

**PERAMALAN DATA DERET WAKTU MUSIMAN DENGAN METODE
SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE
(SARIMA) DAN METODE DEKOMPOSISI PADA DATA JUMLAH
PENUMPANG MELALUI BANDARA POLONIA TAHUN 2009-2018**

(Skripsi)

Oleh

ABDUL ROFI



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2019**

ABSTRAK

FORECASTING SEASON TIME SERIES DATA WITH SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (SARIMA) METHOD AND DECOMPOSITION METHOD IN PASSENGER NUMBER THROUGH 2009-2018 POLONIA AIRPORT

By

Abdul Rofi

The purpose of this study is to compare Seasonal ARIMA methods and Decomposition methods to get the best method in seasonal forecasting. The ARIMA Seasonal Method and Decomposition method are suitable methods for forecasting seasonal data. The Seasonal ARIMA method that looks for the influence of past data on current data produces an ARIMA (2,1,0) (1,1,1) 12 model with a MAPE value of 42% while the Decomposition method that breaks data into several factors results in a Decomposition model with a better MAPE value of 7%.

Kata kunci : Seasonal, ARIMA Seasonal Method, and Decomposition

ABSTRAK

PERAMALAN DATA DERET WAKTU MUSIMAN DENGAN METODE *SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) DAN METODE DEKOMPOSISI PADA DATA JUMLAH PENUMPANG MELALUI BANDARA POLONIA TAHUN 2009-2018

Oleh

Abdul Rofi

Tujuan dari penelitian ini adalah membandingkan metode Seasonal ARIMA dan metode Dekomposisi untuk mendapatkan metode yang terbaik dalam peramalan musiman. Metode Seasonal ARIMA dan metode Dekomposisi merupakan metode yang cocok untuk melakukan peramalan data musiman. Metode Seasonal ARIMA yang mencari pengaruh data di masa lalu terhadap data masa kini menghasilkan model ARIMA $(2,1,0)(1,1,1)^{12}$ dengan nilai MAPE sebesar 42% sedangkan metode Dekomposisi yang memecah data menjadi beberapa faktor menghasilkan model Dekomposisi dengan nilai MAPE yang lebih baik yakni 7%.

Kata kunci : Musiman, Metode Seasonal ARIMA, dan Dekomposisi

Judul Skripsi : **PERAMALAN DATA DERET WAKTU MUSIMAN
DENGAN METODE *SEASONAL AUTOREGRESSIVE
INTEGRATED MOVING AVERAGE (SARIMA)* DAN
METODE DEKOMPOSISI PADA DATA JUMLAH
PENUMPANG MELALUI BANDARA POLONIA
TAHUN 2009-2018**

Nama Mahasiswa : **Abdul Rofi**

No. Pokok Mahasiswa : 1517031148

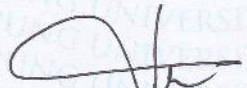
Jurusan : Matematika

Fakultas : Matematika dan Ilmu Pengetahuan Alam



MENYETUJUI

1. Komisi Pembimbing



Drs. Nusyirwan, M.Si.
NIP 19661010 199205 1 001



Dr. Muslim Ansori, S.Si., M.Si.
NIP 19720227 199802 1 001

2. Ketua Jurusan Matematika

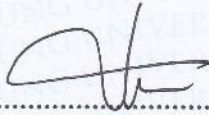


Prof. Dra. Wamiliana, M.A., Ph.D.
NIP 19631108 198902 2 001

MENGESAHKAN

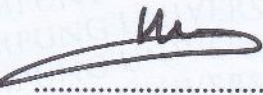
1. Tim Penguji

Ketua : **Drs. Nusyirwan, M.Si.**



.....

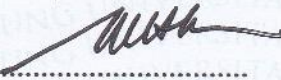
Sekretaris : **Dr. Muslim Ansori, S.Si., M.Si.**



.....

Penguji

Bukan Pembimbing : **Ir. Netti Herawati, M.Sc., Ph.D.**



.....

2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Drs. Suratman, M.Sc.

NIP. 19640604 199003 1 002

Tanggal Lulus Ujian Skripsi : **11 Juli 2019**

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini :

Nama : **Abdul Rofi**

Nomor Pokok Mahasiswa : **1517031148**

Judul : **Peramalan Data Deret Berkala Waktu Dengan Metode *Seasonal Autoregressive Integrated Moving Average (Sarima)* Dan Metode Dekomposisi Pada Data Jumlah Penumpang Melalui Bandara Polonia Tahun 2009-2018**

Jurusan : **Matematika**

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan semua tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah karya penulisan ilmiah Universitas Lampung.

Bandar Lampung, 11 Juli 2019

Penulis,



Abdul Rofi
NPM: 1517031148

RIWAYAT HIDUP

Penulis dilahirkan di Lampung pada tanggal 23 Oktober 1996. Sebagai anak ke Tiga Bapak Mutri dan Ibu Dadiarti.

Penulis menempuh pendidikan Sekolah Dasar Negeri (SDN) 1 Labuhan Ratu Satu pada tahun 2002-2008, Sekolah Menengah Pertama Yayasan Pendidikan Islam (YPI) 3 Way Jepara Lampung Timur pada tahun 2008-2011, Sekolah Menengah Atas Negeri (SMAN) 1 Way Jepara Lampung Timur pada tahun 2011-2014.

Pada tahun 2018 Penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Sinar Mulyo, Kecamatan Pulau Panggung, Kabupaten Tanggamus, Provinsi Lampung. Pada tahun 2018 penulis melaksanakan Kerja Praktek (KP) di PT. Penerbit Erlangga. Pengalaman organisasi penulis yaitu menjadi staf ahli bidang Eksternal Badan Eksekutif Mahasiswa Fakultas (BEMF) Periode 2016-2017, Anggota Bidang Kesekretariatan Himpunan Mahasiswa Jurusan Matematika (HIMATIKA) periode 2016 dan 2017, Kepala bidang Badan Semi Otonom (BSO) Bimbingan Baca Qur'an (BBQ) Rohani Islam (ROIS) FMIPA Periode 2017, Kepala Departemen Akademik Riset dan Penelitian (ARP) Bina Rohani Mahasiswa (BIROHMAH) Periode 2018.

PERSEMBAHAN

Puji Syukur kepada Allah SWT, Karena atas limpahan berkah, rahmad, dan karunia-Nya skripsi ini dapat diselesaikan.

Ku persembahkan karya sederhana penuh perjuangan dan kesabaran ini kepada :

Ayahanda Mutris dan Ibu Dadiarti

Terimakasih atas limpahan kasih sayang, pengorbanan, semangat, motivasi, serta doa dan sujud yang selalu menantikan keberhasilanku dengan sabar dan penuh pengertian.

Karena atas doa dan ridho kalian, Allah memudahkan setiap perjalanan hidup ini.

Terimalah bukti kecil ini sebagai kado keseriusanku untuk membalas semua pengorbanan, keikhlasan, dan jerih payah yang selama ini kalian lakukan.

