gamma^{(k)})$$

Dengan $0 < \alpha \leq 1$ dan $l(\gamma) = -E \left(\frac{\partial^2 l}{\partial \gamma \partial \gamma^T} \right) = \frac{1}{\phi} \frac{\partial \eta^T}{\partial \gamma} W \frac{\partial \eta}{\partial \gamma^T}$ yang disebut matriks informasi Fisher, $w = \text{diag}(w_t)$ dengan

(2.57)

$$w_t^{-1} = \left(\frac{\partial \eta}{\partial \gamma} \right)^2 V(\mu_t)$$

Adapun langkah-langkah algoritma IRLS secara umum sebagai berikut:

a. Diberikan $\gamma^{(k)}$ kemudian hitung nilai:

$$\eta^{(k)}, \mu^{(k)}, \left(\frac{\partial \eta}{\partial \mu} \right)^{(k)}, V(\mu)^{(k)}, \left(\frac{\partial \eta}{\partial \gamma} \right)^{(k)}, w^{(k)}, z^{(k)} \text{ dengan nilai } z^{(k)} \text{ dan } w^{(k)}$$

dikonstruksi berdasarkan variabel dependen yang disesuaikan dengan persamaan berikut:

$$z_t = \frac{\partial \eta}{\partial \gamma^T} \gamma + \alpha (y_t - \mu_t) \frac{\partial \eta}{\partial \mu}$$

$$w_t^{-1} = \left(\frac{\partial \eta}{\partial \mu} \right)^2 V(\mu_t) \text{ untuk } t = m + 1, \dots, n$$

b. Estimasi $\gamma^{(k+1)}$ dengan meregresikan $z^{(k)}$ pada $\left(\frac{\partial \eta}{\partial \gamma} \right)^{(k)}$ dengan bobot

$$w^{(k)}, \gamma^{(k+1)} = l^{-1}(\gamma^{(k)}) \left(\frac{\partial \eta}{\partial \gamma} \right)^{(k)} w^{(k)} z^{(k)}$$

c. Update k ke $k+1$ dan ulangi langkah a dan b sampai estimasi parameter konvergen

Untuk $\eta^{(k)}$ dihitung dengan proses rekursif sementara turunan dari $\left(\frac{\partial \eta_t}{\partial \gamma}\right)^{(k)}$ dihitung dari proses rekursif parameter regresi, *autoregressive* dan *moving average*.

(2.58)

$$\frac{\partial \eta_t}{\partial \beta_s} = x_{ts} - \sum_{j=1}^p \phi_j x_{t-j,s} - \sum_{j=1}^q \theta_j \frac{\partial \eta_{t-j}}{\partial \beta_s} \text{ untuk } s = 1, 2, \dots, r$$

$$\frac{\partial \eta_t}{\partial \phi_s} = \{g(y_{t-s}) - x_{t-s}^T \beta\} - \sum_{j=1}^q \theta_j \frac{\partial \eta_{t-j}}{\partial \phi_s} \text{ untuk } s = 1, 2, \dots, r$$

$$\frac{\partial \eta_t}{\partial \theta_s} = \{g(y_{t-s}) - \eta_{t-s} \beta\} - \sum_{j=1}^q \theta_j \frac{\partial \eta_{t-j}}{\partial \theta_s} \text{ untuk } s = 1, 2, \dots, r$$

2.1.10 Kriteria Pemilihan Model Terbaik

Dalam analisis *time series* atau lebih umum analisis data mungkin ada beberapa jenis model sesuai yang dapat digunakan untuk menunjukkan data. Alat untuk mengidentifikasi seperti ACF dan PACF digunakan hanya untuk mengidentifikasi model yang cocok. *Residual* dari semua model yang cocok adalah *white noise*. Kriteria yang digunakan untuk pemilihan model ARIMA yang terbaik setelah dilakukan identifikasi model dan *diagnose checking* diantaranya:

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

Akaike's Information Criterion (AIC) diperkenalkan pertama kali oleh Akaike untuk mengidentifikasi model dari suatu kumpulan data. Metode ini merupakan salah satu dari metode yang menerapkan pendekatan *penalized maximum likelihood*. Persamaan AIC dalam melakukan pemilihan model adalah sebagai berikut:

(2.59)

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M$$

Dengan : M = Jumlah parameter pada model

$\hat{\sigma}_a^2$ = Estimator maximum likelihood bagi σ_a^2

n = jumlah observasi

Kriteria AIC untuk memilih model yang terbaik, jika nilai AIC (M) minimum.

