



TUGAS AKHIR - SS091324

PEMODELAN KECEPATAN ANGIN DI PERAIRAN PULAU BAWEAN DENGAN MENGGUNAKAN FUNGSI TRANSFER

MUHAMMAD TAYYIB
NRP 1312 105 033

Dosen Pembimbing
Dra. Wiwiek Setya Winahju, MS

JURUSAN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2014



TUGAS AKHIR - SS091324

PEMODELAN KECEPATAN ANGIN DI PERAIRAN PULAU BAWEAN DENGAN MENGGUNAKAN FUNGSI TRANSFER

MUHAMMAD TAYYIB
NRP 1312 105 033

Dosen Pembimbing
Dra. Wiwiek Setya Winahju, MS

JURUSAN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2014



FINAL PROJECT - SS091324

MODELING WIND SPEED IN SEA OF BAWEAN ISLAND USING TRANSFER FUNCTION METHOD

MUHAMMAD TAYYIB
NRP 1312 105 033

Supervisor
Dra. Wiwiek Setya Winahju, MS

DEPARTMENT OF STATISTICS
Faculty of Mathematics and Natural Sciences
Sepuluh Nopember Institute of Technology
Surabaya 2014



FINAL PROJECT - SS091324

MODELING WIND SPEED IN SEA OF BAWEAN ISLAND USING TRANSFER FUNCTION METHOD

MUHAMMAD TAYYIB
NRP 1312 105 033

Supervisor
Dra. Wiwiek Setya Winahju, MS

DEPARTMENT OF STATISTICS
Faculty of Mathematics and Natural Sciences
Sepuluh Nopember Institute of Technology
Surabaya 2014

PERAMALAN KECEPATAN ANGIN DI PERAIRAN PULAU BAWEAN DENGAN MENGGUNAKAN FUNGSI TRANSFER

Nama : Muhammad Tayyib
NRP : 1312 105 033
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Dra. Wiwiek Setya Winahju, MS

ABSTRAK

Kecepatan Angin merupakan salah satu indikator dalam mengukur cuaca di suatu tempat terutama untuk kehidupan nelayannya. Pulau Bawean merupakan salah satu pulau di Kabupaten Gresik yang sebagian besar kehidupan dilakukan di perairan. Penelitian ini dilakukan dengan memodelkan kecepatan angin dengan menggunakan fungsi transfer dengan tekanan udara sebagai variabel input. Kemudian model yang didapatkan digunakan untuk meramalkan beberapa periode berikutnya. Apabila hasil peramalan tidak baik maka dilakukan pemodelan dengan metode yang lain. Metode yang bisa digunakan untuk memodelkan yaitu *Vector Autoregressive* (VAR) dan regresi time series. Kecepatan angin rata-rata tertinggi terjadi pada tahun 2012 sedangkan untuk rata-rata tekanan udara tertinggi terjadi pada tahun 2012. Berdasarkan hasil analisis fungsi transfer kecepatan angin hari ini dipengaruhi oleh tekanan udara pada hari ini juga. Metode alternatif yang terbaik yaitu regresi robust. Pada pemodelan regresi robust kecepatan angin hari ini dipengaruhi oleh tekanan udara dua hari sebelumnya dan kecepatan a-ngin sehari sebelumnya.

Kata Kunci: kecepatan Angin, Tekanan Udara, Fungsi Transfer,

FORCASTING WIND SPEED IN SEA OF BAWEAN ISLAND USING TRANSFER FUNCTION METHOD

Name : Muhammad Tayyib
NRP : 1312 105 033
Department : Statistics FMIPA-ITS
Supervisor : Dra. Wiwiek Setya Winahju, MS

ABSTRACT

Wind speed is one of the indicators in measuring the weather in a place primarily for the life of fishermen. Bawean island is an island in Gresik mostly conducted in the waters of life. This research was conducted by modeling the wind speed by using the transfer function of air pressure as input variables. Then the obtained models are used to predict the next few periods. If the result is not good then the forecasting modeling done by other methods. The method can be used to model the Vector Autoregressive (VAR) and time series regression. The average wind speed was highest in 2012, while the average for the highest air pressure occurred in 2012 Based on the analysis of the transfer function of wind speed today is influenced by the air pressure on this day. The best alternative method that is robust regression. In the robust regression modeling wind speed today is influenced by the air pressure two days before and the day before the wind speed..

Key words: Wind, Air Pressure, Transfer Function.

(Halaman ini sengaja dikosongkan)

LEMBAR PENGESAHAN

PEMODELAN KECEPATAN ANGIN DI PERAIRAN PULAU BAWEAN DENGAN MENGGUNAKAN FUNGSI TRANSFER

TUGAS AKHIR

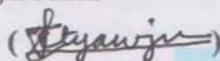
Diajukan Untuk Memenuhi Salah Satu Syarat Kelulusan
Program Studi S-1 Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

MUHAMMAD TAYYIB
1312 105 033

Disetujui oleh Pembimbing Tugas Akhir

Dra. Wiwiek Setya Winahju MS
NIP. 19560424 198303 2 001



Mengetahui,
Ketua Jurusan Statistika FMIPA-ITS


DR. Muhammad Mashuri, MT
NIP. 19620408 198701 1 001

Surabaya, Agustus 2014



KATA PENGANTAR

Puji syukur kehadirat Allah SWT atas segala limpahan rahmat serta hidayah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul

“PERAMALAN KECEPATAN ANGIN DI PERAIRAN PULAU BAWEAN DENGAN MENGGUNAKAN FUNGSI TRANSFER”

Penulis sadar bahwa dalam pengerjaan Tugas Akhir ini tidak terlepas dari bantuan dan dukungan berbagai pihak, maka dalam kesempatan ini penulis menyampaikan rasa terima kasih kepada pihak-pihak yang telah terlibat baik secara langsung maupun tidak.

1. Ibu Wiwiek Setya Winahyu MS selaku dosen pembimbing Tugas Akhir yang telah memberikan masukan, ilmu, dan pengarahan yang sangat membantu dalam pengerjaan Tugas Akhir ini.
2. Bapak Dr. Muhammad Mashuri, M.T selaku Ketua Jurusan Statistika yang telah memberikan banyak fasilitas, sarana dan prasarana sehingga memperlancar penyelesaian Tugas Akhir yang penulis kerjakan.
3. Ibu Irhamah, M.Si dan Ibu Adatul Mukarromah, M.Si selaku dosen penguji yang telah memberikan banyak masukan dan arahan sehingga Tugas Akhir ini dapat diselesaikan dengan baik.
4. Bapak I Nyoman Latra selaku dosen wali selama masa perkuliahan yang telah banyak memberikan sarandan arahan dalam proses belajar di Jurusan Statistika ITS.
5. Ibu Dra. Lucia Aridinanti, M.T selaku koordinator Tugas Akhir yang membantu secara administrasi dalam proses penyusunan Tugas Akhir.
6. Kedua orang tua, Bapak dan Ibu, serta keluarga di rumah kedua kakak saya yang selalu memberikan dukungan dan mendoakan dalam setiap langkah demi kesuksesan penulis.

7. Bapak dan Ibu dosen Jurusan Statistika yang telah membagikan ilmu dan wawasan selama masa perkuliahan di Jurusan Statistika, serta seluruh karyawan Jurusan Statistika ITS.
8. Sahabat terbaik yang selalu mendukung dan menemani suka duka penulis selama dua tahun menjalani masa perkuliahan, Galih, Bagoes, Peh, mas Yopie, Woro, Icha, dan tari serta teman-teman Lintas jalur lain yang selalu memberikan doa dan semangat bagi penulis.
9. Rekan seperjuangan dari Lab komputasi Juniar Iqbalullah dan Mbak Dhika Rezti Witiandi yang selalu berbagi suka dan duka selama pengerjaan tugas akhir.
10. Semua sahabat dan teman-teman Statistika ITS angkatan 2009 yang tidak dapat disebutkan satu per satu.

Penulis menyadari bahwa laporan Tugas Akhir ini masih belum sempurna, atas segala kekurangan, diharapkan saran dan kritik yang membangun. Semoga hasil dari Tugas Akhir ini memberikan manfaat bagi semua pihak yang terkait.