Almamater yang kucintai, Universitas Lampung

KATA INSPIRASI

“Jika kamu mengejar Dunia, kamu akan mendapatkan Dunia. Jika kamu mengejar Akhirat kamu akan mendapatkan dunia dan Akhirat”

*“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.”
(Q.S. Al-Baqarah : 286)*

“Selama 16 Tahun kita belajar sungguh sungguh untuk mendapatkan gelar sarjana. Berapa lama kamu belajar AGAMA dengan Sungguh Sungguh?? Jangan tertipu dengan Kecantikan Dunia”

“Kunci dari Kehidupan ini adalah Mencari Ridho-nya Allah SWT”

“Kehidupan ini penuh dengan pilihan. So, Kamu lah Yang Menentukan Arah Jalan Hidupmu”

(Abdul Rofi)

SANWACANA

Penulis mengucapkan puji syukur kehadirat Allah SWT, karena dengan ridho dan karunia-Nya serta atas berkah dan rahmat-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Peramalan Data Deret Berkala Musiman Dengan Metode *Seasonal Autoregressive Integrated Moving Average (Sarima)* Dan Metode Dekomposisi Pada Data Jumlah Penumpang Melalui Bandara Polonia Tahun 2009-2018”. Selesainya penulisan skripsi ini adalah berkat motivasi, pengarahan serta bimbingan dari berbagai pihak. Dengan segala kerendahan dan ketulusan hati penulis ingin menyampaikan ucapan terima kasih kepada :

1. Bapak Drs. Nusyirwan, M.Si., selaku pembimbing pertama atas saran, bimbingan, arahan, motivasi, dan kesabaran dalam membimbing penulis selama penelitian hingga penyelesaian skripsi dan memberi arahan kepada penulis selama menuntut ilmu di Universitas Lampung.
2. Bapak Dr. Muslim Ansori, S.Si., M.Si., selaku pembimbing kedua yang telah memberikan arahan, saran, serta dukungan bagi penulis.
3. Ibu Ir. Netti Herawati, M.Sc., Ph.D. selaku Pembahas yang telah memberikan ide, kritik dan saran sehingga terselesaikannya skripsi ini.

4. Ibu Prof. Dra.Wamiliana, M.A., Ph.D. selaku Kepala Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung.
5. Bapak Drs. Suratman,M.Sc. selaku Dekan FMIPA Universitas Lampung
6. Para Dosen dan Staff Jurusan Matematika FMIPA Universitas Lampung.
7. Ibu, Ayah, Uni, Abang, adik dan keluarga tercinta yang selalu memberikan motivasi, semangat, dan doa yang tak terhingga kepada penulis.
8. Sahabat-sahabat di Kontrakan, di kosan Doni, Temen belajar Statmat dan Pimpinan Birohmah 2018 yang telah membantu, memberikan semangat dan keceriaan pada penulis.
9. Teman-teman Matematika 2015 yang selalu menjadi semangat bagi penulis.
10. Semua pihak yang terlibat dalam penyelesaian skripsi yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa masih ada kekurangan dari skripsi ini, akan tetapi besar harapan semoga skripsi ini dapat bermanfaat bagi kita semua.

Bandar Lampung, 11 Juli 2019
Penulis

Abdul Rofi

DAFTAR ISI

Halaman

DAFTAR ISI	i
DAFTAR TABEL	iii
DAFTAR GAMBAR	iv
I. PENDAHULUAN	
1.1 Latar Belakang dan Masalah	1
1.2 Tujuan Penelitian	2
1.3 Manfaat Penelitian	3
II. TINJAUAN PUSTAKA	
2.1 Bandara	4
2.2 <i>Airlines</i> atau Perusahaan Penerbangan	4
2.3 Analisis Deret Waktu	5
2.4 Stasioneritas	7
2.5 <i>Differencing</i>	9
2.6 Transformasi <i>Box-Cox</i>	10
2.7 Fungsi Autokorelasi (ACF)	11
2.8 Fungsi Autokorelasi Parsial (PACF)	13
2.9 Proses White Noise	13
2.10 Metode SARIMA	14
2.10.1 Proses AR	14
2.10.2 Proses MA	15
2.10.3 Proses Campuran AR dan MA	18
2.10.4 Model ARIMA	19
2.10.5 Model SARIMA	21
2.11 Kriteria Keباikan Model	22
2.12 Metode Dekomposisi	24
2.13 Evaluasi Model	27

III. METODOLOGI PENELITIAN	
3.1 Waktu dan Tempat	29
3.2 Data Penelitian	29
3.3 Metode Penelitian	29
IV. HASIL DAN PEMBAHASAN	
4.1 Penduga Model dengan Metode SARIMA	33
4.1.1 Pemeriksaan Kestasioneran Data.....	33
4.1.2 Identifikasi Model.....	36
4.1.3 Pendugaan Parameter Model.....	39
4.1.4 Uji Diagnostik Model.....	41
4.2 Pengolahan Data dengan Metode Dekomposisi	45
4.2.1 Plot Data Penumpang Bandara di Polonia.....	45
4.2.2 Prediksi Menggunakan Metode Dekomposisi	46
4.3 Perbandingan Hasil Metode SARIMA dan Dekomposisi.....	49
4.3. Peramalan	50
V. KESIMPULAN.....	51
DAFTAR PUSTAKA.....	52
LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
1. Pendugaan Parameter.....	28
2. Uji Signifikan Parameter Model Terbaik.....	30
3. Nilai Kesalahan.....	31
4. Nilai Kesalahan.....	32
5. Nilai Peramalan	33

DAFTAR GAMBAR

Gambar	Halaman
1. Plot Deret Waktu Jumlah Penumpang Bandara Ngurah Rai 2006-2014 ..	6
2. Plot Data.....	33
3. <i>Box-Cox</i> Plot Data	34
4. Plot Data <i>Differencing</i>	35
5. Korelogram ACF Data <i>Differencing</i>	36
6. Korelogram PACF Data <i>Differencing</i>	36
7. Plot Data <i>Differencing</i> Musiman $S = 12$	37
8. Korelogram ACF Data <i>Differencing</i> Musiman	38
9. Korelogram PACF Data <i>Differencing</i> Musiman	38
10. Histogram Normalitas Residual.....	43
11. Korelogram ACF	43
12. Korelogram PACF Residual Model.....	44
13. Plot Data Jumlah Penumpang Bandara Polonia	45
14. Analisis Tren	46
15. Analisis Musiman	47

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Pada era modern ini, mode transportasi menjadi sangatlah penting dalam pengaturan dan menejemennya. Hal tersebut dikarenakan transportasi telah menjadi kebutuhan pokok bagi kebanyakan orang. Baik transportasi darat, laut maupun udara telah menjadi indikasi penting yang dapat dilihat untuk memperkirakan perkembangan suatu daerah. Terlebih lagi pada mode transportasi umum, yakni mode transportasi yang digunakan oleh masyarakat umum yang dikelola oleh swasta maupun pemerintah. Mode transportasi umum harus mendapat perhatian lebih baik dari segi perencanaan maupun pelaksanaan. Mode transportasi umum yang tidak termenejemen dengan baik akan menimbulkan berbagai masalah.

