



**PERBANDINGAN PERAMALAN MENGGUNAKAN
METODE *EXPONENTIAL SMOOTHING HOLT-
WINTERS* DAN ARIMA**

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

oleh
Tias Safitri
4111412010



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI SEMARANG
2016**

PERNYATAAN

Saya menyatakan bahwa skripsi ini bebas plagiat, dan apabila di kemudian hari terbukti terdapat plagiat dalam skripsi ini, maka saya bersedia menerima sanksi sesuai ketentuan peraturan perundang-undangan



Semarang, 22 Agustus 2016



Tias Safitri
NIM 4111412010

UNNES
UNIVERSITAS NEGERI SEMARANG

PENGESAHAN

Skripsi yang berjudul

Perbandingan Peramalan Menggunakan Metode *Exponential Smoothing Holt-Winters* dan ARIMA

disusun oleh

Tias Safitri

4111412010

Telah dipertahankan di hadapan sidang Panitia Ujian Skripsi FMIPA UNNES pada tanggal 22 Agustus 2016.



Sekretaris

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

Drs. Arief Agoestanto, M.Si
196807221993031005

Ketua Penguji

Drs. Arief Agoestanto, M.Si
196807221993031005

Anggota Penguji/
Pembimbing I

Dr. Nurkaromah Dwidayati, M.Si
196605041990022001

Anggota Penguji/
Pembimbing II

Drs. Sugiman, M.Si
196401111989011001

MOTTO DAN PERSEMBAHAN

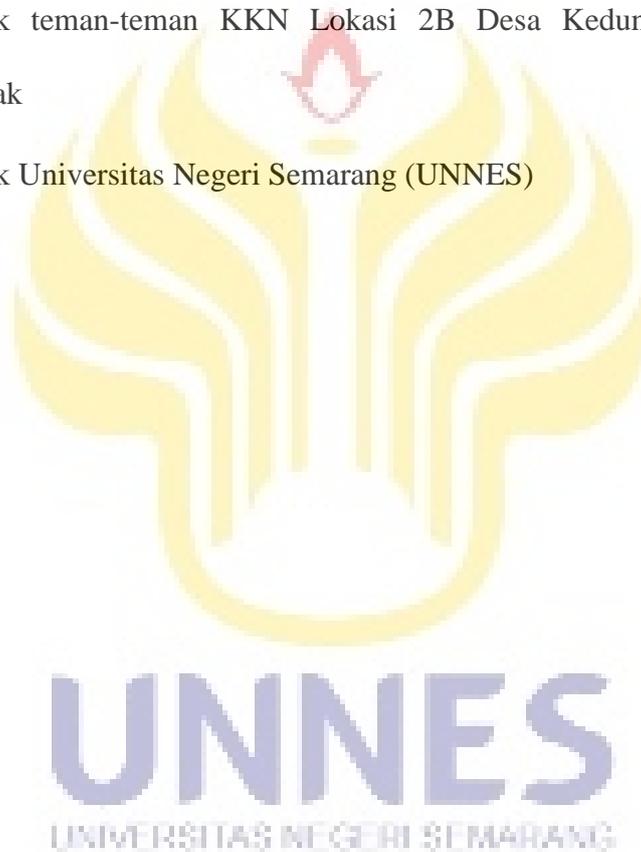
MOTTO

- * Sesungguhnya bersama kesulitan itu ada kemudahan (QS. Al-Insyirah: 6)
- * Boleh jadi kamu membenci sesuatu, padahal ia amat baik bagimu, dan boleh jadi (pula) kamu menyukai sesuatu, padahal ia amat buruk bagimu; Allah mengetahui, sedang kamu tidak mengetahui (Q.S Al-Baqarah: 216)
- * Permudahkanlah dan jangan mempersulit, gembirakanlah dan janganlah menakut-nakuti (Mustafaq'lah)
- * Lelah bukan alasan untuk menyerah. Baru saat selesai kamu boleh merasa sudah
- * Hidup adalah bagaimana kamu menjalaninya bukan bagaimana kamu melihatnya

PERSEMBAHAN

- * Untuk kedua orang tua tercinta, Ibu Siti Sukesi dan Bapak Ashari yang senantiasa memberikan doa terbaik dan dukungan kepadaku
- * Untuk Kakak-kakak dan Adikku tersayang, Darus Afriadi, Adriani Miharsi dan Rio Pamungkas yang senantiasa memberikan semangat dan motivasi kepadaku
- * Untuk keluarga besar tercinta

- * Untuk teman-teman seperjuangan Matematika 2012, Kelompok Ilmiah Matematika
- * Untuk sahabat-sahabatku yang selalu memberikan nasihat dan mengiringi langkahku dengan doa
- * Untuk teman-teman keluarga besar Kos “Trisanja 2”
- * Untuk teman-teman KKN Lokasi 2B Desa Kedungmutih Kabupaten Demak
- * Untuk Universitas Negeri Semarang (UNNES)



KATA PENGANTAR

Puji syukur kehadiran Allah SWT, yang telah melimpahkan rahmat, hidayah dan inayah-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Perbandingan Peramalan Menggunakan Metode *Exponential Smoothing Holt-Winters* dan ARIMA”.

Selama menyusun skripsi ini, penulis telah banyak menerima bantuan, kerjasama, dan sumbangan pikiran dari berbagai pihak. Oleh karena itu penulis menyampaikan terima kasih 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. Prof. Dr. St. Budi Waluya M.Si., Dosen Wali yang telah memberikan arahan dan motivasi kepada penulis dalam penyusunan skripsi ini.
6. Dr. Nurkaromah Dwidayati, M.Si dan Drs. Sugiman, M.Si., Dosen Pembimbing yang telah sabar dan tulus memberikan bimbingan, arahan, nasihat, motivasi dan saran kepada penulis dalam penyusunan skripsi ini.
7. Drs. Arief Agoestanto, M.Si., Dosen Penguji yang telah memberikan saran kepada penulis dalam penyusunan skripsi ini.

8. Bapak dan Ibu Dosen Jurusan Matematika Universitas Negeri Semarang yang telah memberikan bekal ilmu kepada penulis selama perkuliahan di Universitas Negeri Semarang.
9. Staff Tata Usaha Universitas Negeri Semarang yang telah banyak membantu penulis selama mengikuti perkuliahan dan penulisan skripsi ini.
10. Kedua orang tua dan keluarga besar tercinta, atas doa, perjuangan, pengorbanan dan segala dukungannya hingga penulis dapat menyelesaikan perkuliahan ini.
11. Teman-teman organisasi Kelompok Ilmiah Matematika.
12. Teman-teman seperjuangan Matematika 2012 yang telah memberikan motivasi dan dukungan kepada penulis.
13. Sahabat-sahabat yang telah memberikan semangat, nasihat, dukungan dan doa.
14. Semua pihak yang telah membantu terselesaikannya skripsi ini, yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa dalam penyusunan skripsi ini masih terdapat banyak kekurangan. Oleh karena itu, penulis mengharapkan saran dan kritik yang membangun dari pembaca. Akhirnya penulis berharap semoga skripsi ini bermanfaat bagi pembaca demi kebaikan di masa yang akan datang.

Semarang, 22 Agustus 2016

Penulis

ABSTRAK

Safitri, Tias. 2016. *Perbandingan Peramalan Menggunakan Metode Exponential Smoothing Holt-Winters dan ARIMA*. Skripsi, Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Univeristas Negeri Semarang. Pembimbing Utama Dr. Nurkaromah Dwidayati, M.Si. dan Pembimbing Pendamping Drs. Sugiman, M.Si.

Kata kunci: Peramalan, *Exponential Smoothing Holt-Winters*, ARIMA, metode terbaik.

Peramalan merupakan suatu kegiatan untuk memprediksi kejadian di masa yang akan datang dengan menggunakan dan mempertimbangkan data dari masa lampau. Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien. Peramalan *time series* seringkali menunjukkan perilaku yang bersifat musiman. Agar diperoleh hasil ramalan yang baik maka dilakukanlah metode peramalan yang dapat meramalkan data musiman. Penelitian ini bertujuan untuk mengetahui model peramalan terbaik dengan metode *exponential smoothing Holt-Winters* dan ARIMA serta mengetahui perbandingan hasil peramalan dengan kedua metode tersebut sehingga diperoleh metode terbaik.. Data jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai melalui pintu masuk Tahun 2010-2015 merupakan data yang mengandung pola musiman sehingga *exponential smoothing Holt-Winters* dan ARIMA dapat digunakan. Data diperoleh dengan cara dokumentasi dengan pengumpulan data sekunder dan studi pustaka.

Analisis metode *exponential smoothing Holt-Winters* menggunakan *trial and error* dengan RMSE terkecil untuk mencari model terbaik. Peramalan dengan metode *exponential smoothing Holt-Winters* menghasilkan $\alpha = 0,3$, $\beta = 0,1$, $\gamma = 0,1$, model peramalan $S_t = 0,3 \frac{X_t}{I_{t-12}} + 0,7 (S_{t-1} + b_{t-1})$, $b_t = 0,1(S_t - S_{t-1}) + 0,9 b_{t-1}$, $I_t = 0,1 \frac{X_t}{S_t} + 0,9 I_{t-12}$ dan $F_{t+m} = (S_t + b_t m) I_{t-12+m}$ dengan nilai MSE 1436553590 dan MAPE 8,86198%. Analisis metode ARIMA dilakukan dengan estimasi model dengan kriteria SSR, AIC, SBC terkecil dan tidak terdapat autokorelasi, heteroskedastisitas dan berdistribusi normal. Peramalan dengan metode ARIMA menghasilkan model ARIMA (2,1,0)(0,1,1)₁₂ dengan transformasi logaritma dengan nilai MSE 1353169319 dan MAPE 9,40981%.

Berdasarkan hasil penelitian dapat disimpulkan bahwa metode *exponential smoothing Holt-Winters* merupakan metode terbaik untuk peramalan jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai melalui pintu masuk Tahun 2010-2015 karena menghasilkan nilai MAPE lebih kecil.

DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	i
PERNYATAAN.....	ii
PENGESAHAN	iii
MOTTO DAN PERSEMBAHAN	iii
KATA PENGANTAR	vi
ABSTRAK	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xv
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN.....	xix
DAFTAR LAMBANG	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	5
1.5.1 Bagi Pembaca.....	5

1.5.2	Bagi Peneliti	5
1.5.3	Bagi Masyarakat.....	5
1.5.4	Bagi Institusi/Perusahaan Pengguna Jasa.....	6
1.6	Penegasan Masalah.....	6
BAB 2 TINJAUAN PUSTAKA		8
2.1	<i>Time Series</i>	8
2.2	Peramalan (<i>Forecasting</i>)	11
2.2.1	Definisi dan Tujuan Peramalan (<i>Forecasting</i>).....	13
2.2.2	Kegunaan Peramalan (<i>Forecasting</i>).....	14
2.3	Peramalan (<i>Forecasting</i>) dengan Eksponensial <i>Smoothing</i>	16
2.3.1	Metode Eksponensial <i>Holt Smoothing</i>	19
2.3.2	Metode Eksponensial <i>Winters Smoothing</i>	20
2.4	Metode <i>Exponential Smoothing Holt-Winters</i>	21
2.4.1	<i>Exponential Smoothing Holt-Winters</i> dengan Model Aditif.....	25
2.4.2	<i>Exponential Smoothing Holt-Winters</i> dengan Model Multiplikaif	27
2.4.3	Proses Inisialisasi	28
2.4.4	Nilai Kesalahan <i>Exponential Smoothing Holt-Winters</i>	30
2.5	Analisis Metode ARIMA	31
2.5.1	Stasioner dan Nonstasioner	31

2.5.1.1	<i>Stasioner dalam Mean</i>	34
2.5.1.2	<i>Stasioner dalam Variansi</i>	35
2.5.2	Operator <i>Backward Shift</i> (Kemunduran)	37
2.5.3	ACF (<i>Autocorrelation Function</i>)	38
2.5.4	PACF (<i>Partial Autocorrelation Function</i>).....	41
2.5.5	Proses <i>White Noise</i>	44
2.6	Metode ARIMA	47
2.6.1	Model <i>Autoregressive</i> (AR).....	56
2.6.2	Model <i>Moving Average</i> (MA).....	57
2.6.3	Model Campuran.....	58
2.6.3.1	Model <i>Autoregressive Moving Average</i> (ARMA).....	58
2.6.3.2	Model <i>Autoregressive Integrated Moving Average</i> (ARIMA)	59
2.6.4	Model ARIMA dengan Faktor Musiman (<i>Seasonal ARIMA</i>) ...	62
2.6.4.1	Model <i>Autoregressive</i> (AR) Musiman	64
2.6.4.2	Model <i>MA</i> Musiman	65
2.6.5	Menghitung Kesalahan Ramalan	66
2.7	Penelitian Terdahulu.....	67
2.8	Kerangka Berpikir	72
2.9	Tahapan Peramalan Menggunakan Software Eviews 7	76
2.9.1	Tahapan Peramalan ARIMA Menggunakan Software Eviews 7	77

2.9.2	Tahapan Peramalan <i>Exponential Smoothing Holt-Winters</i> Menggunakan Software Eviews 7.....	84
BAB 3 METODE PENELITIAN.....		87
3.1	Identifikasi Masalah	87
3.2	Perumusan Masalah.....	88
3.3	Studi Pustaka	88
3.4	Analisis dan Pemecahan Masalah	88
3.4.1	<i>Exponential Smoothing Holt-Winters</i>	89
3.4.2	ARIMA	90
3.5	Tahapan Penelitian	91
3.6	Penarikan Kesimpulan.....	97
BAB 4 HASIL PENELITIAN DAN PEMBAHASAN		98
4.1	Hasil Penelitian.....	98
4.1.1	<i>Exponential Smoothing Holt-Winters</i>	98
4.1.1.1	Membuat Scatter Diagram	98
4.1.1.2	Menentukan Panjang atau Periode Musiman	99
4.1.1.3	Menentukan Nilai Awal Taksiran (Inisialisasi).....	99
4.1.1.4	Seleksi Model <i>Exponential Smoothing Holt-Winters</i>	100
4.1.1.5	Uji Autokorelasi Seleksi Model <i>Exponential Smoothing Holt- Winters</i>	100

4.1.1.6	<i>Uji Autokorelasi Seleksi Model Exponential Smoothing Holt-Winters</i>	100
4.1.1.7	<i>Peramalan Exponential Smoothing Holt-Winters</i>	101
4.1.1.8	<i>Nilai Kesalahan Exponential Smoothing Holt-Winters</i>	104
4.1.2	ARIMA	105
4.1.2.1	<i>Identifikasi Data</i>	105
4.1.2.1.1	<i>Plot Data</i>	105
4.1.2.2	<i>Uji Stasioneritas</i>	106
4.1.2.2.1	<i>Plot Data</i>	107
4.1.2.2.2	<i>Correlogram</i>	107
4.1.2.2.3	<i>Uji Akar Unit</i>	107
4.1.2.2	<i>Estimasi Model ARIMA</i>	109
4.1.2.3	<i>Uji Signifikansi Parameter</i>	110
4.1.2.3	<i>Uji Asumsi Residual (Diagnostic Checking)</i>	112
4.1.2.4	<i>Pemilihan Model Terbaik</i>	115
4.1.2.5	<i>Peramalan ARIMA</i>	117
4.1.2.6	<i>Perbandingan Metode Exponential Smoothing Holt-Winters dan ARIMA</i>	120
4.2	Pembahasan	123
4.2.1	<i>Exponential Smoothing Holt-Winters</i>	123

4.2.2	ARIMA	128
BAB 5 PENUTUP		137
5.1	Simpulan.....	137
5.2	Saran.....	138
DAFTAR PUSTAKA		140
LAMPIRAN.....		145



DAFTAR TABEL

Tabel	Halaman
Tabel 2.1 Nilai λ untuk Membentuk Transformasi.....	36
Tabel 2.2 Pola Autokorelasi dan Autokorelasi Parsial (Sadeq, 2008) dan (Rosadi, 2012).....	61
Tabel 2.3 Penelitian Terdahulu	69
Tabel 2.4 Uji Unit Root Data Bandara.....	81
Tabel 4.1 Inisialisasi faktor musiman I_L	99
Tabel 4.2 Inisialisasi faktor musiman $\alpha = 0,3, \beta = 0,1$ dan $\gamma = 0,1$	102
Tabel 4.3 Hasil Peramalan kedatangan wisatawan mancanegara ke Bali Ngurai Rai Tahun 2015 dengan <i>exponensial smoothing Holt-Winters</i>	103
Tabel 4.4 Perbandingan Data Aktual dan Hasil Ramalan <i>exponential smoothing Holt-Winters</i>	103
Tabel 4.5 Nilai Tertinggi dan Terendah Jumlah kedatangan Wisatawan Mancanegara ke Bali Ngurai Rai	106
Tabel 4.6 Hasil Peramalan kedatangan wisatawan mancanegara ke Bali Ngurai Rai dari bulan Januari 2015 sampai Desember 2015 dengan ARIMA	118
Tabel 4.7 Perbandingan Data Aktual dan Hasil Ramalan ARIMA	118
Tabel 4.8 Perbandingan data aktual dengan hasil peramalan <i>exponential smoothing Holt-Winters</i> dan ARIMA	121

Tabel 4.9 Perbandingan nilai MSE dan MAPE metode ARIMA dan *exponential smoothing Holt-Winters* 122



DAFTAR GAMBAR

Gambar	Halaman
Gambar 2.1 Plot Horizontal	9
Gambar 2.2 Plot Musiman	9
Gambar 2.3. Plot Siklis	10
Gambar 2.4 Plot trend	10
Gambar 2.5 <i>Flowchart Holt-Winters</i>	25
Gambar 2.6 Contoh plot data asli model aditif	26
Gambar 2.7 Contoh plot data asli model multiplikatif.....	27
Gambar 2.8 Contoh plot data stasioner dalam rata-rata dan varians.....	35
Gambar 2.9 Contoh plot data nonstasioner dalam rata-rata.....	35
Gambar 2.10 Contoh plot data stasioner dalam varians.....	36
Gambar 2.11 <i>Flowchart</i> model ARIMA.....	50
Gambar 2.12 Diagram Alur Kerangka Berpikir.....	75
Gambar 2.13 Tampilan Jendela Eviews 7.....	76
Gambar 2.14 Kotak Dialog <i>Workfile Create</i>	78
Gambar 3.1 Diagram Alir Analisis Data.....	96
Gambar 4.1 Hasil plot data jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai Tahun 2010-2014.....	98

Gambar 4.2 Hasil <i>Exponential Smoothing</i> dengan $\alpha = 0,3$, $\beta = 0,1$ dan $\gamma = 0,1$	102
Gambar 4.3 Data aktual dan <i>exponential smoothing Holt-Winters</i>	104
Gambar 4.4 Jumlah kedatangan wisatawan mancanegara ke Bali Ngurai Rai melalui pintu masuk dari bulan Januari 2010 sampai dengan Desember 2014.....	105
Gambar 4.5 Output data jumlah kedatangan wisatawan mancanegara ke Bali hasil <i>differencing</i> (dlogbandara) dan variansi (dslogbandara).....	108
Gambar 4.6 <i>Correlogram-Q-Statistic</i> ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi logaritma.....	112
Gambar 4.7 <i>Correlogram Squared Residual</i> ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi logaritma.....	113
Gambar 4.8 <i>Histogram Normality Test</i> ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi logaritma.....	114
Gambar 4.9 Hasil Ramalan ARIMA dan Data Aktual Jumlah Kedatangan Wisatawan Mancanegara ke Bali Ngurai Rai Tahun 2015	119
Gambar 4.10 Peramalan bandara dan bandaraff	120
Gambar 4.11 Perbandingan data aktual dengan <i>exponential smoothing Holt- Winters</i> dan ARIMA	121
Gambar 4.12 Perbandingan peramalan data aktual <i>exponential smoothing Holt- Winters</i> dan ARIMA	122

DAFTAR LAMPIRAN

Lampiran	Halaman
Lampiran 1 Data Jumlah Kedatangan Wisatawan Mancanegara ke Bali Ngurah Rai per Bulan Menurut Pintu Masuk 2010-2015	146
Lampiran 2 Output <i>Trial and Error</i> Seleksi Model Terbaik <i>Exponential Smoothing Holt-Winters</i> $\alpha = 0,3$ $\beta = 0,1$ $\gamma = 0,1$	147
Lampiran 3 Output Uji Autokorelasi Model Terbaik <i>Exponential Smoothing Holt-Winters</i> $\alpha = 0,3$ $\beta = 0,1$ $\gamma = 0,1$	148
Lampiran 4 Hasil Seleksi Model <i>Exponential Smoothing Holt-Winters</i> Menggunakan Kriteria RMSE.....	149
Lampiran 5 Uji Autokorelasi Seleksi Model <i>Exponential Smoothing Holt-Winters</i>	169
Lampiran 6 Nilai Kesalahan Ramalan <i>Exponential Smoothing Holt-Winters</i> ...	191
Lampiran 7 Correlogram Data Bandara Tanpa Differencing	192
Lampiran 8 Uji Akar Unit Nonstasioner.....	193
Lampiran 9 Correlogram Hasil Differencing dan Transformasi Log	194
Lampiran 10 Uji Akar Unit Stasioner	195
Lampiran 11 Estimasi Model ARIMA.....	196
Lampiran 12 Output Estimasi Model Terbaik	209

Lampiran 13 Output Uji Autokorelasi ARIMA	237
Lampiran 14 Output Uji Heteroskedastisitas	265
Lampiran 15 Output Normalitas	293
Lampiran 16 Uji Diagnostik.....	312
Lampiran 17 Output Gambar Tampilan Peramalan Model ARIMA(2,1,0)(0,1,1) ₁₂ dengan transformasi logaritma	317
Lampiran 18 Estimasi Model Terbaik ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi Logaritma	318
Lampiran 19 Output Uji Autokorelasi Model Terbaik ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi Logaritma.....	319
Lampiran 20 Output Uji Heteroskedastisitas Model Terbaik ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi Logaritma.....	320
Lampiran 21 Output Uji Normalitas Model Terbaik ARIMA (2,1,0)(0,1,1) ₁₂ dengan transformasi Logaritma.....	321
Lampiran 22 Nilai Kesalahan Ramalan ARIMA (2,1,0)(0,1,1) ₁₂ dengan Transformasi Logaritma.....	322

DAFTAR LAMBANG

- S_t : nilai pemulusan eksponensial pada waktu t
- X_t : data pada waktu t
- b_t : nilai pemulusan *trend* pada waktu t
- I_t : nilai pemulusan untuk pola musiman pada waktu t
- S_L : inisialisasi atau nilai awal pemulusan pada periode L
- b_L : inisialisasi atau nilai awal faktor *trend* pada periode L
- I_L : inisialisasi atau nilai awal faktor *seasonal* atau musiman pada periode L
- α : alpha; konstanta pemulusan untuk data asli $0 < \alpha < 1$
- β : beta; konstanta pemulusan untuk pola *seasonal*/musiman $0 < \beta < 1$
- γ : gamma; konstanta pemulusan untuk pola *trend* $0 < \gamma < 1$
- F_{t+m} : nilai peramalan untuk m periode ke depan
- m : jumlah periode ke depan yang akan diramalkan
- L : periode atau panjang musiman (seperti bulan atau kuartal pada tahun)
- n : jumlah data atau observasi
- e : nilai *error* atau kesalahan
- t : waktu, $t = 1, 2, 3, \dots$
- PE_t : kesalahan presentase = $\frac{X_t - F_t}{X_t}$
- $Z_t, Z_{t-1}, \dots, Z_{t-k}$: himpunan variabel random (setiap pengamatan yang dinyatakan sebagai variabel random Z_t yang diperoleh berdasarkan indeks waktu tertentu t)
- $T(Z_t)$: fungsi transformasi dari Z_t

- ADF : *Augmented Dickey-Fuller*
- ACF : *Autocorrelation Function*
- PACF : *Partial Autocorrelation Function*
- $\hat{\beta}$: estimasi *least square* dari β yang merupakan tes akar unit ADF
- c_t : determinasi fungsi untuk indeks waktu t
- B : *backward shift* (operator shift mundur)
- d : *differencing/pembeda* (ordo pembedaan bukan faktor musiman)
- D : ordo pembedaan faktor musiman
- S : jumlah periode per musim
- H_0 : hipotesis nol (hipotesis yang memberi gambaran bahwa ketidadaan hubungan atau perbedaan antara sampel dan populasi)
- H_1 : hipotesis alternatif (hipotesis yang memberi gambaran adanya keterkaitan atau perbedaan antara sampel dan populasi)
- μ : rata-rata
- γ_k : autokovariansi pada *lag-k*
- ρ_k : autokorelasi pada *lag-k*
- ϕ_k : autokorelasi parsial pada *lag-k*
- r_k : koefisien autokorelasi untuk *time lag-k*
- k : selisih waktu
- $Z \frac{\alpha}{2}$: nilai distribusi normal
- SE_{r_k} : kesalahan standar (*standart error*) dari r_k
- Q : hasil perhitungan Ljung-Box/Chi Square
- ϕ_0 : intersep

a_t	: variabel residual pada waktu t
$\phi_1, \phi_2, \dots, \phi_p$: koefisien/parameter dari model <i>autoregressive</i>
$\theta_1, \theta_2, \dots, \theta_p$: koefisien/parameter dari model <i>moving average</i>
p	: orde AR
q	: orde MA
(p, d, q)	: bagian yang tidak musiman dari model
(P, D, Q)	: bagian musiman dari model
$\Phi_p(B^S)$: <i>Autoregressive</i> (AR) musiman dengan periode S dan orde P
$\Theta_Q(B^S)$: <i>Moving average</i> (MA) musiman periode S dan orde Q
$\phi_p(B)$: <i>Autoregressive</i> (AR) non musiman orde p
$\theta_q(B)$: <i>Moving average</i> (MA) non musiman orde q
$(1 - B^S)^D$: Pembedaan (<i>differencing</i>) musiman orde D dan periode musiman S
$(1 - B)^D$: Pembedaan (<i>differencing</i>) non musiman orde d
X_t	: data sebenarnya/data aktual
F_t	: data ramalan dihitung dari model yang akan digunakan pada waktu atau tahun t
MSE	: <i>Mean Squared Error</i>
$MAPE$: <i>Mean Absolute Percentage Error</i>

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien (Makridakis *et al.*, 1991). Peramalan merupakan suatu kegiatan untuk memprediksi kejadian di masa yang akan datang dengan menggunakan dan mempertimbangkan data dari masa lampau. Banyak metode dalam statistika yang dapat digunakan untuk peramalan suatu data *time series*, seperti metode *smoothing*, *Box-Jenkins*, ekonometrika, regresi, fungsi transfer dan sebagainya. Metode-metode tersebut diharapkan dapat mengidentifikasi data yang digunakan untuk meramalkan kondisi pada waktu yang akan datang sehingga *error*-nya menjadi seminimal mungkin.