Surabaya, Agustus 2013

Penulis

(Halaman ini sengaja dikosongkan)

DAFTAR ISI

| | |
|--|----------|
| JUDUL | i |
| LEMBAR PENGESAHAN | iii |
| ABSTRAK | v |
| ABSTRACT | vii |
| KATA PENGANTAR | ix |
| DAFTAR ISI | xi |
| DAFTAR TABEL | xiii |
| DAFTAR GAMBAR | xvii |
| DAFTAR LAMPIRAN | xix |
| | |
| BAB I PENDAHULUAN | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Rumusan Masalah | 3 |
| 1.3 Tujuan Penelitian | 4 |
| 1.4 Manfaat Penelitian..... | 4 |
| | |
| BAB II LANDASAN TEORI | 5 |
| 2.1 Konsep Time Series | 5 |
| 2.2 Kestasioneran Data..... | 5 |
| 2.2.1 Data Stasioner | 6 |
| 2.2.2 Data Non Stasioner | 6 |
| 2.3 Metode ARIMA Box-Jenkins | 8 |
| 2.3.1 Identifikasi Model | 8 |
| 2.3.2 Estimasi Parameter Model | 10 |
| 2.3.3 Diagnostic Checking..... | 12 |
| 2.3.4 Pemilihan Model Terbaik..... | 13 |
| 2.4 Fungsi Transfer | 14 |
| 2.5 Pembentukan Model Fungsi Transfer..... | 14 |
| 2.5.1 Perhitungan CCF | 14 |
| 2.5.2 Identifikasi Model Fungsi Transfer | 16 |
| 2.5.3 Penaksiran Parameter Model Fungsi Transfer . | 17 |
| 2.5.4 Pemeriksaan Diagnosa | 18 |
| 2.6 Beberapa Metode Alternatif..... | 19 |
| 2.6.1 <i>Vector Autoregressive</i> | 19 |

| | | |
|----------------|---|-----------|
| 2.6.2 | Regresi Time Series..... | 23 |
| 2.7 | Kriteria Model Terbaik..... | 26 |
| 2.8 | Kecepatan Angin..... | 26 |
| BAB III | METODOLOGI PENELITIAN..... | 29 |
| 3.1 | Sumber Data | 29 |
| 3.2 | Variabel Penelitian | 29 |
| 3.3 | Metode Analisis Data..... | 30 |
| BAB IV | ANALISIS DAN PEMBAHASAN | 33 |
| 4.1 | Deskripsi Kecepatan Angin dan Tekanan Udara | 33 |
| 4.2 | Pemodelan Kecepatan Angin dengan Metode Fungsi Transfer..... | 35 |
| 4.2.1 | <i>Prewhitening</i> Deret <i>Input</i> dan Deret <i>Output</i> | 36 |
| 4.2.2 | Pembentukan Model Fungsi Transfer | 40 |
| 4.3 | Pemodelan Kecepatan Angin Dengan Model Alternatif yang lain..... | 45 |
| 4.4 | Pemilihan Model Terbaik | 53 |
| BAB V | KESIMPULAN DAN SARAN | 55 |
| 5.1 | Kesimpulan..... | 55 |
| 5.2 | Saran..... | 55 |
| | DAFTAR PUSTAKA..... | 57 |
| | LAMPIRAN..... | 59 |
| | BIODATA PENULIS | |

DAFTAR GAMBAR

| | | |
|-------------|--|----|
| Gambar 4.1 | Plot <i>Time Series</i> Tekanan Udara | 34 |
| Gambar 4.2 | Plot <i>Time Series</i> Kecepatan Angin | 35 |
| Gambar 4.3 | Transformasi <i>Box-cox</i> Tekanan Udara..... | 36 |
| Gambar 4.4 | Plot ACF Tekanan Udara..... | 37 |
| Gambar 4.5 | Plot Tekanan Udara (a) Autocorrelation Function (b) Partial Autocorrelation Function | 37 |
| Gambar 4.6 | Plot CCF Tekanan Udara Terhadap Kecepatan Udara | 41 |
| Gambar 4.7 | Plot deret noise (a) Autocorrelation Function (b) Partial Autocorrelation Function..... | 42 |
| Gambar 4.8 | Plot MPACF Tekanan udara dan kecepatan angin setelah <i>Differencing</i> | 46 |
| Gambar 4.9 | Plot MACF Residual VAR(5)..... | 48 |
| Gambar 4.10 | Plot Pengujian Multinormal Residual VAR (5) | 48 |
| Gambar 4.11 | Time Series Plot (a) Residual Murni (b) Standardize Residual..... | 49 |
| Gambar 4.12 | ACF Residual Regresi Time Series | 52 |
| Gambar 4.13 | Pengujian Kolmogorv-Smirnov Residual model Regresi Time Series | 53 |

DAFTAR TABEL

| | | |
|------------|---|----|
| Tabel 2.1 | Transformasi Box-Cox | 7 |
| Tabel 2.2 | Identifikasi Model ARIMA Berdasarkan ACF dan PACF | 9 |
| Tabel 4.1 | Statistik Deskriptif Variabel | 33 |
| Tabel 4.2 | Korelasi Antar Variabel..... | 34 |
| Tabel 4.3 | Estimasi dan Uji Signifikansi Parameter Model ARIMA Tekanan Udara | 38 |
| Tabel 4.4 | Uji <i>White Noise</i> Residual Model ARIMA Tekanan Udara..... | 39 |
| Tabel 4.5 | Hasil Uji Normalitas Residual Model ARIMA Tekanan Udara..... | 39 |
| Tabel 4.6 | Kriteria Pemilihan Model ARIMA Terbaik Tekanan Udara Berdasarkan SBC..... | 40 |
| Tabel 4.7 | Estimasi dan Signifikansi Parameter ARIMA Deret <i>Noise</i> dengan $b=0$, $r=0$, dan $s=0$ | 43 |
| Tabel 4.8 | Pengujian <i>White Noise</i> untuk Deret <i>Noise</i> dengan $b=0$ $r=0$ $s=0$ | 43 |
| Tabel 4.9 | Hasil Uji Normalitas Residual Fungsi Transfer.. | 44 |
| Tabel 4.10 | Hasil Peramalan Fungsi Transfer | 44 |
| Tabel 4.11 | Identifikasi Model VAR berdasarkan AIC | 46 |
| Tabel 4.12 | Estimasi Parameter Model Restrict untuk Model VAR(5)..... | 46 |
| Tabel 4.13 | Granger Causality Test antara kecepatan angin dan Tekanan Udara | 47 |
| Tabel 4.14 | Uji korelasi antara kecepatan angin (t) dengan tekanan udara (t-k) dan kecepatan angin (t-i) | 49 |
| Tabel 4.15 | Estimasi parameter dan Uji signifikansi parameter | 50 |
| Tabel 4.16 | Estimasi Parameter dan Uji Signifikansi Parameter | 50 |
| Tabel 4.17 | ANOVA Regresi time series | 50 |
| Tabel 4.18 | Pemodelan dengan Metode Regresi Robust | 51 |

| | | |
|------------|--|----|
| Tabel 4.19 | Uji Parameter pada Pengujian <i>Glejser</i> | 53 |
| Tabel 4.20 | Pemilihan model terbaik berdasarkan RMSE outsampel..... | 54 |

BAB I

PENDAHULUAN

1.1 Latar Belakang

Cuaca merupakan suatu kondisi udara di suatu tempat pada saat yang relatif singkat yang meliputi kondisi suhu, kelembaban, serta kecepatan angin sebagai komponen utamanya. Pencarian metode untuk memprediksi cuaca adalah kegiatan yang akhir-akhir ini banyak dilakukan oleh peneliti terhadap atmosfer atau cuaca. Karena banyaknya tuntutan dari berbagai pihak yang membutuhkan informasi kondisi atmosfer yang lebih cepat, lengkap, dan akurat. Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) sebagai perusahaan negara yang bertugas sebagai pengamat cuaca mampu memprediksikan cuaca melalui metode konvensional baik itu metoda statistik maupun dinamik yang mencakup radius 5 sampai 10 km untuk 1 titik pengamatan di wilayah yang dapat diprediksikan.

Cuaca selalu berubah, termasuk didalamnya kecepatan angin karena itu disadari bahwa memperkirakan cuaca tidak mudah karena disamping harus memahami sifat atmosfer atau dinamika atmosfer, diperlukan juga pengalaman dan keberanian dalam membuat keputusan suatu prakiraan. Namun demikian, pendekatan-pendekatan dalam membuat prakiraan cuaca sudah banyak dikembangkan oleh negara maju meskipun pendekatan-pendekatan tersebut tidak sepenuhnya sesuai dengan keadaan cuaca pada lintang tropis seperti Indonesia.

Perairan Pulau Bawean merupakan pusat bagi kehidupan nelayan disana. Kondisi cuaca yang buruk akan berakibat terhadap menganggurnya para nelayan untuk melaut. Kecepatan angin menjadi indikator penting bagi nelayan dalam mencari ikan dilaut. Perahu yang kecil tidak bisa berangkat apabila kecepatan angin disekitar pulau buruk. Kondisi angin belakangan ini semakin tidak menentu dan pada saat-saat tertentu kecepatan angin sangat ekstrim yang menyebabkan aktifitas nelayan di Pulau Bawean terpaksa kembali dihentikan.

Kecepatan angin merupakan kecepatan udara bergerak horizontal pada ketinggian tertentu. Perbedaan tekanan udara antara asal dan tujuan angin merupakan faktor yang menentukan kecepatan angin. Menurut Tjasjono (1995) kecepatan angin ditunjukkan oleh kecuraman beda tekanan. Jika beda tekanan besar maka angin menjadi kencang. Sebaliknya, jika beda tekanan kecil maka angin juga melemah.

Model fungsi transfer adalah suatu model yang menggambarkan nilai prediksi masa depan dari suatu *time series* didasarkan pada nilai-nilai masa lalu *time series* itu sendiri dan satu atau lebih variabel yang berhubungan dengan output series tersebut (wei, 2006). Data kecepatan angin merupakan suatu deret *series* yang dipengaruhi oleh data sebelumnya tetapi juga dipengaruhi oleh variabel lain yaitu tekanan udara. Pemodelan kecepatan angin bisa dimodelkan dengan fungsi transfer dimana tekanan udara sebagai variabel input yang diduga mempengaruhinya.

Apabila model belum memuaskan maka akan dicoba model-model yang lain. Kecepatan angin digunakan sebagai variabel utama yang digunakan untuk memodelkan. Sehingga metode yang bisa digunakan untuk memodelkan kecepatan angin dengan tekanan udara yaitu *Vector Autoregressive* (VAR) dan regresi *time series*. VAR merupakan salah satu model *multivariate time series*. Sedangkan untuk regresi *time series* sama seperti model regresi yang lain tetapi yang menjadi variabel prediktor yaitu tekanan udara pada lag- k dan kecepatan angin lag ke- m .