Misalnya saja pada mode transportasi udara, jumlah penumpang baik tiba maupun berangkat akan meningkat dengan signifikan pada setiap bulan tertentu. Di Indonesia sendiri biasanya akan terjadi penigkatan penumpang pada setiap cuti Idul Fitri dan libur panjang sekolah. Oleh sebab itu perencanaan untuk mengatasi hal tersebut dapat mencegah hal yang tidak diinginkan seperti penumpukan

penumpang karena kurangnya maskapai, atau banyaknya maskapai yang hanya membawa sedikit penumpang yang tentu merugikan dari segi prasional.

Kegiatan peramalan merupakan kegiatan memprediksi suatu hal dimasa yang akan datang. Perlu adanya data berkala/deret waktu untuk melakukan peramalan.

Terdapat jenis pola data berkala dan berbeda pula cara meramalkannya. Salah satu jenis pola data berkala yaitu pola musiman. Dibutuhkan metode yang tepat untuk meramalkan data pola musiman. Dalam penelitian ini akan menggunakan metode dekomposisi dan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA).

Pada penelitian ini akan dibahas peramalan jumlah penumpang di bandar udara polonia dengan menggunakan metode dekomposisi dan metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA).

1.2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah

1. Menentukan metode yang lebih baik untuk digunakan dalam meramalkan data jumlah penumpang di bandar udara Polonia tahun 2019.
2. Meramalkan jumlah penumpang di bandar udara Polonia pada periode berikutnya menggunakan metode terpilih.

1.3 Manfaat Penelitian

Manfaat dari penelitian ini adalah menambah pengetahuan dan meningkatkan kemampuan penulis maupun pembaca dalam melakukan analisis data deret waktu musiman.

II. TINJAUAN PUSTAKA

2.1 Bandara

Bandara singkatan dari bandar udara. Bandara adalah daerah tertentu di daratan maupun di daerah perairan termasuk setiap bangunan, instansi dan perlengkapan yang diperuntukkan bagi seluruh atau sebagian keberangkatan dan kedatangan serta gerakan udara di permukaan bumi (Poerwadarminta, 1991).

2.2 Airlines atau Perusahaan Penerbangan

Menurut Damardjati (2001), *airlines* atau perusahaan penerbangan adalah perusahaan milik swasta atau pemerintah yang khusus menyelenggarakan pelayanan angkutan udara untuk penumpang umum baik yang berjadwal maupun yang tidak berjadwal. Penerbangan berjadwal menempuh rute penerbangan berdasarkan jadwal waktu, kota tujuan maupun kota-kota persinggahan yang tetap. Sedangkan penerbangan tidak berjadwal sebaliknya, dengan waktu, rute maupun kota-kota tujuan dan persinggahan bergantung kepada kebutuhan dan permintaan pihak penyewa.

2.3 Analisis deret waktu


Deret waktu merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap. Dasar pemikiran deret waktu adalah pengamatan sekarang (z_t) tergantung pada 1 atau beberapa pengamatan sebelumnya (z_{t+k}), dimana t adalah indeks waktu dari urutan pengamatan. Tujuan analisis deret waktu antara lain memahami dan menjelaskan mekanisme tertentu, meramalkan suatu nilai dimasa depan, dan mengoptimalkan sistem kendali. Meramalkan satu fenomena alami atas fenomena yang lain. dengan kata lain, untuk menggambarkan fenomena- fenomena yang ada, yang berlangsung pada saat ini atau saat yang lampau. Model deret waktu dibuat karena secara statistis ada korelasi (independen) antar deret pengamatan. Tahap-tahap dalam melakukan analisis deret waktu yaitu:

a) Identifikasi model

Pada tahap ini, kita memilih model yang tepat yang bisa mewakili deret pengamatan. Identifikasi model dilakukan dengan membuat plot deret waktu, dengan plot deret waktu ini, kita akan mengetahui pola data dan tren deret pengamatan. Identifikasi model tidak hanya dilakukan dengan melihat plot data, tetapi harus pula disertai dengan pengetahuan mengenai data yang akan dianalisis. Berdasarkan plot data dan pengetahuan yang cukup mengenai data, model yang akan dibuat dapat menggunakan parameter sesedikit mungkin. Prinsip ini disebut prinsip Parsimoni.

Berikut adalah contoh bagaimana mengidentifikasi data deret waktu:

Identifikasi stasioner dapat dilakukan dalam bentuk grafik seperti contoh di bawah ini:



Gambar 1. Plot Deret Waktu Jumlah Penumpang Bandara Ngurah Rai 2006-2014.

Berdasarkan Gambar 2.1 di atas dapat dilihat bahwa data dipengaruhi pola tren dan pola musiman karena plot data tersebut menunjukkan fluktuasi meningkat, yaitu gerakan dari kiri bawah ke kanan atas pada grafik serta berulang pada bulan-bulan tertentu.

b) Taksiran model

Pada tahap taksiran model, kita memilih taksiran model yang baik. Dalam hal ini, menaksir model dilakukan dengan metode menaksir kuadrat terkecil, MSE, OLS dan maksimum likelihood.

c) Diagnosis model

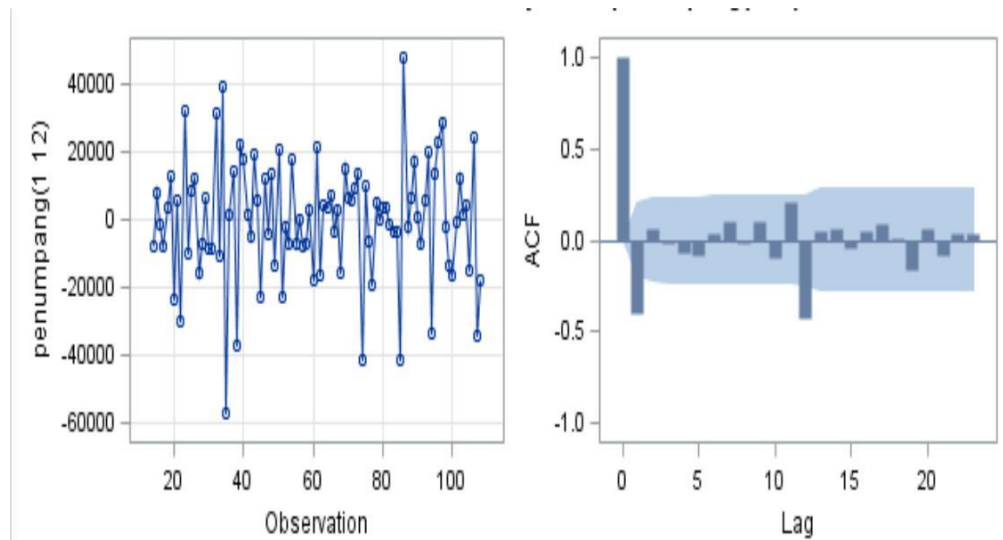
Model yang dibuat belum tentu sesuai dengan data yang dimiliki atau dengan asumsi dari model yang dibuat. Oleh karena itu, kita perlu mendiagnosis model yang telah dibuat dengan menyesuaikannya dengan hasil peramalan.