Pemulusan eksponensial (*exponential smoothing*) merupakan metode peramalan yang digunakan untuk meramalkan masa yang akan datang dengan melakukan proses pemulusan (*smoothing*) dengan menghasilkan data ramalan yang lebih kecil nilai kesalahannya. Dalam pemulusan (*smoothing*) eksponensial terdapat satu atau lebih parameter pemulusan yang ditentukan secara eksplisit dan hasil pilihan menentukan bobot yang dikenakan pada nilai observasi (Makridakis *et al.*, 1999: 79).

Seringkali, dalam peramalan data *time series* menunjukkan perilaku yang bersifat musiman. Musiman didefinisikan sebagai kecenderungan data *time series* yang berulang setiap periode. Musiman adalah istilah yang digunakan untuk

mewakili periode waktu yang berulang (Kalekar: 2004). Data musiman didefinisikan sebagai data dengan pola yang berulang-ulang dalam selang waktu yang tetap. Data musiman berarti kecenderungan mengurangi pola tingkah gerak dalam periode musim, biasanya satu tahun. Runtun waktu musiman mempunyai karakteristik yang ditunjukkan oleh adanya korelasi beruntun yang kuat pada jarak semusim, yakni waktu yang berkaitan dengan banyak observasi per periode musiman.

Peramalan untuk data musiman dikembangkan dengan menggunakan metode *exponential smoothing Holt-Winters*. Metode *Holt-Winters* adalah nama sebutan dari metode pemulusan eksponensial *triple* dimana dilakukan pemulusan tiga kali kemudian dilakukan peramalan. Metode *Holt-Winters* merupakan perluasan dari dua parameter *Holt*. Metode *Holt-Winters* yakni metode prediksi runtun waktu (*time series*) yang dapat menangani perilaku musiman (*seasonal*) pada sebuah data berdasarkan pada data masa lalu. Metode *exponential smoothing Holt-Winters* pernah digunakan oleh Hapsari Vannisa (2013) dengan melakukan perbandingan peramalan metode dekomposisi klasik, dimana metode *Holt-Winters* lebih baik dalam meramalkan tingkat pencemaran udara di Kota Bandung periode Januari 2003 sampai Desember 2012. Kelebihan dari metode *exponential smoothing Holt-Winters* adalah metode ini sangat baik meramalkan pola data yang berpengaruh musiman dengan unsur *trend* yang timbul secara bersamaan, metode yang sederhana dan mudah dimasukkan ke dalam praktek dan kompetitif terhadap model peramalan yang lebih rumit.

Seiring perkembangan teknologi yang semakin maju, menurut Bowerman dan Richard (1993) sebagaimana dikutip oleh Hermawan (2011) bahwa metode peramalan data *time series* telah banyak dikembangkan seperti metode ARIMA. ARIMA merupakan metode yang umum digunakan untuk memprediksi suatu data. Metode ARIMA memanfaatkan sepenuhnya data masa lalu dan sekarang untuk peramalan (Anggriningrum *et al.*, 2013). *Autoregressive Integrated Moving Average* (ARIMA) merupakan model peramalan yang menghasilkan ramalan-ramalan yang berdasarkan sintesis dari pola data secara historis. Metode ARIMA akan bekerja baik apabila data pada deret waktu yang digunakan bersifat dependen atau berhubungan satu sama lain secara statistik (Makridakis *et al.*, 1999). Metode ARIMA pernah digunakan oleh Hermawan (2011) dengan melakukan perbandingan peramalan dengan metode *Holt-Winters* dalam memprediksi anomali OLR pentad di kawasan barat Indonesia, dengan hasil peramalan metode ARIMA lebih baik. Kelebihan metode ARIMA adalah cocok digunakan untuk meramalkan data dengan sederhana dan pengaplikasian metode yang relatif mudah dalam menganalisis data yang mengandung pola musiman maupun *trend*, mengatasi masalah sifat keacakan bahkan sifat siklis data *time series* yang dianalisis.

Untuk mengetahui besarnya tingkat keakuratan ramalan yang dihasilkan, maka penulis mencoba menganalisa perbandingan peramalan menggunakan metode *exponential smoothing Holt-Winters* dan ARIMA dengan menghitung kesalahan ramalan antara lain *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) sehingga *error*-nya menjadi seminimal mungkin.

1.2 Rumusan Masalah

Berdasarkan latar belakang, rumusan masalah dalam penelitian ini antara lain.

- (1) Bagaimana model peramalan terbaik dengan metode *Exponential Smoothing Holt-Winters*?
- (2) Bagaimana model peramalan terbaik dengan metode ARIMA?
- (3) Bagaimana perbandingan peramalan dari model terbaik menggunakan metode *Exponential Smoothing Holt-Winters* dan ARIMA?

1.3 Batasan Masalah

Batasan masalah dari penelitian ini adalah sebagai berikut.

Dalam penulisan penelitian ini, penulis hanya membahas penerapan metode *Exponential Smoothing Holt-Winters*, metode ARIMA, dan perbandingan keduanya untuk peramalan suatu data musiman dengan *Mean Squared Error (MSE)*, *Mean Absolute Percentage Error (MAPE)* sebagai pembandingnya. Data yang digunakan dalam penelitian ini adalah data jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai per bulan melalui pintu masuk Tahun 2010-2015

1.4 Tujuan Penelitian

Berdasarkan latar belakang dan rumusan masalah yang telah dikemukakan, maka penelitian ini bertujuan sebagai berikut.

- (1) Mengetahui model peramalan terbaik dengan metode *exponential smoothing Holt-Winters*.
- (2) Mengetahui model peramalan terbaik dengan metode ARIMA.

- (3) Mengetahui perbandingan peramalan dari model terbaik menggunakan metode *exponential smoothing Holt-Winters* dan ARIMA.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini antara lain.

1.5.1 Bagi Pembaca

- (1) Menambah pengetahuan tentang informasi peramalan.
- (2) Mengetahui cara meramalkan data dengan metode *exponential smoothing Holt-Winters* dan metode ARIMA.
- (3) Dapat dijadikan sebagai salah satu rujukan dalam melakukan peramalan atau penelitian selanjutnya.
- (4) Sebagai motivasi pembaca agar dapat mempelajari dan mengembangkan matematika, khususnya dalam bidang statistika dalam *forecasting*.

1.5.2 Bagi Peneliti

- (1) Menjadi bahan referensi untuk penelitian yang berkaitan dengan metode *exponential smoothing Holt-Winters* dan metode ARIMA.
- (2) Menjadi bahan perbandingan metode *exponential smoothing Holt-Winters* dan metode ARIMA dengan metode peramalan lainnya.

1.5.3 Bagi Masyarakat

- (1) Menambah ilmu pengetahuan, wawasan dan informasi bagi masyarakat.
- (2) Menambah pengetahuan tentang peramalan suatu data sehingga dapat menjadi tolak ukur dalam melakukan rencana kegiatan misalnya wisata pada hari libur.

- (3) Menjadi motivasi semangat bagi masyarakat akan pentingnya perencanaan.

1.5.4 Bagi Institusi/Perusahaan Pengguna Jasa

Membantu institusi/perusahaan yang memanfaatkan data masa lalu untuk menentukan model peramalan terbaik dalam rangka penentuan kebijakan di masa yang akan datang didasarkan pada tingkah gerak data di masa lalu.

1.6 Penegasan Masalah

Nilai ramalan menggunakan metode *exponential smoothing Holt-Winters* dan ARIMA lebih baik jika mendekati nilai data aktual. Untuk mendukung dugaan, maka dilakukanlah perbandingan nilai *Mean Squares of Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE) dari kedua metode. Dengan model peramalan yang nantinya dipilih adalah model peramalan terbaik yang memiliki nilai MSE dan MAPE terkecil. Hasil ramalan metode *exponential smoothing Holt-Winters* dan hasil ramalan ARIMA dibandingkan dengan data aktual. Data yang digunakan dalam peramalan adalah data yang mengandung musiman.

1.7 Sistematika Penulisan Skripsi

Secara garis besar sistematika penulisan skripsi ini terdiri dari tiga bagian utama yaitu bagian awal, bagian isi dan bagian akhir yang masing-masing dijelaskan sebagai berikut.

Bagian awal skripsi meliputi halaman judul, pernyataan keaslian tulisan, pengesahan, motto dan persembahan, prakata, abstrak, daftar isi, daftar tabel, daftar gambar, daftar lampiran dan daftar lambang.

Bagian isi skripsi merupakan bagian pokok skripsi. Secara garis besar bagian pokok skripsi terdiri dari lima bab, yakni: (1) Bab 1 Pendahuluan. Bab ini berisi tentang pendahuluan memuat latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, penegasan masalah dan sistematika penulisan skripsi; (2) Bab 2 Tinjauan Pustaka. Bab ini berisi tentang tinjauan pustaka mengenai teori-teori pendukung yang digunakan sebagai landasan teori yang mendasari pemecahan masalah yang dibahas pada penelitian ini. Pada bab ini dijelaskan tentang *time series*, peramalan (*forecasting*), peramalan (*forecasting*) dengan eksponensial *smoothing*, metode *exponential smoothing Holt-Winters*, metode ARIMA, penelitian terdahulu dan kerangka berpikir; (3) Bab 3 Metode Penelitian. Bab ini berisi metode penelitian berisi tentang prosedur atau langkah-langkah yang dilakukan dalam penelitian mencakup identifikasi masalah, perumusan masalah, studi pustaka, analisis dan pemecahan masalah, tahapan penelitian dan penarikan kesimpulan; (4) Bab 4 Hasil Penelitian dan Pembahasan. Bab ini berisi hasil penelitian dan pembahasannya yang disajikan dalam rangka menjawab permasalahan penelitian. Bab ini berisi hasil penelitian dan pembahasan perbandingan peramalan menggunakan metode *exponential smoothing Holt-Winters* dan ARIMA; (5) Bab 5 Penutup. Bab ini berisi penutup yang mengemukakan simpulan yang diperoleh dari hasil pembahasan sebelumnya dan saran-saran yang diberikan peneliti berdasarkan simpulan yang diperoleh.

Bagian akhir skripsi berisi daftar pustaka yang memberikan informasi tentang buku sumber serta literatur yang digunakan dan lampiran-lampiran yang mendukung penulisan skripsi.

BAB 2

TINJAUAN PUSTAKA

2.1 *Time Series*

Time series merupakan suatu rangkaian variabel yang diamati pada interval waktu ruang yang sama ditunjukkan sebagai sebuah deret berkala (Hendikawati, 2015: 214). Berdasarkan Iriawan dan Astuti (2006) dalam Munawaroh (2010) menjelaskan bahwa analisis *time series* dikenalkan oleh George E. P. Box dan Gwilym M. Jenkins pada tahun 1970 melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. Analisis *time series* merupakan metode peramalan kuantitatif untuk menentukan pola data pada masa lampau yang dikumpulkan berdasarkan waktu, yang disebut data *time series*.

Analisis *time series* terdiri dari metode untuk menganalisis data *time series* dengan mengambil parameter data statistik dan karakteristik lain dari data untuk memprediksi nilai masa depan berdasarkan nilai-nilai sebelumnya yang diamati (Phumchusri & Udom, 2014). *Time series* atau runtun waktu merupakan serangkaian hasil pengamatan yang berasal dari satu sumber tetap yang terjadi berdasarkan indeks waktu berurutan dengan interval waktu yang tetap. Ciri khas dari runtun waktu ini deretan observasi pada suatu variabel yang dinilai sebagai realisasi dari variabel random yang berdistribusi bersama.

Berdasarkan Makridakis *et al.*, (1999: 9-11) menjelaskan bahwa langkah penting dalam memilih suatu metode runtun waktu (*time series*) yang tepat adalah dengan mempertimbangkan jenis pola data, sehingga metode yang paling tepat

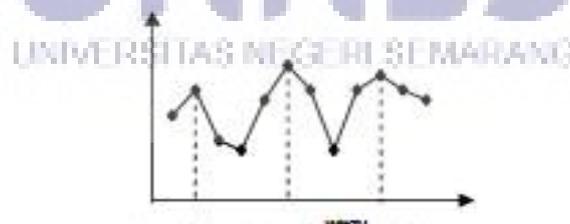
dengan pola data tersebut dapat diuji. Pola data dapat dibedakan menjadi empat, yaitu.

- (1) Pola horizontal terjadi pada saat ini data berfluktuasi di sekitar nilai rata-rata konstan (deret seperti itu adalah stasioner terhadap nilai rata-ratanya). Secara umum struktur datanya dapat digambarkan seperti Gambar 2.1.



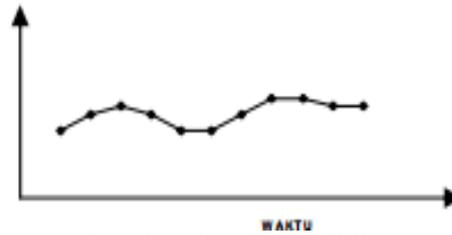
Gambar 2.1 Plot Horizontal

- (2) Pola musiman terjadi jika suatu deret dipengaruhi oleh faktor musiman. Pola musiman merupakan fluktuasi dari data yang terjadi secara periodik dalam kurun waktu satu tahun, seperti triwulan, kuartalan, bulanan, mingguan, atau harian. Pola ini sulit dideteksi dan tidak dapat dipisahkan dari pola *trend*. Seperti pada penjualan minuman ringan, es krim, bahan bakar pemanas ruangan. Secara umum struktur datanya dapat digambarkan seperti Gambar 2.2.



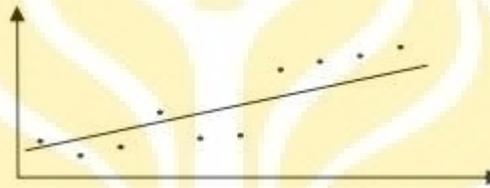
Gambar 2.2 Plot Musiman

- (3) Pola siklis terjadi bilamana datanya dipengaruhi oleh fluktuasi ekonomi jangka panjang seperti yang berhubungan dengan siklus bisnis. Secara umum struktur datanya dapat digambarkan seperti Gambar 2.3.



Gambar 2.3. Plot Siklis

- (4) Pola trend terjadi jika data terdapat pertambahan atau kenaikan atau penurunan sekuler jangka panjang dalam data. Secara umum struktur datanya dapat digambarkan seperti Gambar 2.4.



Gambar 2.4 Plot trend

Time series merupakan suatu deretan observasi yang diambil secara berurutan berdasarkan waktu dengan interval sama, harian, bulanan, tahunan atau yang lain (Box dkk, 1994). Teknik analisis runtun waktu yang merupakan salah satu metode peramalan yang dapat memberikan sumbangan dalam membuat peramalan yang operasional. Ciri-ciri analisis runtun waktu yang menonjol adalah bahwa deretan observasi dalam suatu variabel dipandang sebagai realisasi dari variabel random yang berdistribusi sama.

Pola historis yang dimiliki dapat berpola horizontal, yaitu nilai data berfluktuasi di sekitar rata-rata. Namun dalam kenyataan data tersebut bervariasi karena dipengaruhi *trend* yaitu rata-rata gerakan penurunan atau perumbuhan jangka panjang pada serangkaian data historis. Siklis adalah perubahan atau gelombang pasang surut sesuatu yang berulang kembali dalam runtun waktu lebih

dari satu tahun. Musiman adalah gelombang pasang surut yang berulang kembali dalam waktu sekitar satu tahun (Subagyo, 2013:32,51,58).

Data dikatakan berpola musiman apabila deret data terdapat kenaikan atau penurunan sekuler jangka panjang dalam data. Contohnya data penjualan jas yang berpola musiman yaitu penjualan meningkat menjelang dan saat musim hujan. Juga dalam penjualan baju akan meningkat untuk baju-baju yang sesuai dengan trend yang sedang berlaku dalam masyarakat.

2.2 Peramalan (*Forecasting*)

Menurut Makridakis *et al.*, (1999: 8), metode peramalan dibagi ke dalam dua kategori utama, yaitu metode kualitatif dan metode kuantitatif. Metode kuantitatif dilakukan apabila informasi masa lalu tersedia sehingga peramalan bisa dilakukan, informasi tersebut dapat dikuantitatifkan dalam bentuk data numerik. Dalam metode kualitatif pendapat-pendapat dari para ahli akan menjadi pertimbangan dalam pengambilan keputusan sebagai hasil dari peramalan yang telah dilakukan. Namun, apabila data masa lalu tersedia, peramalan dengan metode kuantitatif akan lebih efektif digunakan dibandingkan dengan metode kualitatif.

Contoh dari metode peramalan kualitatif adalah metode peramalan berdasarkan perkiraan (*judgement*) dan matrik penarikan keputusan. Metode peramalan kuantitatif antara lain seperti metode regresi, metode pemulusan eksponensial, metode dekomposisi, dan metode ARIMA. Pada umumnya digunakan pendekatan kira-kira (*judgemental*) untuk meramalkan dari sebuah pendekatan yang lebih objektif.

Menurut Makridakis *et al.*, (1999) langkah awal dalam membuat ramalan mendatang adalah menentukan apakah akan digunakan metode peramalan formal atau prosedur informal. Metode kuantitatif atau metode peramalan formal lebih baik daripada prosedur informal. Peramalan biasanya dilakukan untuk mengurangi ketidakpastian terhadap sesuatu yang akan terjadi di masa yang akan datang. Suatu usaha untuk mengurangi ketidakpastian tersebut dilakukan dengan menggunakan metode peramalan. Menurut Santoso (2009) yang dijelaskan oleh Munawaroh (2010), peramalan dengan metode kuantitatif dapat dibagi menjadi dua bagian, yaitu *time series model* dan *casual model*. *Time series model* didasarkan pada data yang dikumpulkan, dicatat, atau diamati berdasarkan urutan waktu dan peramalannya dilakukan berdasarkan pola tertentu dari data.

Metode peramalan yang termasuk dalam *time series model*, antara lain *moving average*, *eksponensial smoothing*, dan Box-Jenkins (ARIMA). *Casual model* didasarkan pada hubungan sebab-akibat dan peramalan dilakukan dengan dugaan adanya hubungan antar variabel yang satu dengan yang lain. Pada model ini dikembangkan mana variabel *dependent* dan mana variabel *independent*, kemudian dilanjutkan dengan membuat sebuah model dan peramalan dilakukan berdasarkan model tersebut.

Selanjutnya Makridakis *et al.*, (1999) merangkum menjadi:

- (1) Berbagai ukuran keakuratan *Mean Squared of Errors* (MSE) dan *Mean Absolute Percentage Error* (MAPE) menghasilkan hasil yang konsisten ketika digunakan untuk mengevaluasi metode peramalan yang berbeda,

- (2) Metode pemulusan eksponensial berkinerja baik dibandingkan metode lain, jika terdapat jumlah data yang relatif sedikit,
- (3) Kinerja berbagai metode peramalan tergantung dari panjangnya waktu peramalan (tahunan, triwulan, bulanan) dan jenis data yang dianalisa.

2.2.1 Definisi dan Tujuan Peramalan (*Forecasting*)

Peramalan atau *forecasting* adalah suatu usaha untuk meramalkan keadaan di masa mendatang melalui pengujian keadaan di masa lalu. Segala sesuatu tidak pasti dalam kehidupan sosial, sukar diperkirakan secara tepat, oleh karena itu perlu diadakan peramalan. Peramalan (*forecasting*) bertujuan mendapatkan peramalan yang bisa diminimumkan kesalahan (*forecast error*) yang bisa diukur dengan *mean squared error*, *mean absolute error*, dan sebagainya (Subagyo, 2013:4).

Membuat peramalan diupayakan supaya pengaruh ketidakpastian dapat diminimumkan, dengan kata lain ramalan bertujuan untuk menemukan model terbaik dengan data historis. Namun, ketidakpastian pengumpulan data akan terjadi karena kesalahan yang disebabkan *time lag* dan pengaruh antar variabel (Phumchusri & Udom: 2014). Agar ramalan yang dibuat dapat meminimumkan kesalahan prediksi (*forecast error*) dapat diukur dengan *Mean Absolute Percentage Error* (MAPE) yaitu rata-rata nilai *absolute error* dari kesalahan meramal (tidak dihiraukan tanda positif ataupun negatifnya) dan *Mean Squared Error* (MSE) yaitu rata-rata dari kesalahan peramalan dikuadratkan (Subagyo, 2013:10).

Nilai *error* yang asli biasanya tidak dirata-rata sebagai ukuran besar kecilnya *error*, sebab ada yang nilainya positif dan ada juga yang nilainya negatif. Sehingga jika dijumlah nilai *error* pasti akan kecil, akibatnya penyimpangan dari peramalan sebenarnya besar seolah-olah kelihatannya kecil karena jika *error* dijumlahkan begitu saja *error* positif besar dikurangi dengan *error* negatif yang besar. Menghindari hal ini maka *error* perlu dijadikan angka mutlak atau dikuadratkan kemudian baru dirata-rata (Subagyo, 2013:10).