2.1.11 Pasar Uang Antar Bank

Pasar uang (*Money market*) adalah pasar dengan instrumen finansial jangka pendek, umumnya yang diperjualbelikan berkualitas tinggi. Jangka waktu instrumen pasar uang biasanya jatuh tempo dalam waktu satu tahun atau kurang dari satu tahun.

Pasar uang sebagaimana dengan semua pasar keuangan menyediakan fasilitas atau jaringan transaksi jual beli aset finansial. Namun, pasar ini sangat menekankan pada kredit untuk memenuhi kebutuhan kas jangka pendek. Pasar uang adalah mekanisme yang mempertemukan pihak yang memiliki surplus dana dengan pihak yang mengalami defisit. Transaksi dalam pasar uang pada dasarnya dirancang untuk mempertemukan kebutuhan dana jangka pendek perusahaan, lembaga keuangan, dan pemerintah mulai dari *overnight* sampai dengan jangka waktu jatuh tempo satu tahun. Pada waktu yang sama pasar uang mulai menyediakan *Outlet* investasi bagi pihak surplus dana jangka pendek yang ingin memperoleh pendapatan atas dana yang belum terpakai. Dengan demikian, keadaan pasar uang memungkinkan terjadinya transaksi pinjam-meminjam.

Adapun fungsi pasar uang antara lain sebagai berikut:

1. Sarana alternatif khususnya bagi lembaga-lembaga keuangan, perusahaan-perusahaan non-keuangan, dan peserta-peserta lainnya, baik dalam memenuhi kebutuhan dana jangka pendeknya maupun dalam rangka melakukan penempatan dana atas kelebihan likuiditasnya.
2. Sebagai sarana pengendali moneter (secara tidak langsung) oleh pengusaha moneter dalam melaksanakan operasi terbuka, karena di Indonesia pelaksanaan operasi pasar terbuka oleh Bank Sentral Indonesia dilakukan melalui pasar uang dengan Sertifikat Bank Indonesia (SBI) dan Surat Berharga Pasar Uang (SBPU) sebagai instrumennya.
3. Memberikan kesempatan masyarakat berpartisipasi dalam pembangunan dengan membeli Sertifikat Bank Indonesia (SBI) dan Surat Berharga Pasar Uang (SBPU)
4. Menunjang program pemerataan pendapatan bagi masyarakat.

Mekanisme dalam pasar uang pada dasarnya dirancang untuk mempertemukan kebutuhan dana jangka pendek perusahaan, lembaga keuangan, dan pemerintah, mulai dari *overnight* sampai dengan jangka waktu jatuh tempo satu tahun. Pada waktu yang sama pasar uang menyediakan *outlet* investasi bagi pihak surplus dana jangka pendek yang ingin memperoleh pendapatan atas dana yang belum terpakai. Dengan demikian, keberadaan pasar uang memungkinkan terjadinya transaksi pinjam-meminjam.

Instrumen atau surat-surat berharga yang diperjualbelikan dalam pasar uang jenisnya cukup bervariasi termasuk surat-surat berharga yang diterbitkan

oleh badan-badan usaha swasta dan negara serta lembaga-lembaga pemerintah.