2.4 Stasioneritas

Sebelum melakukan analisis, kita harus mengetahui terlebih dahulu apakah data runtut waktu yang kita gunakan sudah stasioner. Asumsi yang sangat penting dalam deret waktu adalah stasioneritas deret pengamatan. Suatu deret pengamatan dikatakan stasioner apabila proses tidak berubah seiring dengan perubahan waktu. Maksudnya rata-rata deret pengamatan disepanjang waktu selalu konstan (Makridakis, 1999). Stasioner dibagi menjadi 2, yaitu:

1. Stasioner dalam rata-rata

Stasioner dalam rata-rata adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan variansi dari fluktuasi tersebut. Dari bentuk plot data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner. Apabila dilihat dari plot *ACF*, maka nilai-nilai autokorelasi dari data stasioner akan turun menuju nol sesudah time lag (selisih waktu) kelima atau keenam. Pada analisis regresi, yang menggunakan data time series model regresi tidak hanya variabel x pada waktu t , tetapi juga variabel bebas x waktu (t, i) yang disebut dengan variabel lag. Pada ekonomi, biasanya yang terjadi tidak langsung / seketika itu juga namun Y merespon untuk X dengan jarak waktu. Waktu yang diperlukan dalam reaksi disebut lag. Berikut adalah contoh data stasioner dalam rata-rata:



Gambar 2. Grafik Plot Deret Waktu dan *ACF* setelah Pembedaan Pertama Non Musiman dan Musiman.

Berdasarkan Gambar 2.2 data di atas yakni pada deret waktu plot di atas dapat dilihat sebaran data cenderung konstan berada disekitar nilai nol dan pada grafik *ACF* yakni lag kelima dan keenam mempunyai nilai yang minimum (berada dalam batas biru) sehingga dapat dikatakan data telah stasioner dalam rata-rata.

2. Stasioner dalam variansi

Sebuah data deret waktu dikatakan stasioner dalam variansi apabila struktur dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan plot deret waktu, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

2.5 Differencing

Differencing (Pembedaan) digunakan untuk mengatasi data yang tidak stasioner dalam rata-rata (Makridakis, 1999). Proses pembedaan dilakukan setelah data stasioner dalam varians. Pembedaan di bagi menjadi dua yaitu pembedaan biasa dan pembedaan musiman.

1. Pembedaan Biasa

Ketika data tidak mempunyai rata-rata yang konstan, kita dapat membuat data dengan rata-rata konstan dengan cara pembedaan data, artinya kita menghitung perubahan pada data secara berturut-turut.

Pembedaan pertama atau $d = 1$ dirumuskan:

$$w_t = z_t - z_{t-1} \quad (2.1)$$

Jika pembedaan pertama $d = 1$ belum membuat data mempunyai rata-rata yang konstan, maka dilakukan pembedaan ke-2 atau $d = 2$ yang berarti kita menghitung perbedaan pertama dari perbedaan pertama. Kita definisikan w^*_t sebagai pembedaan pertama dari z_t sehingga rumus untuk pembedaan kedua $d = 2$ sebagai berikut:

$$\begin{aligned} w_t &= w^*_t - w^*_{t-1} \\ w_t &= (z_t - z_{t-1}) - (z_{t-1} - z_{t-2}) \end{aligned} \quad (2.2)$$

2. Perbedaan Musiman

Pembedaan musiman berarti menghitung pergeseran data secara musiman berdasarkan periode waktu tertentu, biasanya dinotasikan s untuk menstimulasi rata-rata dalam seri menjadi konstan. Untuk data kuartalan, $s = 4$ untuk data bulanan, $s = 12$ dan seterusnya. Sebuah data seri mungkin cukup dilakukan dengan pembedaan biasa, cukup dengan pembedaan musiman saja atau kedua-duanya. Misalkan didefinisikan D adalah derajat pembedaan musiman (berapa kali pembedaan musiman dilakukan). Jika ($d = 0$) dan pembedaan musiman ($d = 1$) dihitung untuk semua t sebagai

$$w_t = z_t - z_{t-s} \quad (2.3)$$

Jika transformasi telah digunakan untuk menstabilkan varian, pembedaan musiman digunakan untuk z_t . Pembedaan musiman digunakan untuk menghapus sebagian besar data musiman.

2.6 Transformasi Box-Cox

Untuk menstabilkan varian dalam suatu data seri digunakan transformasi Box-Cox. Transformasi log dan akar kuadrat merupakan anggota dari keluarga *power transformation* yang disebut Box-Cox Transformation (Box and Cox, 1964).

Dengan transformasi ini kita mendefinisikan seri baru Z'_t sebagai

$$Z'_t = \frac{z_t^{\lambda-1}}{\lambda} \quad (2.4)$$

dimana λ adalah bilangan real. Jika nilai $\lambda=1/2$ maka disebut transformasi akar karena $xt^{1/2}$ adalah akar dari z_t .

2.7 Fungsi Autokorelasi (ACF)

Autokorelasi merupakan suatu alat untuk menunjukkan tingkat asosiasi atau hubungan diantara variabel-variabel yang sama, tetapi waktu terjadinya berbeda. Dengan mengetahui koefisien autokorelasi dapat diketahui ciri, pola dan jenis data sehingga dapat mengidentifikasi model tentatif yang disesuaikan dengan data (Makridakis, dkk., 1992).

Dari proses stasioner suatu data deret waktu (X_t) diperoleh $E(X_t) = \mu$ dan variansi $Var(X_t) = E(X_t - \mu)^2 = \sigma^2$, yang konstan dan kovarian $Cov(X_t, X_{t+k})$, yang fungsinya hanya pada perbedaan waktu $|t - (t - k)|$. Oleh karena itu, hasil tersebut dapat ditulis sebagai kovariansi antara X_t dan X_{t+k} sebagai berikut:

$$\gamma = Cov(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu) \quad (2.5)$$

dan korelasi antara X_t dan X_{t+k} didefinisikan sebagai

$$\rho_k = \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)Var(X_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.6)$$

dengan:

μ = rata-rata data

γ_k = autokovarians pada lag ke-k

ρ_k = autokorelasi pada lag ke-k

t = waktu pengamatan ke-t untuk semua t adalah 1,2,3,...dst.

Notasi $Var(X_t)$ dan $Var(X_{t+k}) = \gamma_0$. Sebagai fungsi dari k, γ_k disebut fungsi autokovarians dan ρ_k disebut fungsi autokorelasi (ACF). Dalam analisis deret waktu γ_k dan ρ_k menggambarkan kovarian dan korelasi antara X_t dan X_{t+k} dari proses yang sama, hanya diperoleh oleh lag ke-k.

Fungsi autokovarians γ_k dan fungsi autokorelasi ρ_k memiliki sifat-sifat sebagai berikut:

$$1. \gamma_0 = \text{Var}(X_t); \rho_0 = 1 \quad (2.7)$$

$$2. |\gamma_k| \leq \gamma_0; |\rho_k| \leq 1 \quad (2.8)$$

$$3. \gamma_k = \gamma - k \text{ dan } \rho_k = \rho - k \quad (2.9)$$

Untuk semua k , γ_k dan ρ_k adalah fungsi yang sama dan simetrik lag ke- $k = 0$.

Sifat tersebut diperoleh dari perbedaan waktu antara X_k dan X_{t+k} . Oleh sebab itu, fungsi autokorelasi sering hanya diplotkan untuk lag nonnegatif. Plot tersebut kadang disebut korrelogram.