Selama ini, BMKG menggunakan metode matematis untuk peramalan. Pada penelitian sebelumnya telah dilakukan penelitian tentang cuaca metode peramalan menggunakan *fuzzy clustering* (Arifin,2009). Selanjutnya Kresnawan (2009) melakukan penelitian tentang prediksi cuaca maritim menggunakan jaringan syaraf tiruan. Faulina (2011) juga melakukan penelitian kecepatan angin di Sumenep menggunakan metode *Adaptive Neuro Fuzzy Inference Systems* (ANFIS). Nurvitasari (2012) melakukan pene-

litian tentang peramalan kecepatan angin rata-rata dengan pendekatan fungsi transfer sebagai input ANFIS.

1.2 Rumusan Masalah

Dari latar belakang yang telah dikemukakan diatas, maka dapat dirumuskan beberapa permasalahan sebagai berikut :

1. Bagaimana karakteristik data kecepatan angin rata-rata dan tekanan udara di Bawean?
2. Bagaimana model Fungsi Transfer untuk peramalan data kecepatan angin rata-rata dengan variabel tekanan udara di Bawean ?
3. Bagaimana model alternative terbaik yang mungkin didapatkan dari data kecepatan angin dan tekanan tekanan udara?

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai berdasarkan permasalahan yang diteliti adalah sebagai berikut.

1. Mengetahui karakteristik data kecepatan angin rata-rata dan tekanan udara di Bawean.
2. Memperoleh model Fungsi Transfer untuk peramalan data kecepatan angin rata-rata dengan variabel tekanan udara di Bawean.
3. Mendapatkan model alternative terbaik dari data kecepatan angin dan tekanan udara.

1.4 Manfaat Penelitian

Penelitian ini diharapkan dapat menghasilkan nilai ramalan yang memiliki akurasi tinggi untuk kecepatan angin di Bawean, sehingga dapat digunakan BMKG atau institusi lain yang terkait dengan peramalan cuaca, diharapkan metode ini menjadi alternatif baru dalam melakukan peramalan cuaca terutama kecepatan angin, karena kecepatan angin tidak hanya dipengaruhi oleh kece-

patan angin itu sendiri, melainkan ada variabel lain yang mempengaruhi, yaitu tekanan udara.

BAB II

TINJAUAN PUSTAKA

2.1 Konsep Dasar Time Series

Deret berkala time series adalah serangkaian variabel yang diamati pada interval waktu ruang yang sama ditujukan sebagai sebuah deret berkala. Jika time series maka akan dapat diketahui apakah peristiwa, kejadian, gejala/variabel yang diamati itu berkembang mengikuti pola-pola perkembangan yang teratur, maka dapat dibuat suatu model yang cukup kuat mengenai tingkah laku gejala tersebut dan selanjutnya berdasarkan model dapat dibuat random untuk beberapa periode kedepan (Makridakis, Wheelwright, dan McGee, 1999).

Time series adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadiannya dengan interval waktu yang tetap, dimana setiap pengamatan dinyatakan sebagai variabel random Z_t yang didapatkan berdasarkan indeks waktu tertentu (t_i) sebagai urutan waktu pengamatan, sehingga penulisan data time Series adalah $Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_{tn}$ (Wei, 2006).

2.2 Kestasioneran Data

Stasioneritas *time series* berarti bahwa tidak terdapat pertumbuhan atau penurunan pada data. Data secara kasarnya harus horizontal sepanjang sumbu waktu. Dengan kata lain, fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan ragam dari fluktuasi tersebut pada pokoknya tetap konstan setiap waktu, maka data tersebut dapat dibuat dengan cara melakukan penggunaan metode pembeda atau *differencing* (Makridakis dkk, 1999).

Dan jika data tidak stasioner dalam varians, maka dapat distabilkan dengan menggunakan transformasi. Salah satu adalah dengan melakukan transformasi Box Cox (Wei, 2006).

2.2.1 Data Stasioner

Data stasioner adalah data runtun waktu yang paling sederhana dan sangat bermanfaat untuk menjelaskan beragam jenis analisis runtun waktu lainnya. Dan stasioner tidak terdapat pertumbuhan atau penurunan pada data. Data secara kasar-nya harus horizontal sepanjang sumbu waktu. Dengan kata lain, fluktuasi data berada disekitar nilai rata-rata yang konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut pada pokoknya tetap konstan setiap waktu (Makridakis dkk, 1999).

2.2.2 Data Non Stasioner

Data non stasioner muncul karena ada banyak data diberbagai bidang yang tidak stasioner, terutama dibidang ekonomi dan bisnis. Dalam suatu *time series* dapat terjadi ketidakstasioneran baik dalam mean maupun varians. Adapun penjelasan mengenai dalam mean maupun varians dapat dijelaskan sebagai berikut:

1. Non Stasioner Dalam Mean

Time series yang tidak stasioner dalam mean berarti meannya dipengaruhi oleh waktu pengamatan. Cara yang digunakan untuk mengatasi keadaan ini adalah dengan melakukan pembedaan (*differencing*) pada data *time series* yang biasa dirumuskan sebagai berikut :

$$Y_t = Z_t - Z_{t-1} \quad (2.1)$$

dimana Y_t merupakan nilai *series* setelah dilakukan pembedaan atau *differencing* (Cryer, 1986).

2. Non Stasioner Dalam Varians

Pada kasus non stasioner dalam varians Z_t berubah sejalan dengan perubahan level varian $(Z_t) = c f(\mu_t)$. Untuk nilai konstan c yang positif dan fungsi f dibutuhkan transformasi $T(Z_t)$ yang memiliki nilai varians konstan yang disebut sebagai transformasi varians. Umumnya untuk menstabilkan varians maka dapat menggunakan alat transformasi Box-cox (Wei, 2006) sebagai berikut.

$$T(Z_t) = Z_t^{(\lambda)} = \frac{(Z_t^\lambda - 1)}{\lambda} \quad (2.2)$$

Dimana λ = parameter transformasi

$Z_t^{(\lambda)}$ = pengamatan hasil transformasi.

Menurut Wei (2006) ketentuan-ketentuan yang menyertai proses menstabilkan (stasioner) varians adalah sebagai berikut :

- Transformasi hanya boleh dilakukan sebelum proses *differencing*.
- Transformasi boleh dilakukan untuk series Z_t yang bernilai positif.
- Nilai λ dipilih berdasarkan SS (*Sums of Square*) residual dari series hasil transformasi. Nilai SS terkecil memberikan hasil transformasi berupa series dengan varians yang konstan.

Perhitungan SS (*Sums of Square*) adalah sebagai berikut :

$$S(\lambda) = \sum_{t=1}^n (Z_t(\lambda) - \mu)^2 \quad (2.3)$$

Tabel 3.1 Transformasi Box Cox

| Nilai Estimasi λ | Transformasi |
|--------------------------|--------------------------------|
| -1,0 | $1 / Z_t$ |
| -0,5 | $1 / \sqrt{Z_t}$ |
| 0,0 | $\text{Ln } Z_t$ |
| 0,5 | $\sqrt{Z_t}$ |
| 1,0 | Z_t (tidak ada transformasi) |

(Sumber : Wei, 2006)

Data *time series* dikatakan sudah stasioner dalam mean jika nilai meannya konstan. Data dikatakan stasioner dalam *time series* plot jika berada di sekitar garis yang sejajar dengan sumbu waktu (t). Data yang tidak stasioner dalam mean perlu dilakukan *differencing* atau pembedaa. Jika suatu data telah dilakukan transformasi berkali-kali namun belum stasioner dalam mean maupun

varians maka cara mengatasinya adalah dengan cara melakukan pembedaan (*differencing*) sebelum ditransformasi.

2.3 Metode ARIMA Box-Jenkins

Sering terdapat waktu senjang (*Time lag*) antara kesadaran akan peristiwa atau kebutuhan mendatang dengan peristiwa itu sendiri. Adanya waktu tenggang (*Lead Time*) ini merupakan alasan utama bagi perencanaan dan peramalan. Jika waktu tenggang ini nol atau sangat kecil, maka perencanaan tidak diperlukan. Jika waktu tenggang ini panjang dan hasil peristiwa akhir bergantung pada faktor-faktor yang dapat diketahui, maka perencanaan dapat memegang peranan penting. Dalam situasi seperti ini peramalan diperlukan untuk menetapkan kapan suatu peristiwa akan terjadi atau timbul, sehingga tindakan yang tepat dapat dilakukan. Model-model *Autoregressive Intergrated Moving Average* (ARIMA) telah banyak dipelajari secara mendalam oleh George Box dan Gwilyn Jenkins (1976) dan nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis deret berkala, peramalan dan pengendalian (Makridakis dkk, 1999).

2.3.1 Identifikasi Model ARIMA Box-Jenkins

Pemeriksaan kestasioneran dapat dilakukan dengan bantuan *time series* plot dan plot fungsi autokorelasi (plot ACF). *Time series* adalah penyajian data dengan menggunakan *scatter* plot, sumbu tegak adalah nilai variabel *time series* dan sumbu datar adalah waktu. Sedangkan plot ACF adalah penyajian nilai korelasi antara pengamatan ke- t dengan pengamatan ke $t-k$ untuk nilai $k = 1, 2, \dots$

Di dalam identifikasi model dilakukan penentuan model awal. Alat yang dipakai untuk menentukan model awal adalah plot ACF dan PACF. Plot PACF adalah penyajian nilai korelasi parsial untuk nilai $k = 1, 2, \dots$. Korelasi parsial adalah korelasi antara Z_t dengan Z_{t+k} setelah pengaruh Z_1, \dots, Z_{t-k-1} dihilangkan.