2.2.2 Kegunaan Peramalan (*Forecasting*)

Sering terdapat senja waktu (*time lag*) antara kesadaran akan peristiwa. Adanya waktu tenggang (*lead time*) ini merupakan alasan utama bagi perencanaan dan peramalan. Dalam situasi ini peramalan diperlukan untuk menetapkan kapan suatu peristiwa akan terjadi atau timbul, sehingga tindakan yang tepat dapat dilakukan. Dalam perencanaan misalnya di organisasi atau perusahaan peramalan merupakan kebutuhan yang sangat penting, baik buruknya peramalan dapat mempengaruhi seluruh bagian organisasi karena waktu tenggang untuk pengambilan keputusan dapat berkisar dari beberapa tahun. Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien.

Kegunaan peramalan menurut Makridakis *et al.*, (1999) antara lain:

- (1) Untuk penjadwalan sumber daya yang tersedia. Penggunaan sumber daya yang efisien memerlukan penjadwalan produksi, transportasi, kas, personalia, dan sebagainya. Input yang penting untuk penjadwalan seperti itu adalah ramalan tingkat permintaan akan konsumennya atau pelanggan.

- (2) Penyediaan sumber daya tambahan. Waktu tenggang (*lead time*) untuk memperoleh bahan baku, menerima pekerja baru atau membeli bensin dan peralatan dapat berkisar antara beberapa hari sampai dimasa mendatang. Berguna untuk menentukan sumber daya yang diinginkan. Setiap organisasi harus menentukan sumber daya yang dimiliki dalam jangka panjang. Keputusan semacam ini bergantung kepada faktor-faktor lingkungan, manusia, dan pengembangan sumber daya keuangan. Semua penentuan ini memerlukan ramalan yang baik dan manager yang dapat menafsirkan pendugaan serta membuat keputusan yang baik.
- (3) Penentuan sumberdaya yang diinginkan. Setiap organisasi harus menentukan sumberdaya yang ingin dimiliki dalam jangka panjang. Keputusan semacam itu bergantung pada kesempatan pasar, faktor-faktor lingkungan, dan pengembangan internal dari sumberdaya finansial, manusia, produk, dan teknologis. Semua penentuan ini memerlukan ramalan yang baik dan manager yang dapat menafsirkan pendugaan serta membuat keputusan yang tepat.

Berdasarkan uraian yang dijelaskan, dapat dikatakan metode peramalan sangat berguna, karena akan membantu dalam mengadakan analisis terhadap data dari masa lalu, sehingga dapat memberikan cara pemikiran, pengerjaan yang teratur dan terarah, perencanaan yang teratur serta memberikan ketepatan hasil peramalan yang dibuat atau disusun.

2.3 Peramalan (*Forecasting*) dengan Eksponensial *Smoothing*

Exponential Smoothing adalah suatu metode peramalan rata-rata bergerak yang melakukan pembobotan menurun secara eksponensial terhadap nilai observasi yang lebih tua (Mardakis, 1999: 79). Pengaruh dari metode ini adalah menghilangkan unsur random dalam data sehingga diperoleh suatu pola yang akan berguna dalam meramalkan nilai masa datang.

Bobot yang diberikan dalam metode *exponential smoothing* berciri menurun secara eksponensial dari titik data terakhir sampai data yang terawal. Karena bila dalam perhitungan peramalan mengasumsikan bahwa *mean* akan bergerak secara lambat sepanjang waktu. Suatu data runtun waktu yang mengandung pola *trend*, pola musiman, atau mengandung pola *trend* dan musiman sekaligus, maka metode rata-rata sederhana tidak dapat digunakan untuk menggambarkan pola data tersebut. Peramalan pada data tersebut dapat dilakukan dengan metode *smoothing*. *Smoothing* adalah mengambil rata-rata dari nilai-nilai pada beberapa periode untuk menaksir nilai pada satu tahun (Subagyo, 2013: 7).

Metode *smoothing* diklasifikasikan menjadi dua kelompok, yaitu metode perataan dan metode pemulusan eksponensial (*exponential smoothing*) (Makridakis *et al.*, 1999: 63). Sesuai dengan pengertian konvensional tentang nilai rata-rata, metode perataan merupakan pembobotan yang sama terhadap nilai-nilai observasi.

Apabila data dipengaruhi oleh pola *trend* maupun musiman, metode perataan tidak dapat digunakan untuk peramalan. Peramalan pada data yang

dipengaruhi pola *trend* maupun musiman dilakukan dengan menggunakan metode *exponential smoothing*.

Metode *exponential smoothing* merupakan pengembangan dari metode *moving average*. Dalam metode ini peramalan dilakukan dengan mengulang perhitungan secara terus-menerus dengan menggunakan data terbaru, setiap data terbaru diberi bobot yang lebih besar. Metode *exponential smoothing* menggunakan bobot yang berbeda untuk data masa lalu dan bobot tersebut mempunyai ciri menurun secara eksponensial. Metode dalam kelompok ini memerlukan adanya penentuan parameter tertentu dan nilai dari parameter terletak antara 0 dan 1 (Makridakis *et al.*, 1999: 63).

Metode yang termasuk dalam metode *exponential smoothing*, antara lain:

(1) Metode *Single Exponential Smoothing*

Metode ini juga dikenal sebagai pemulusan eksponensial sederhana. Pemulusan sederhana digunakan untuk jangka pendek peramalan, biasanya hanya satu bulan ke depan. Model ini mengasumsikan bahwa data berfluktuasi di sekitar rata-rata cukup stabil (tidak ada trend atau konsisten pola kenaikan) (Kalekar, 2004). Metode ini cocok digunakan untuk meramalkan hal-hal yang fluktuasinya secara random (tidak teratur). Dalam melakukan peramalan dengan metode ini besarnya α ditentukan *trial and error* sampai ditemukan α yang menghasilkan *forecast error* terkecil.

(2) Metode *Double Exponential Smoothing*

Pada metode ini proses penentuan peramalan dimulai dengan menentukan besarnya α secara *trial and error*. Metode ini biasanya lebih tepat untuk

meramalkan data yang mengalami *trend* pada data. Metode ini dibagi menjadi dua, yaitu.

(a) Metode linear satu parameter dari *Brown* menggunakan parameter yang sama untuk dua pemulusan eksponensial yang digunakan. Metode ini menggunakan rumus pemulusan berganda secara langsung, yaitu pemulusan antara pola *trend* dan pola lainnya dilakukan secara bersamaan dengan hanya menggunakan satu parameter.

(b) Metode dua parameter dari *Holt* menggunakan dua parameter berbeda untuk dua pemulusan eksponensial yang digunakan. Metode ini memuluskan pola *trend* secara terpisah dengan menggunakan parameter yang berbeda dari parameter yang digunakan pada data asli.

(3) Metode *Triple Exponential Smoothing*

Metode ini digunakan ketika data menunjukkan trend dan musiman. Untuk menyelesaikan musiman dengan menambahkan parameter ketiga. Persamaan ketiga untuk menyelesaikan musiman. Jika data *time series* tidak memperlihatkan pola konstan atau linier, maka untuk melakukan peramalan digunakan metode *Triple Exponential* untuk menangani pola *trend* dan pola musiman pada data.

Metode ini dibagi menjadi dua, yaitu:

(a) Metode kuadratik satu parameter dari *Brown* pendekatan dasarnya adalah memasukkan tingkat pemulusan tambahan dan pada peramalannya diberlakukan persamaan kuadratik.

(b) Metode *trend* dan musiman tiga parameter dari *Winters* merupakan perluasan dari metode dua parameter dari *Holt* dengan tambahan satu persamaan untuk mengatasi pola musiman pada data.

Keuntungan penggunaan metode *exponential smoothing* adalah banyak mengurangi masalah penyimpanan data, sehingga tidak perlu lagi menyimpan semua data historis atau sebagian, hanya pengamatan terakhir, ramalan terakhir, dan suatu nilai konstanta yang harus disimpan.

2.3.1 Metode Eksponensial *Holt Smoothing*

Menurut Santoso (2009) yang dijelaskan oleh Munawaroh (2010) menyebutkan bahwa metode *Holt's exponential smoothing* atau metode pemulusan eksponensial dua parameter dari *Holt* dipopulerkan pada tahun 1957. Metode ini digunakan jika data dipengaruhi pola *trend* dan data nonstasioner. Eksponensial *Holt smoothing* memuluskan pola *trend* dengan parameter yang berbeda dengan parameter yang digunakan pada data asli (Annisa, Jaya Andi Kresna & Suwandi, Adi: 2013).

Menurut Makridakis *et.al.*, (1999: 91), ada tiga persamaan yang digunakan dalam metode ini, yaitu.

- (1) Pemulusan eksponensial data asli (keseluruhan)

$$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.1)$$

- (2) Pemulusan pola *trend*

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.2)$$

- (3) Ramalan m periode ke depan

$$F_{t+m} = S_t + b_t m \quad (2.3)$$

dengan

S_t = nilai pemulusan eksponensial pada waktu t

X_t = data pada waktu ke t

b_t = nilai pemulusan *trend* pada waktu t

α = konstanta pemulusan untuk data asli $0 < \alpha < 1$

γ = konstanta pemulusan untuk pola *trend* $0 < \gamma < 1$

F_{t+m} = nilai peramalan untuk m periode ke depan

m = jumlah periode ke depan yang akan diramalkan

2.3.2 Metode Eksponensial *Winters Smoothing*

Eksponensial *Holt smoothing* tepat digunakan jika data hanya dipengaruhi pola *trend*. Namun, jika data tidak hanya dipengaruhi pola *trend*, tetapi juga pola musiman, maka Eksponensial *Holt smoothing* tidak tepat digunakan untuk melakukan peramalan karena tidak dapat mendeteksi adanya pola musiman. Oleh karena itu, *Winters* menyempurnakan eksponensial *Holt smoothing* dengan menambahkan satu parameter untuk mengatasi pola musiman pada data. Metode ini dibagi menjadi dua model, yaitu model aditif dan multiplikatif. Perhitungan dengan model aditif dilakukan jika plot data asli menunjukkan fluktuasi musim yang relatif stabil, sedangkan model multiplikatif digunakan jika plot data asli menunjukkan fluktuasi musim yang bervariasi.

Menurut Makridakis *et.al.*, yang berjudul Metode dan Aplikasi Peramalan (1999: 97), ada tiga persamaan yang digunakan dalam metode ini, yaitu.

(1) Pemulusan eksponensial data asli (keseluruhan)

$$S_t = \alpha \frac{X_t}{I_{t-L}} + (1 + \alpha) (S_{t-1} + b_{t-1}) \quad (2.4)$$

- (2) Pemulusan pola
- trend*

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.5)$$

- (3) Pemulusan pola musiman

$$I_t = \beta \frac{X_t}{S_t} + (1 - \beta)I_{t-L} \quad (2.6)$$

- (4) Ramalan
- m
- periode ke depan

$$F_{t+m} = (S_t + b_t m)I_{t-L+m} \quad (2.7)$$

dengan I_t = nilai pemulusan untuk pola musiman pada waktu t

S_t = nilai pemulusan eksponensial pada waktu t

X_t = data ke t

α = konstanta pemulusan untuk data asli $0 < \alpha < 1$

γ = konstanta pemulusan untuk pola *trend* $0 < \gamma < 1$

β = konstanta pemulusan untuk pola musiman $0 < \beta < 1$

L = periode/panjang musiman

b_t = konstanta pemulusan musiman pada waktu t

F_{t+m} = nilai peramalan untuk m periode ke depan

m = jumlah periode ke depan yang akan diramalkan

2.4 Metode *Exponential Smoothing Holt-Winters*

Teknik peramalan sebagian besar dikelompokkan sebagai perkiraan (judgmental), univariat atau multivariat. Peramalan dengan judgmental dibuat oleh para ahli. Peramalan univariat hanya melibatkan satu variabel penjelas. Metode *Holt-Winters smoothing* termasuk metode univariat. Metode *Holt-Winters smoothing* populer untuk ramalan yang diproduksi secara massal, misalnya dalam

perencanaan produksi, karena kesederhanaanya (UK Centre for the Measurement of Government Activity: 2008).

Metode *Holt-Winters smoothing* disebut juga pemulusan eksponensial ganda, merupakan perluasan dari pemulusan eksponensial yang dirancang untuk data runtun waktu *trend* dan musiman. Metode *Holt-Winters smoothing* adalah alat yang banyak digunakan untuk bisnis peramalan yang mengandung musiman, perubahan *trend* dan kaitannya dengan musiman (Croux *et al*, 2008). Metode *exponential smoothing Holt-Winters* sering digunakan untuk menghaluskan dan peramalan *time series* univariat. Alasan utama dari popularitas metode ini adalah metode yang sederhana dan mudah dimasukkan ke dalam praktek, pada saat yang sama metode *exponential smoothing Holt-Winters* cukup kompetitif terhadap model peramalan yang lebih rumit (Croux *et al.*, 2008: 18). Metode *exponential smoothing Holt-Winters* adalah prosedur peramalan secara luas digunakan dalam analisis *time series* yang memperhitungkan setiap trend yang mendasari dan komponen musiman terlepas dari apakah bersifat aditif atau multiplikatif (Thoplan, 2014).

Metode ini digunakan untuk mengatasi permasalahan adanya musiman dan atau tanpa trend dari suatu *time series* data, yang merupakan gabungan dari metode *Holt* dan metode *Winters*. Metode ini merupakan penghalusan eksponensial dengan tiga kali pembobotan. Peramalan dengan metode *exponential smoothing Holt-Winters* pada umumnya tidak selalu harus memenuhi kaidah-kaidah deret waktu seperti signifikansi autokorelasi dan stasioneritas. Metode rata-rata bergerak dan pemulusan eksponensial dapat digunakan untuk data

stasioner maupun data nonstasioner. Namun apabila data mengandung unsur musiman, seringkali ditemukan galat yang bersifat sistematis. Salah satu penemuan penting dalam bidang peramalan yakni ditemukannya metode *exponential smoothing Holt-Winters* yang mampu menangani data yang memiliki unsur trend dan musiman, yang merupakan penyempurnaan dari metode *Holt-Brown*.

Metode ini serupa dengan Metode *Holt*, dengan suatu persamaan tambahan untuk mengatasi musiman. Metode *Holt-Winters* menggunakan tiga persamaan pemulusan yakni level, trend, dan musiman (Suseelatha & Sudheer, 2014). Kelemahan pada *Holt-Winters* yakni metode ini membutuhkan tiga parameter pemulusan (α, β, γ) yang bernilai antara 0 dan 1 untuk meminimumkan galat, sehingga banyak kombinasi yang mungkin digunakan. Metode *Holt-Winters* menggunakan tiga pembobotan atau parameter pemulusan yakni α , β , dan γ dimana parameter-parameter tersebut berada pada interval antara 0 dan 1 (Szmit Anna & Szmit Maciej, 2012).

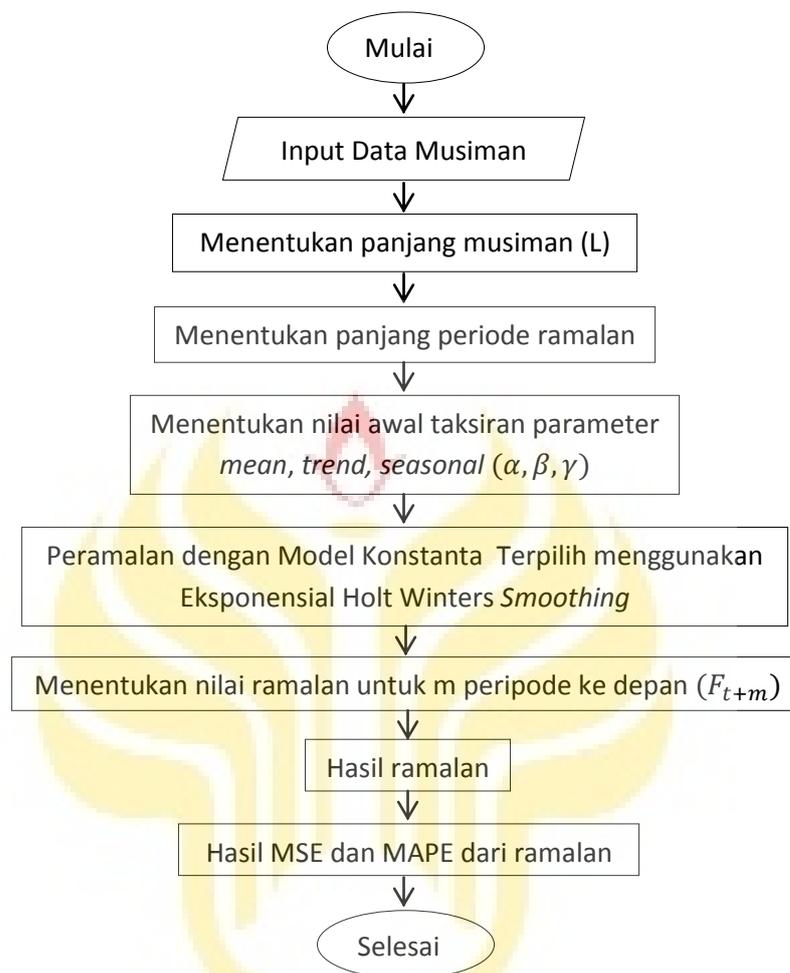
Berdasarkan Makridakis (1999: 110-111) penetapan nilai α , β , dan γ sekitar 0,1 sampai dengan 0,2. Hal ini bermanfaat untuk mencapai stabilitas jangka panjang dan menyediakan metode yang umum dan murah untuk peramalan semua jenis data. Menurut Pramita dan Tanuwijaya (2010) menyebutkan bahwa nilai konstanta yang digunakan adalah 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8 dan 0.9. Hal ini dilakukan untuk mengurangi waktu dalam proses peramalan. Semakin banyak jumlah konstanta maka proses peramalan akan memakan waktu yang cukup lama karena sistem akan melakukan perulangan yang lebih banyak. Sistem

peramalan ini akan mengkombinasikan 3 (tiga) parameter untuk menentukan perpaduan konstanta yang terbaik untuk menghasilkan MAPE dan MSE terkecil.

Berdasarkan penelitian Sungkawa dan Megasari (2011) menyebutkan bahwa metode alternatif yang dapat mengurangi keraguan tentang nilai optimal adalah mencari nilai taksiran awal yang lebih baik, lalu menetapkan nilai kecil untuk ketiga parameter pemulusan (sekitar 0,1 sampai dengan 0,3). Nilai 0,1 membuat ramalan bersifat terlalu hati-hati, sedangkan nilai 0,3 memberikan sistem yang lebih responsif. Dalam perhitungan program Eviews dipilih nilai RMSE terkecil dari nilai α (*mean*), β (*trend*), dan γ (*seasonal*) secara *trial and error*. Untuk mendapatkan model terbaik dengan rumus sebagai berikut.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n e_t^2}{n}} \quad (2.8)$$

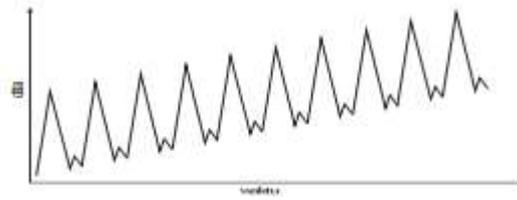
Gambar 2.5 berikut tahapan dalam bentuk *flowchart* metode *Holt-Winters*.



Gambar 2.5 *Flowchart Holt-Winters*

2.4.1 *Exponential Smoothing Holt-Winters* dengan Model Aditif

Model musiman aditif digunakan untuk variasi musiman yang bersifat konstan. Model musiman aditif cocok untuk prediksi deret berkala (*time serie*) yang mana amplitudo (ketinggian) pola musimannya tidak tergantung pada rata-rata level atau ukuran data (Padang: 2013). Komponen musiman pada metode *Holt-Winters* dapat bersifat aditif, namun jarang terjadi. Gambar 2.6 berikut merupakan contoh plot data model aditif.



Gambar 2.6 Contoh plot data asli model aditif
(Hanke dan Wichern, 2005: 160)

Menurut Makridakis *et al.*, (1999) persamaan-persamaan yang digunakan dalam model aditif, yaitu:

- (1) Pemulusan eksponensial data asli (keseluruhan)

$$S_t = \alpha(X_t - I_{t-L}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.9)$$

- (2) Pemulusan faktor *trend*

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.10)$$

- (3) Pemulusan faktor musiman

$$I_t = \beta(X_t - S_t) + (1 - \beta)I_{t-L} \quad (2.11)$$

- (4) Ramalan m periode ke depan

$$F_{t+m} = (S_t + b_t m)I_{t-L+m} \quad (2.12)$$

dengan I_t = nilai pemulusan untuk pola musiman pada waktu t

S_t = nilai pemulusan eksponensial pada waktu t

X_t = data ke t

α = konstanta pemulusan untuk data asli $0 < \alpha < 1$

γ = konstanta pemulusan untuk pola *trend* $0 < \gamma < 1$

β = konstanta pemulusan untuk pola musiman $0 < \beta < 1$

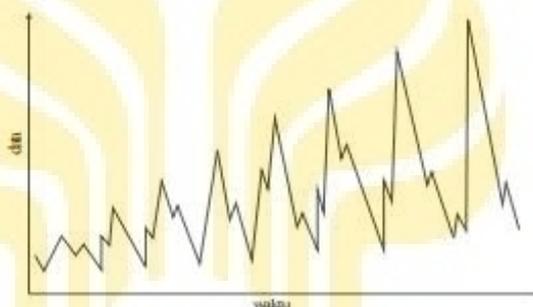
L = periode/panjang musiman

b_t = konstanta pemulusan musiman pada waktu t

m = jumlah periode ke depan yang akan diramalkan

2.4.2 Exponential Smoothing Holt-Winters dengan Model Multiplikaif

Model musiman multiplikatif digunakan untuk variasi data musiman yang mengalami peningkatan atau penurunan (fluktuasi). Model musiman multiplikatif cocok untuk prediksi deret berkala (*time series*) dimana amplitudo (ketinggian) dari pola musimannya proporsional dengan rata-rata level atau tingkatan dari deret data (Padang: 2013). Dengan kata lain, pola musiman membesar atau seiring meningkatnya ukuran data (Koehler *et al*: 2001). Gambar 2.7 berikut merupakan contoh plot data model multiplikatif.



Gambar 2.7 Contoh plot data asli model multiplikatif (Hanke dan Wichern, 2005: 160)

Menurut Hendikawati (2015: 42), ada empat persamaan yang digunakan dalam model multiplikatif, yaitu.

- (1) Pemulusan eksponensial data asli (keseluruhan)

$$S_t = \alpha \frac{X_t}{I_{t-L}} + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (2.13)$$

- (2) Pemulusan faktor *trend*

$$b_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)b_{t-1} \quad (2.14)$$

- (3) Pemulusan faktor musiman

$$I_t = \beta \frac{X_t}{S_t} + (1 - \beta)I_{t-L} \quad (2.15)$$

(4) Ramalan m periode ke depan

$$F_{t+m} = (S_t + b_t m) I_{t-L+m} \quad (2.16)$$

dimana,

X = data observasi

L = panjang atau periode musiman (seperti bulan atau kuartal pada tahun)

S_t = nilai pemulusan eksponensial data asli

b_t = komponen faktor *trend* pada periode t

I_t = komponen faktor musiman pada periode t , dan

F_{t+m} = peramalan untuk m periode berikutnya.

Memulai perhitungan dilakukan dengan menentukan nilai awal untuk S_t , b_t , dan I_t . Proses penentuan nilai awal atau inisialisasi pada prediksi dengan metode *exponential smoothing Holt-Winters* ini diperlukan paling sedikit satu periode (kelompok) data musiman lengkap yaitu L periode untuk menentukan estimasi awal dari indeks musiman I_{t-L} , dan untuk menaksir faktor *trend* dari suatu periode ke periode selanjutnya (Hendikawati, 2015: 43).