Pengujian koefisien autokorelasi:

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

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

Dimana jika ρ_k terletak dalam selang persamaan (2.8), keputusannya belum cukup bukti untuk menolah H_0 sehingga dapat disimpulkan data stasioner. Sebaliknya jika ρ_k terletak diluar selang persamaan (2.8), keputusannya belum cukup bukti untuk terima H_0 sehingga dapat disimpulkan data tidak stasioner (Wei, 2006)

Statistik uji:

$$\tau = \frac{r_k}{SE_{r_k}} \quad (2.10)$$

$$r_k = \frac{\sum_{t=1}^T (x_t - \bar{x})(x_{t+k} - \bar{x})}{\sum_{t=1}^T (x_t - \bar{x})^2} \quad (2.11)$$

$$SE_{r_k} = \sqrt{\frac{1+2\sum_{j=1}^{k-1} r_j^2}{T}} \approx \frac{1}{\sqrt{T}} \quad (2.12)$$

dengan:

$$\tau = \text{uji } t$$

$$SE_{r_k} = \text{galat baku autokorelasi pada saat lag ke-}k$$

r_k = autokorelasi pada saat lag ke-k

k = time lag

T = banyak observasi dalam data deret waktu

kriteria keputusan: tolak H_0 jika nilai $|t_{hitung}| > t_{\alpha/2,df}$ dengan derajat bebas $df = t-1$, t merupakan banyaknya data dan k adalah lag koefisien korelasi yang diuji (Pankratz, 1991).

2.8 Fungsi Autokorelasi Parsial (PACF)

Fungsi autokorelasi parsial menyatakan hubungan antara suatu hasil observasi dengan hasil observasi itu sendiri. Autokorelasi parsial pada lag ke-k dinyatakan sebagai korelasi antara Z_t dan Z_{t-k} setelah dihilangkannya efek dari variabel-variabel $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}$. Levinson (1940) dan Durbin (1960) memberikan metode yang efisien untuk mendapatkan penyelesaian dari persamaan Yule-Walker untuk mendapatkan nilai autokorelasi parsial sebagai berikut:

ϕ_{kk} = koefisien autokorelasi parsial untuk lag periode ke-k.

$$\phi_{kj} = \phi_{k-1,j} - \phi_{kk} \phi_{k-1,j-1}, \quad j=1,2,\dots,k-1$$

2.9 Proses White Noise

Proses *White Noise* sama dengan kesalahan/eror pada model regresi biasa. Untuk model deret waktu ini, proses *White Noise* dinotasikan dengan $\{Z_t\}$. Proses *White Noise* memiliki sifat-sifat antara lain deretnya terdiri dari peubah acak yang berurutan tidak saling berkorelasi, $E(Z_t) = 0$ untuk setiap waktu, $\text{Var}(Z_t) = \sigma^2$ untuk setiap waktu dan $\gamma_h = \text{Cov}(Z_{t+h}, Z_t) = 0$ untuk $h \neq 0$.

2.10 Metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

Metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) merupakan metode ARIMA yang digunakan untuk menyelesaikan deret waktu musiman. Metode ini terdiri dari dua bagian, yaitu bagian tidak musiman dan bagian musiman. Bagian tidak musiman dari metode ini adalah model ARIMA. Model ARIMA terdiri dari model *autoregressive* dan model *moving average*.

2.10.1 Proses *Autoregressif* (AR)

Model AR adalah model yang menggambarkan bahwa variable dependen dipengaruhi oleh variabel dependen itu sendiri pada periode sebelumnya. Menurut (Wei, 2006) model AR orde ke- p atau AR(p)

Secara umum dapat dituliskan sebagai berikut:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.13)$$

dengan:

\dot{Z}_t = nilai variabel dependen pada waktu t

$\dot{Z}_{t-1}, \dots, \dot{Z}_{t-p}$ = nilai variabel dependen pada *time-lag* $t-1, \dots, t-p$

ϕ_1, \dots, ϕ_p = koefisien *autoregressive*

a_t = nilai residu pada waktu t

Persamaan (2.13) dapat ditulis dalam bentuk:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \dot{Z}_t = a_t$$

atau

$$\phi_p(B)\dot{Z}_t = a_t \quad (2.14)$$

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

Untuk menemukan fungsi autokorelasinya, persamaan (2.14) dikalikan dengan

\dot{Z}_{t-k} , hasilnya:

$$\dot{Z}_{t-k}\dot{Z}_t = \phi_1 \dot{Z}_{t-k}\dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-k}\dot{Z}_{t-p} + \dot{Z}_{t-k}a_t. \quad (2.15)$$

Jika memasukkan nilai harapan (*expected value*) pada kedua ruas persamaan

(2.15) dan diasumsikan terdapat stasioneritas, maka persamaan tersebut akan

menjadi:

$$E(\dot{Z}_{t-k}\dot{Z}_t) = \phi_1 E(\dot{Z}_{t-k}\dot{Z}_{t-1}) + \dots + \phi_p E(\dot{Z}_{t-k}\dot{Z}_{t-p}) + E(\dot{Z}_{t-k}a_t). \quad (2.16)$$

Karena nilai residual (a_t) bersifat random dan tidak berkorelasi dengan \dot{Z}_{t-k} ,

maka $E(\dot{Z}_{t-k}a_t)$ adalah nol untuk $k > 0$, maka persamaan (2.17) akan menjadi:

$$\gamma_k = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p}, \quad k > 0. \quad (2.18)$$

Jika kedua ruas pada persamaan (2.23) dibagi dengan γ_0 , maka diperoleh:

$$\frac{\gamma_k}{\gamma_0} = \frac{\phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p}}{\gamma_0}$$

atau

$$\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p}, \quad k > 0 \quad (2.19)$$

2.10.2 Proses *Moving Average* (MA)

Menurut (Wei, 2006) secara umum model MA orde ke- q atau MA(q) dapat ditulis

sebagai berikut:

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.20)$$

dengan:

$$\begin{aligned} \dot{Z}_t &= \text{nilai variabel dependen pada waktu } t \\ a_t, a_{t-1}, \dots, a_{t-q} &= \text{nilai residu pada waktu } t, t-1, \dots, t-q \\ \theta_1, \dots, \theta_q &= \text{koefisien } \textit{Moving Average}. \end{aligned}$$

Persamaan (2.20) dapat ditulis dalam bentuk:

$$\begin{aligned} \dot{Z}_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \\ &\text{atau} \\ \dot{Z}_t &= \theta_q(B) a_t \end{aligned} \tag{2.21}$$

dengan:

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

Karena $1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2 < \infty$, maka proses MA berhingga selalu stasioner.