Tabel 3.2 Identifikasi Model ARIMA berdasarkan ACF dan PACF

| Proses | ACF | PACF |
|----------------------|---|---|
| AR (p) | <i>Dies Down</i> (turun eksponensial) | <i>Cut off after</i> lag p (terpotong setelah lag- p) |
| MA (q) | <i>Cut off after</i> lag q (terpotong setelah lag- q) | <i>Dies Down</i> (turun eksponensial) |
| ARMA (p, q) | <i>Dies Down</i> (turun eksponensial menuju nol setelah lag $q-p$) | <i>Dies Down</i> (turun eksponensial menuju nol setelah lag $p-q$) |
| White Noise (Random) | Tidak ada yang signifikan (tidak ada yang keluar batas) | Tidak ada yang signifikan (tidak ada yang keluar batas) |

(Sumber : Wei, 2006)

a. Model Autoregressive (AR)

Model *autoregressive* (AR) berorde p menyatakan suatu model dimana pengamatan waktu t berkombinasi linier dengan pengamatan sebelumnya $t-1, t-2, \dots, t-p$. Bentuk persamaan model AR (p) adalah :

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.4)$$

untuk proses *autoregressive* orde pertama AR (1) ditulis :

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + a_t \quad (2.5)$$

b. Model Moving Average (MA)

Model *moving average* orde q atau MA (q) terbentuk dari waktu pengamatan t merupakan penyimpangan saat $t, t-1, t-2$ sampai dengan penyimpangan waktu $t-q$. Bentuk persamaan model MA (q) dapat ditulis sebagai berikut :

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.6)$$

untuk proses *moving average* orde pertama MA (1) ditulis :

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} \quad (2.7)$$

c. Model *Autoregressive Moving Average* (ARMA)

Model campuran *autoregressive* dan *moving average* dapat ditulis ARMA (p,q) atau ARIMA (p,0,q) merupakan model gabungan dari AR (p) dan MA (q), dengan bentuk persamaan sebagai berikut :

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.8)$$

d. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA (p,d,q) merupakan model campuran AR-MA (p,q) yang mengalami perbedaan orde d. Secara umum persamaan model ARIMA (p,d,q) adalah :

$$\phi_p(B)(1-B)^d \dot{Z}_t = \theta_q(B)a_t$$

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

misalkan proses ARIMA (1,1,1) dapat dirumuskan sebagai berikut :

$$(1 - \phi_1 B)(1 - B)\dot{Z}_t = (1 - \theta_1 B)a_t$$

$$\dot{Z}_t = (1 + \phi_1)\dot{Z}_{t-1} - \phi_1 \dot{Z}_{t-2} + a_t - \theta_1 a_{t-1} \quad (2.9)$$

2.3.2 Estimasi Parameter

Sebelum melakukan estimasi parameter, terlebih dahulu menaksir model dugaan yang sudah stasioner yaitu model AR-MA(p, q) pada Persamaan (8) sebagai berikut.

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

Menurut Wei (2006) ada empat cara dalam melakukan estimasi parameter model ARIMA yaitu metode *moments*, *maximum likelihood*, *nonlinear estimation*, dan *ordinary least square*. Dalam menaksir parameter dengan menggunakan *conditional maximum likelihood estimation*. Dimana model *conditional loglikelihood function* dapat ditunjukkan

$$\ln L_*(\phi, \mu, \theta) = -\frac{n}{2} \ln 2\pi \sigma_a^2 - \frac{S_*(\phi, \mu, \theta)}{2\sigma_a^2} \quad (2.10)$$

dimana

$$S_*(\phi, \mu, \theta) = \sum_{t=1}^n a_t^2 (\phi, \mu, \theta | Z_*, a_*, Z) \quad (2.11)$$

Keterangan :

$$\begin{aligned} Z &= (Z_1, Z_2, \dots, Z_n)' \\ Z_* &= (Z_{1-p}, \dots, Z_{-1}, Z_0)' \\ a_* &= (a_{1-q}, \dots, a_{-1}, a_0)' \end{aligned}$$

Apabila diasumsikan $\{Z_t\}$ stasioner dan $\{a_t\}$ *i.idN*(0, σ_a^2) merupakan variable random maka Z_t dapat diganti dengan \bar{Z} dan ekspektasi a_t bernilai 0. Sehingga persamaannya menjadi

$$S_*(\phi, \mu, \theta) = \sum_{t=p+1}^n a_t^2 (\phi, \mu, \theta | Z) \quad (2.12)$$

dan setelah estimasi parameter ϕ, μ , dan θ , estimasi dari σ_a^2 dapat ditulis

$$\sigma_a^2 = \frac{S_*(\hat{\phi}, \hat{\mu}, \hat{\theta})}{d.f.} \quad (2.13)$$

dimana ,

$$d.f. = n - (2p - q + 1)$$

Koefisien parameter yang telah dihasilkan perlu dilakukan pengujian apakah parameter tersebut layak dimasukkan ke dalam model atau tidak dengan hipotesis sebagai berikut :

$$H_0 : \beta_i = 0$$

$$H_1 : \beta_i \neq 0$$

Statistik uji :

$$t_{hitung} = \frac{\hat{\beta}}{se(\hat{\beta})} \quad (2.14)$$

Daerah penolakan : Tolak H_0 jika $|t_{hitung}| > t_{\alpha/2, n-1}$

Keterangan :

- k = jumlah parameter dalam model
 $se(\hat{\beta})$ = standar *error* dari taksiran parameter
 $\hat{\beta}$ = taksiran parameter model AR (ϕ) atau MA (θ)

2.3.3 Diagnostic Checking

Uji kesesuaian model ini terdiri dari dua asumsi yakni asumsi *white noise* dan asumsi kenormalan, sebagai berikut :

a. Menguji *white noise*

Menguji residual dengan menggunakan uji L-jung box chi-square dengan hipotesis sebagai berikut :

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$$

$$H_1 : \text{Minimal ada satu } \rho_k \neq 0 ; k = 1, 2, \dots, K$$

Statistik uji :

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.15)$$

Daerah penolakan : $Q > \chi^2$, df = $K-p-q$ yang artinya bahwa residual tidak memenuhi asumsi *white noise*.

b. Asumsi Kenormalan

Untuk mengetahui apakah residual berdistribusi normal atau tidak dengan pengujian *Kolmogorov Smirnov* hipotesisnya sebagai berikut.

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

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

$$\text{Statistik uji : } D = \sup_x |s(x) - F_0(x)|$$

dimana :

$s(x)$: Distribusi frekwensi kumulatif observasi.

$F_0(x)$: Fungsi distribusi frekwensi kumulatif teoritis di bawah hipotesis nol.

Daerah penolakan : Tolak H_0 jika $D > (D_{(u/n)})$.

2.3.4 Pemilihan Model Terbaik

Pemilihan model terbaik atau seleksi model dilakukan jika terdapat lebih dari satu model *time series* yang layak dipakai yaitu dengan menggunakan dua pendekatan diantaranya pendekatan out sampel dan in sampel.

1. Berdasarkan In sampel

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

Adalah suatu kriteria pemilihan model terbaik yang diperkenalkan oleh Akaike pada tahun 1973 dengan mempertimbangkan banyaknya parameter dalam model. Menurut Wei (1990), semakin kecil nilai AIC maka semakin besar kemungkinan suatu model tersebut dipilih. Nilai AIC dapat dihitung dengan :

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

Dengan : m = banyaknya parameter dalam model.

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

n = banyaknya observasi (pengamatan).

b. SBC (*Schwartz's Bayessin Criterion*)

Semakin kecil nilai SBC semakin besar kemungkinan model tersebut dipilih. Nilai SBC dapat dihitung :

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

Dengan : m = banyaknya parameter dalam model.

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

n = banyaknya observasi (pengamatan).

2. Berdasarkan Out sampel

Kriteria pemilihan model berdasarkan out sampel menggunakan MAPE (*Mean Absolute Percentage Error*) yaitu persentase kesalahan absolute rata-rata yang memberikan petunjuk seberapa besar kesalahan peramalan dibandingkan dengan nilai sebenarnya. MAPE dapat dihitung dengan rumus :

$$MAPE = \sum_{t=1}^n \frac{|(Y_t - \hat{Y}_t) / Y_t|}{n} \times 100\% \quad (2.16)$$

2.4 Fungsi Transfer

Model fungsi transfer adalah suatu model yang menggambarkan nilai prediksi masa depan dari suatu *time series* didasarkan pada nilai-nilai masa lalu *time series* itu sendiri dan satu atau lebih variable yang berhubungan dengan output series tersebut (wei, 2006). Bentuk umum persamaan model fungsi transfer *single input* (x_t) dengan *single output* (y_t) adalah sebagai berikut.

$$y_t = v(B)x_{t-b} + \eta_t \quad (2.17)$$

dimana :

y_t = representasi dari deret output yang stasioner

x_t = representasi dari deret input yang stasioner

η_t = representasi dari komponen error (deret noise) yang mengikuti suatu model ARMA tertentu

Bentuk persamaan diatas dapat pula dituliskan dalam bentuk sebagai berikut.

$$v(B) = \frac{\omega(B)B^b}{\delta(B)} \text{ dan } \eta_t = \frac{\theta(B)}{\phi(B)} a_t$$

$$y_t = \frac{\omega(B)B^b}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \quad (2.18)$$

Keterangan :

$$\omega(B) = \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s$$

$$\delta(B) = (1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_y B^y)$$

b = periode sebelum deret input mulai berpengaruh terhadap deret output

s = lama periode deret output mulai dipengaruhi oleh deret input

r = lama periode deret output mulai dipengaruhi oleh masa lalunya

2.5 Pembentukan Model Fungsi Transfer

2.5.1 Perhitungan *Cross-Correlation Function*(CCF)

Dalam menghitung korelasi silang (*Cross Correlation Function*) dan autokorelasi untuk deret input dan output harus diputihkan (*prewhitening*). Dalam permodelan ARIMA univariat, koefisien autokorelasi merupakan statistik kunci dalam mene-

tapkan model. Sedangkan pada fungsi transfer, autokorelasi mempunyai peranan dalam menentukan koefisien korelasi silang. Hubungan antar lag dalam time series penting untuk dipelajari, sehingga pemeriksaan CCF dilakukan untuk menduga order b, s, r dari model fungsi transfer (Makridakis dkk, 1999).