2.4.3 Proses Inisialisasi

Pemilihan nilai awal untuk prosedur peramalan penting karena ramalan bergantung pada nilai awal yang ditetapkan (Thoplan, 2014). Beberapa pendekatan yang dapat diterapkan untuk menentukan nilai awal (proses inisialisasi) pada metode *exponential smoothing Holt-Winters* berpengaruh terhadap prediksi berikutnya juga bergantung pada panjang deret waktu dan nilai dari ketiga parameternya. Menurut Montgomery sebagaimana dikutip oleh

Yulitasari (2011) menyebutkan bahwa rumus metode *exponential smoothing Holt-Winters* dapat digunakan dengan mengambil secara sembarang beberapa nilai awal yang telah ditetapkan yakni.

(1) Untuk model Aditif

- (a) Nilai inisialisasi S dapat disamakan dengan nilai aktualnya (X_L) atau berupa rata-rata dari beberapa nilai pada musim yang sama.

$$S_L = X_L \text{ atau } S_L = \frac{1}{L}(X_1 + X_2 + \dots + X_L) \quad (2.17)$$

Persamaan di atas merupakan rata-rata bergerak berorder L yang akan mengeliminasi unsur musiman pada data.

- (b) Inisialisasi faktor *trend* digunakan:

$$b_L = \frac{1}{L} \left\{ \frac{(X_{L+1} - X_1)}{L} + \frac{(X_{L+2} - X_2)}{L} + \dots + \frac{(X_{L+L} - X_L)}{L} \right\} \quad (2.18)$$

dimana $L = 1, 2, \dots, L$ dan L adalah panjang musiman.

- (c) Inisialisasi untuk faktor musiman, pada satu siklus musiman pertama dilakukan dengan mengurangi setiap data nilai aktual (X_L) dengan rata-rata pada siklus itu.

$$I_L = X_L - S_L \quad (2.19)$$

(2) Untuk model Multiplikatif

Nilai awal yang digunakan sama dengan model aditif kecuali untuk penghalusan musiman dimana pada siklus musiman pertama dilakukan dengan membagi setiap data nilai aktual (X_L) dengan rata-rata pada siklus itu. Inisialisasi untuk faktor musiman model multiplikatif menggunakan

$$I_L = \frac{X_1}{S_L}, I_2 = \frac{X_2}{S_L}, \dots, I_L = \frac{X_L}{S_L} \quad (2.20)$$

2.4.4 Nilai Kesalahan *Exponential Smoothing Holt-Winters*

Tidak mungkin suatu ramalan benar-benar akurat ramalan akan selalu berbeda dengan permintaan aktual. Perbedaan antara nilai ramalan dengan data aktual disebut kesalahan ramalan. Meskipun suatu jumlah kesalahan ramalan tidak dapat dielakkan, namun tujuan ramalan adalah agar kesalahan sekecil mungkin. Kesalahan ramalan terkecil sebagai kriteria dalam pemilihan metode ramalan yang akan digunakan (Andelkovic & Lepojevic, 2011).

Berikut adalah jenis-jenis cara menghitung nilai kesalahan.

(1) *Mean Squared Error* (MSE)

Mengevaluasi hasil peramalan yaitu dengan metode *Mean Squared Error* (MSE) digunakan untuk mengukur ketepatan nilai dugaan model yang dinyatakan dalam rata-rata kuadrat dari kesalahan. Dengan menggunakan MSE, *error* yang ada menunjukkan seberapa besar perbedaan hasil estimasi dengan hasil yang akan diestimasi. Dalam fase peramalan, menggunakan MSE sebagai suatu ukuran ketepatan juga dapat menimbulkan masalah.

Ukuran ini tidak memudahkan perbandingan antar *time series* yang berbeda dan untuk selang waktu yang berlainan, karena MSE merupakan ukuran absolut.

Adapun diberikan persamaan untuk menghitung MSE yaitu:

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n} \quad (2.21)$$

dengan :

e_t : kesalahan periode $t = X_t - F_t$

n : jumlah data

(2) *Mean Absolute Percentage Error* (MAPE)

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur ketepatan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase absolute kesalahan. Metode ini melakukan perhitungan perbedaan antara data asli dan hasil peramalan. Perbedaan tersebut diabsolutkan, kemudian dihitung ke dalam bentuk persentase terhadap data asli. Hasil persentase tersebut kemudian didapatkan nilai mean-nya. Suatu model mempunyai kinerja bagus jika nilai MAPE berada maksimal 20%. Adapun diberikan persamaan untuk menghitung MAPE yaitu:

$$MAPE = \frac{\sum_{t=1}^n |PE_t|}{n} \times 100\% \quad (2.22)$$

dimana:

PE_t : kesalahan persentase = $\frac{X_t - F_t}{X_t}$

X_t : data aktual periode t

n : jumlah data

2.5 Analisis Metode ARIMA

2.5.1 Stasioner dan Nonstasioner

Suatu data runtun waktu dikatakan stasioner (dalam *mean* dan variansi) jika rata-rata maupun variansi tetap pada keadaan waktu yang kondusif atau suatu keadaan tidak ada unsur *trend* dalam data dan bila suatu diagram *time series* berfluktuasi secara lurus. *Time series* dapat membantu secara visual yaitu dengan membuat plot terhadap data runtun waktu. Jika hasil plot tidak menunjukkan gejala *trend* maka dapat diduga bahwa data stasioner.

Menurut Makridakis *et al.*, (1999: 351) stasioner berarti bahwa tidak terdapat perubahan yang drastis pada data. Fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan varians dari fluktuasi tersebut. Bentuk visual plot data *time series* sering kali cukup meyakinkan para *forecaster* bahwa data tersebut stasioner atau nonstasioner.

Suatu data dapat dikatakan stasioner apabila pola data tersebut berada pada kesetimbangan di sekitar nilai rata-rata yang konstan dan variansi di sekitar rata-rata tersebut konstan selama waktu tertentu, data yang bersifat flat, tidak mengandung komponen *trend*, dengan keragaman konstan, serta tidak terdapat fluktuasi periodik (Makridakis *et al.*, 1999: 61). Menurut Djoni Hatidja (2010) bahwa jika data tidak stasioner maka metode yang digunakan untuk membuat data stasioner dilakukan adalah dengan *differencing* untuk data yang tidak stasioner dalam rata-rata dan proses transformasi untuk data yang tidak stasioner dalam varian. Mengukur kestasioneran suatu data dalam runtun waktu dapat menggunakan suatu uji.

Uji akar unit (*Unit Root Test*) digunakan untuk menguji kestasioneran data yang dikembangkan oleh Dickey-Fuller. Uji ini dilakukan untuk menguji adanya anggapan bahwa sebuah data *time series* tidak stasioner (Hendikawati, 2015: 126).

Stasioneritas juga dapat diperiksa dengan mengamati apakah data runtun waktu mengandung akar unit (*unit root*), yakni apakah terdapat komponen *trend* yang berupa *random walk* dalam data. Terdapat berbagai metode untuk melakukan uji akar unit, diantaranya *Dickey-Fuller*, *Augmented Dickey-Fuller*. Komponen uji yang sering digunakan adalah akar unit *Augmented Dickey Fuller*, yakni dengan

melihat apakah terdapat *unit root* di dalam model (disebut data *integrated*) atau tidak (Rosadi, 2012: 38, 41).

Setiap pengamatan dinyatakan sebagai variabel random Z_t yang diperoleh berdasarkan indeks waktu tertentu t sebagai urutan waktu pengamatan dengan $t = 1, 2, 3, \dots, n$ sehingga suatu *time series* yang dinyatakan sebagai himpunan variabel random adalah $\{Z_1, Z_2, Z_3, \dots, Z_n\}$ (Andalita & Irhamah: 2015). Dalam literatur ekonometrika, model AR (p) sering digunakan didefinisikan *series* dengan Z_t untuk memeriksa keberadaan akar unit diproses AR(p).

Pengujian hipotesis dilakukan dengan:

$$H_0: \beta = 0 \text{ (proses tidak stasioner)}$$

$$H_1: \beta \neq 0 \text{ (proses stasioner)}$$

Uji statistik:

$$t_\beta = \frac{\hat{\beta} - \beta_0}{se(\hat{\beta})} \quad (2.23)$$

Menggunakan regresi

$$Z_t = c_t + \beta Z_{t-1} + c_t \sum_{i=1}^p \Phi_i \Delta Z_{t-i+1} + a_t \quad (2.24)$$

Dimana c_t determinasi fungsi untuk indeks waktu t (biasanya menjadi nol/konstan) dan $\Delta Z_t = Z_t - Z_{t-1}$ pembeda dari Z_t .

Sedangkan rasio- t dari $\hat{\beta} - 1$.

$$ADF = \frac{\hat{\beta} - 1}{std(\hat{\beta})} \quad (2.25)$$

Dimana $\hat{\beta}$ didefinisikan estimasi *Least Square* dari β yang merupakan tes akar unit *Augmented Dickey-Fuller*. Karena *differencing* pertama pada persamaan

(2.24) ekuivalen dengan model AR(p) dengan determinasi fungsi c_t . Persamaan

(2.24) dapat ditulis menjadi

$$\Delta Z_t = c_t + \beta_c Z_{t-1} + c_t \sum_{i=1}^p \Phi_i \Delta Z_{t-i} + a_t \quad (2.26)$$

dimana $\beta_c = \beta - 1$.

Ini ekuivalen dengan $H_0: \beta_c = 0$ versus $H_1: \beta_c < 0$.

Uji statistik:

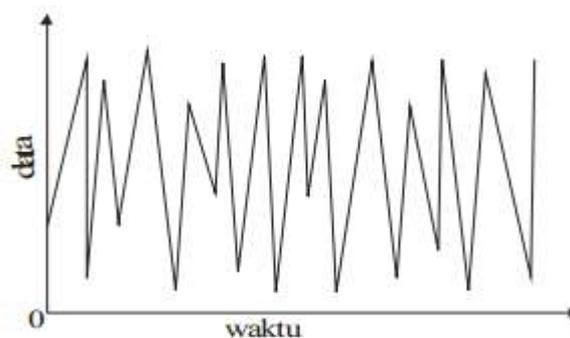
$$t_\beta = \frac{\hat{\beta} - \beta_0}{se(\hat{\beta})} \quad (2.27)$$

(Gujarati, 2000).

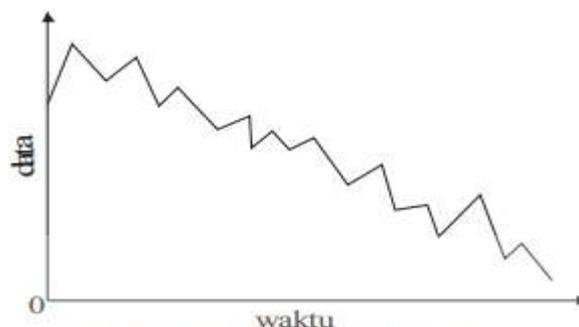
2.5.1.1 Stasioner dalam Mean

Data *time series* dikatakan stasioner dalam rata-rata jika rata-ratanya tetap. Apabila suatu deret waktu yang tidak stasioner dalam *mean* harus diubah menjadi data stasioner dengan melakukan *differencing* atau pembedaan. Proses *differencing* dapat dilakukan untuk beberapa periode sampai data menjadi stasioner, yaitu dengan cara mengurangkan suatu data hari ini dengan sebelumnya.

Gambar 2.8 merupakan contoh plot data *time series* yang stasioner dalam rata-rata dan varians. Gambar 2.9 menunjukkan plot data *time series* yang nonstasioner dalam rata-rata.



Gambar 2.8 Contoh plot data stasioner dalam rata-rata dan varians

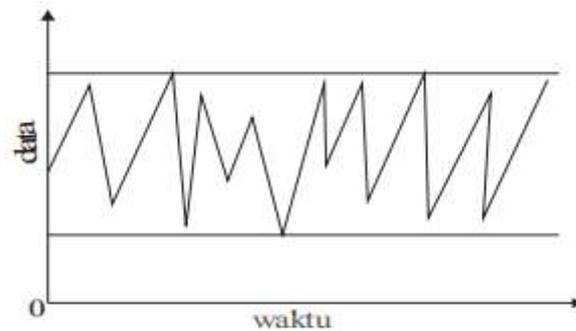


Gambar 2.9 Contoh plot data nonstasioner dalam rata-rata

Untuk menstasionerkan data nonstasioner dalam rata-rata dapat dilakukan proses *differencing* (pembedaan). Operator shift mundur (*backward shift*) sangat tepat untuk menggambarkan proses *differencing* (Makridakis *et al.*, 1999: 383). Menurut azriati, dkk menyebutkan bahwa untuk memeriksa kestasioneran dapat digunakan diagram deret waktu (*time series plot*) dapat juga menggunakan uji *unit root* yang bertujuan untuk mengetahui apakah data tersebut mengandung *unit root* atau tidak. Uji *unit root* yang digunakan adalah *Augmented Dickey Fuller* (ADF-*test*).

2.5.1.2 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 (horizontal sepanjang sumbu waktu), dan tidak berubah-ubah, atau tidak ada perubahan variansi dalam besarnya fluktuasi. Secara visual untuk melihat hal tersebut dapat dilihat dengan menggunakan plot *time series* yang berfluktuasi dari waktu ke waktu. Data *time series* dikatakan stasioner dalam varians jika fluktuasi datanya tetap atau konstan seperti pada Gambar 2.10.



Gambar 2.10 Contoh plot data stasioner dalam varians

Ketidakstasioneran dalam hal varian dapat dihilangkan dengan melakukan transformasi untuk menstabilkan variansi. Menstasionerkan data nonstasioner dalam varians dapat menggunakan transformasi kuasa (*the power transformation*) dengan λ disebut parameter transformasi (Makridakis *et al.*, 1999).

Bila data tidak stasioner dalam variansi, maka dapat dihilangkan dengan melakukan transformasi. Misalkan $T(Z_t)$ adalah fungsi transformasi dari Z_t dan untuk menstabilkan variansi, dapat menggunakan transformasi kuasa:

$$T(Z_t) = \frac{z_t^\lambda - 1}{\lambda} \quad (2.28)$$

(Wei, 2006: 85).

Beberapa nilai λ yang umum digunakan seperti Tabel 2.1 (Wei, 2006: 85).

Tabel 2.1 Nilai λ untuk Membentuk Transformasi

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

Dalam penerapan, biasanya jenis transformasi yang digunakan untuk mengatasi data tidak stasioner dalam variansi yaitu transformasi logaritma natural ditulis

ln Z_t . Jika data telah stasioner setelah dilakukan transformasi, maka tahap selanjutnya dapat dilakukan.

2.5.2 Operator *Backward Shift* (Kemunduran)

Model ARIMA sangat berhubungan dengan variabel dependen yaitu unsur rentang atau *lag* itu sendiri dan kesalahan rentang atau *lag*. Operator *backshift* sesungguhnya tidak melibatkan konsep statistik yang baru, notasi ini hanya suatu cara untuk memudahkan menuliskan model ARIMA. Notasi yang sangat bermanfaat dalam metode deret berkala ARIMA adalah operator shift mundur (*backward shift*) dinotasikan B , yang penggunaannya adalah sebagai berikut.

$$BZ_t = Z_{t-1} \quad (2.29)$$

(Hendikawati, 2015: 77)

dengan: Z_t = nilai variabel Z pada waktu t
 Z_{t-1} = nilai variabel Z pada waktu $t-1$
 B = *backward shift*

Notasi B yang dipasang pada Z_t , mempunyai pengaruh menggeser data 1 periode ke belakang. Dua penerapan B untuk shift Z akan menggeser data tersebut 2 periode ke belakang.

$$B(BZ_t) = B^2Z_t = BZ_{t-2} \quad (2.30)$$

Secara umum, mengalikan Z_t dengan B^k akan menghasilkan definisi $B^kZ_t = Z_{t-k}$ (Hendikawati, 2015: 77).

Operator *backshift* mundur ini juga dapat digunakan dalam mempermudah proses diferensiasi. Diferensiasi orde pertama dapat ditulis sebagai berikut.

$$Z'_t = Z_t - Z_{t-1} = Z_t - BZ_t = (1 - B)Z_t \quad (2.31)$$

dengan $Z'_t =$ nilai variabel Z pada waktu t setelah *differencing* dan mengganti t dengan $t-1$ diperoleh

$$\begin{aligned} Z'_{t-1} &= Z_{t-1} - Z_{t-2} \\ &= BZ_t - B^2Z_t \end{aligned} \quad (2.32)$$

Sehingga diferensiasi orde kedua dapat dituliskan sebagai berikut.

$$\begin{aligned} Z'' &= (Z'_t - Z'_{t-1}) \\ &= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\ &= Z_t - 2BZ_{t-1} + B^2Z_t \\ &= (1 - 2B + B^2)Z_t \\ &= (1 - B)^2Z_t \end{aligned} \quad (2.33)$$

Differencing orde kedua pada persamaan di atas dinotasikan oleh $(1 - B)^2$.

Secara umum turunan tingkat- d dapat dituliskan sebagai berikut.

$$Z^d = (1 - B)^d Z_t, \quad d \geq 1 \quad (2.34)$$

2.5.3 ACF (*Autocorrelation Function*)

Beberapa konsep yang berkaitan dengan analisis *time series* adalah *Autocorrelation Function (ACF)* atau fungsi autokorelasi dan *Partial Autocorrelation Function (PACF)* atau fungsi autokorelasi parsial. Autokorelasi merupakan korelasi atau hubungan antar data pengamatan suatu data *time series*.

Dalam model *time series*, alat utama untuk mengidentifikasi data yang akan diramalkan dengan menggunakan ACF/*Autocorrelation Function*/ Fungsi Autokorelasi. Menurut Wei (2006: 10) dari proses stasioner suatu data *time series* $\{Z_t\}$, dipunyai *mean* $E(Z_t) = \mu$ dan *variansi* $Var(Z_t) = E(Z_t - \mu_t)^2 = \sigma^2$ yang

konstan dan kovariansi $Cov(Z_t, Z_{t+k})$ yang fungsinya hanya pada perbedaan waktu $|t - (t + k)|$.

Maka dari itu hal tersebut dapat ditulis sebagai kovariansi antara Z_t dan Z_{t+k} sebagai berikut.

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.35)$$

$$\gamma_0 = \sqrt{Var Z_t} \sqrt{Var(Z_{t+k})} = \sqrt{E(Z_t - \mu)^2} \sqrt{E(Z_{t+k} - \mu)^2} \quad (2.36)$$

Korelasi antara Z_t dan Z_{t+k} yaitu

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var Z_t} \sqrt{Var(Z_{t+k})}} = \frac{E(Z_t - \mu)(Z_{t+k} - \mu)}{\sqrt{E(Z_t - \mu)^2} \sqrt{E(Z_{t+k} - \mu)^2}} = \frac{\gamma_k}{\gamma_0} \quad (2.37)$$

(Wei, 2006: 10)

dengan,

μ = rata-rata

γ_k = autokovariansi pada lag- k

ρ_k = autokorelasi pada lag- k

t = waktu pengamatan, $t = 1, 2, 3, \dots$

Dimana notasi $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$. Sebagai fungsi dari k, γ_k disebut dengan fungsi autokovariansi dan ρ_k disebut ACF/Autocorrelation Function/fungsi autokorelasi, dalam analisis *time series* γ_k dan menggambarkan kovarian dan korelasi antara Z_t dan Z_{t+k} dari proses yang sama, hanya dipisahkan oleh lag ke- k .

Menurut Wei (2006:10) fungsi autokovariansi γ_k dan fungsi autokorelasi ρ_k memiliki sifat-sifat sebagai berikut:

$$(1) \gamma_0 = Var(Z_t); \rho_0 = 1. \quad (2.38)$$

$$(2) |\gamma_k| \leq \gamma_0; |\rho_k| \leq 1. \quad (2.39)$$

$$(3) \gamma_k = \gamma_{-k} \text{ dan } \rho_k = \rho_{-k} \quad (2.40)$$

untuk semua k , γ_k dan ρ_k adalah fungsi yang sama dan simetrik dalam *time origin* $k = 0$. Sifat tersebut diperoleh dari perbedaan waktu antara Z_t dan Z_{t+k} . Oleh sebab itu, fungsi autokorelasi sering hanya diplotkan untuk *lag* non negatif. Plot tersebut terkadang disebut korrelogram.

Menurut Makridakis *et al.*, (1999: 338), koefisien autokorelasi untuk *lag-k* dari runtun waktu dinyatakan sebagai berikut:

$$r_k = \rho_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z}_t)(Z_{t+k} - \bar{Z}_t)}{\sum_{t=1}^n (Z_t - \bar{Z}_t)^2} \quad (2.41)$$

dengan r_k = koefisien autokorelasi

k = selisih waktu

n = jumlah observasi

Z_t = nilai variabel Z pada waktu t

Z_{t+k} = nilai variabel Z pada waktu $t+k$

\bar{Z}_t = nilai rata-rata variabel Z_t

Menurut Mulyana (2004: 8), karena r_k merupakan fungsi atas k , maka hubungan koefisien autokorelasi dengan *lag*nya disebut dengan fungsi autokorelasi dan dinotasikan dengan ρ_k . Untuk mengetahui apakah koefisien autokorelasi signifikan atau tidak, perlu dilakukan uji.

Pengujian dapat dilakukan hipotesis:

$$H_0: \rho_k = 0 \text{ (koefisien autokorelasi tidak signifikan)}$$

$$H_1: \rho_k \neq 0 \text{ (koefisien autokorelasi signifikan)}$$

Statistik uji yang digunakan adalah

$$t_{hit} = \frac{r_k}{SE_{r_k}} \quad (2.42)$$

dengan
$$SE_{r_k} = \frac{1}{\sqrt{n}} \quad (2.43)$$

Kriteria keputusan H_0 ditolak jika $t_{hit} > t_{\frac{\alpha}{2}, n-1}$. Selain menggunakan uji tersebut, untuk mengetahui apakah koefisien autokorelasi yang diperoleh signifikan atau tidak dapat dilihat pada output, yaitu grafik *ACF* residual.

Suatu koefisien autokorelasi disimpulkan tidak berbeda secara signifikan dari 0 apabila nilainya berada diantara:

$$\left(-Z \frac{\alpha}{2}\right) SE_{r_k} \leq r_k \leq \left(Z \frac{\alpha}{2}\right) SE_{r_k} \quad (2.44)$$

(Habinuddin & Lusiani, 2011)

dengan: n = jumlah data,

r_k = koefisien korelasi dengan *time lag* k ,

$Z \frac{\alpha}{2}$ = nilai distribusi normal,

SE_{r_k} = kesalahan standar (*standard error*) dari r_k .

Jika pada grafik *ACF* tidak ada *lag* (bar) yang melebihi garis batas signifikansi (garis putus-putus), maka koefisien autokorelasi yang diperoleh signifikan atau tidak terjadi korelasi antar *lag*.

2.5.4 PACF (*Partial Autocorrelation Function*)

Menurut Makridakis *et al.*, (1999: 345), autokorelasi parsial digunakan dalam mengukur tingkat (*association*) antara Z_t dan Z_{t+k} apabila adanya pengaruh *time lag* 1,2,3, ..., dan seterusnya sampai $k - 1$ dianggap terpisah sedangkan Wei (2006: 11), fungsi autokorelasi parsial dapat dinotasikan dengan

$$\text{Corr}((Z_t, Z_{t+k} | Z_{t+1}, Z_{t+2}, \dots, Z_{t+k+1})) \quad (2.45)$$

Ini ditunjuk sebagai fungsi autokorelasi parsial dalam analisis runtun waktu. Autokorelasi parsial merupakan korelasi antara Z_t dan Z_{t+k} dengan mengabaikan ketidakbebasan $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$.