Apabila kedua ruas pada persamaan (2.20) dikalikan dengan \dot{Z}_{t-k} , hasilnya:

$$\begin{aligned} \dot{Z}_{t-k} \dot{Z}_t &= (a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}) \\ &\quad (a_{t-k} - \theta_1 a_{t-k-1} - \dots - \theta_q a_{t-k-q}) \end{aligned} \tag{2.22}$$

Jika memasukkan nilai harapan pada kedua ruas persamaan (2.22), maka persamaan tersebut akan menjadi:

$$\begin{aligned} E(\dot{Z}_{t-k} \dot{Z}_t) &= E[(a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q})(a_{t-k} - \\ &\quad \theta_1 a_{t-k-1} - \dots - \theta_q a_{t-k-q})]. \end{aligned}$$

$$\begin{aligned}
\gamma_k &= E(a_t a_{t-k} - \theta_1 a_t a_{t-k-1} - \cdots - \theta_q a_t a_{t-k-q} \\
&\quad - \theta_1 a_{t-1} a_{t-k} + \theta_1^2 a_{t-1} a_{t-k-1} + \cdots + \theta_1 \theta_q a_{t-1} a_{t-k-q} \\
&\quad \vdots \\
&\quad - \theta_q a_{t-q} a_{t-k} + \theta_q \theta_1 a_{t-q} a_{t-k-1} + \cdots + \theta_q^2 a_{t-q} a_{t-k-q}). \quad (2.23)
\end{aligned}$$

Nilai harapan pada persamaan (2.22) tergantung pada nilai k . jika $k = 0$, maka persamaan (2.23) menjadi:

$$\gamma_0 = E(a_t a_{t-0}) - E(\theta_1^2 a_{t-1} a_{t-0-1}) + \cdots + \theta_q^2 E(a_{t-q} a_{t-0-q}). \quad (2.24)$$

Seluruh suku yang lain pada persamaan (2.23) hilang karena

$$E(a_t a_{t-1}) = 0 \text{ untuk } i \neq 0$$

dan

$$E(a_t a_{t-1}) = \sigma_e^2 \text{ untuk } i = 0.$$

Jadi, persamaan (2.24) menjadi:

$$\begin{aligned}
\gamma_0 &= \sigma_a^2 + \theta_1^2 \sigma_a^2 + \cdots + \theta_q^2 \sigma_a^2 \\
&= (1 + \theta_1^2 + \cdots + \theta_q^2) \sigma_a^2. \quad (2.25)
\end{aligned}$$

Persamaan (2.25) merupakan varians dari proses model MA(q).

Jika $k = 1$, maka persamaan (2.23) menjadi:

$$\begin{aligned}
\gamma_1 &= -\theta_1 E(a_{t-1} a_{t-1}) + \theta_1 \theta_2 E(a_{t-2} a_{t-2}) + \cdots + \theta_{q-1} \theta_q E(a_{t-q} a_{t-q}) \\
&= -\theta_1 \sigma_e^2 + \theta_1 \theta_2 \sigma_e^2 + \cdots + \theta_{q-1} \theta_q \sigma_e^2 \\
&= (-\theta_1 + \theta_1 \theta_2 + \cdots + \theta_{q-1} \theta_q) \sigma_e^2.
\end{aligned}$$

Secara umum untuk $k = k$, persamaan (2.23) menjadi:

$$\gamma_k = (-\theta_k + \theta_1 \theta_{k+1} + \cdots + \theta_{q-k} \theta_q) \sigma_e^2. \quad (2.26)$$

Sehingga fungsi autokovarians dari proses MA(q) adalah

$$\gamma_k = \begin{cases} (-\theta_k + \theta_1\theta_{k+1} + \dots + \theta_{q-k}\theta_q)\sigma_e^2, & k = 1, 2, \dots, q. \\ 0 & k > q. \end{cases} \quad (2.27)$$

Dengan membagi persamaan (2.27) dengan persamaan (2.25), maka fungsi autokorelasinya adalah

$$\rho_k = \begin{cases} \frac{-\theta_k + \theta_1\theta_{k+1} + \dots + \theta_{q-k}\theta_q}{1 + \theta_1^2 + \dots + \theta_q^2}, & k = 1, 2, \dots, q. \\ 0, & k > q. \end{cases} \quad (2.28)$$

Fungsi autokorelasi parsial dari bagian akhir proses umum MA(q) merupakan pemulusan eksponensial dan/atau gelombang sinus tergantung dari akar-akar $1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q = 0$. *PACF* akan berisi gelombang sinus jika akar-akar berupa bilangan kompleks.

2.10.3 Proses Campuran *Autoregressif* dan *Moving Average* (ARMA)

Menurut (Wei, 2006) model ARMA(p, q) merupakan kombinasi dari model AR (p) dan MA (q) yaitu:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (2.29)$$

Persamaan (2.29) dapat ditulis dalam bentuk

$$1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \dot{Z}_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (2.30)$$

atau

$$\phi_p(B) \dot{Z}_t = \theta_q(B) a_t. \quad (2.31)$$

Apabila kedua ruas pada persamaan (2.29) dikalikan dengan \dot{Z}_{t-k} , hasilnya

$$\begin{aligned} \dot{Z}_{t-k} \dot{Z}_t &= \phi_1 \dot{Z}_{t-k} \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-k} \dot{Z}_{t-p} + \dot{Z}_{t-k} a_t - \theta_1 \dot{Z}_{t-k} a_{t-1} \\ &\quad - \dots - \theta_p \dot{Z}_{t-k} a_{t-q} \end{aligned} \quad (2.32)$$

Jika memasukkan nilai harapan pada kedua ruas persamaan (2.32), maka persamaan tersebut akan menjadi:

$$\begin{aligned} \gamma_k = & \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p} + E(\dot{Z}_{t-k} a_t) - \theta_1 E(\dot{Z}_{t-k} a_{t-1}) \\ & - \dots - \theta_q E(\dot{Z}_{t-k} a_{t-q}). \end{aligned} \quad (2.33)$$

Karena $E(\dot{Z}_{t-k} a_{t-i}) = 0$ untuk $k > i$, maka:

$$\gamma_k = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p}, \quad k \geq (q + 1) \quad (2.34)$$

Dan fungsi autokorelasinya adalah

$$\rho_k = \phi_1 \rho_{k-1} + \dots + \phi_p \rho_{k-p}, \quad k \geq (q + 1) \quad (2.35)$$

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

2.10.4 Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ARMA (p, q) pada persamaan (2.34), yaitu:

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

dapat ditulis:

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \dot{Z}_t = & \theta_0 + (1 - \theta_1 B - \theta_2 B^2 \\ & - \dots - \theta_q B^q) a_t \end{aligned} \quad (2.36)$$

dengan:

$$\theta_0 = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \mu = (1 - \phi_1 - \phi_2 - \dots - \phi_p) \mu. \quad (2.37)$$

Dari persamaan (2.36), model AR(p) menjadi:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = \theta_0 + a_t \quad (2.38)$$

dan model $MA(q)$ menjadi:

$$Z_t = \theta_0 + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t . \quad (2.39)$$

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

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

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

dengan:

p = orde model *autoregressive*

q = orde model *moving average*

d = banyaknya *differencing*

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

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B) a_t , \quad (2.40)$$

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

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

Parameter θ_0 mempunyai peran yang berbeda untuk $d = 0$ dan $d > 0$. Untuk $d = 0$, data asli telah stasioner dan seperti persamaan (2.40) bahwa θ_0 merupakan rata-rata proses, yaitu $\theta_0 = (1 - \phi_1 - \phi_1 - \dots - \phi_p)\mu$. sedangkan untuk $d \geq 1$, data asli nonstasioner dan θ_0 merupakan istilah tren deterministik yang biasanya dihilangkan (Wei, 2006).