Sedangkan untuk *cross correlation function* x_t dan y_t sebagai berikut.

$$\rho_{xy}(k) = \frac{\gamma_{xy}(k)}{\sigma_x \sigma_y} \quad (2.19)$$

$$k = 0, \pm 1, \pm 2, \dots,$$

dimana fungsi taksirannya

$$\hat{\rho}_{xy}(k) = \frac{\hat{\gamma}_{xy}(k)}{S_x S_y}, \quad k = 0, \pm 1, \pm 2, \dots,$$

dimana

$$\hat{\gamma}_{xy}(k) = \begin{cases} \frac{1}{n} \sum_{t=1}^{n-k} (x_t - \bar{x})(y_{t+k} - \bar{y}), & k \geq 0 \\ \frac{1}{n} \sum_{t=1-k}^n (x_t - \bar{x})(y_{t+k} - \bar{y}), & k < 0 \end{cases} \quad (2.20)$$

$$S_x = \sqrt{\hat{\gamma}_{xy}(0)} S_y = \sqrt{\hat{\gamma}_{yy}(0)}$$

Untuk menguji apakah nilai-nilai tertentu dari $\rho_{xy}(k)$ sama dengan nol, dengan membandingkan sampel $CCF \hat{\rho}_{xy}(k)$ dengan *standard error*. Dengan asumsi normal, Bartlett(1995) menjabarkan bahwa nilai dugaan varians dan kovarians antara dua sampel korelasi silang $\hat{\rho}_{xy}(k)$ dan $\hat{\rho}_{xy}(k+j)$. Sehingga nilai kovarian dapat ditunjukkan (Wei, 2006).

$$\begin{aligned} Cov[\hat{\rho}_{xy}(k), \hat{\rho}_{xy}(k+j)] &\simeq (n-k)^{-1} \sum_{t=1}^{n-k} \{ \rho_{xx}(i) \rho_{yy}(i+j) + \rho_{xy}(i+j+k) \rho_{xy}(k-i) \\ &+ \rho_{xy}(k) \rho_{xy}(k+j) \left[\rho_{xy}^2(i) + \frac{1}{2} \rho_{xx}^2(i) + \frac{1}{2} \rho_{yy}^2(i) \right] \\ &- \rho_{xy}(k) [\rho_{xy}(i) \rho_{xy}(i+k+j) + \rho_{xy}(-i) \rho_{xy}(i+k+j)] \\ &- \rho_{xy}(k+j) [\rho_{xx}(i) \rho_{xy}(i+k) + \rho_{xy}(-i) \rho_{xy}(i+k)] \} \quad (2.21) \end{aligned}$$

dan nilai varians

$$\begin{aligned} \text{var}[\hat{\rho}_{xy}(k)] \approx (n-k)^{-1} \sum_{i=-\infty}^{\infty} \{ & \rho_{xx}(i)\rho_{yy}(i) + \rho_{xy}(k+i)\rho_{xy}(k-i) \\ & + \rho_{xy}^2(k) \left[\rho_{xy}^2(i) + \frac{1}{2}\rho_{xy}^2(i) + \frac{1}{2}\rho_{xy}^2(i) \right] \\ & - 2\rho_{xy}(k) [\rho_{xy}(i)\rho_{xy}(i+k) + \rho_{xy}(-1)\rho_{yy}(i+k)] \} \end{aligned} \quad (2.22)$$

Jika x_t dan y_t tidak berkorelasi dan x_t white noise maka akan menjadi

$$\begin{aligned} \text{covar}[\hat{\rho}_{xy}(k), \hat{\rho}_{xy}(k+j)] & \approx (n-k)^{-1} \hat{\rho}_{yy}(j) \\ & \text{dan} \\ \text{var}[\hat{\rho}_{xy}(k)] & \approx (n-k)^{-1} \end{aligned}$$

2.5.2 Identifikasi Model Fungsi Transfer

Menurut Wei(2006) dalam mengidentifikasi model fungsi transfer dapat dilakukan langkah-langkah sebagai berikut.

1. *Prewhitening* deret input (x_t),

$$\begin{aligned} \phi_x(B)x_t &= \theta_x(B)\alpha_t \\ \alpha_t &= \frac{\phi_x(B)}{\theta_x(B)} x_t \end{aligned} \quad (2.23)$$

2. *Prewhitening* deret input (y_t)

$$\beta_t = \frac{\phi_x(B)}{\theta_x(B)} y_t \quad (2.24)$$

3. Menghitung sampel korelasi silang (CCF), $\hat{\rho}_{\alpha\beta}(k)$ antara α_t dan β_t untuk \hat{v}_k

$$\hat{v}_k = \frac{\hat{\sigma}_\beta}{\hat{\sigma}_\alpha} \hat{\rho}_{\alpha\beta}(k)$$

4. Penetapan (b, r, s) untuk model fungsi transfer yang menghubungkan deret input dan output.

$$\begin{aligned} \omega(B) &= \omega_0 - \omega_1 B - \omega_2 B^2 - \dots - \omega_s B^s \\ \delta(B) &= (1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_y B^y) \end{aligned}$$

sehingga nilai dugaan untuk $v(B)$ menjadi

$$\hat{v}(B) = \frac{\hat{\omega}(B)}{\hat{\delta}(B)} B^b \quad (2.25)$$

Setelah menghitung korelasi silang (CCF) maka dari nilai tersebut akan ditentukan nilai (r, s, b). Tiga parameter kunci di da-

lam fungsi transfer adalah (r, s, b) , dimana r menunjukkan derajat fungsi $\delta(B)$, s menunjukkan derajat fungsi $\omega(B)$, dan b menunjukkan keterlambatan yang dicatat pada subtranskrip dari x_{t-b} . Nilai b menyatakan bahwa y tidak dipengaruhi oleh x_t sampai periode $t+b$. Nilai s menyatakan untuk berapa lama deret output (y) secara terus-menerus dipengaruhi oleh nilai-nilai baru dari deret input (x) (Makridakis dkk, 1999).

Tiga prinsip petunjuk dalam menentukan nilai yang tepat untuk (r, s, b) :

- a. Sampai lag waktu ke- b , korelasi-silang tidak akan berbeda dari nol secara signifikan.
- b. Untuk s time lag selanjutnya, korelasi silang tidak akan memperlihatkan adanya pola yang jelas.
- c. Untuk r time lag selanjutnya, korelasi silang akan memperlihatkan suatu pola yang jelas.

5. Penaksiran deret *noise*

$$\begin{aligned}\eta_t &= y_t - \hat{v}(B)x_t \\ &= y_t - \frac{\hat{\omega}(B)}{\hat{\delta}(B)}B^b x_t\end{aligned}\quad (2.26)$$

Model yang sesuai untuk *noise* kemudian dapat diidentifikasi dengan memeriksa sampel ACF dan PACF atau dengan alat identifikasi univariate time series yang lainnya, memberikan hasil sebagai berikut.

$$\phi(B)n_t = \theta(B)a_t \quad (2.27)$$

2.5.3 Penaksiran Parameter Model Fungsi Transfer

Penaksiran parameter model fungsi transfer sama dengan univariate yaitu dengan metode *maximum likelihood estimation*. Parameter yang akan ditaksir yaitu $\delta = (\delta_1, \dots, \delta_r)'$, $\omega = (\omega_0, \omega_1, \dots, \omega_s)'$, $\phi = (\phi_1, \dots, \phi_p)'$, $\theta = (\theta_1, \dots, \theta_q)'$ dan σ_a^2 . Dimana penaksiran dimulai dari model dugaan awal yaitu

$$y_t = \frac{\omega(B)}{\delta(B)}x_{t-b} + \frac{\theta(B)}{\phi(B)}a_t, \quad \delta(B)\phi(B)y_t = \phi(B)\omega(B)x_{t-b} + \delta(B)\theta(B)a_t \quad (2.28)$$

atau ekuivalen dengan,

$$c(B)y_t = d(B)x_{t-b} + e(B)a_t \quad (2.29)$$

dimana

$$\begin{aligned} c(B) &= \delta(B)\phi(B) \\ &= (1 - \delta_1 B - \dots - \delta_r B^r)(\phi_0 - \phi_1 B - \dots - \phi_p B^p) \\ &= (1 - c_1 B - c_2 B^2 - \dots - c_{p+r} B^{p+r}) \end{aligned}$$