Menurut Wei (2006: 12), autokorelasi parsial Z_t dan Z_{t+k} dapat diturunkan dari model regresi linear, dengan variabel *dependent* Z_{t+k} dan variabel $Z_{t+k-1}, Z_{t+k-2}, \dots,$ dan Z_t , yaitu

$$Z_{t+k} = \phi_{k1}Z_{t+k-1} + \phi_{k2}Z_{t+k-2} + \dots + \phi_{kk}Z_t + a_{t+k} \quad (2.46)$$

(Wei, 2006: 12)

dengan ϕ_{ki} merupakan parameter regresi ke- i untuk $i = 1, 2, \dots, k$ dan a_{t+k} merupakan residu dengan rata-rata nol dan tidak berkorelasi dengan Z_{t+k-j} untuk $j = 1, 2, \dots, k$. Dengan mengalikan Z_{t+k-j} pada kedua ruas persamaan dan menghitung nilai harapannya (*expected value*), diperoleh

$$E(Z_{t+k-j}Z_{t+k}) = \phi_{k1}E(Z_{t+k-j}Z_{t+k-1}) + \phi_{k2}E(Z_{t+k-j}Z_{t+k-2}) + \dots + \phi_{kk}E(Z_{t+k-j}e_{t+k}) \quad (2.47)$$

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \dots + \phi_{kk}\gamma_{j-k} \quad (2.48)$$

dan

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad (2.49)$$

Untuk $j = 1, 2, \dots, k$ dan $k \geq 1$ diperoleh sistem persamaan berikut

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0 \end{aligned} \quad (2.50)$$

dengan menggunakan aturan Cramer, berturut-turut unuk $k = 1, 2, \dots,$ diperoleh

$$\begin{aligned}
 \phi_{11} &= \rho_1 \\
 \phi_{22} &= \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} \\
 \phi_{33} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_3 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}} \\
 &\vdots \\
 &\vdots \\
 \phi_{kk} &= \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}} \quad (2.51)
 \end{aligned}$$

(Wei, 2006:15)

Karena ϕ_{kk} merupakan fungsi atas k , maka ϕ_{kk} disebut fungsi autokorelasi parsial. Hipotesis untuk menguji koefisien autokorelasi parsial sebagai berikut:

$$H_0: \phi_{kk} = 0$$

$$H_1: \phi_{kk} \neq 0$$

Statistik uji yang digunakan:

$$t = \frac{\phi_{kk}}{SE(\phi_{kk})} \quad (2.52)$$

dengan $SE(\phi_{kk}) = \frac{1}{\sqrt{n}}$ (2.53)

kriteria keputusan tolak H_0 jika $|t_{hitung}| > t_{\frac{\alpha}{2}, df}$,

dengan derajat bebas $df = n - 1$, n adalah banyaknya data (Wei, 2006: 50).

Menurut Andreoni dan Postorino (2006), tahap identifikasi dalam model ARIMA pertama kali ditentukan atas dasar perkiraan ACF dan PACF. Karakteristik ACF dan PACF yang memungkinkan untuk identifikasi data antara lain:

- (1) Korelasi yang menurun secara lambat (eksponensial), terdapat nonstasioneritas dan data harus dilakukan *differencing* sampai stasioneritas diperoleh, kemudian model ARIMA dapat diidentifikasi,
- (2) Jika ACF $\rho_k = 0$ untuk $k > q$ dan PACF menurun, maka proses yang mendasari adalah MA(q),
- (3) PACF $\phi_{kk} = 0$ untuk $k > p$ dan ACF menurun, maka proses yang mendasari adalah AR(p),
- (4) Jika tidak ada indikasi untuk MA atau AR maka model ARMA dapat dilakukan.

2.5.5 Proses *White Noise*

Proses *white noise* merupakan proses yang paling penting karena dianggap sebagai faktor pembangun bagi proses runtun waktu lainnya (*building block*). Dapat ditunjukkan bahwa *white noise* bersifat stasioner, sering ditulis $X_t \sim WN(0, \sigma^2)$.

Suatu model bersifat *white noise* artinya residual dari model tersebut telah memenuhi asumsi identik (variasi residual homogen) serta independen (antar residual tidak berkorelasi) (Lestari & Wahyuningsih: 2012).

Suatu proses $\{a_t\}$ disebut proses *white noise* jika terdapat sebuah barisan variabel random yang tidak berkorelasi dengan rata-rata konstan $E(a_t) = \mu_0 = 0$,

variansi konstan $Var(a_t) = \sigma_a^2$, dan $\gamma_k = Cov(a_t, a_{t+k}) = 0$ untuk $k \neq 0$ (Wei, 2006: 15).

Sesuai dengan definisi tersebut, proses *white noise* adalah stasioner dengan fungsi autokovarians

$$\gamma_k = \begin{cases} \sigma_a^2, & k = 0, \\ 0, & k \neq 0, \end{cases} \quad (2.54)$$

Fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & k = 0, \\ 0, & k \neq 0, \end{cases} \quad (2.55)$$

dan fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & k = 0, \\ 0, & k \neq 0, \end{cases} \quad (2.56)$$

Dasar dari proses *white noise* adalah nilai fungsi autokorelasi dan fungsi autokorelasi parsial dari residu mendekati nol. Untuk mengetahui apakah residu memenuhi proses *white noise* atau tidak, perlu dilakukan uji.

Langkah-langkah pengujian *white noise* dengan hipotesis (Abdullah, Lazim: 2012) dan Hendikawati (2015: 139).

$$H_0: \rho_1 = \dots = \rho_k = 0 \text{ (residu memenuhi proses } white \text{ noise)}$$

$$H_1: \rho_1 \neq \dots \neq \rho_k \neq 0, \text{ untuk } k = 1, 2, \dots, k \text{ (residu tidak memenuhi proses } white \text{ noise)}$$

Statistik uji yaitu uji Ljung Box-Pierce atau Uji Q Box dann Pierce.

Menurut Wei (2006) sebagaimana dikutip oleh Alexander (2016) dan Hendikawati (2015:139) bahwa rumus uji Ljung Box-Pierce:

$$Q(m) = n(n + 2) \sum_{k=1}^m \frac{r_k^2}{n-k} \quad (2.57)$$

Menyebar secara Chi-Kuadrat (χ^2) dengan derajat bebas (db)=(k-p-q-P-Q)

dimana:

Q = hasil perhitungan Ljung-Box / Chi-Square

m = jumlah lag autokorelasi residu (lag waktu musiman)

$n = N - (d + SD)$

N = jumlah keseluruhan data

d = ordo pembedaan bukan faktor musiman

D = ordo pembedaan faktor musiman

S = jumlah periode per musim

r_k = autokorelasi untuk *time lag* ke k , dimana $k = 1, 2, 3, 4, \dots, k$

Sedangkan menurut Sugiarto & Harijono (2000:190) dan Makridakis *et al.*, (1999: 340) untuk melakukan Uji Box-Pierce Q dihitung dengan rumus

$$Q = n \sum_{k=1}^m r_k^2 \quad (2.58)$$

dimana,

n : banyaknya data asli

m : lag (selisih waktu) maksimum yang akan dilakukan

r_k : nilai koefisien autokorelasi *time lag* k

Kriteria keputusan:

H_0 diterima jika $Q \leq \chi_{\alpha, db}^2$, berarti nilai *error* bersifat random (model dapat diterima)

H_0 ditolak jika $Q > \chi_{\alpha, db}^2$, berarti nilai *error* tidak bersifat random (model tidak dapat diterima)

Jika nilai Q lebih kecil dari nilai pada tabel Chi-Square dengan derajat kebebasan $m-p-q$ dimana p dan q masing-masing menunjukkan orde AR dan MA, model dianggap memadai. Sebaliknya apabila nilai Q lebih besar dari nilai pada tabel Chi-Square, model belum dianggap memadai (Sugiarto & Harijono, 2000: 190).

Menurut Anderson (1942), Bartlett (1946), Quenouille (1949) dan yang lainnya, koefisien autokorelasi dari data random mempunyai distribusi sampling yang mendekati kurva normal dengan nilai tengah nol dan kesalahan standar $1/\sqrt{n}$. Hal ini dapat digunakan untuk menetapkan apakah nilai r_k berasal dari populasi yang mempunyai nilai autokorelasi nol pada *time lag* k (Makridakis *et al*, 1999: 341)

Jika dengan p dan q adalah orde dari ARMA (p,q) dan k adalah *time-lag*. Residu memenuhi proses *white noise* jika residu bersifat random dan berdistribusi normal. Residu bersifat random jika pada grafik ACF residu tidak ada *lag* (bar) yang melebihi garis batas signifikansi (garis putus-putus).

2.6 Metode ARIMA

Berdasarkan Bowerman dan Richard (1993) dalam Hermawan (2011) menyebutkan bahwa metode *time series* yang paling populer dan banyak digunakan dalam peramalan data *time series* adalah model *Autoregressive Integrated Moving Average* atau yang dikenal dengan model ARIMA. Dalam aplikasinya model ini mengharuskan dipenuhinya asumsi stasioneritas pada nilai rata-rata (*mean*) dan varians dari *time series*.

Model-model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins (1976), dan nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis deret berkala, peramalan, dan pengendalian. Model *Autoregressive* (AR) pertama kali dikenalkan oleh Yule (1926) dan kemudian dikembangkan oleh Walker (1931), sedangkan model *Moving Average* (MA) pertama kali digunakan oleh Slutsky (1937). Akan tetapi Wold-lah (1938) yang menghasilkan dasar-dasar teoritis dalam proses kombinasi ARMA. Wold membentuk model ARMA yang dikembangkan pada tiga arah yaitu identifikasi efisien dan prosedur penaksiran (untuk proses AR, MA, dan ARMA campuran), perluasan dari hasil tersebut untuk mencakup deret berkala musiman (*seasonal time series*) dan pengembangan sederhana yang mencakup proses-proses nonstasioner (ARIMA) (Makridakis *et al*, 1999: 381).

Model ARIMA adalah suatu model runtun waktu nonstasioner homogen yang menggunakan prosedur yang praktis dan sederhana bagi penerapan model atau skema *Autoregressive* dan *Moving Average* dalam penyusunan ramalan.

Model *Autoregressive* adalah suatu model yang menggambarkan bahwa variabel dependen dipengaruhi oleh variabel dependen itu sendiri pada periode-periode atau waktu-waktu sebelumnya.

Model *Moving Average* adalah rata-rata bergerak yang digunakan untuk data observasi baru yang tersedia dan dipergunakan secara random. ARIMA memiliki beberapa keuntungan untuk digunakan sebagai model peramalan, antara lain.

- (1) Merupakan model tanpa teori karena variabel yang digunakan adalah nilai-nilai lampau dan kesalahan yang mengikutinya;
- (2) Memiliki tingkat akurasi peramalan yang cukup tinggi karena setelah mengalami pengukuran kesalahan peramalan *Mean Absolute Error* (MSE), nilainya mendekati nol;
- (3) Cocok digunakan untuk meramalkan sejumlah variabel dengan cepat, sederhana, akurat dan murah karena hanya membutuhkan data variabel yang akan diramal (Makridakis *et al*, 1999).

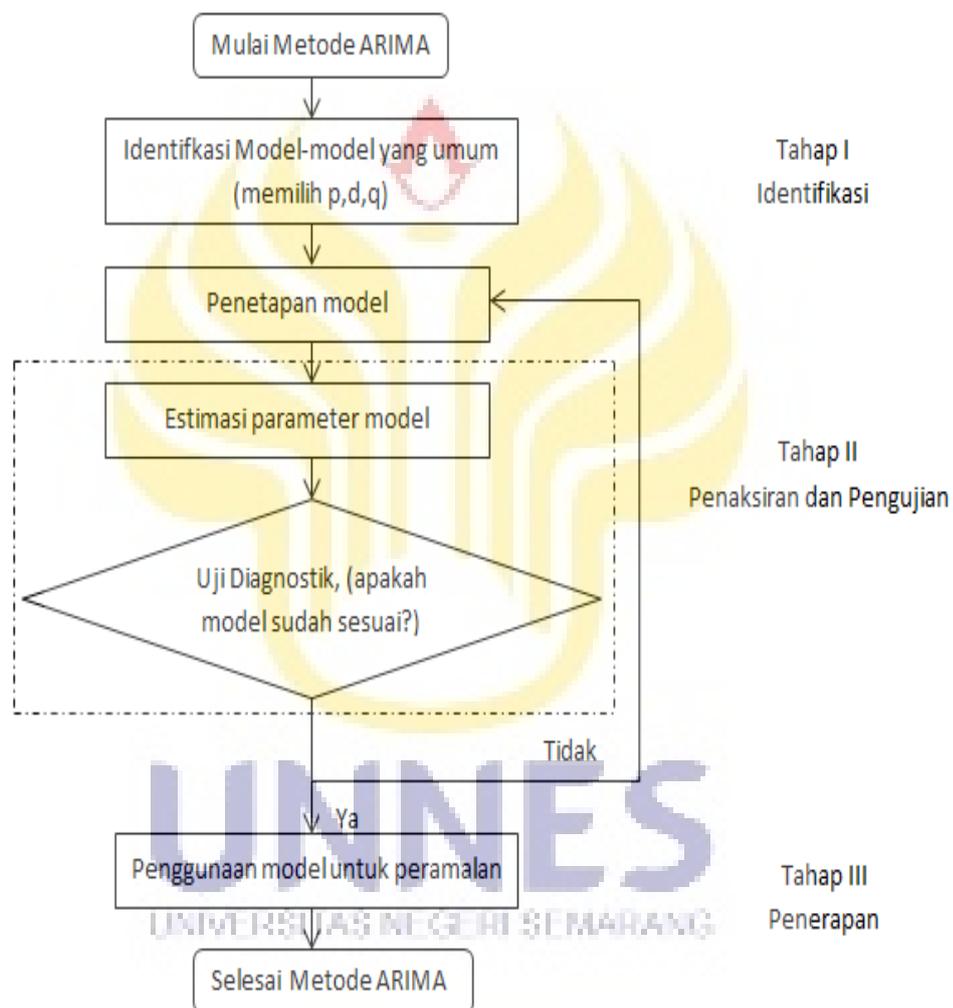
Box dan Jenkins (1976) secara efektif telah berhasil mencapai kesepakatan mengenai informasi relevan yang diperlukan untuk memahami dan memakai model-model ARIMA untuk deret berkala univariat.

Metode ARIMA hanya menggunakan satu variabel sebagai dasar untuk melakukan proyeksi sehingga dalam model ini tidak ada istilah variabel independen (bebas) yang digunakan untuk memprediksi nilai variabel tergantung (Abdullah, dkk: 2012). Model ini sepenuhnya hanya menggunakan nilai-nilai sekarang dan nilai masa lampau sebagai dasar untuk menyusun proyeksi. Oleh karena itu metode ini akan sangat tepat digunakan untuk menyusun proyeksi jika:

- (1) Data runtut waktu yang diamati bersifat dependen atau berhubungan satu sama lain secara statistik.
- (2) Hanya sedikit diketahui informasi mengenai variabel independen (bebas) yang dapat digunakan untuk memproyeksikan nilai variabel dependen (tergantung).

- (3) Jika mempunyai data runtut waktu yang cukup besar sehingga membentuk runtut waktu yang cukup panjang.

Berikut tahapan dalam bentuk *flowchart* model ARIMA sebagaimana terlihat pada Gambar 2.11.



Gambar 2.11 *Flowchart* model ARIMA

Menurut (Box and Jenkins, 1976), sebagaimana dikutip oleh Widyasari (2015) secara umum metode ini dibagi dalam beberapa tahap, yakni.

- (1) Identifikasi data (membuat plot data apakah stasioner atau tidak, dan kemudian menganalisis plot data dengan ACF (*Auto Correlation Function*), PCAF (*Partial Auto Correlation Function*),
- (2) Penaksiran parameter model dengan cara coba-coba dikenal dengan istilah “*trial and error*”, dan perbaikan secara iteratif,
- (3) Uji diagnostik dengan cara:
 - (a) Mempelajari nilai sisa atau (galat residual), dan
 - (b) Mempelajari statistik sampling,
- (4) Pengujian apakah model yang didapat sudah stasioner atau belum. Jika belum stasioner, maka dilakukanlah tahap ke (5)
- (5) *Differencing* atau transformasi dari model yang tidak stasioner menjadi stasioner.
- (6) Penaksiran parameter model,
- (7) Diagnostik (uji) model sebelum akhirnya ditentukan model peramalan musiman yang relatif paling tepat.

(a) Identifikasi data

Identifikasi data merupakan metodologi dalam mengidentifikasi transformasi untuk menstabilkan variansi dan pembeda (*differencing*) dan menentukan orde p dan q yang sesuai model.

Langkah pertama plot data runtun waktu dan pilih transformasi yang sesuai dalam analisis runtun waktu. Melalui pengujian yang seksama terhadap plot dapat mengetahui apakah data mengandung trend, musiman, pencilan, variansi yang tidak konstan dan fenomena ketidakstasioneran

dan ketidaknormalan lainnya. Dalam analisis runtun waktu, transformasi untuk menstabilkan variansi dan *differencing* (pembeda). Karena *differencing* mungkin menghasilkan nilai negatif, maka sebaiknya transformasi untuk menstabilkan variansi dilakukan sebelum pembeda. Deret yang memiliki variansi tidak konstan biasanya memerlukan transformasi logaritma.

Langkah kedua yaitu menghitung dan menguji autokorelasi dan autokorelasi parsial sampel dari deret asli untuk mengetahui apakah diperlukan *differencing*.

Langkah ketiga yaitu menghitung dan menguji autokorekasi parsial sampel dari data yang telah ditransformasikan atau di *difference* untuk mengidentifikasi orde p dan q . Biasanya orde p dan q kurang dari atau sama dengan tiga (Indayani, 2009).

(b) Penaksiran atau Estimasi

Setelah melakukan identifikasi data, selanjutnya estimasi model parameter dari AR dan MA, musiman harus ditetapkan dengan cara yang baik. Jika menginginkan taksiran nilai yang terbaik untuk mencocokkan runtun waktu yang sedang dimodelkan.

Terdapat dua cara yang mendasar untuk mendapatkan parameter-parameter tersebut yaitu:

- (1) Dengan cara mencoba-coba yaitu menguji beberapa nilai yang berbeda dan memilih salah satu nilai tersebut yang meminimumkan jumlah kudrat nilai sisa/*sum of squared residuals* (SSR),

mempertimbangkan jumlah parameter dalam model/ *Akaike's Information Criterion* (AIC) dan *Schwartz Bayesian Criterion* (SBC).

(2) Perbaiki secara iteratif dengan memilih taksiran awal dan kemudian membiarkan program komputer yang memperhalus penaksiran tersebut secara iteratif.

(c) Pemeriksaan Diagnostik

Setelah berhasil mengestimasi parameter dari model ARIMA yang diterapkan, selanjutnya perlu dilakukan pemeriksaan diagnostik untuk membuktikan bahwa model tersebut cukup memadai dan menentukan model mana yang terbaik digunakan untuk peramalan. Salah satu cara yang paling mendasar untuk melakukan pemeriksaan diagnostik dengan cara mempelajari nilai sisa atau residual (Makridakis *et al.*, 1999: 411).

- Asumsi residual yang harus dipenuhi yaitu:

- 1) Non Autokorelasi artinya tidak ada korelasi antara residual. Non Autokorelasi terjadi jika tidak ada lag yang signifikan dari plot ACF dan PACF.
- 2) Heteroskedastisitas artinya variansi residual konstan. Terjadi jika tidak ada lag yang signifikan dari plot ACF dan PACF atau dengan melihat plot residual. Jika residual berfluktuasi disekitar 0, maka residual bersifat homoskedastisitas
- 3) Normalitas artinya residual mengikuti distribusi normal.

Suatu model dikatakan baik jika model tersebut dapat memenuhi ketiga asumsi tersebut.

- *Overfitting*

Langkah selanjutnya dalam metode ARIMA setelah pemeriksaan diagnostik adalah verifikasi, yakni memeriksa apakah model yang kita estimasi cukup cocok dengan data yang dipunyai. Apabila menjumpai yang cukup serius, harus merumuskan kembali model yang baru kemudian estimasi dan verifikasi.

Seperti salah satu prosedur pemeriksaan diagnostik yang telah dikemukakan oleh Box-Jenkins adalah *overfitting* yaitu menggunakan beberapa parameter lebih banyak daripada yang diperlukan atau memilih model AR orde kedua apabila model AR orde pertama telah ditetapkan (Makridakis *et al.*, 1999: 414). Hal ini dapat dilakukan jika estimasi dari parameter tambahan tidak signifikan dan berbeda dengan nol, estimasi dari parameter model awal (sebelum dilakukan penambahan parameter) tidak berubah secara signifikan setelah dilakukan penambahan parameter dan jika model dengan parameter tambahan menyebabkan *sum squared error* bertambah besar, maka model yang digunakan adalah model semula (awal).

- Kriteria pemilihan model

Menurut Machmudin dan Ulama (2012) beberapa kriteria yang digunakan untuk pemilihan model ARIMA yang terbaik setelah dilakukan identifikasi model dan pemeriksaan diagnostik diantaranya yaitu.

a) Kriteria Akaike's AIC

AIC (*Akaike's Information Criteria*) yang dikemukakan oleh Akaike (1973) dan didefinisikan sebagai berikut.

$$AIC(M) = -2 \ln[\text{maximum likelihood}] + 2M \quad (2.59)$$

M adalah parameter pada model ARIMA.

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

b) *Shwarz Bayesian Criterion* (SBC)

Shwarz Bayesian Criterion (SBC) dimana kriteri pemilihan model terbaik dipilih berdasarkan nilai terkecil. Semakin kecil nilai SBC, maka model yang diperoleh akan semakin baik. Berikut ini merupakan rumus kriteria SBC.

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \quad (2.60)$$

dimana:

n = banyaknya observasi

$\hat{\sigma}_a^2$ = estimasi maksimum likelihood dari $\hat{\sigma}_a^2$

M = jumlah parameter dalam model ARIMA

Menurut Hendikawati (2015) pemilihan model peramalan terbaik dengan beberapa kriteria di atas atau dengan meminimumkan nilai *Sum Squared of Residual* (SSR). Rumus SSR sebagaimana pada persamaan 2.61.

(a) *Sum Squared of Residual (SSR)*

Sum Squared of Residual adalah nilai jumlahan dari kuadrat residual/error dan didefinisikan sebagai berikut.

$$SSR = \sum_{i=1}^n e_i^2 \quad (2.61)$$

e = residual/error

(d) *Forecasting*

Langkah yang terakhir dalam proses runtun waktu adalah peramalan runtun waktu untuk masa yang akan datang berdasarkan tingkat gerakannya di masa lalu atau data sebelumnya. Misalnya didapat model data yang musiman dengan model ARIMA (0,1,1)(0,1,1)¹² yaitu

$$(1 - B)(1 - B^{12})Z_t = (1 - \theta_1 B)(1 - \Theta_1 B^{12})a_t \quad (2.62)$$

Namun agar dapat menggunakan suatu model yang ditetapkan untuk peramalan, perlu dilakukan pengembangan persamaan tersebut dan membuatnya lebih menyerupai persamaan regresi biasa. Untuk model di atas, bentuknya adalah

$$Z_t = Z_{t-1} + Z_{t-12} - Z_{t-13} + a_t - \theta_1 a_{t-1} - \Theta_1 a_{t-12} + \theta_1 \Theta_1 a_{t-13} \quad (2.63)$$

(Makridakis *et al.*, 1999: 414-415)

2.6.1 Model Autoregressive (AR)

Jika *series* stasioner adalah fungsi linier dari nilai-nilai yang berurutan atau nilai sekarang *series* merupakan rata-rata tertimbang nilai-nilai lampaunya bersama dengan kesalahan sekarang, maka persamaan itu dinamakan model *autoregressive*.