2.10.5 Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

Menurut (Wei, 2006) secara umum model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dinotasikan sebagai berikut:

$$\text{ARIMA}(p,d,q)(P,D,Q)_S$$

dengan:

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

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

P = orde musiman untuk AR

Q = orde musiman untuk MA

D = banyaknya *seasonal differencing*

S = jumlah periode per musim

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

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)b_t . \quad (2.41)$$

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

$$\rho_{j(s)} = \frac{E(b_{t-js} - \mu_b)(b_t - \mu_b)}{\sigma_b^2}, \quad j = 1, 2, 3, \dots \quad (2.42)$$

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

$$\Phi_p(B^s)(1-B^s)^D b_t = \Theta_Q(B^s)a_t \quad (2.43)$$

dengan: $\Phi_p(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{Ps}$

dan $\Theta_Q(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}$

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

dengan mengkombinasikan persamaan (2.41) dan persamaan (2.43) diperoleh model SARIMA, yaitu:

$$\Phi_p(B^s)\phi_p(B)(1-B)^d(1-B^s)^D\dot{Z}_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (2.44)$$

dengan:

$$\dot{Z}_t = \begin{cases} Z_t - \mu, & d = 0 \text{ atau } D = 0 \\ Z_t, & \text{lainnya} \end{cases}$$

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

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

$\Phi_p(B^s)$ = faktor AR musiman

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

μ = rata-rata Z_t .

2.11 Kriteria Keباikan Model

Penggunaan metode peramalan tergantung pada pola data yang akan dianalisis.

Jika metode yang digunakan sudah dianggap benar untuk melakukan peramalan,

maka penelitian metode peramalan terbaik didasarkan pada tingkat kesalahan

prediksi (Santoso, 2009). Seperti diketahui tidak ada metode peramalan yang

dapat dengan tepat meramalkan keadaan data di masa yang akan datang. Oleh

karena itu, setiap metode peramalan pasti menghasilkan kesalahan. Jika galat yang

dihasilkan semakin kecil, maka hasil peramalan akan semakin mendekati tepat.

Besarnya galat tersebut dapat dihitung melalui ukuran galat peramalan sebagai berikut:

a. *Mean Absolute Deviation (MAD)*

simpangan rata-rata *MAD* mengukur akurasi peramalan dengan meratakan nilai absolut galat peramalan. Nilai galat ukur dalam unit yang sama seperti pada data aslinya

$$MAD = \left(\frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \right)$$

dengan: n = banyaknya data yang diamati

\hat{Y}_t = peramalan ke-t

Y_t = data ke-t

b. *Mean Absolute Percentage Error (MAPE)*

persentase galat rata-rata mutlak (*MAPE*) memberikan petunjuk seberapa besar galat peramalan dibandingkan dengan nilai sebenarnya.

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \right)$$

dengan: n = banyaknya data yang diamati

\hat{Y}_t = peramalan ke-t

Y_t = data ke-t

Dimana suatu model data akan memiliki kinerja yang sangat baik apabila nilai *MAPE* dibawah 10%.

c. *Mean Squared Deviation (MSD)* atau *Mean Squared Error (MSE)*

pada metode ini hampir mirip dengan metode MAD, rumus *MSE* adalah

$$MSE = \left(\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \right)$$

dimana:

n = banyaknya data yang diamati

\hat{Y}_t = peramalan ke-t

Y_t = data ke-t

2.12 Metode Dekomposisi

Suatu pendekatan pada analisis data deret berkala meliputi usaha untuk mengidentifikasi komponen-komponen yang mempengaruhi tiap-tiap nilai pada sebuah data deret berkala. Prosedur pengidentifikasian ini disebut dekomposisi. Tiap-tiap komponen diidentifikasi secara terpisah. Proyeksi tiap-tiap komponen ini kemudian digabung untuk menghasilkan ramalan nilai-nilai masa mendatang dari data deret berkala tersebut (Pangestu, 2005).

Metode dekomposisi biasanya mencoba memisahkan tiga komponen dari pola dasar yang cenderung mencirikan pola deret data ekonomi dan bisnis. Komponen-komponen tersebut adalah tren, siklus dan musiman. Faktor tren menggambarkan perilaku data dalam jangka panjang dan dapat meningkat, menurun atau tidak berubah sama sekali. Faktor siklus menggambarkan naik turunnya ekonomi atau industri tertentu. Faktor musiman berkaitan dengan fluktuasi periodik dengan panjang konstan. Perbedaan antara musiman dan siklus adalah bahwa musiman

berulang dengan sendirinya pada interval yang tetap, sedangkan faktor siklus mempunyai jangka waktu yang lebih lama dan panjangnya berbeda dari siklus yang satu ke siklus yang lain. Metode dekomposisi berasumsi bahwa data tersusun sebagai berikut:

$$data = pola + kesalahan$$

$$= f(\text{tren, siklus, musiman}) + \text{kesalahan}$$

Jadi selain komponen pola, terdapat pula unsur kesalahan yang acak.

Keempat komponen dalam analisis deret berkala adalah sebagai berikut:

- Komponen tren, adalah komponen jangka panjang yang mendasari pertumbuhan atau penurunan dalam suatu data deret berkala.
- Komponen musiman, menggambarkan pola perubahan yang berulang secara teratur dari waktu ke waktu
- Komponen siklus, fluktuasi gelombang yang mempengaruhi keadaan selama lebih dari semusim.
- Komponen kesalahan, komponen tak beraturan yang terbentuk dari fluktuasi-fluktuasi yang disebabkan oleh peristiwa tak terduga.

Metode dekomposisi termasuk pendekatan peramalan tertua. Metode ini digunakan oleh para ahli ekonomi untuk mengenali dan mengendalikan siklus bisnis. Terdapat beberapa pendekatan alternatif untuk mendekomposisi suatu deret berkala, yang semuanya bertujuan memisahkan data deret berkala seteliti mungkin. Konsep dasar dalam pemisahan tersebut bersifat empiris dan tetap yang mula-mula adalah memisahkan musiman, lalu tren, dan akhirnya siklus. Residual

yang ada dianggap yang walaupun tidak dapat diprediksi, namun dapat diidentifikasi. Menurut penulisan matematis secara umum dari model dekomposisi adalah:

$$X_t = f I_t, T_t, C_t, E_t$$

dengan: X_t adalah data aktual pada periode ke- t

I_t adalah indeks musiman pada periode ke- t

C_t adalah unsur siklus pada periode ke- t

E_t adalah unsur kesalahan pada periode ke- t .

Bentuk fungsional yang pasti dari persamaan di atas bergantung pada metode dekomposisi yang digunakan diantaranya yakni metode dekomposisi rata-rata sederhana yang berasumsi pada model aditif:

$$X_t = I_t + T_t + C_t + E_t$$

Metode dekomposisi rasio-tren yang berasumsi pada model multiplikatif:

$$X_t = f I_t * T_t * C_t * E_t$$

Metode dekomposisi rata-rata sederhana dan rasio pada tren pada masa lampau telah digunakan terutama karena perhitungannya yang mudah tetapi metode-metode tersebut kehilangan daya tarik dengan dikenalnya komputer secara meluas, dimana mengakibatkan aplikasi pendekatan dengan variasi metode rata-rata bergerak lebih disukai.