Instrumen pasar uang yang ada di Indonesia diantaranya:

1. Sertifikat Bank Indonesia (SBI). Instrumen hutang yang diterbitkan oleh pemerintah atau bank sentral atas unjuk dengan jumlah tertentu yang akan dibayarkan kepada pemegang pada tanggal yang telah ditetapkan. Instrument ini berjangka waktu jatuh tempo satu tahun atau kurang.
2. Surat Berharga Pasar Uang (SBPU). Surat-surat berharga berjangka pendek yang dapat dipublikasikan secara diskonto dengan Bank Indonesia atau lembaga diskonto yang ditunjuk oleh BI.
3. Sertifikat Deposito. Instrumen keuangan yang diterbitkan oleh suatu bank atas unjuk dan dinyatakan dalam suatu jumlah, jangka waktu dan tingkat bagi hasil tertentu. Sertifikat Deposito adalah deposito berjangka yang bukti simpanannya dapat diperdagangkan.
4. *Commercial Paper*. Proses yang tidak disertai dengan jaminan yang diterbitkan oleh perusahaan untuk memperoleh dana jangka pendek dan dijual kepada investor dalam pasar uang.
5. *Call Money*. Kegiatan pinjam meminjam dana antara satu bank dengan bank lainnya untuk jangka waktu pendek.
6. *Repurchase Agreement*. Transaksi jual surat-surat berharga disertai dengan perjanjian bahwa penjual akan membeli kembali surat-surat berharga yang dijual tersebut pada tanggal dan dengan harga yang telah ditetapkan lebih dahulu.

7. *Banker's Acceptance*. Suatu instrumen pasar uang yang digunakan untuk memberikan kredit pada eksportir atau importir untuk membayar sejumlah barang atau untuk membeli valuta asing.

Indikator pasar uang sangat diperlukan untuk mengukur atau paling tidak mengamati perkembangan pasar uang, indikator pasar uang meliputi:

1. Suku bunga Pasar Uang Antar Bank (Rp). Tingkat bunga yang dikenakan oleh bank terhadap bank lain dalam hal pinjam meminjam dana dalam bentuk rupiah.
2. Volume transaksi Pasar Uang Antar Bank (Rp). Jumlah transaksi antar bank dalam hal pinjam meminjam dalam bentuk rupiah.
3. Suku bunga Pasar Uang Antar Bank (US\$). Tingkat bunga yang dikenakan oleh bank terhadap bank lain dalam hal pinjam meminjam dan dalam bentuk US \$.
4. Volume transaksi Pasar Uang Antar Bank (US\$). Jumlah transaksi antar bank dalam hal pinjam meminjam dalam bentuk US \$.
5. JIBOR (*Jakarta Interbank Offered*). Suku bunga yang ditawarkan untuk transaksi pinjam meminjam antar bank.
6. Suku bunga deposito Rupiah (%/Th). Tingkat bunga yang diberikan para deposan yang mendepositokan uangnya dalam bentuk rupiah.
7. Suku bunga deposito US\$ (%/Th). Tingkat bunga yang diberikan para deposan yang mendepositokan uangnya dalam bentuk US \$.
8. Nilai Tukar Rupiah (Kurs). Harga suatu mata uang yang dikenakan bank atau lembaga keuangan lainnya kepada para kreditor.

9. Suku bunga kredit. Tingkat bunga kredit yang dikenakan bank atau lembaga keuangan lainnya kepada para kreditor.
10. Inflasi. Kenaikan tingkat harga barang dan jasa secara umum dan terus menerus suatu waktu tertentu.
11. Indeks Harga Konsumen (IHK). Angka indeks yang menunjukkan tingkat harga barang barang dan jasa yang harus dibeli konsumen dalam suatu periode tertentu.
12. Sertifikat Bank Indonesia (SBI). Instrument investasi jangka pendek yang bebas resiko.

2.1.12 Software R

Menurut Suhartono (2008: 1) Program R merupakan suatu sistem analisis statistik yang relatif lengkap, sebagai hasil dari kolaborasi riset berbagai statistikawan di seluruh dunia. Saat ini R dapat dikatakan merupakan *lingua franca* (bahasa standar) untuk keperluan komputasi statistic modern. Versi paling awal R dibuat tahun 1992 di Universitas Auckland, New Zealand oleh Ross Ihaka dan Robert Gentleman (yang menjadi asal muasal akronim nama R untuk perangkat lunak ini).