Model AR (*Autoregressive*) adalah suatu model yang menggambarkan bahwa variabel dependen dipengaruhi oleh variabel dependen itu sendiri pada periode-periode atau waktu-waktu sebelumnya (Sugiarto dan Harijono, 2000: 177). Bentuk umum suatu proses *Autoregressive* tingkat AR (p) adalah

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.64)$$

(Hendikawati, 2015: 16)

dengan,

Z_t : nilai variabel dependen pada waktu ke-t

ϕ_0 : intersep

Z_{t-p} : variabel independen yang dalam hal ini merupakan lag (beda waktu) dari variabel dependen pada satu periode sebelumnya

a_t : variabel residual pada waktu t

ϕ_1, ϕ_2, ϕ_p : koefisien/parameter dari model *Autoregressive*

p : order AR

Persamaan (2.61) dapat ditulis dengan menggunakan operator B (*backshift*):

$$Z_t = \phi_1 B X_t + \phi_2 B^2 X_t + \dots + \phi_p B^p X_t + a_t \quad (2.65)$$

dimana: $\phi B = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$, disebut operator AR (p) orde dari model AR diberi notasi p yang ditentukan oleh jumlah periode variabel dependen yang masuk dalam model.

2.6.2 Model *Moving Average* (MA)

Jika *series* yang stasioner merupakan fungsi linear dari kesalahan peramalan sekarang dan masa lalu yang berurutan, persamaan itu dinamakan model *moving average*.

Menurut Sugiarto dan Harijono (2000: 179), secara umum bentuk model MA mempunyai persamaan sebagai berikut

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.66)$$

dengan,

Z_t : variabel dependen pada waktu t

$\theta_1, \theta_2, \theta_3, \dots, \theta_q$: koefisien model MA yang menunjukkan bobot.

$a_{t-1}, a_{t-2}, \dots, a_{t-q}$: variabel residual sebelumnya

a_t : variabel residual pada waktu t

Persamaan di atas dapat ditulis menggunakan operator *backshift* (B), menjadi:

$$Z_t = \theta(B)a_t \quad (2.67)$$

dengan $\theta B = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)a_t$ merupakan operator MA (q).

(Hendikawati, 2015:17)

Perbedaan model AR dan model MA terletak pada jenis variabel independen. Bila variabel pada MA yang menjadi variabel independen adalah nilai residual pada periode sebelumnya sedangkan variabel pada model AR adalah nilai sebelumnya dari variabel independen.

2.6.3 Model Campuran

2.6.3.1 Model Autoregressive Moving Average (ARMA)

Model ini merupakan model campuran antara AR dan MA, bentuk umum dari model ARMA (p,q) adalah sebagai berikut.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (2.68)$$

Dari persamaan di atas dapat ditulis menggunakan operator B (*backshift*) menjadi

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad \text{atau} \quad \phi(B)Z_t = \theta(B)a_t \quad (2.69)$$

(Hendikawati, 2015:18)

dimana:

Z_t : variabel dependen pada waktu t

ϕ_1, ϕ_2, ϕ_3 : koefisien atau parameter model AR

$\theta_1, \theta_2, \theta_3$: koefisien atau parameter model MA

a_t : variabel residual pada waktu t

$a_{t-1}, a_{t-2}, a_{t-q}$: variabel pada saat $t, t-1, t-2$, dan a_t diasumsikan *white noise* dan normal.

2.6.3.2 Model Autoregressive Integrated Moving Average (ARIMA)

Jika data deret waktu tidak stasioner, model *Box-Jenkins* ini disebut model *Autoregressive Integrated Moving Average* (ARIMA). Kestasioneran deret data pada *level* merupakan syarat utama dari model AR, MA, dan ARMA, apabila deret data tidak stasioner pada *mean* maka proses transformasi data dapat dilakukan. Bentuk transformasi data yang dapat dilakukan adalah dengan melakukan proses diferensiasi. Transformasi data dapat dilakukan melalui transformasi logaritma natural (\ln) dan proses diferensiasi.

Menurut Ekata & Shivastav (2012) model AR, MA, atau ARMA dengan data yang stasioner melalui proses diferensiasi ini disebut sebagai model *autoregressive integrated moving average* atau disebut ARIMA (p, d, q). Istilah *integrated* pada model ARIMA (p, d, q) mengacu pada proses transformasi data dapat dilakukan untuk membuat data menjadi stasioner. Notasi p merupakan nilai

ordo dari proses *autoregressive*, notasi d merupakan tingkat dari proses diferensiasi yang harus dilakukan agar data menjadi stasioner, dan q merupakan nilai ordo dari proses *moving average*. Identifikasi model ARIMA yang sesuai untuk *time series* dimulai dengan proses mencari nilai p , d , q (misalnya, 0, 1, atau 2). Data yang dipakai sebagai input model ARIMA adalah data hasil transformasi yang sudah stasioner, bukan data asli.

Secara umum Model ARIMA (*Auto Regressive Integrated Moving Average*) p, d, q dirumuskan dengan notasi sebagai berikut.

$$\phi B(1 - B)^d Z_t = \theta(B) a_t \quad (2.70)$$

Persamaan di atas dapat ditulis dengan menggunakan operator B (*backshift*), menjadi:

$$1 - B^d 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p Z_t = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) a_t \quad (2.71)$$

merupakan operator AR yang stasioner

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p \quad (2.72)$$

merupakan operator MA yang invertibel

$$\theta_p(B) = 1 - \theta_1 B - \dots - \theta_p B^p \quad (2.73)$$

Secara umum model ARIMA (*Autoregressive Moving Integrated Average*) p, d, q dirumuskan dengan notasi sebagai berikut:

$$Z_t = (1 + \phi_1)Z_{t-1} + (\phi_2 - \phi_1)Z_{t-2} + \dots + (\phi_p - \phi_{p-1})Z_{t-p} - \phi_p Z_{t-p-1} + a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (2.74)$$

Untuk ARIMA (1,1,1) model runtun waktunya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} - \phi Z_{t-2} + a_t + \theta_1 a_{t-1} \quad (2.75)$$

dengan,

AR : p menunjukkan orde/derajat *Autoregressive*

I : d menunjukkan orde/derajat *Differencing* (pembedaan)

MA : q menunjukkan orde/derajat *Moving Average*

Penentuan nilai p dan q dapat dibantu dengan acuan pada Tabel 2.2 dengan mengamati pola fungsi *autocorrelation* dan *partial correlation* (*correlogram*) dari runtut waktu yang dipelajari.

Tabel 2.2 Pola Autokorelasi dan Autokorelasi Parsial (Sadeq, 2008) dan (Rosadi, 2012)

<i>Autocorrelation</i> (ACF)	<i>Partial Autocorrelation</i> (PACF)	ARIMA tentatif
Tidak ada yang melewati batas interval pada lag > 0	Tidak ada yang melewati batas interval pada lag > 0	<i>White noise</i> (random error)
Menuju nol setelah lag q ; Di atas batas interval maksimum sampai pada lag q dan di bawah batas pada lag $> q$	Menurun secara bertahap (eksponensial)/bergelombang	ARIMA (0,d,q)
Menurun secara bertahap (eksponensial)/bergelombang	Menuju nol setelah lag q ; Di atas batas interval maksimum sampai pada lag p dan di bawah batas pada lag $> p$	ARIMA (p,d,0)
Menurun secara bertahap/bergelombang (sampai lag q masih berbeda dari nol)	Menurun secara bertahap/bergelombang (sampai lag p masih berbeda dari nol)	ARIMA (p,d,q)

Menurut Arsyad (1995) sebagaimana dikutip oleh Sadeq (2008) bahwa pada umumnya, analisis harus mengidentifikasi autokorelasi yang secara eksponensial menjadi nol. Jika autokorelasi secara eksponensial melemah menjadi

nol berarti terjadi proses AR. Jika autokorelasi parsial melemah secara eksponensial berarti terjadi proses MA. Jika keduanya melemah berarti terjadi proses ARIMA.

2.6.4 Model ARIMA dengan Faktor Musiman (*Seasonal ARIMA*)

Box dan Jenkins telah mengembangkan metodologi untuk pemodelan *time series* univariat. Dengan menambahkan *differencing* pada lag satu dan lag musiman serta untuk komponen musiman dalam model ARIMA model Sarima dapat didefinisikan.

Menurut Tseng dan Tzeng sebagaimana dikutip oleh Gyimah-Oduro F.K *et.al* bahwa model *time series seasonal ARIMA* (Sarima) awalnya dibawakan oleh Box-Jenkins (Box & Jenkins, 1976) dan telah berhasil digunakan dalam peramalan ekonomi, pemasaran, masalah sosial, dan lain-lain. Model ini memiliki keuntungan peramalan yang akurat selama periode jangka pendek, juga memiliki keterbatasan bahwa setidaknya 50 dan sebaiknya 100 pengamatan atau lebih harus digunakan.

Musiman dapat diartikan sebagai suatu pola yang terbentuk secara berulang dalam waktu yang tetap. Dalam suatu data yang stasioner, dapat dicari dengan cara mengidentifikasi koefisien autokorelasi pada *time lag* yang berbeda dari nol. Autokorelasi yang secara signifikan berbeda dari nol menyatakan adanya suatu pola dalam data. Untuk mengenali faktor musiman dilihat pada autokorelasi yang tinggi.

Adanya faktor musiman dapat dengan mudah dilihat di dalam grafik autokorelasi atau dilihat sepiintas pada autokorelasi dari *time lag* yang berbeda,

apabila hanya ini pola yang ada. Namun, hal ini tidaklah terlalu mudah apabila dikombinasikan dengan pola lain seperti trend. Semakin kuat pengaruh trend akan semakin tidak jelas adanya faktor musiman, karena secara relatif besarnya yang positif merupakan hasil dari adanya ketidakstasioneran data (adanya trend). Sebagai pedoman, data tersebut harus ditransformasikan ke bentuk yang stasioner sebelum ditentukan adanya faktor musiman.

Faktor musiman pada suatu deret berkala memerlukan penanganan yang hati-hati karena dapat menyebabkan sifat AR, MA, ARMA, dan ARIMA terpisah dimana satu musim dan musim lainnya memperlihatkan sifat-sifat yang sama. Untuk pembeda dapat dilakukan secara musiman atau non musiman.

Adanya faktor musiman pada model ARIMA dapat teridentifikasi jika deret data memperlihatkan bahwa pada satu musim penuh terdapat sifat-sifat ARIMA tertentu, kemudian sifat yang sama muncul lagi pada musim-musim berikutnya. Fenomena musiman sering terjadi pada data bulanan atau kuartalan.

Sebagai contoh untuk data yang dikumpulkan bulanan, pembeda satu musiman penuh (tahun) dapat dihitung sebagai berikut:

$$Z'_t = Z_t - Z_{t-12} = (1 - B^{12})Z_t$$

Notasi ARIMA dapat diperluas untuk menangani aspek musiman, notasi

umum ARIMA Musiman adalah sebagai berikut.

$$ARIMA(p, d, q)(P, D, Q)^S \quad (2.76)$$

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

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

S = jumlah periode per musim

Adapun rumus umum dari $ARIMA(p, d, q)(P, D, Q)^S$ sebagai berikut:

$$\Phi_P B^S \phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (2.77)$$

(Hendikawati, 2015:133)

dengan:

$\Phi_P(B^S)$: *Autoregressive (AR)* musiman dengan periode S dan orde P

$\Theta_Q(B^S)$: *Moving Average (MA)* musiman periode S dan orde Q

$\phi_p(B)$: *Autoregressive (AR)* non musiman orde p

$\theta_q(B)$: *Moving Average (MA)* non musiman orde q

$(1-B^S)^D$: *Pembedaan (differencing)* musiman orde D dan periode musiman S

$(1-B)^d$: *Pembedaan (differencing)* non musiman orde d

2.6.4.1 Model Autoregressive (AR) Musiman

Bentuk umum dari proses *autoregressive* musiman periode S tingkat P atau $AR(P)^S$

$$Z_t = \Phi_1 Z_{t-s} + \Phi_2 Z_{t-2s} + \dots + \Phi_p Z_{t-ps} + \alpha_t \quad (2.78)$$

dimana α_t bersifat independent (saling bebas) terhadap Z_{t-1}, Z_{t-2}, \dots yang berdistribusi normal dengan rata-rata 0 dan variansi σ^2 .

Persamaan di atas dapat juga ditulis dalam bentuk

$$\Phi(B)Z_t = \alpha \quad (2.79)$$

dengan $\Phi(B) = 1 - \Phi_1 B^S - \Phi_2 B^{2S}$ yang dikenal sebagai operator $AR(P)^S$.

Model $AR(P)^S$ suatu proses Z_t dikatakan mengikuti model jika Z_t mengikuti model

$$Z_t = \Phi_t Z_{t-s} - \alpha_t \quad (2.80)$$

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

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

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

Dengan demikian diperoleh:

$$E(Z_t \cdot Z_{t-k}) = E[(\Phi_1 Z_{t-12} + \alpha_t)(\Phi_1 Z_{t-12-k} + \alpha_{t-k})] \quad (2.81)$$

Jika persamaan di atas dibagi dengan γ_0 , maka diperoleh $\rho_k = \Phi_1 \rho_{k-12}$, untuk $k \geq 1$. Dengan demikian

$$\rho_{12} = \Phi_1 \rho_0 \text{ dan } \rho_{24} = \Phi_1 \rho_{12} = \Phi_1^2 \rho_0 \quad (2.82)$$

Sehingga secara umum diperoleh

$$\rho_{12k} = \Phi_1^k \text{ untuk } k = 1, 2, \dots \quad (2.83)$$

Selanjutnya, untuk $k = 1$ dan $k = 11$ dan dengan menggunakan $\rho_k = -\rho_k$ akan memberikan $\rho_1 = \Phi_1 \rho_{11}$ 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, ... atau secara umum lag $s, 2s, 3s, \dots$ untuk $AR(1)^S$ (Sitepu: 2008).

2.6.4.2 Model MA Musiman

Bentuk umum dari proses MA (*moving average*) musiman periode S tingkat Q atau $MA(Q)^S$

$$Z_t = \alpha_t - \Theta_1 \alpha_{t-s} - \Theta_2 \alpha_{t-2s} - \dots - \Theta_Q \alpha_{t-Qs} \quad (2.84)$$

dimana α_t bersifat independent (saling bebas) terhadap Z_{t-1}, Z_{t-2}, \dots yang

berdistribusi normal dengan rata-rata 0 dan variansi σ^2 . Persamaan di atas dapat

juga ditulis dalam bentuk persamaan 2.85.

$$Z_t = \Theta(B)\alpha_t \quad (2.85)$$

dengan $\Theta(B) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}$ yang dikenal sebagai operator yang dikenal sebagai operator $MA(Q)^S$. Model $MA(Q)^S$ suatu proses Z_t dikatakan mengikuti model jika Z_t mengikuti model

$$Z_t = \Phi_t Z_{t-S} - \alpha_t \quad (2.86)$$

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

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

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

$$E(Z_t, Z_{t-k}) = E[(\alpha_t - \Theta_{12} \alpha_{t-12})(\alpha_{t-k} - \Theta_{12} \alpha_{t-k-12})] \quad (2.87)$$

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:

$$\gamma_0 = \text{var}(Z_t) = \alpha_a^2(1 + \Theta_{12}^2)$$

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

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

dan $\gamma_k = \rho_k = 0$ untuk $k \neq 12$ (Sitepu: 2008).

2.6.5 Menghitung Kesalahan Ramalan

Kesalahan ramalan diterapkan untuk menentukan perbedaan antara data historis aktual dan data peramalan (Alli *et al*: 2013). Selanjutnya untuk mengukur error (kesalahan) *forecast* biasanya digunakan *Mean Squared Error (MSE)* dan *Mean Absolute Percetage Error (MAPE)* (Subagyo, 2013).

(1) *Mean Squared Error* (MSE)

Mean Squared Error (MSE) digunakan untuk mengukur kesalahan nilai dugaan model yang dinyatakan dalam rata-rata dari kuadrat kesalahan. Rumus untuk menentukan nilai MSE dinyatakan dengan persamaan (2.88) (Hendikawati, 2015: 95).

$$MSE = \frac{\sum(X_t - F_t)^2}{n} \quad (2.88)$$

dengan

X_t : data sebenarnya terjadi

F_t : data ramalan dihitung dari model yang akan digunakan pada waktu atau tahun t

n : banyak data

(2) *Mean Squared Error* (MAPE)

Mean Absolute Percentase Error (MAPE) adalah nilai rata-rata kesalahan digunakan untuk mengukur kesalahan nilai dugaan model yang dinyatakan dalam bentuk rata-rata persentase *absolute* kesalahan. Rumus untuk menentukan nilai MAPE dinyatakan dengan persamaan (2.89).

$$MAPE = \frac{\sum \left| \frac{X_t - F_t}{X_t} \right|}{n} \times 100\% \quad (2.89)$$

2.7 Penelitian Terdahulu

Penelitian yang dilakukan oleh (Warsini, 2011) melakukan perbandingan metode pemulusan (*smoothing*) eksponensial dan ARIMA (*Box-Jenkins*) sebagai metode peramalan Indek Harga Saham Gabungan (IHSG). Penelitian ini dilakukan untuk mengetahui metode mana yang lebih tepat digunakan pada indik harga saham gabungan. Diperoleh hasil bahwa model yang tepat adalah ARIMA karena memiliki nilai *mean*

absolute percentage error yang lebih kecil yakni bernilai 0,0063 sedangkan model eksponensial bernilai 0,0070.

Pada penelitian (Afrida Ningsih, 2015) yang melakukan perbandingan Metode Pemulusan (*Smoothing*) Eksponensial Ganda (Linier Satu Parameter Dari *Brown*) dan Metode *Box-Jenkins* dalam meramalkan Curah Hujan di Kota Medan. Penelitian ini menyebutkan bahwa model *Box-Jenkins* lebih baik dalam meramalkan curah hujan tahun 2015 dengan model ARIMA (2,1,0)(1,1,0)¹² karena mempunyai nilai SSE dan MSE terkecil dan jenis curah hujan hasil peramalan adalah menengah.

Pada penelitian yang ditulis oleh Metta Octora (2013) Fakultas Kesehatan Masyarakat Universitas Airlangga dengan judul “Perbandingan Metode ARIMA (*Box-Jenkins*) dan Metode *Winters* dalam Peramalan Jumlah Kasus Demam Berdarah Dengue”. Perbandingan keakuratan dari penelitian ini bahwa metode ARIMA adalah metode terbaik untuk menggambarkan dan meramalkan pola atau fluktuasi jumlah kasus DBD dibandingkan dengan metode *Winters*. Hal ini disebabkan karena metode *Winters* menggunakan parameter yang ditentukan secara *trial and error*, tidak ada dasar tolak ukurnya, sedangkan metode ARIMA terdapat kriteria yang dapat ditentukan dengan ACF dan PACF. Dengan kata lain metode ARIMA lebih efisien.

Perbedaan penelitian ini dengan penelitian yang akan dilakukan adalah peramalan dengan menggunakan metode *exponential smoothing Holt-Winters* dan ARIMA.

Ringkasan penelitian terdahulu dapat dilihat pada Tabel 2.3.

Tabel 2.3 Penelitian Terdahulu

No	Peneliti	Judul	Metode	Keterangan
1.	Warsini (2011)	Perbandingan Metode Pemulusan (<i>Smoothing</i>) Eksponensial dan ARIMA (<i>Box-Jenkins</i>) sebagai Metode Peramalan Indeks Harga Saham Gabungan (IHSG)	Metode <i>smoothing</i> dan ARIMA	Diperoleh bahwa hasil peramalan dengan menggunakan metode ARIMA lebih baik dibandingkan metode pemulusan (<i>smoothing</i>) karena nilai MAPE hasil peramalannya lebih kecil. Nilai MAPE hasil peramalan data Indeks Harga Saham Gabungan (IHSG) masing-masing memiliki nilai <i>mean absolute percentage error</i> yakni MAPE dengan metode ARIMA bernilai 0,0063 sedangkan model eksponensial bernilai 0,0070

Lanjutan Tabel 2.3 Penelitian Terdahulu

No	Peneliti	Judul	Metode	Keterangan
2.	Afrida Ningsih (2015)	Metode Pemulusan (<i>Smoothing</i>) Eksponensial Ganda (Linier Satu Parameter Dari <i>Brown</i>) dan Metode <i>Box-Jenkins</i> dalam Meramalkan Curah Hujan di Kota Medan	Metode Pemulusan (<i>Smoothing</i>) Eksponensial Ganda (Linier Satu Parameter Dari <i>Brown</i>) dan Metode <i>Box-Jenkins</i>	Model <i>Box-Jenkins</i> lebih baik dalam meramalkan curah hujan tahun 2015 dengan model ARIMA (2,1,0)(1,1,0) ₁₂ karena mempunyai nilai SSE dan MSE terkecil dan jenis curah hujan hasil peramalan adalah menengah
3.	Metta Octora (2013)	Perbandingan Metode ARIMA (<i>Box-Jenkins</i>) dan Metode <i>Winters</i> dalam Peramalan Jumlah Kasus Demam Berdarah Dengue	Metode ARIMA dan Metode <i>Winters</i>	Metode ARIMA adalah metode terbaik untuk menggambarkan dan meramalkan pola atau fluktuasi jumlah kasus DBD dibandingkan dengan metode <i>Winters</i> . Hal ini disebabkan karena metode <i>Winters</i> menggunakan parameter yang ditentukan secara <i>trial and error</i> , tidak ada dasar tolak ukurnya, sedangkan metode ARIMA terdapat kriteria yang dapat ditentukan dengan ACF dan PACF. Dengan kata lain metode ARIMA lebih efisien.

Lanjutan Tabel 2.3 Penelitian Terdahulu

No	Peneliti	Judul	Metode	Keterangan
4.	Hapsari Vannisa (2013)	Perbandingan Metode Dekomposisi Kalsik dengan Metode Pemulusan Eksponensial <i>Holt-Winters</i> dalam Meramalkan Tingkat Pencemaran Udara di Kota Bandung Periode 2003-2012	Metode Dekomposisi Klasik dan Metode <i>Holt-Winters</i>	Metode <i>Holt-Winters</i> lebih baik dalam meramalkan data partikulat kasar di kota Bandung periode 2003-2012 karena memiliki nilai MSD, MAD dan MAPE yang lebih kecil
5.	Brian L. Djumaty, Andeka Rocky Tanaamah dan Alz Danny Wowor (2013)	Analisis Perbandingan Metode <i>Holt-Winters</i> , <i>Single Exponential</i> dan Polinomial <i>Newton</i> dalam Meramalkan Data Produksi Ubi Kayu (Studi Kasus: Produksi Ubi Kayu Provinsi Jawa Tengah)	Metode <i>Holt-Winters</i> , <i>Single Exponential</i> dan Polinomial <i>Newton</i>	Metode yang lebih tepat untuk peramalan produksi ubi kayu provinsi Jawa Tengah adalah metode <i>Holt-Winters</i>

2.8 Kerangka Berpikir

Secara umum, semua aktifitas yang dilakukan manusia sering mengalami ketidakpastian dalam hal pengambilan keputusan sehingga diperlukan suatu peramalan. Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien (Makridakis *et al.*, 1991). Peramalan merupakan suatu kegiatan untuk memprediksi kejadian di masa yang akan datang dengan menggunakan dan mempertimbangkan data dari masa lampau.

Time series merupakan metode peramalan kuantitatif untuk menentukan pola data pada masa lampau yang dikumpulkan berdasarkan waktu, yang disebut data *time series*. Analisis *time series* terdiri dari metode untuk menganalisis data *time series* dengan mengambil parameter data statistik dan karakteristik lain dari data untuk memprediksi nilai masa depan berdasarkan nilai-nilai sebelumnya yang diamati (Phumchusri & Udom, 2014).

Peramalan seringkali dijumpai dalam kehidupan sehari-hari masalah pola musiman dengan unsur *trend*, seperti rata-rata suhu per bulan di suatu kota, produksi padi bulanan di suatu kabupaten atau provinsi, penjualan payung atau jas hujan di musim hujan dan sebagainya. Data musiman didefinisikan sebagai data dengan pola yang berulang-ulang dalam selang waktu yang tetap. Untuk mengatasi peramalan dengan pola data musiman banyak metode yang dapat digunakan antara lain metode dekomposisi, metode *Winters*, regresi *time series* dan model ARIMA.