$$\begin{aligned} d(B) &= \phi(B)\omega(B) \\ &= (1 - \phi_1 B - \dots - \phi_p B^p)(\omega_0 - \omega_1 B - \dots - \omega_s B^s) \\ &= (d_0 - d_1 B - d_2 B^2 - \dots - d_{p+s} B^{p+s}) \end{aligned}$$

$$\begin{aligned} e(B) &= \delta(B)\theta(B) \\ &= (1 - \delta_1 B - \dots - \delta_r B^r)(1 - \theta_1 B - \dots - \theta_q B^q) \\ &= (1 - e_1 B - e_2 B^2 - \dots - e_{r+q} B^{r+q}) \end{aligned}$$

sehingga,

$$\begin{aligned} a_t &= y_t - c_1 y_{t-1} - \dots - c_{p+r} y_{t-p-r} \\ &\quad - d_0 x_{t-b} + d_1 x_{t-b-1} + \dots + d_{p+s} x_{t-b-p-s} \\ &\quad + e_1 a_{t-1} + \dots + e_{r+q} a_{t-r-q} \end{aligned}$$

dimana c_i , d_j , dan e_k merupakan fungsi dari δ_i , ω_j , ϕ_k , dan θ_l . Dengan asumsi a_t deret white noise dan berdistribusi normal $N(0, \sigma_a^2)$. Model likelihood dari fungsi transfer

$$L(\delta, \omega, \phi, \theta, \sigma_a^2 | b, x, y, x_0, y_0, a_0) = (2\pi\sigma_a^2)^{-\frac{n}{2}} \exp\left[-\frac{1}{2\sigma_a^2} \sum_{t=1}^n a_t^2\right] \quad (2.30)$$

Dimana,

$$\begin{aligned} S(\delta, \omega, \phi, \theta | b) &= \sum_{t=1}^n a_t^2 \\ t_0 &= \max(p+r+1, b+p+s+1) \end{aligned} \quad (2.31)$$

2.5.4 Pemeriksaan Diagnosa

Wei (2006) menjelaskan bahwa untuk sebuah model fungsi transfer yang layak maka koefisien korelasi silang antara a_t dengan a_t seharusnya tidak menunjukkan suatu pola tertentu dan berada diantara dua kesalahan standar $2(n-k)^{-1/2}$. Sebuah uji Ljung-Box dapat digunakan untuk mengetahui kelayakan model fungsi transfer di bawah hipotesis nol yaitu korelasi silang antara

α_t dan α_t tidak berbeda nyata dari nol, dengan statistik uji sebagai berikut.

$$Q = m(m + 2) \sum_{k=0}^K \frac{r_{at,at}^2(k)}{m-k} \quad (2.32)$$

Box dan Jenkins (1976) menyatakan bahwa jika fungsi autokorelasi nilai sisa menunjukkan suatu pola dapat dikatakan model fungsi transfer tidak cukup layak atau jika korelasi silang menunjukkan ketidaklayakan model fungsi transfer kemungkinan karena kesalahan dalam mengidentifikasi model untuk *noise* (nt). Model untuk *noise* dikatakan layak jika koefisien ACF dan PACF dari *noise* tidak menunjukkan suatu pola tertentu (Wei, 2006). Ljung-Box digunakan untuk menguji kelayakan model *noise* dibawah hipotesis nol yaitu autokorelasi nilai sisa (α_t) tidak berbeda nyata dari nol, dengan menghitung statistik Q sebagai berikut.

$$Q = m(m + 2) \sum_{k=1}^K \frac{r_k^2}{m-k} \quad (2.33)$$

dimana :

$$m = n - t_0 + 1$$

r_k = koefisien autokorelasi α_t pada lag-k

$$t_0 = \max(p+r+1, p+s+1)$$

K = lag maksimum

m = jumlah parameter yang diduga dalam model

2.6 Beberapa Metode Alternatif

Setiap metode statistika yang digunakan dalam menganalisa suatu permasalahan belum tentu mendapatkan hasil yang baik. Apabila metode tersebut menghasilkan kesimpulan kurang baik maka dilakukan analisa dengan menggunakan metode yang lain. Dalam penelitian ini metode alternative yang mungkin bisa digunakan dalam menganalisa permasalahan yang ada pada penelitian ini diantaranya yaitu *Vector Autoregressive* (VAR) dan regresi time series.

2.6.1 *Vector Autoregressive*

Model *Vector Autoregressive* (VAR) merupakan bagian dari model *multivariate time series*. Pemodelan VAR tidak jauh berbeda dengan model *Autoregressive* (AR), pada intinya model AR

diidentifikasi dari fungsi PACF dalam menentukan orde ke- p , sedangkan model VAR diidentifikasi dari MPACF. Dalam VAR asumsi yang harus dipenuhi adalah sama dengan AR, yaitu data harus stasioner dalam varians dan mean serta *error white noise*. Bentuk umum dari VAR (p) adalah sebagai berikut (Wei, 2006) :

$$\left(\mathbf{I} - \Phi_1 B - \dots - \Phi_p B^p \right) \mathbf{Z}_t = \mathbf{a}_t \quad (2.34)$$

dimana : $\mathbf{Z}_t : \mathbf{Z}_t - \boldsymbol{\mu}$

\mathbf{a}_t : Vektor error

Φ : Parameter VAR dengan ukuran matrik $k \times k$

Identifikasi model VAR awal dapat dilakukan dengan melihat plot MACF dan MPACF atau melalui nilai AIC terkecil (Enders, 1995)

Jika diberikan suatu vektor *time series* sebanyak n observasi Z_1, Z_2, \dots, Z_n maka matriks korelasi sampelnya adalah (Wei, 2006) :

$$\hat{\boldsymbol{\rho}}(k) = [\hat{\rho}_{ij}(k)] \quad (2.35)$$

dimana $\hat{\rho}_{ij}(k)$ adalah sampel *cross-correlations* dari komponen deret ke i dan j yaitu :

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{i,t} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{\left[\sum_{t=1}^n (Z_{i,t} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{j,t} - \bar{Z}_j)^2 \right]^{1/2}} \quad (2.36)$$

dan \bar{Z}_i dan \bar{Z}_j merupakan mean sampel dari komponen deret data yang bersesuaian.

Sampel matriks autokorelasi sangat berguna dalam menentukan orde dari MA proses. Tiao dan Box dalam Wei (2006) memperkenalkan metode yang mudah untuk meringkas sampel korelasi, yaitu dengan mengenali simbol (+), (-), dan (\cdot) pada posisi matriks korelasi sampel ke (i, j) yaitu :

1. Simbol “+” apabila nilai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali standar error.

2. Simbol “-“ apabila nilai $\hat{\rho}_{ij}(k)$ lebih kecil dari -2 kali standar error.
3. Simbol “.” apabila nilai $\hat{\rho}_{ij}(k)$ terletak diantara -2 dan 2 standar error.

Pada dasarnya prinsip dalam mengidentifikasi model vektor *time series* hampir sama dengan *univariate time series*. Untuk mengidentifikasi model VAR(p) dapat menggunakan *partial autoregression matrices* atau matriks parsial autoregresi setelah ditransformasi dari data tidak stasioner menjadi stasioner. Fungsi parsial autoregresi digunakan untuk mengidentifikasi model AR univariat namun dapat pula diterapkan pada data multivariat (Wei, 2006).

$$\phi_{kk} = \frac{\text{Cov}[(Z_t - \hat{Z}_t), (Z_{t+k} - \hat{Z}_{t+k})]}{\sqrt{\text{Var}(Z_t - \hat{Z}_t)} - \sqrt{\text{Var}(Z_{t+k} - \hat{Z}_{t+k})}} \quad (2.37)$$

Tiao dan Box dalam Wei (2006) mendefinisikan bahwa matriks parsial autoregresi pada lag ke- s dinotasikan dengan $\mathcal{P}(s)$ dimana $\mathcal{P}(s)$ sama dengan $\Phi_{s,s}$ dalam regresi linier multivariat.

$$Z_{t+s} = \Phi_{s,1}Z_{t+s-1} + \Phi_{s,2}Z_{t+s-2} + \dots + \Phi_{s,s}Z_t + e_{s,t+s} \quad (2.38)$$

dimana $e_{s,t+s}$ merupakan error, dan $m \times m$ koefisien matrik $\Phi_{s,k}$, $k = 1, 2, \dots, s$.

Seperti halnya fungsi parsial autokorelasi untuk kasus univariat, fungsi matriks parsial autoregresi $\mathcal{P}(s)$ juga *cut off* untuk vektor AR (Wei, 2006).