R menyediakan berbagai teknik statistika (permodelan linier dan nonlinier, uji statistik klasik, analisis deret waktu, klasifikasi, klasterifikasi dan sebagainya) serta grafik R, sebagaimana dirancang sebagai bahasa computer sebenarnya, dan mengizinkan pengguna untuk menambah fungsi tambahan dengan mendefinisikan fungsi baru. Kekuatan besar dari R yang lain adalah fasilitas grafiknya, yang menghasilkan grafik dengan kualitas publikasi yang dapat memuat simbol

matematika. R memiliki format dokumentasi seperti LaTeX, yang digunakan untuk menyediakan dokumentasi yang lengkap, baik secara daring (dalam berbagai format) maupun cetakan.

2.2. Penelitian Terdahulu

Berdasarkan penelitian terdahulu yang dilakukan oleh Hu, Tong, Mengersen, dan Connell (2007) menggunakan pendekatan Gaussian (normal) untuk peramalan data jumlahan. Hu *et al.* membandingkan antara model Poisson deret waktu dengan model SARIMA yang diaplikasikan pada kasus variabilitas cuaca dari *cryptosporidiosis*. Namun, transformasi logaritma (transformasi *Box-Cox*) tidak dapat digunakan jika terdapat data yang bernilai nol atau memiliki rata-rata taksiran rendah.

Pada penelitian Yu, Chen, dan Wen (2002) mengemukakan bahwa ada dua pendekatan yang sering digunakan untuk memodelkan data deret waktu non-Gaussian. Pendekatan pertama adalah menggunakan kombinasi linier pada variabel acak distribusi non-Gaussian dan pendekatan yang kedua adalah mentransformasi data deret waktu Gaussian ke dalam distribusi marginal yang lebih spesifik sehingga mampu digunakan untuk pendekatan non-Gaussian.

Berdasarkan penelitian yang dilakukan oleh Benjamin, Rigby, dan Stasinopoulos (2003) mengembangkan model stokastik untuk data-data yang mengikuti distribusi non-Gaussian seperti distribusi Poisson dan Negatif Binomial. Model tersebut adalah model *generalized autoregressive moving average* (GARMA). Model GARMA menghubungkan komponen ARMA dengan variabel prediktor ke transformasi parameter rata-rata dari distribusi data dengan

menggunakan fungsi link (*link function*). Fungsi link ini digunakan untuk memastikan bahwa distribusi data tetap dalam domain bilangan riil positif. Model GARMA sangat fleksibel untuk memodelkan data jumlahan dengan struktur AR dan atau MA. Benjamin *et al.* (2003) menggunakan pendekatan *iteratively reweighted least square* (IRLS) untuk mengestimasi parameter-parameter model GARMA.

Berdasarkan penelitian Briet, Amerasinghe, dan Vounatsou (2013) mengembangkan suatu model *generalized seasonal autoregressive integrated moving average* (GSARIMA) dengan melibatkan efek musiman dan order *differencing*. Briet *et al.* mengidentifikasi beberapa model yang sesuai, diantaranya model GSARIMA dan *generalized autoregressive moving average* (GARIMA) yang tidak memasukkan efek musiman. Dengan menggunakan pendekatan Bayesian dihasilkan bahwa GSARIMA lebih baik daripada GARIMA dengan kriteria DIC.