Metode yang dapat meramalkan untuk suatu pola data musiman yang memiliki unsur *trend* adalah metode *exponential smoothing Holt-Winters*. Menurut Makridakis *et al.*, (1999), metode ini sangat baik meramalkan pola data yang berpengaruh musiman dengan unsur *trend* yang timbul secara bersamaan. Metode *exponential smoothing Holt-Winters* adalah prosedur peramalan secara luas digunakan dalam analisis *time series* yang memperhitungkan setiap *trend* yang mendasari dan komponen musiman terlepas dari apakah bersifat aditif atau multiplikatif (Thoplan, 2014). Peramalan dengan metode *exponential smoothing Holt-Winters* pada umumnya tidak selalu harus memenuhi kaidah-kaidah deret waktu seperti signifikansi autokorelasi dan stasioneritas.

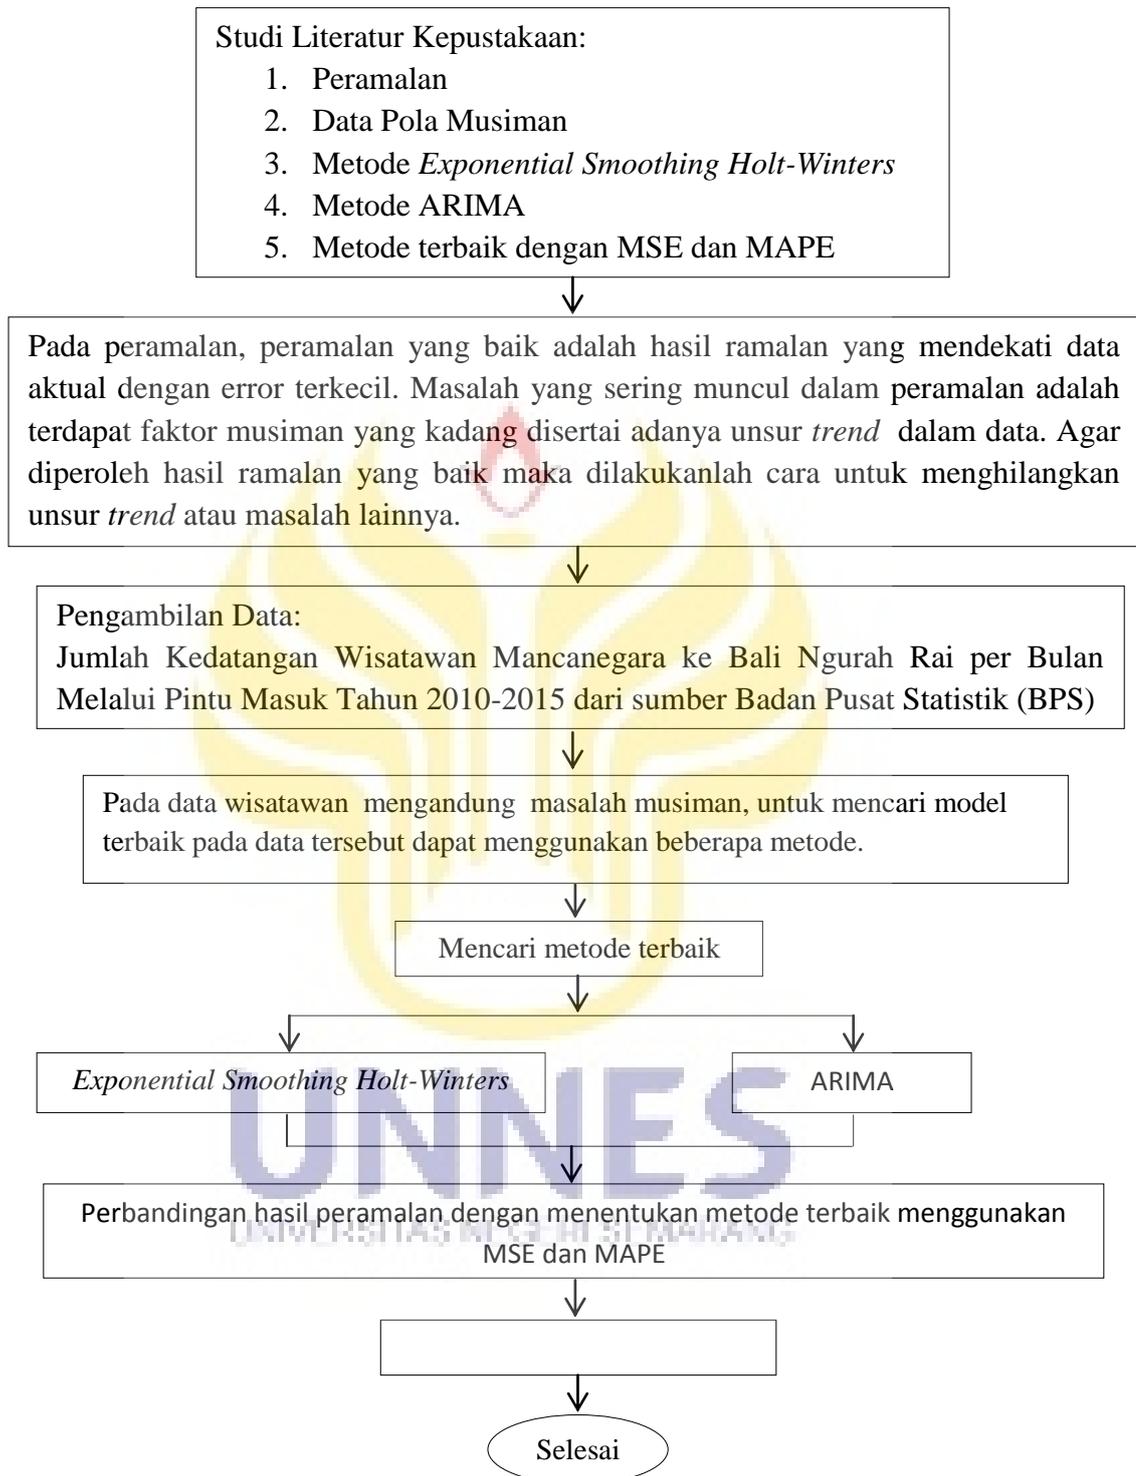
Salah satu metode lain yang dapat meramalkan data musiman adalah metode ARIMA. Metode ARIMA adalah metode peramalan yang tidak menggunakan teori atau pengaruh antar variabel seperti pada model regresi *time series*. Sehingga metode ini tidak memerlukan penjelasan mengenai mana variabel bebas atau terikat. Menurut Bowerman dan Richard (1993) sebagaimana dikutip oleh Hermawan (2011) bahwa *autoregressive Integrated Moving Average* (ARIMA) merupakan metode yang dapat menganalisis data secara univariat yang mengandung pola *trend* musiman, mengatasi masalah sifat keacakan bahkan sifat siklis data *time series* yang dianalisis. Metode ARIMA juga tidak perlu melihat pola seperti pada *time series decomposition*, artinya data yang akan diprediksi tidak perlu dibagi menjadi *trend*, musiman, siklis atau irregular (acak). Menurut Santoso (2009) dalam Munawaroh (2010) metode ARIMA melakukan prediksi berdasarkan data-data historis yang ada. Metode ARIMA dapat diterapkan,

menjelaskan atau mewakili *series* yang stasioner atau telah dijadikan stasioner melalui proses *differencing* atau *transformasi*. Metode ARIMA tidak mensyaratkan suatu pola data tertentu agar model yang diperoleh dapat bekerja dengan baik. Analisis metode ARIMA dilakukan dengan prapemrosesan data dan identifikasi data stasioner, estimasi model, cek diagnostik dan pemilihan model terbaik.

Metode ARIMA dan metode *exponential smoothing Holt-Winters* dianalisis untuk peramalan data musiman. Hasil peramalan dari kedua metode tersebut dilakukan perbandingan untuk memperoleh model peramalan terbaik. Pemilihan model terbaik didasarkan pada nilai ukuran ketepatan yaitu MSE dan MAPE terkecil dari kedua metode tersebut.

Gambar 2.12 di bawah ini merupakan gambaran umum dari kerangka berpikir penelitian.

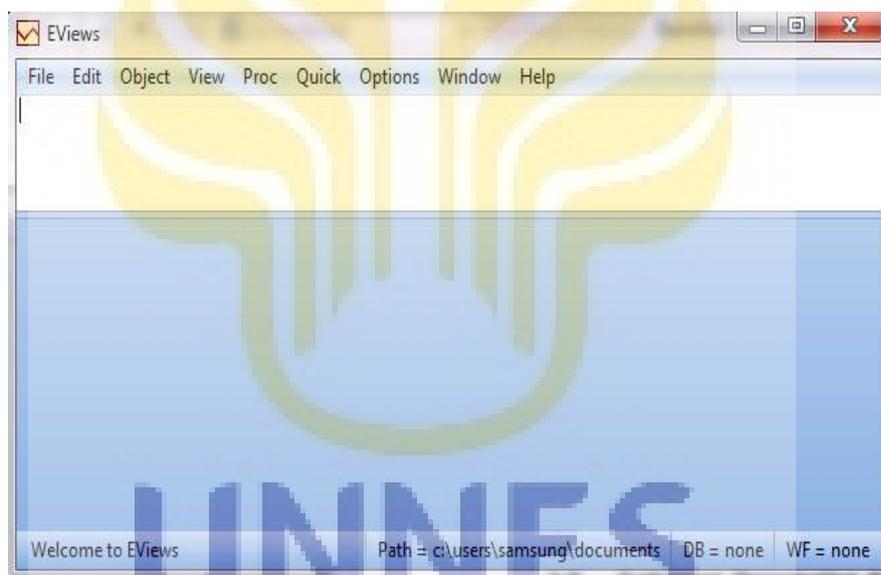




Gambar 2.12 Diagram Alur Kerangka Berpikir

2.9 Tahapan Peramalan Menggunakan Software Eviews 7

Eviews merupakan program komputer yang digunakan untuk mengolah data statistik dan data ekonometri. Eviews dapat digunakan untuk menyelesaikan masalah-masalah yang memuat data yang berbentuk runtun waktu, *cross section*, maupun data panel (Hendikawati, 2015). Eviews juga mempunyai kemampuan untuk melakukan analisis eksplorasi data, konstruksi grafik maupun uji-uji hipotesis sederhana, baik parametrik maupun nonparametrik. Tampilan awal jendela evIEWS seperti Gambar 2.13.



Gambar 2.13 Tampilan Jendela Eviews 7

Ada beberapa cara yang dapat dilakukan untuk memulai program evIEWS yaitu: Arahkan mouse pada direktori Eviews melalui icon pada desktop, kemudian dobel klik pada *icon* evIEWS. Perhatikan tampilan dasar evIEWS windows di atas, terdapat beberapa bagian yang diketahui antara lain.

(1) *Title Bar*

Title Bar terletak paling atas dari tampilan main windows ketika evIEWS sedang aktif, maka *title bar* akan berwarna lebih gelap dari bagian lain jendela utama.

(2) Menu Utama

Menu utama terletak di bawah *title bar*. Jika mengarahkan kursor dan mengklik kiri mouse maka akan muncul menu *drop-down* yang bisa dipilih.

(3) Kotak Perintah

Kotak perintah terletak di bawah menu utama. Perintah-perintah EvIEWS dapat diketik dalam kotak ini. Perintah akan dijalankan setelah tombol enter ditekan.

(4) Kotak Status

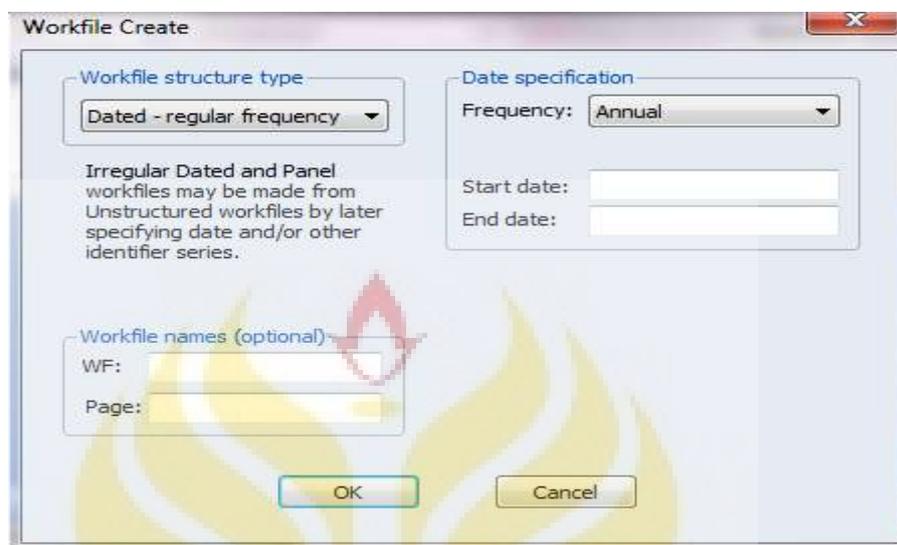
Kotak status terletak pada bagian bawah window, terbagi menjadi beberapa bagian. Bagian paling kiri berisi pesan status yang dikirimkan EvIEWS. Pesan status dapat dihapus dengan mengklik kotak kecil yang terletak di bagian atas kiri bawah jendela EvIEWS. Bagian selanjutnya menunjukkan direktori default yang digunakan EvIEWS untuk mencari data dan program. Dua bagian terakhir menunjukkan nama database (*DB*) dan file kerja (*workfile*) yang sedang aktif.

2.9.1 Tahapan Peramalan ARIMA Menggunakan Software EvIEWS 7

Berikut langkah-langkah proses analisis model runtun waktu (*time series*) dengan program EvIEWS.

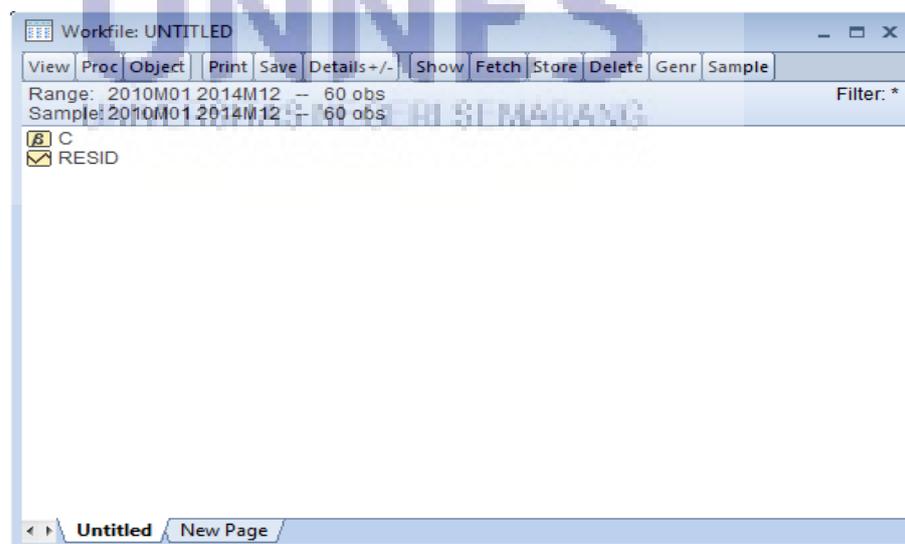
(1) Memasukkan data ke dalam program EvIEWS 7

- (a) Klik icon Eviews 7 pada desktop kemudian klik *file, new, workfile* maka akan muncul kotak dialog *workfile create* seperti Gambar 2.14.



Gambar 2.14 Kotak Dialog *Workfile Create*

- (b) Untuk memasukkan data runtun waktu (*time series*) maka *date specification default frequency* diganti dengan *monthly* karena data yang digunakan adalah data per bulan. Kemudian isikan *start date* dengan “2010:01” dan *end date* “2014:12”. Selanjutnya klik OK. Akan muncul tampilan *workfile* seperti Gambar 2.15.



Gambar 2.15 Tampilan Menu *workfile*

(c) Selanjutnya klik *object*, *new object*. Maka akan muncul kotak dialog *new object* seperti Gambar 2.16.



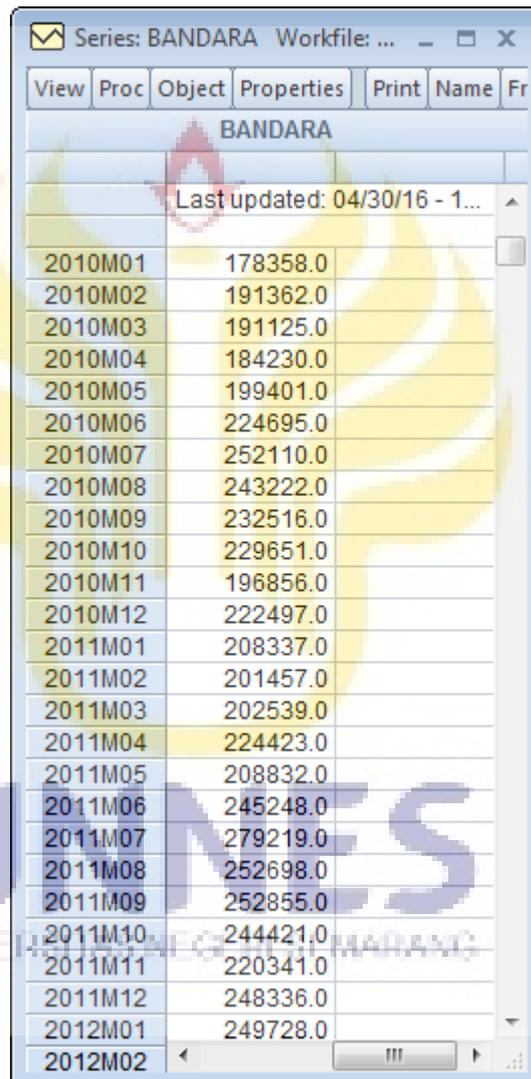
Gambar 2.16 Kotak Dialog *new object*

(d) Untuk data runtun waktu maka pilih series kemudian ketikkan nama data yang akan diolah pada *name for object*. Klik OK, maka akan muncul tampilan seperti Gambar 2.17.

Time Series	Value
2010M01	NA
2010M02	NA
2010M03	NA
2010M04	NA
2010M05	NA
2010M06	NA
2010M07	NA
2010M08	NA
2010M09	NA
2010M10	NA
2010M11	NA
2010M12	NA
2011M01	NA
2011M02	NA
2011M03	NA
2011M04	NA
2011M05	NA
2011M06	NA
2011M07	NA
2011M08	NA
2011M09	NA
2011M10	NA
2011M11	NA
2011M12	NA
2012M01	NA

Gambar 2.17 Tampilan Series bandara

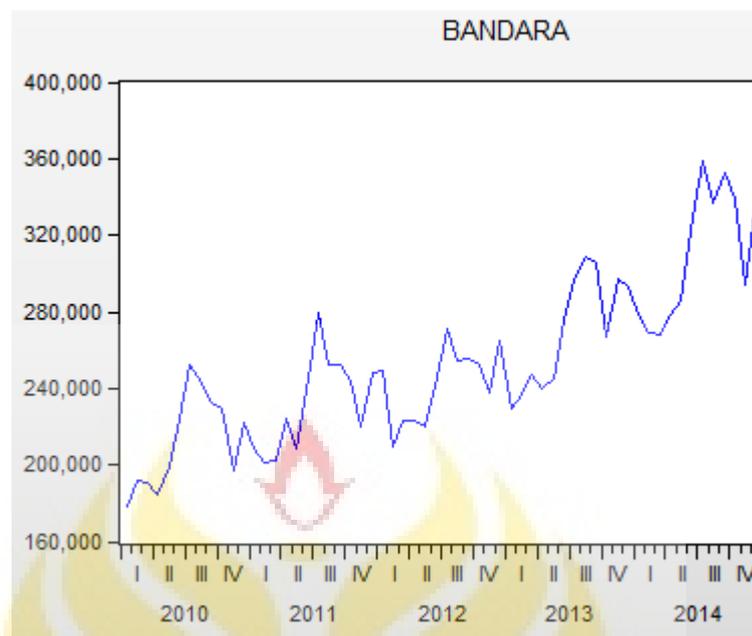
- (e) Untuk mengisikan data bandara maka aktifkan menu *edit* yaitu dengan mengklik kemudian *copy-paste* data yang akan diolah dari excel, kemudian klik *edit* untuk menonaktifkan. Sehingga diperoleh output Gambar 2.18.



View	Proc	Object	Properties	Print	Name	Fr
BANDARA						
Last updated: 04/30/16 - 1...						
2010M01			178358.0			
2010M02			191362.0			
2010M03			191125.0			
2010M04			184230.0			
2010M05			199401.0			
2010M06			224695.0			
2010M07			252110.0			
2010M08			243222.0			
2010M09			232516.0			
2010M10			229651.0			
2010M11			196856.0			
2010M12			222497.0			
2011M01			208337.0			
2011M02			201457.0			
2011M03			202539.0			
2011M04			224423.0			
2011M05			208832.0			
2011M06			245248.0			
2011M07			279219.0			
2011M08			252698.0			
2011M09			252855.0			
2011M10			244421.0			
2011M11			220341.0			
2011M12			248336.0			
2012M01			249728.0			
2012M02						

Gambar 2.18 Input Data bandara

- (f) Melihat bentuk data melalui grafiknya dengan cara klik *view*, *graph* kemudian klik OK, sehingga diperoleh grafik seperti terlihat pada Gambar 2.19.



Gambar 2.19 Grafik Hasil Plot Data

(2) Menguji stasioneritas data.

Langkah untuk menguji stasioneritas data yaitu dengan uji unit root. Dengan cara klik menu *view, unit root test*. Maka akan muncul hasil berikut seperti pada Tabel 2.4.

Tabel 2.4 Uji Unit Root Data Bandara

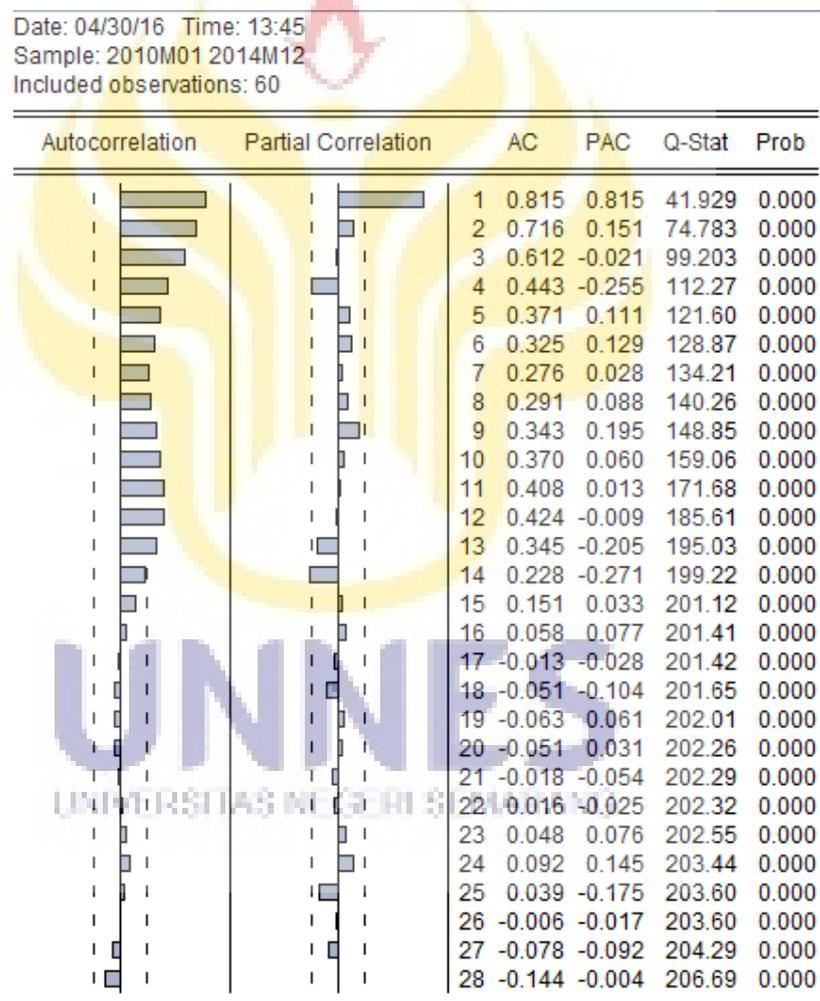
Null Hypothesis: BANDARA has a unit root Exogenous: Constant Lag Length: 0 (Automatic - based on SIC, maxlag=10)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.844049	0.3561
Test critical values:		
1% level	-3.546099	
5% level	-2.911730	
10% level	-2.593551	

*MacKinnon (1996) one-sided p-values.