Selain menggunakan plot MACF dan MPACF, identifikasi model VAR dapat dilakukan melalui pemilihan nilai AIC. Orde p dipilih jika kriteria AIC memiliki nilai yang minimum (Enders, 1995).

$$AIC = T \log |\Sigma| + 2N \quad (2.39)$$

dimana T : banyaknya observasi
 N : jumlah parameter yang diestimasi

$|\Sigma|$: determinan matriks varians-kovarian dari residual

Proses stasioner dari vektor AR(p) dapat ditulis sebagai berikut (Wei, 2006) :

$$\mathbf{z}'_t = \boldsymbol{\tau}' + \sum_{j=1}^p \mathbf{z}'_{t-j} \boldsymbol{\Phi}'_j + \mathbf{a}'_t \quad (2.40)$$

dimana $\boldsymbol{\tau}'$ adalah vektor konstanta. Jika terdapat n observasi, untuk $t=p+1, \dots, n$, diperoleh :

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e} \quad (2.41)$$

dimana

$$\mathbf{Y} = \begin{bmatrix} Z'_{p+1} \\ \vdots \\ Z'_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} 1 & Z'_p & \cdots & Z'_1 \\ \vdots & \vdots & & \vdots \\ 1 & Z'_{n-1} & \cdots & Z'_{n-p} \end{bmatrix},$$

$$\boldsymbol{\beta} = \begin{bmatrix} \tau' \\ \Phi'_1 \\ \vdots \\ \Phi'_p \end{bmatrix}, \text{ dan } \mathbf{e} = \begin{bmatrix} a'_{p+1} \\ a'_{p+2} \\ \vdots \\ a'_n \end{bmatrix}$$

Maka penaksir koefisien regresi dengan pendekatan OLS adalah sebagai berikut :

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \quad (2.42)$$

Pengujian signifikansi parameter dilakukan dengan hipotesis sebagai berikut

$$H_0 : \phi_i = 0$$

$$H_1 : \phi_i \neq 0, i = 1, 2, \dots, p$$

Statistik uji yang digunakan adalah

$$t = \frac{\hat{\phi}_i}{s.e(\hat{\phi}_i)} \quad (2.43)$$

Tolak H_0 jika $|t| > t_{\frac{\alpha}{2}, n-p}$

dimana,

p : jumlah parameter yang ditaksir pada setiap persamaan model VAR.

n : jumlah observasi.

α : tingkat kesalahan yang dapat ditoleransi.

2.6.2 Regresi Time Series

Metode alternative kedua yang digunakan yaitu Regresi time series. Metode regresi merupakan suatu metode yang menggambarkan kecenderungan berubahnya variable predictor secara sistematis sejalan dengan berubahnya variable respon (Drapper & Smith, 1992). Regresi time series merupakan fungsi antara satu variabel respon (Y) dengan satu atau lebih variable predictor (X) dimana kedua variabel bersyarat pada waktu. Secara umum model regresi time series dapat dituliskan sebagai berikut (Wei, 2006).

$$Y_t = \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_k X_{k,t} + \varepsilon_t$$

dimana :

Y_t : variabel respon regresi time series

β_k : koefisien regresi time series ke-i

X_t : variable prediktor regresi time series

ε_t : Residual

Salah satu prosedur pendugaan model untuk regresi adalah dengan prosedur *least square* atau metode kuadrat terkecil. Konsep metode least square adalah menduga koefisien regresi β dengan meminimumkan *error*. Pendugaan parameter β dapat dituliskan sebagai berikut.

$$Y_t = \mathbf{X}_t' \boldsymbol{\beta} + \varepsilon_t \quad (2.44)$$

untuk $t = 1, 2, \dots, n$

misalkan

$$Y = [y_1 y_2 \dots y_n]^T \quad \varepsilon = [\varepsilon_1 \varepsilon_2 \dots \varepsilon_n]^T$$

$$x = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1k} \\ 1 & x_{21} & \cdots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{nk} \end{bmatrix} \quad x = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}$$

Penaksir β sebagai berikut :

$$\hat{\beta} = (X^T X)^{-1} X^T Y \quad (2.45)$$

Setelah penaksiran parameter model dilakukan pengujian dari parameter. Pengujian parameter diagnostik model merupakan pengujian dilakukan dengan tujuan untuk mengetahui signifikansi penaksir parameter yang digunakan melalui pengujian hipotesis secara serentak dan parsial.

a. *Uji Serentak*

Uji serentak atau uji ketepatan model pada dasarnya menunjukkan apakah semua variabel bebas yang dimasukkan dalam model mempunyai pengaruh secara bersama-sama terhadap variabel terikat (Walpole, 1995).

$$H_0 : \beta_1 = \beta_2 = \cdots = \beta_k = 0$$

$$H_1 : \text{Minimal terdapat satu } \beta_j \neq 0, \text{ dengan } j = 1, 2, 3, \dots, k$$

Statistik uji :

$$F = \frac{MS_{\text{regression}}}{MS_{\text{residual error}}} \quad (2.46)$$

Daerah Penolakan : Tolak H_0 , jika $F_{\text{hitung}} \geq F_{\alpha; (db1; db2)}$.

Dimana db1 adalah k dan db2 adalah n-k-1.

b. *Uji Parsial*

Uji parsial digunakan untuk mengetahui penduga parameter secara parsial apakah memiliki pengaruh atau tidak dengan asumsi bahwa variabel tidak bebas lainnya konstan (Walpole, 1995).

$$H_0 : \beta_j = 0$$

$H_1 : \beta_j \neq 0$, dimana $j = 0, 1, 2, \dots, k-1$.

Statistik uji :

$$t = \frac{\hat{\beta}}{se(\hat{\beta})} \quad (2.47)$$

Dimana $se(\hat{\beta})$ = simpangan baku bagi dugaan koefisien variabel bebas.

Daerah Penolakan : Tolak H_0 , jika $|t| > t_{(\alpha/2, n-k-1)}$, dimana n adalah banyaknya pengamatan dan k adalah jumlah parameter dalam model.

Terdapat beberapa metode yang biasanya digunakan untuk mendapatkan model terbaik, salah satu diantaranya adalah metode *stepwise*. Metode *Stepwise* merupakan gabungan dari metode *forward* dan *backward*. Variabel yang pertama kali masuk pada metode *stepwise* adalah variabel yang korelasinya tertinggi dan masih *significant* dengan variabel dependen. Kemudian variabel yang masuk berikutnya adalah variabel yang korelasi parsialnya tertinggi dan masih *significant*. Setelah variabel tertentu masuk ke dalam model maka variabel lain yang ada didalam model dievaluasi. Jika ada variabel yang tidak *significant* maka variabel tersebut dikeluarkan.

Asumsi yang harus dipenuhi dalam regresi time series yaitu residual harus IIDN (Identik, Independen, dan Distribusi Normal). Untuk mengetahui residual identik atau tidak dilihat dari ACF plot. Apabila plot residual berada di dalam batas kendali atau tidak signifikan maka residual dikatakan identik. Pengujian terhadap residual independen dilakukan dengan pengujian *glejser* yaitu dengan cara melakukan pemodelan regresi antara absolute residual dengan variabel independen. Apabila semua parameter tidak signifikan maka residual sudah independen. Pengujian residual berdistribusi normal dilakukan melalui Uji Kolmogorov-Smirnov. Adanya outlier juga mempengaruhi kebaikan dari model. Salah satu metode yang digunakan untuk menangani *outlier* yaitu regresi robust.

Regresi robust diperkenalkan oleh Andrews (1972) dan merupakan metode regresi yang digunakan ketika distribusi dari error tidak normal dan atau adanya beberapa *outlier* yang berpengaruh pada model (Ryan, 1997). Metode ini merupakan alat penting untuk menganalisa data yang dipengaruhi oleh *outlier* sehingga dihasilkan model yang robust atau *resistance* terhadap *outlier*. Suatu estimasi yang resistant adalah relatif tidak terpengaruh oleh perubahan besar pada bagian kecil data atau perubahan kecil pada bagian besar data. Beberapa metode estimasi dalam regresi robust diantaranya *M-Estimation*, *Least Trimmed Square* (LTS), *MM estimation*, *S estimation*, *Least Mean Square* (LMS).

2.7 Kriteria Pemilihan Model Terbaik

Untuk menentukan model terbaik dari beberapa model terpilih, digunakan kriteria *out sample* yaitu *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).

1. MAPE (*Mean Absolute Percentage Error*)

Nilai rata-rata persentase kesalahan peramalan (MAPE) dapat digunakan sebagai bahan pertimbangan dalam menentukan model yang terbaik yaitu.

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right|}{n} \times 100\% \quad (2.48)$$

dimana n adalah banyaknya periode peramalan/dugaan.

2. RMSE (*Root Mean Square Error*)

Perumusan kriteria RMSE diperoleh dari akar *Mean Square Error* (MSE) yang dinyatakan sebagai berikut.

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (Z_t - \hat{Z}_t)^2}{n}} \quad (2.49)$$

2.8 Kecepatan Angin

Angin merupakan gerakan udara yang sejajar dengan permukaan bumi. Udara bergerak dari daerah bertekanan tinggi ke daerah bertekanan rendah. Gerak rata-rata dari angin di permukaan bumi merupakan sirkulasi umum dari atmosfer. Pemahaman sirkulasi umum atmosfer dapat didekati dengan pemeriksaan pola

angin utama dan pemeriksaan berbagai daerah bertekanan rendah dan tinggi. Angin terjadi disebabkan oleh adanya beda tekanan. Sedangkan kecepatan angin ditunjukkan oleh kecuraman beda tekanan. Jika beda tekanan besar maka angin menjadi kencang. Sebaliknya, jika beda tekanan kecil maka angin juga melemah (Tjasjono, 1995).

(Halaman ini sengaja dikosongkan)

BAB III

METODOLOGI PENELITIAN

1.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang didapat dari Badan Meteorologi dan Klimatologi dan Geofisika (BMKG) di Pulau Bawean. Data yang digunakan adalah data insampel dan outsampel. Data insampel yaitu harian kecepatan angin dan tekanan udara mulai periode januari 2012 sampai dengan Desember 2013 sedangkan untuk data outsampel yaitu data pada bulan januari 2014.

1.2 Variabel Penelitian

Variabel penelitian yang digunakan dalam setiap metode berbeda. Karena dalam penelitian ini menggunakan tiga metode maka ada tiga tipe variabel yang digunakan tetapi menggunakan data yang sama. Pemilihan variabel input dan output didasarkan pada serang-kaian studi literature bahwa ada pengaruh variable lain yang mempengaruhi kecepatan angin dan penelaahan terhadap bebe-rapa hasil penelitian yang telah dilakukan. Berikut adalah variabel yang digunakan dalam fungsi transfer.