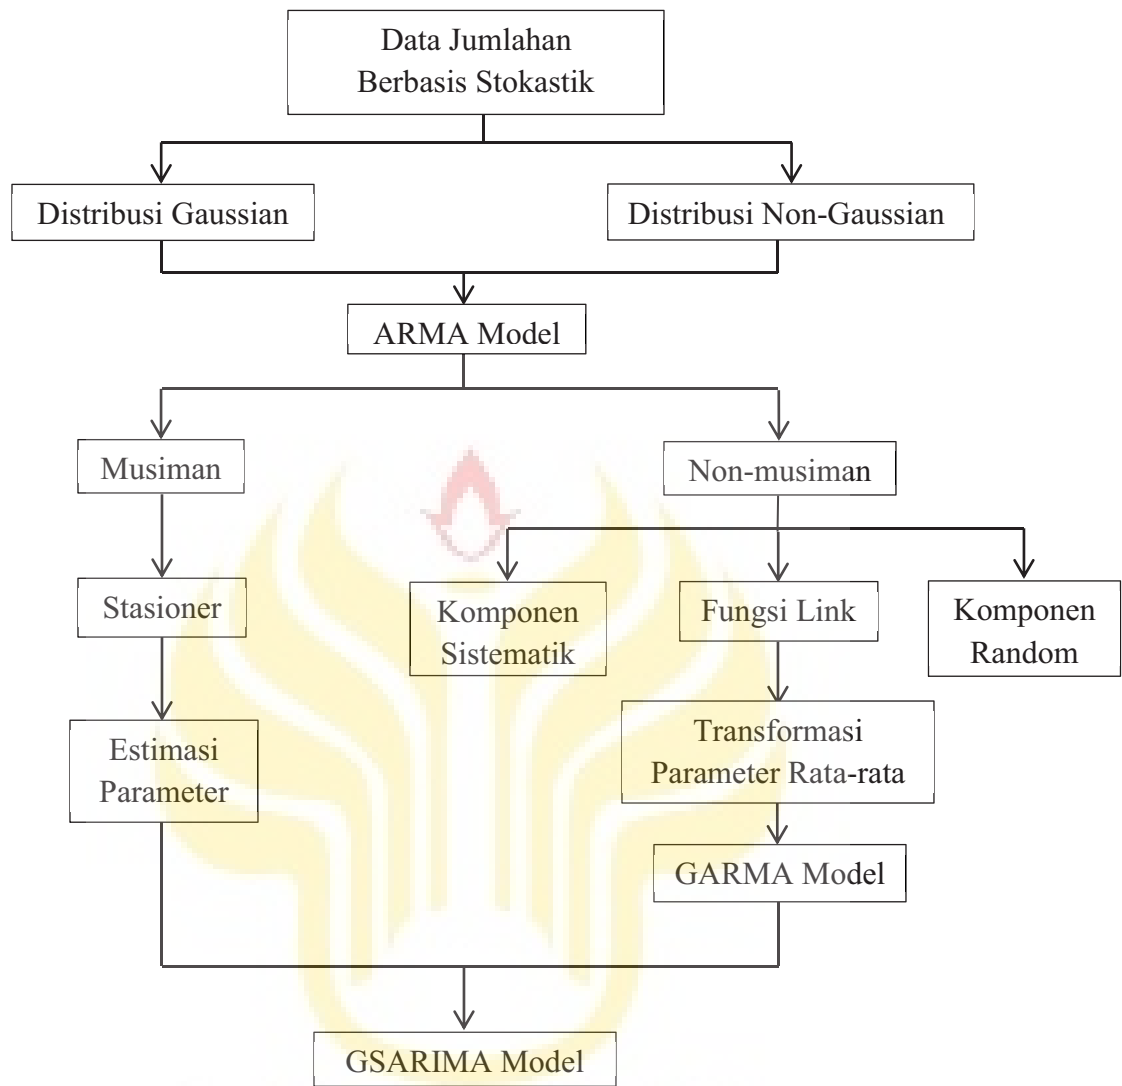
2.3. Kerangka Berpikir

Kemampuan untuk memprediksi data hanya dengan menggunakan data masa lalu, dapat berguna bagi organisasi atau individu untuk meraih kesuksesan. Prediksi time series adalah meramalkan suatu nilai variabel yang terurut berdasarkan waktu, tanpa mempedulikan faktor-faktor yang mempengaruhi dan memodelkan pola data tersebut untuk prediksi. Banyak metode yang dapat digunakan untuk meramalkan suatu data masa lalu. Salah satunya adalah metode Box-Jenkins. Metode Box-Jenkins ada yang bersifat musiman dan bukan musiman. Banyak metode Box-Jenkins yang dapat meramalkan data namun

peramalan data jumlahan yang berbasis model stokastik masih belum banyak dilakukan.