Dari keluaran hasil *unit root test* dapat dikatakan bahwa: Karena nilai mutlak ADF yaitu $1,844049 < \text{nilai mutlak } t \text{ statistik yaitu } 2,911730$ maka H_0 diterima, artinya data memuat akar unit, maka data tidak stasioner.

(3) Identifikasi Model ARIMA

Selanjutnya melihat plot ACF dan PACF dari correlogram. Dari plot ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*) tersebut dapat diidentifikasi beberapa kemungkinan model yang cocok untuk dijadikan model. Langkah-langkahnya yaitu klik *view, correlogram*, pilih *level*. Mekanisme akan muncul hasil seperti Gambar 2.20.



Gambar 2.20 *Output* correlogram data bandara

Dari correlogram ACF tidak signifikan pada lag ke-1 dan terpotong (*cut off*) setelah lag ke-1 dan PACF perlahan-lahan menghilang (*dying down*), maka diperoleh model seasonal MA(Q=1), model non seasonal AR (p=1

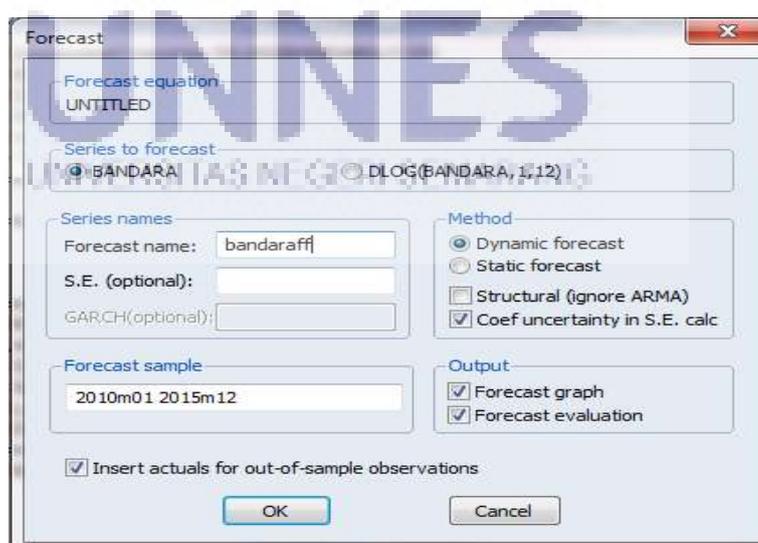
atau 2). Sehingga diperoleh model ARIMA $(0,1,1)(0,1,1)_{12}$. Walaupun tidak menutup kemungkinan terdapat model ARIMA lain yang terbentuk

(4) Estimasi Model ARIMA

Karena data mengandung musiman maka untuk mengestimasi model terbaik dilakukan dengan mengklik menu *quick, estimation equation*, kemudian ketikkan script model ARIMA $(0,1,1)(0,1,1)$. selanjutnya script dapat diubah sesuai model yang ingin diestimasi. Klik OK. Lakukan percobaan estimasi model berulang kali dengan model yang berbeda-beda hingga menemukan model terbaik. Kriteria model terbaik adalah dengan nilai probabilitas kurang dari tingkat kesalahan 5% dan memenuhi asumsi-asumsi tidak terdapat autokorelasi, heteroskedastisitas dan normalitas.

(5) Peramalan

Setelah menemukan model terbaik maka dilakukan proses peramalan yaitu dengan klik *forecast* seperti tampilan Gambar 2.22.



Gambar 2.22 Kotak Dialog *forecast*

2.9.2 Tahapan Peramalan *Exponential Smoothing Holt-Winters* Menggunakan Software Eviews 7

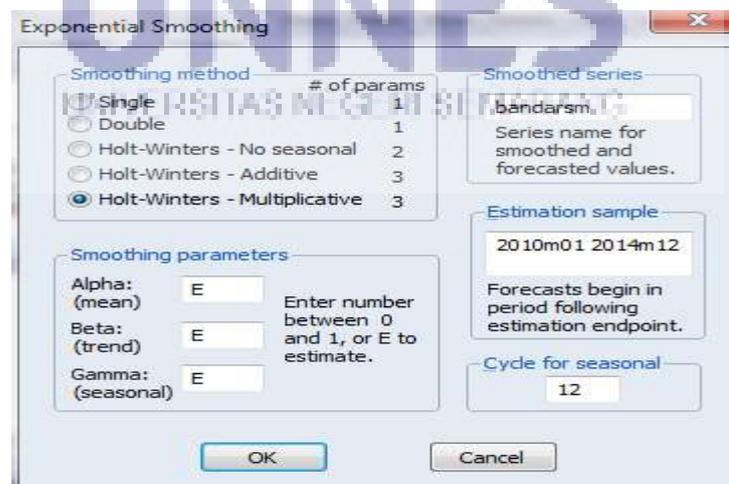
Untuk melakukan peramalan emnggunakan metode eksponensial *Holt-Winters smootihing* pada data bandara, langkah-langkahnya adalah sebagai berikut:

- (1) Melalui menu, pilih *Quick > Series Statistic > Exponential Smoothing* sehingga tampil kotak seperti Gambar 2.23.



Gambar 2.23 Kotak Dialog *Series Name*

- (2) Isi dalam kotak Series name dengan bandara yang merupakan objek series yang terdapat pada workfile bandara. Kemudian klik OK sehingga tampil kotak dialog seperti terlihat pada Gambar 2.24.



Gambar 2.24 Kotak Dialog *Exponential Smoothing*

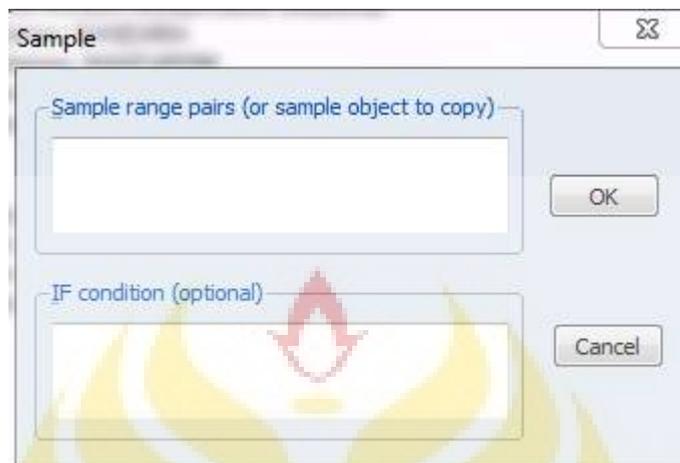
- (3) Dari kotak dialog ini menentukan metode dan nama series yang akan dihasilkan. Karena data merupakan *Holt-Winters* yang bersifat multiplikatif maka pada kotak *Smoothing Method* pilih *Holt-Winters-Multiplicative* dan pada kotak *Smoothed series* berikan nama bandarsm. Pemberian nama ini boleh bebas. Pada *Smoothing Parameters* diberikan nilai mean (α), *trend* (β) dan musiman (γ) dengan cara *trial and error* dengan nilai dari 0 sampai 1. Nilai peramalan (*forecasting*) pada akhir periode untuk metode *Holt-Winters* tidak konstan.
- (4) Untuk membuat peramalan pada akhir tahun 2015, maka sebelumnya dilakukan perubahan pada Range Workfile melalui double klik *Range* pada workfile. Karena akan dilakukan peramalan sampai dengan bulan Desember 2015, maka pada kotak dialog *Workfile Structure* yaitu pada *Date Specification* di kotak *End Date* ganti dengan "2015:12". Akan terjadi perubahan Range pada workfile seperti ditunjukkan pada bagian atas di window workfile seperti terlihat pada Gambar 2.25.



Gambar 2.25 Kotak Dialog *Workfile Structure*

- (5) Untuk menampilkan hasil peramalan (*forecasting*) pada grafik, maka diperlukan perubahan range sample pada workfile melalui menu *Quick >*

Sample yang akan menampilkan kotak dialog yang terlihat pada Gambar 2.26 sebagai berikut.



Gambar 2.26 Kotak Dialog *Sample*

- (6) Pada kotak *sample range pairs (or sample object to copy)* ganti dengan “2015:12”. Selanjutnya pilih bandara dan nama smoothed series, klik kanan kemudian *as group*. Akan terlihat dua data bandara dan data sesuai nama smoothed series yang diberikan. Kemudian klik *view, graph*. Grafik plot series dari series bandara dan nama smoothed series, maka akan muncul grafik.
- (7) Hasil peramalan *exponential smoothing Holt-Winters* berada dalam tabel nama data peramalan dalam *smoothed series*.

BAB 5

PENUTUP

5.1 Simpulan

Berdasarkan analisis dan pembahasan pada bab 4, maka dapat disimpulkan sebagai berikut.

1. Peramalan jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai melalui pintu masuk dengan metode *exponential smoothing Holt-Winters* menghasilkan konstanta data asli $\alpha = 0,3$ sehingga persamaan pemulusan eksponensial data asli adalah $S_t = 0,3 \frac{X_t}{I_{t-12}} + 0,7 (S_{t-1} + b_{t-1})$, konstanta pemulusan untuk pola musiman $\beta = 0,1$ sehingga persamaan pemulusan pola musiman adalah $I_t = 0,1 \frac{X_t}{S_t} + 0,9 I_{t-12}$, konstanta pemulusan untuk pola *trend* $\gamma = 0,1$ sehingga persamaan pemulusan pola *trend* adalah $b_t = 0,1(S_t - S_{t-1}) + 0,9 b_{t-1}$ dan boleh peramalan m periode ke depan adalah $F_{t+m} = (S_t + b_t m) I_{t-12+m}$.
2. Peramalan jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai menurut pintu masuk metode ARIMA dengan transformasi logaritma menghasilkan model ARIMA (2,1,0)(0,1,1)₁₂ mempunyai persamaan model sebagai berikut.

$$\begin{aligned}
\log Z_t = & 0,121384 \log Z_{t-1} + 0,271443 \log Z_{t-2} + 0,607173 \log Z_{t-3} \\
& + 0,119947 \log Z_{t-12} - 0,01456 \log Z_{t-13} \\
& - 0,032559 \log Z_{t-14} - 0,07283 \log Z_{t-15} \\
& + 0,880053 \log Z_{t-24} - 0,10682 \log Z_{t-25} \\
& - 0,23888 \log Z_{t-26} - 0,534344 \log Z_{t-27} - a_t
\end{aligned}$$

3. Peramalan jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai melalui pintu masuk dengan metode *exponential smoothing Holt-Winters* menghasilkan nilai *Mean Square Error* (MSE) yaitu 1436553590 dan nilai *Mean Absolute Percentage Error* (MAPE) yaitu 8,86198%. Sedangkan metode ARIMA menghasilkan nilai *Mean Square Error* (MSE) yaitu 1353169319 dan nilai *Mean Absolute Percentage Error* (MAPE) yaitu 9,40981%. Jadi peramalan jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai melalui pintu masuk Tahun 2010-2015 lebih efektif menggunakan metode *exponential smoothing Holt-Winters* dibandingkan metode ARIMA karena nilai MAPE yang lebih kecil daripada nilai MAPE yang dihasilkan metode ARIMA.

5.2 Saran

Berdasarkan simpulan di atas, peneliti memberikan saran sebagai berikut.

1. Peneliti selanjutnya yang akan meramalkan data jumlah kedatangan wisatawan mancanegara ke Bali Ngurah Rai pada periode berikutnya lebih baik menggunakan metode *exponential smoothing Holt-Winters* dilakukan dengan kombinasi parameter, namun untuk mendapatkan nilai parameter yang optimal disarankan menggunakan algoritma optimasi non-linear

seperti *the Marquardt Algorithm* agar memperoleh keakurasian ramalan yang lebih baik.

2. Pada penerapan metode ARIMA untuk data kedatangan wisatawan mancanegara ke Bali Ngurah Rai melalui pintu masuk Tahun 2010-2015 menggunakan 72 data pengamatan. Untuk peneliti selanjutnya disarankan sebaiknya menggunakan ukuran sampel data *time series* yang lebih besar, agar dapat mengetahui pola dari data tersebut, sehingga dapat diketahui apakah data stasioner atau tidak, dan tiap pengujian model perlu diperhatikan prinsip parsimony (pengambilan model sesederhana mungkin).
3. Pengukuran tingkat kesalahan ramalan selain melihat nilai MSE dan MAPE terkecil yaitu dapat digunakan ukuran-ukuran alternatif yang diantaranya menyangkut kesalahan persentase seperti MAE, MPE dan dapat menggunakan sistem pemantauan *trigg (Tracking Signal)*.
4. Pada penelitian selanjutnya dapat digunakan metode lain sebagai pembandingan sehingga diperoleh hasil peramalan yang lebih mendekati nilai aktualnya agar dapat dibandingkan keakuratannya.

DAFTAR PUSTAKA

- Abdullah, Ade Gafar., Mulyadi Yadi., Wibowo Helmi., 2012. Peramalan Beban Listrik Jangka Pendek Terklasifikasi Berbasis Metode Autoregressive Integrated Moving Average. *Jurnal Teknik Elektro UPI*. 2(2): 44-50.
- Abdullah, Lazim. 2012. ARIMA Model for Gold Bullion Coin Selling Prices Forecasting. *International Journal of Advances in Applied Sciences (IJAAS)*. 1(4): 153-158
- Alexander. 2016. *Peramalan Kebutuhan Bahan Baku Pembuatan Produk Plastik Berdasarkan Data Pendapatan Menggunakan Metode ARIMA*. Skripsi. Univeristas Sumatera Utara: Medan.
- Alli, P., Sundar, D., Devi B. Uma. 2013. An Effective Time Series Analysis for Stock Trend Prediction Using ARIMA Model for Nifty Midcap-50. *International Journal of Data Mining Knowledge Management Process (IJDKP)*. 3(1): 65-78.
- Andalita Ilafi, Irhamah. 2015. Peramalan Jumlah Penumpang Kereta Api Kelas Ekonomi Kertajaya Menggunakan ARIMA dan ANFIS. *Jurnal Sains dan Seni ITS*. 4(2): 1-6.
- Andelkovic Pesic Marija & Lepojevic, Vinko. 2011. *Forecasting Electricity Consumption by Using Holt-Winters and Seasonal Regression Models*. Fakultas Ekonomi Universitas Nis, Serbia. 8(4): 421-431.
- Andreoni, Alberto., Postorino Maria Nadia. 2006. *A Multivaroate ARIMA Model to Forecast Air Transport Demand*. Department of Computer Science, Mathematics, Electronic and Transport: Mediterranean University of Reggio Calabria.
- Anggriningrum, Dwi Prisita., Hendikawati, Putriaji., Abidin, Zaenal. 2013. Perbandingan Prediksi Harga Saham dengan Menggunakan Jaringan Syaraf Tiruan Backpropagation dan ARIMA. *Unnes Journal of Mathematics*. 2(2): 105-109.
- Annisa., Jaya Andi Kresna., Suwandi, Adi. 2013. *Peramalan Data Time Series dengan Metode Penghalusan Eksponensial Holt-Winter*. Makassar: Universitas Hasanuddin.
- Azriati, Kiki Febri dkk. 2014. Verifikasi Model ARIMA Musiman Menggunakan Peta Kendali Moving Average (Studi Kasus: Kecepatan Rata-Rata Angin di Badan Meteorologi Klimatologi dan Geofisika Stasiun Meteorologi Maritim Semarang. *Jurnal Gaussian*. 3(4): 701-710.

- Box, G. E. P. & g. M.Jenkins. 1970. *Time Series Analysis*. California: Holden Day.
- Croux, Christophe., Fried, Roland., Gelper, Sarah. 2008. *Robust Forecasting with Exponential and Holt-Winters Smoothing*. Jerman: Department of Statistics University of Dortmund.
- Ekata & Shivastav Anand Kumar. 2012. Applicability of Box Jenkins ARIMA Model in Crime Forecasting: A Case Study of Counterfeiting in Gujarat State. *Internasional Journal of Advanced Research in Computer Engineering Technology*. Vol I. ISSN 2278-1323.
- Gyimah- Oduro 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*. 2(9): 41-42.
- Habinuddin, Endang., Lusiani, Anie. 2011. *Pemodelan Autoregressive Integrated Moving Average (ARIMA) Curah Hujan di Kota Bandung*. Politeknik Negeri Bandung. 3(2): 9-25.
- Hatidja, Djoni. 2010. *Penerapan Model ARIMA untuk Memprediksi Harga Saham PT. Telkom Tbk*. Manado: Universitas Sam Ratulangi.
- Hendikawati, Putriaji. 2015. *Bahan Ajar Analisis Runtun Waktu*. Universitas Negeri Semarang: Tidak diterbitkan.
- Hendikawati, Putriaji. 2015. *Peramalan Data Runtun Waktu: Metode dan Aplikasinya dengan Minitab & Eviews*. Semarang: FMIPA Universitas Negeri Semarang.
- Hermawan, Eddy. 2011. Perbandingan Metode Box-Jenkins dan Holt-Winters dalam Memprediksi Anomali Air OLR Pentad di Kawasan Barat Indonesia. *Jurnal Sains Dirgantara*. 9(1):25-35.
- Indayani, Eka Ferri. 2009. *Peramalan Jumlah Penumpang Kereta Api dengan Menggunakan Metode Box-Jenkins (Studi Kasus di PT. Kereta Api (Persero) DAOP VI Yogyakarta)*. Skripsi. Yogyakarta: Universitas Islam Negeri Sunan Kalijaga.
- Kalekar, S Prajakta. 2004. *Time Series Forecasting using Holt-Winters Exponential Smoothing: Kanwal Rekhi School of Information Technology*.

- Koehler, Anne B., Snyder, Ralph D., Ord, J Keith. 2011. Forecasting Models and Prediction Intervals for the Multiplicative Holt-Winters Method. *International Journal of Forecasting*. 17: 269-286.
- Lestari, Nofinda., Wahyuningsih, Nuri. 2012. Peramalan Kunjungan Wisata dengan Pendekatan Model SARIMA (Studi Kasus: Kusuma Agrowisata). *Jurnal Sains dan Seni ITS*.1(1): 1-2.
- Machmudin, Ali., Ulama, Brodjol S.S. 2012. Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network. *Jurnal Sains dan Seni ITS*. 1(1): 118-123.
- Makridakis, Spyros, Wheelwright S.C, McGee Viktor E.McGee. 1999. *Metode dan Aplikasi Peramalan* (2th ed). Alih Bahasa: Ir. Untung Sus Adriyanto, M.Sc dan Ir. Abdul Basith, M.Sc. Volume 1. Jakarta: Erlangga.
- Munawaroh, Nurhayati Astin. 2010. *Peramalan Jumlah Penumpang pada PT. Angkasa Pura I (PERSERO) Kantor Cabang Bandar Udara Internasional Adisutjipto Yogyakarta dengan Metode Winter's Eksponensial Smoothing dan Seasonal ARIMA*. Skripsi. Yogyakarta: Universitas Negeri Yogyakarta.
- Padang, Evelina. 2013. *Peramalan Jumlah Penumpang Kereta Api Medan-Rantau Prapat dengan Metode Pemulusan Eksponensial Holt-Winters*. Universitas Sumatera Utara. Medan. 1(2): 161-174.
- Phumchusri, Naragain & Udom, Patimaporn. 2014. A Comparison Study Between Time Series Model and ARIMA Model for Sales Forecasting of Distributor in Plastic Industry. *IOSR Journal of Engineering (IOSRJEN) Departement of Industrial Engineering, Faculty of Engineering, Chulalongkorn University, Bangkok, Thailand*. 4(6): 32-38.
- Pramita, Wahyu & Tanuwijaya, Haryanto. 2010. Penerapan Metode Exponential Smoothing Winter dalam Sistem Informasi Pengendalian Persediaan Produk dan Bahan Baku sebuah Cafe. UPN Veteran Yogyakarta. *Prosiding Seminar Nasional Informatika*. Surabaya: STIKOM Surabaya.
- Rosadi, Dedi. 2012. *Ekonometrika Analisis Runtun Waktu Terapan dengan Eviews*. Yogyakarta: C.V ANDI OFFSET.
- Sadeq, Ahmad. 2008. *Analisis Prediksi Indeks Harga Saham Gabungan dengan Metode ARIMA*. Tesis. Semarang: Universitas Diponegoro.
- Safitri, Arita. 2015. *Perbandingan Hasil Peramalan Penjualan Tas Planet Ocean PT. Delimas Lestari Kencana dengan Metode Pemulusan Eksponensial Ganda Holt dan Metode Holt-Winters*. Skripsi. Medan: Universitas Sumatera Utara.

- Sitepu, Robinson. 2008. *Pemodelan dan Peramalan Deret Waktu Musiman dengan Pendekatan Filter Bank*. Tesis: Medan: Universitas Sumatera Utara.
- Subagyo, Pangestu. 2013. *Forecasting Konsep dan Aplikasi* (3th ed). Yogyakarta: BPFE Yogyakarta.
- Sugiarto dan Harijono. 2000. *Peramalan Bisnis*. Jakarta: PT. Gramedia Utama.
- Sungkawa, Iwa., Megasari, Tri Ries. Penerapan Ukuran Ketepatan Nilai Ramalan Data Deret Waktu dalam Seleksi Model Peramalan Volume Penjualan PT. Satriamandiri Citramulia. *Journal Comtech*. 2(2): 636-645.
- Suseelatha A., G. Sudheer. 2014. Short Term Load Forecasting Using Wavelet Transform Combined with Holt-Winters and Weighted Nearest Neighbor Model. *International Journal of Electrical Power and Energy Systems Department of Mathematics, GVP College of Engineering for Women, Visakhapatnam, Andhra Pradesh: India*. 64: 340-346.
- Szmit Anna., Szmit Maciej. 2012. Usage of Modified Holt-Winters Method in the nomaly Detection of Network Traffic: Case Studies. *Journal of Computer Networks and Communications*. Hindawi Publishing Corporation. Volume 2012: 1-5.
- Thoplan, Ruben. 2014. Simple v/s Sophisticated Methods of Forecasting for Mauritius Monthly Tourist Arrival Data. *International Journal of Statistics and Applications*. 4(5): 217-223.
- UK Centre for the Measurement of Government Activity. 2008. *From Holt-Winters to ARIMA Modelling: Measuring the Impact on Forecasting Errors for Components of Quarterly Estimates of Public Service Output*. Tersedia di <http://www.ons.gov.uk/ons/search/index.html?newquery=From+Holt-Winters+to+ARIMA+Modelling%3A+Measuring+the+Impact+on+Forecasting+Errors+for+Components+of+Quarterly+Estimates+of+Public+Service+Output> [diakses 25 April 2015].
- Widyasari, Dwi Indah. 2015. *Penerapan Metode Autoregressive Integrated Moving Average (ARIMA) Pada Peramalan Kebutuhan Bahan Baku Kertas HVS Dan Volume Produksi Buku*. Skripsi. Semarang: Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Semarang.
- Wei, William W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods* (2th ed). America: Addison-Wesley Publishing Company.

Yulitasari, Astri. 2011. *Perbandingan Metode Pemulusan Eksponensial Ganda Holt dengan Metode Pemulusan Eksponensial Ganda Brown*. Skripsi: FMIPA: Universitas Negeri Semarang.