2.13 Evaluasi Model

Model yang baik tentunya memiliki tingkat keakuratan yang baik. Untuk mengukur tingkat keakuratan ini, ada beberapa alat ukur yang dapat digunakan untuk mengevaluasi hasil peramalan model terhadap data observasi.

Beberapa alat ukur tersebut yakni:

a. *Mean Absolute Deviation (MAD)*

simpangan rata-rata *MAD* mengukur akurasi peramalan dengan meratakan nilai absolut galat peramalan. Nilai galat ukur dalam unit yang sama seperti pada data aslinya

$$MAD = \left(\frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \right)$$

dengan: n = banyaknya data yang diamati

\hat{Y}_t = peramalan ke-t

Y_t = data ke-t

b. *Mean Absolute Percentage Error (MAPE)*

persentase galat rata-rata mutlak (*MAPE*) memberikan petunjuk seberapa besar galat peramalan dibandingkan dengan nilai sebenarnya

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \times 100 \right)$$

Dimana suatu model data akan memiliki kinerja yang sangat baik apabila nilai *MAPE* dibawah 10%.

c. *Mean Squared Deviation (MSD)* atau *Mean Squared Error (MSE)*

pada metode ini hamper mirip dengan metode *MAD*, rumus *MSE* adalah

$$MSE = \left(\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \right)$$

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung pada semester ganjil tahun ajaran 2018/2019.

3.2 Data Penelitian

Penelitian ini menggunakan data jumlah penumpang dibandar udara polonia pada tahun 2009-2018. Data tersebut merupakan data primer yang diperoleh dari Badan Pusat Statistik (BPS).

3.3 Metode Penelitian

A. Metode Seasonal ARIMA

1. Pemeriksaan Kestasioneran Data

Melakukan pemeriksaan dan mengidentifikasi plot data secara umum. Jika data belum stasioner, maka dilakukan proses untuk menstasionerkan data.

Pemeriksaan stasioner dilakukan dengan uji grafik dan uji ADF.

Ketidakstasioneran terhadap nilai tengah, dilakukan proses *differencing* dan ketidakstasioneran terhadap ragam, diatasi dengan melakukan proses *Box-Cox*. Untuk data yang mengandung tren, maka dilakukan *differencing* non musiman, sedangkan yang mengandung musiman dilakukan *differencing* musiman.

2. Identifikasi Model

Identifikasi model diperoleh dengan melihat korelogram *ACF* dan *PACF* untuk menentukan kemungkinan model yang cocok. Identifikasi orde p dan q diperoleh dari grafik *ACF* dan *PACF* hasil *differencing* non musiman. Sedangkan orde P dan Q diperoleh dari grafik *ACF* dan *PACF* hasil *differencing* musiman.

3. Pendugaan Parameter

Estimasi parameter diperoleh dengan melihat korelogram *ACF* dan *PACF* untuk mendapatkan model awal. Model awal yang diperoleh belum tentu merupakan model yang terbaik. Untuk itu perlu dilakukan percobaan terhadap beberapa model dengan menaikkan atau menurunkan orde dari model awal. Dari model-model tersebut dapat dipilih model-model sementara yang parameter nya signifikan.

4. Diagnosis Model

Uji diagnosis model terdiri dari uji signifikan parameter dan uji asumsi residual model. Uji signifikan parameter untuk melihat kelayakan model, dengan melihat nilai probabilitas parameter. Pada uji asumsi residual pada model, model harus bersifat white noise dan berdistribusi normal.

Selanjutnya menentukan model terbaik dilakukan dengan uji independensi menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Deviation* (MAD), dan *Mean Squared Error* (MSE).

B. Metode Dekomposisi

Berikut ini tahapan-tahapan dalam menggunakan metode dekomposisi pada suatu barisan data runtun waktu:

1. Identifikasi data

Melakukan pemeriksaan dan mengidentifikasi plot data secara umum. Data yang digunakan untuk metode ini harus mengandung unsur musiman. Unsur musiman diketahui tidaklah stasioner. Dengan melihat plot dapat diketahui bahwa data mengandung unsur musiman atau tidak.

2. Pencocokan tren

Sebelum dilakukan pencocokan tren, komponen musiman harus dipisahkan terlebih dahulu dengan mengurangi/membagi data awal dengan komponen musimannya yang bersesuaian.

3. Menghitung Indeks Musiman

Indeks musiman dapat digunakan untuk menguraikan perkiraan/ ramalan tahunan menjadi perkiraan perbulan pada tahun mendatang.

4. Nilai Kesalahan

Untuk melihat tingkat keakuratan yang baik dalam peramalan, ada beberapa alat ukur yang dapat digunakan yaitu *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Deviation* (MAD), dan Mean Squared Error (MSE).

C. Perbandingan Metode SARIMA dan Dekomposisi

Hasil pemilihan model yang diperoleh dari metode SARIMA kemudian dibandingkan dengan hasil yang diperoleh dari metode Dekomposisi.

Perbandingan dilakukan dengan mempertimbangkan nilai MAPE, MAD dan MSE untuk dua model tersebut.

D. Peramalan Jumlah Penumpang Di bandar Udara Polonia

Melakukan Jumlah Penumpang di bandar Udara Polonia dengan menggunakan model terpilih selama satu tahun kedepan.

V. KESIMPULAN

Dari hasil penelitian diperoleh kesimpulan bahwa:

1. Metode dekomposisi untuk data jumlah penumpang bandara Polonia periode Januari 2009 – Desember 2018 memberikan nilai duga yang mendekati data sebenarnya. Metode dekomposisi menghasilkan nilai MAPE sebesar 7, MAD sebesar 16401 dan MSD sebesar 421265833. Metode SARIMA menghasilkan nilai MAPE sebesar 42, MAD sebesar 59714 dan MSD sebesar 670951071.
2. Hasil prediksi dengan metode dekomposisi menunjukkan bahwa tingkat keakuratan model yang diperoleh lebih baik dengan hasil ramalan setiap bulannya rata-rata naik sebesar 1-2% .

DAFTAR PUSTAKA

- Pangestu, S. 1986. *Forecasting Konsep dan Aplikasi*. BPFE Yogyakarta, Yogyakarta.
- Makridarkis, S., dkk. 1999. *Metode dan Aplikasi Peramalan*. Erlangga, Jakarta.
- Damardjati, R. 2001. *Istilah-Istilah Dunia Pariwisata*. Pradnya Paramita, Jakarta
- Makridakis, S., dkk. 1993. *Metode dan aplikasi Peramalan*. Jilid I. Erlangga, Jakarta.
- Makridakis, S. dan Wheelwright, S. 1992. *Metode-Metode Peramalan Untuk Manajemen*. Erlangga, Jakarta.
- Wei, D. 2006. *Pengantar Analisis Runtun Waktu*. FMIPA UGM, Yogyakarta.
- Pankratz. 1991. *Peramalan: Metode dan Aplikasi*. Erlangga, Jakarta.
- Santoso. 2009. *Analisis Deret Waktu*. FMIPA UNPAD, Bandung.
- Box, G. E. P. dan Cox, D. R. 1964. *Analysis of Transformations*. John Wiley and Sons, Inc., New York.