Model GSARIMA merupakan model pengembangan dari GARMA yang melibatkan efek stasioner dan musiman (*seasonal*). Untuk data-data yang mengikuti distribusi non-Gaussian menggunakan model GARMA. Model GARMA menghubungkan komponen ARMA dengan variabel prediktor ke transformasi parameter rata-rata dari distribusi data dengan menggunakan fungsi link.

Dalam peramalan model GSARIMA, data jumlahan dimodelkan dengan menggunakan sebuah fungsi link *logarithmic* atau *identity* seperti pada kasus GARMA. Model data yang dibangkitkan menggunakan dua transformasi yaitu transformasi ZQ1 dan transformasi ZQ2. Metode yang digunakan dalam estimasi parameter model GSARIMA Negatif Binomial adalah IRLS. Perbandingan estimasi parameter pada model GSARIMA mengikuti distribusi Negatif Binomial. Untuk data simulasi, ada dua simulasi yang dilakukan. Simulasi pertama adalah simulasi perbandingan estimasi model GSARIMA dengan transformasi ZQ1 dan ZQ2. Sedangkan simulasi yang kedua dilakukan perbandingan tingkat akurasi peramalan model GSARIMA dan model ARIMA musiman.



Gambar 2.10 Kerangka Berfikir

BAB V

PENUTUP

5.1 Simpulan

Berdasarkan analisis dan pembahasan pada bab IV, maka dapat disimpulkan sebagai berikut.

1. Model terbaik metode *seasonal* ARIMA adalah SARIMA (1,1,1) (0,1,1)₁₂ dengan persamaan sebagai berikut.

$$Y_t = 1,2794Y_{t-1} - 0,2794Y_{t-2} + Y_{t-12} - 1,2794Y_{t-13} + 0,2794Y_{t-14} \\ + a_t + a_{t-1} + a_{t-12} + a_{t-13}$$

dengan Y_t adalah nilai variabel dependent pada waktu t atau nilai ramalan, Y_{t-1} , Y_{t-2} , Y_{t-12} , Y_{t-13} dan Y_{t-14} adalah nilai variabel dependent pada waktu $t - 1$, $t - 2$, $t - 12$, $t - 13$ dan $t - 14$, sedangkan a_t , a_{t-1} , a_{t-12} dan a_{t-13} adalah nilai residu pada waktu t , $t - 1$, $t - 12$ dan $t - 13$.

2. Peramalan Nilai Transaksi Pasar Uang Antarbank metode GSARIMA (1,1,1) (0,1,1)₁₂ persamaannya sebagai berikut

$$\begin{aligned}
&= \log(-4,72B + 4,72B^2 - 4,72B^{12} + 15,67B^{13} - 4,72B^{14}) + 2,14 \log(y_{t-1}) \\
&\quad - 0,56 \log(y_{t-2}) - 1,56 \log(y_{t-3}) + 0,64 \log(y_{t-4}) \\
&\quad + 1,91 \log(y_{t-12}) + 0,82 \log(y_{t-13}) - 4,8 \log(y_{t-14}) \\
&\quad + 4,6 \log(y_{t-15}) - 1,28 \log(y_{t-16}) + 1,91 \log(y_{t-24}) \\
&\quad - 4,87 \log(y_{t-25}) + 5,36 \log(y_{t-26}) - 3,04 \log(y_{t-27}) \\
&\quad + 0,64 \log(y_{t-28}) + 1,91 \log(\alpha_t) + 2,73 \log(\alpha_{t-1}) \\
&\quad - 0,82 \log(\alpha_{t-3}) + 3,82 \log(\alpha_{t-12}) + 1,91 \log(\alpha_{t-13}) \\
&\quad - 1,91 \log(\alpha_{t-14}) + 1,91 \log(\alpha_{t-24}) - 0,82 \log(\alpha_{t-25}) \\
&\quad - 1,91 \log(\alpha_{t-26}) + 0,82 \log(\alpha_{t-27}) + 4,28 \log\left(\frac{y_{t-1}}{\mu_{t-1}}\right) \\
&\quad - 0,99 \log\left(\frac{y_{t-2}}{\mu_{t-2}}\right) - 1,363 \log\left(\frac{y_{t-3}}{\mu_{t-3}}\right) + 0,002 \log\left(\frac{y_{t-4}}{\mu_{t-4}}\right) \\
&\quad + 3,82 \log\left(\frac{y_{t-12}}{\mu_{t-12}}\right) - 2,53 \log\left(\frac{y_{t-13}}{\mu_{t-13}}\right) + 0,984 \log\left(\frac{y_{t-14}}{\mu_{t-14}}\right) \\
&\quad + 1,365 \log\left(\frac{y_{t-15}}{\mu_{t-15}}\right) - 0,002 \log\left(\frac{y_{t-16}}{\mu_{t-16}}\right) - 0,003 \log\left(\frac{y_{t-25}}{\mu_{t-25}}\right) \\
&\quad + 0,003 \log\left(\frac{y_{t-26}}{\mu_{t-26}}\right) - 0,002 \log\left(\frac{y_{t-27}}{\mu_{t-27}}\right) + 3,82 \log\left(\frac{\alpha_t}{\mu_t}\right) \\
&\quad + 5,57 \log\left(\frac{\alpha_{t-1}}{\mu_{t-1}}\right) + 1,747 \log\left(\frac{\alpha_{t-2}}{\mu_{t-2}}\right) + 0,003 \log\left(\frac{\alpha_{t-3}}{\mu_{t-3}}\right) \\
&\quad + 3,82 \log\left(\frac{\alpha_{t-12}}{\mu_{t-12}}\right) + 5,567 \log\left(\frac{\alpha_{t-13}}{\mu_{t-13}}\right) + 1,744 \log\left(\frac{\alpha_{t-14}}{\mu_{t-14}}\right) \\
&\quad - 0,003 \log\left(\frac{\alpha_{t-15}}{\mu_{t-15}}\right) - 0,003 \log\left(\frac{\alpha_{t-25}}{\mu_{t-25}}\right) - 0,003 \log\left(\frac{\alpha_{t-26}}{\mu_{t-26}}\right)
\end{aligned}$$

3. Dari penelitian yang telah dilakukan, hasil ramalan GSARIMA pada distribusi binomial negatif memiliki nilai AIC yang lebih kecil dari

SARIMA yaitu lebih kecil 57,83. Hasil tersebut, menunjukkan bahwa model GSARIMA relatif lebih baik dibandingkan dengan SARIMA.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, peneliti memberikan saran sebagai berikut:

1. Perlu diketahui faktor-faktor lain untuk peramalan Nilai Transaksi Pasar Uang Antarbank guna penyelidikan lebih lanjut untuk mendapatkan grafik peramalan yang diharapkan.
2. Penelitian lanjutan tentang peramalan Nilai Transaksi Pasar Uang Antarbank untuk periode yang akan datang (Januari 2016 dan seterusnya) dapat membandingkan metode GSARIMA dengan metode lain dengan penambahan variabel baru untuk peramalan seperti GSARIMAX sehingga diperoleh hasil peramalan yang lebih mendekati nilai aktualnya agar dapat membandingkan keakuratannya.
3. Dalam estimasi parameter GSARIMA dapat menggunakan prosedur yang lainnya seperti metode Quasi Likelihood dan lain sebagainya.
4. Perhitungan estimasi parameter dalam penelitian ini hanya menggunakan *software R* dan *software Microsoft Excel*, diharapkan pada penelitian selanjutnya dapat menggunakan program lain seperti S-Plus atau Matlab.

DAFTAR PUSTAKA

- Benjamin, M. A., Rigby R. A., dan Stasinopoulos, D. M. 1998. *Fitting Non-Gaussian Time Series Models*. *COMPSTAT Proceedings in Computational Statistics*, eds. R. Payne dan P. Green, *Heldelburg: Physica-Verlag*, 191-196.
- Briet, J. T. O., Amerasinghe, H. P., dan Vounatsou, P. 2013. *Generalized Seasonal Autoregressive Integrated Moving Average Models for Count Data with Application to Malaria Time Series with Low Case Numbers*. *Malaria Journal*, PLoS ONE, 8(6): e65761.
- Chen Y-T (2002) On the robustness of Ljung-Box and McLeod-Li Q tests: a simulation study. *Economics Bulletin* 3:1-10.
- Croston, J. D. 1972. *Forecasting and Stock Control for Intermittent Demands*. *Operational Research Quarterly*, 23, 289-303.
- Elfira W, R. Suhartono. 2014. *Peramalan Netflow Uang Kartal dengan Metode ARIMAX dan Radial Basis Function Network (Studi Kasus Di Bank Indonesia)*. *Jurnal Sains dan Seni Pomits*. Vol. 3, No. 2, (2014) 2337-3520 (2301-928X Print). D73-D78.
- Giliant S, G. 2011. *Pengujian Model Peramalan Deret Waktu Sea Surface Temperature (SST) Teluk Ambon Luar Dengan Metode Exponential Smoothing*. *Oseanologi dan Limnologi di Indonesia*. ISSN 0125-9830. Vol. 37, No. 1, January 2011, pp. 43-55.
- Hu W, Tong S, Mengersen K, Connell D (2007) Weather variability and the incidence of cryptosporidiosis: comparison of time series predictive modele. *Occup Environ Med* 67: 307-311.
- Indara W, N. Subekti, R. 2015. *Analisis Komparansi Holt Winter dan SARIMA Pada Peramalan Statistik Wisatawan Asing Kraton Yogyakarta*. *Seminar*

Nasional Matematika dan Pendidikan Matematika UNY 2015. ISBN. 978-602-73403-0-5. pp. 95-100.

Irabor Osarumwense, Osabuohien.(2013). *Applicability of Box Jenkins SARIMA Model in Rainfall Forecasting: A Case Study of Port-Harcourt south south Nigeria*. Canadian Journal on Computing in Mathematics, Natural Sciences, Engineering and Medicine, Vol. 4, No. 1, February 2013, pp.1-4.

Kasmir, J. 2003. *Studi Kelayakan Bisnis*. Jakarta:Prenada Media.

Makridakis, S., Wheelwright, C, Steven., Mcgee, E, Victor, 1999. *Metode dan Aplikasi Peramalan*. Jakarta: PT Erlangga.

N.Gujarati, D. C.Porter, D. 2012. *Dasar-Dasar Ekonometrika*. Jakarta : Salemba Empat.

Oduro-Gyimah, F. K., Harris, E., Darkwah, K. F.(2012). *Sarima Time Series Model Application to Microwave Transmission of Yeji-Salaga (Ghana) Line-Of-Sight Link*. *International Journal of Applied Science and Technology*, Vol. 2, No.9, November 2012, pp.40-51.

Rosadi, D., 2012. *Ekonometrika & Analisis Runtun Waktu Terapan dengan Eviews*. Yogyakarta: Andi Offset.

Soejoeti, Zanzawi. 1987. *Analisis Runtun Waktu*. Jakarta: Karunika.

Suhartono and Hisyam Lee, Muhammad. 2011. *Forecasting of Tourist Arrivals Using Subset, Multiplicative or Additive Seasonal ARIMA Model*. *Journal of Mathematical Science*, Vol. 27, No. 2, pp.169-182

Supranto. 2001. *Statistik teori dan aplikasi*. Jakarta: Erlangga.

Wei, William W.S. 1990. *Time Series Analysis Univariate and Multivariate Methods*: Addison-Wesley Publishing Company.