1. Variabel output (y_t) = Kecepatan angin harian di Bawean satuan (knot)
2. Variabel input (x_t) = Tekanan udara satuan (mb)

Metode kedua yang digunakan yaitu *Vector Autoregressive* (VAR). berikut merupakan variabel yang digunakan dalam analisis VAR.

1. Kecepatan angin harian di Bawean satuan knot (x_1)
2. Tekanan udara satuan mb (x_2)

Metode yang ketiga dalam penelitian ini yaitu regresi time series. Variabel yang digunakan dalam penelitian ini yaitu variabel respon kecepatan angin dan variabel prediktor melalui uji korelasi.

1.3 Metode Analisis Data

Langkah-langkah dalam penelitian ini adalah

1. Menghitung nilai mean, standar deviasi, maksimum, dan minimum dan membuat time series plot pada data kecepatan angin dan tekanan udara.
2. Melakukan permalan data dengan menggunakan analisis fungsi transfer dimana tahapannya sebagai berikut.
 - a. Tahap identifikasi model
 - Mempersiapkan deret input dan output yang stasioner
 - Pemodelan ARIMA
 - Pemutihan deret input x_t yang kemudian disebut dengan deret α_t dan deret output y_t yang kemudian disebut dengan deret β_t
 - Perhitungan autokorelasi dan korelasi silang untuk deret input dan output yang telah diputihkan
 - Identifikasi (b, s, r) untuk menduga parameter model fungsi transfer
 - Identifikasi ARMA untuk deret noise
 - b. Penaksiran parameter model
 - c. Pemeriksaan diagnostic
 - Autokorelasi residual (a_t)
 - Korelasi silang antara deret input (a_1) dengan residual (a_t)
 - d. Peramalan model fungsi transfer
3. Bila hasil pemodelan kurang memuaskan akan dicoba melakukan pemodelan-pemodelan :
 - a. Vektor autoregressive dengan variabel pertama adalah kecepatan angin dan variabel kedua adalah tekanan udara.
 - Identifikasi Kestasioneran kedua variabel terhadap varians dengan transformasi box-cox dan kestasioneran terhadap mean melalui MACF. Apabila belum stasioner terhadap varians maka dilakukan transformasi dan apabila belum stasioner terhadap mean maka dilakukan *differencing*.
 - Identifikasi model dugaan melalui plot MPACF.

- Estimasi model VAR dengan menggunakan MLE.
- Pemeriksaan residual *white noise* dan distribusi normal.
- Pemilihan Model terbaik dengan menggunakan kriteria AIC terkecil
- b. Regresi time series robust dengan variabel respon kecepatan angin (y).
 - Uji korelasi antara y dengan dengan kecepatan angin lag-1 dan 2 serta tekanan udara lag-1 dan 2.
 - Estimasi model dengan menggunakan OLS.
 - Pemeriksaan residual IIDN.
 - Pemeriksaan outlier. Apabila terdapat banyak outlier maka analisis dilanjutkan dengan menggunakan metode regresi robust.
 - Pemilihan model terbaik berdasarkan R-Sq dan RMSE.

(Halaman ini sengaja dikosongkan)

BAB IV ANALISIS DAN PEMBAHASAN

4.1 Deskripsi Kecepatan Angin dan Tekanan Udara

Data yang digunakan dalam penelitian ini merupakan data sekunder dari BMKG. Data tersebut yaitu data kecepatan angin (knot) sebagai variabel output dan data tekanan udara (mb) sebagai variabel input. Deskripsi dari variabel-variabel tersebut ditunjukkan pada Tabel 4.1.

Tabel 4.1 Statistika Deskriptif Variabel

| Variabel | Tahun | Mean | StDev | Minimum | Maximum |
|------------------------|-------|--------|-------|---------|---------|
| Tekanan Udara (mb) | 2012 | 1009,2 | 1,68 | 1004 | 1013,3 |
| | 2013 | 1009 | 1,46 | 1005,2 | 1012,3 |
| Kecepatan Angin (knot) | 2012 | 5,369 | 3,047 | 0,75 | 15,292 |
| | 2013 | 4,958 | 2,871 | 0,458 | 16,542 |

Tabel 4.1 menunjukkan Statistika Deskriptif dari variabel input dan output pada tahun 2012 dan 2013. Rata-rata tekanan udara perhari pada tahun 2012 di perairan pulau Bawean yaitu 1009,2 mb. Pada tahun 2013 rata-rata dari Tekanan Udara lebih kecil yaitu sebesar 1009 mb. Kecepatan angin rata-rata harian untuk tahun 2012 yaitu sebesar 5,369 knot, sedangkan untuk tahun 2013 mengalami penurunan dengan kecepatan angin rata-rata harian sebesar 4,958 knot. Deviasi standar dari tekanan udara tertinggi pada tahun 2012 sebesar 1,68 knot artinya besarnya perubahan tekanan udara lebih tinggi pada tahun 2012 daripada tahun 2013. Perubahan kecepatan angin lebih tinggi pada tahun 2012 dengan nilai deviasi standar sebesar 3,047 knot. Tekanan udara tertinggi terjadi pada tahun 2012 sebesar 1013,3 mb, sedangkan tekanan udara terendah terjadi pada tahun 2012 dengan nilai 1004 mb. Kecepatan angin tertinggi terjadi pada tahun 2013 yaitu sebesar 16,542 knot sedangkan untuk kecepatan angin terendah terjadi pada tahun 2013 yaitu sebesar 0,458.

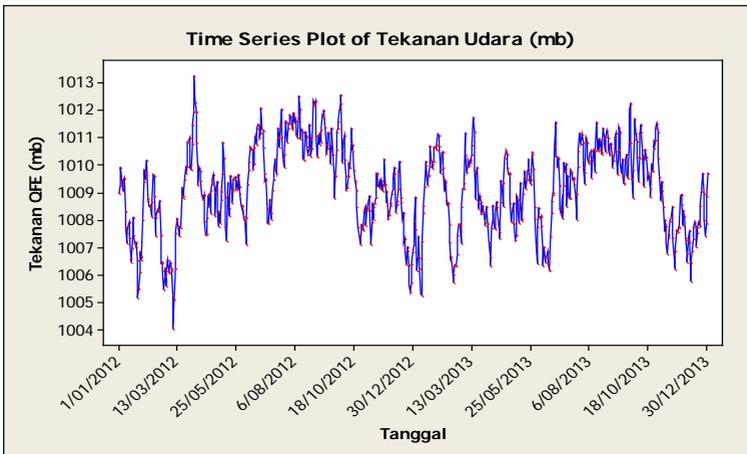
Penggunaan metode analisis fungsi transfer yaitu berdasarkan adanya hubungan antara variable input dan output. Hubungan antara variable input dan output dapat diukur melalui uji korelasi. Pengujian korelasi dapat ditunjukkan pada Tabel 4.2.

Tabel 4.2 Korelasi Antar Variabel

| Variabel | | Kecepatan angin |
|---------------|------------------|-----------------|
| Tekanan Udara | korelasi pearson | 0,235 |
| | P-Value | 0 |

Tabel 4.2 menunjukkan nilai korelasi antara kecepatan angin dengan tekanan udara. Dengan nilai $\alpha = 0,05$ dan nilai P-value sebesar 0, dapat diketahui bahwa ada korelasi antara tekanan udara dan kecepatan angin.

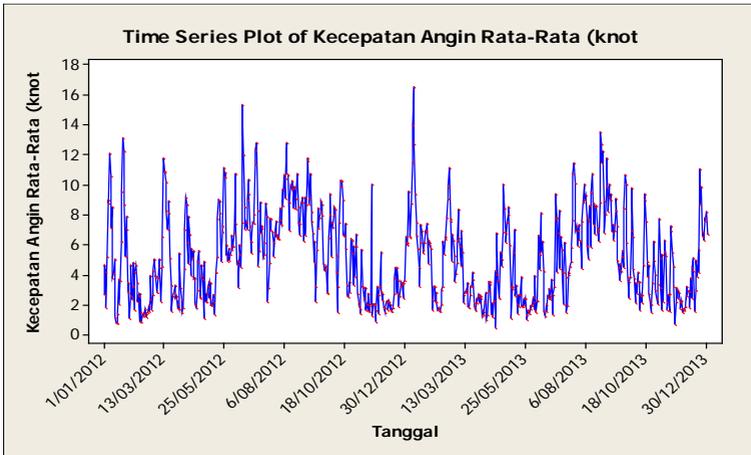
Berikut ini merupakan plot time series dari variable input dan output periode januari 2012-Desember 2013.



Gambar 4.1 Plot *Time Series* Tekanan Udara

Berdasarkan Gambar 4.1 dapat ditunjukkan bahwa data belum stasioner terhadap mean dikarenakan data cenderung tidak

berada pada nilai rata-rata dan juga terindikasi adanya outlier dan juga data belum stasioner dalam varians karena data belum sejajar dengan sumbu horizontal.



Gambar 4.2 Plot *Time Series* Kecepatan Angin

Gambar 4.2 merupakan plot time series dari data kecepatan angin harian dari periode januari 2012 sampai desember 2013. Berdasarkan tabel tersebut dapat diketahui bahwa plot-plot data berada sekitar nilai rata-rata yang artinya data sudah stasioner terhadap mean. Varians dari data kecepatan angin menunjukkan tidak stasioner juga.

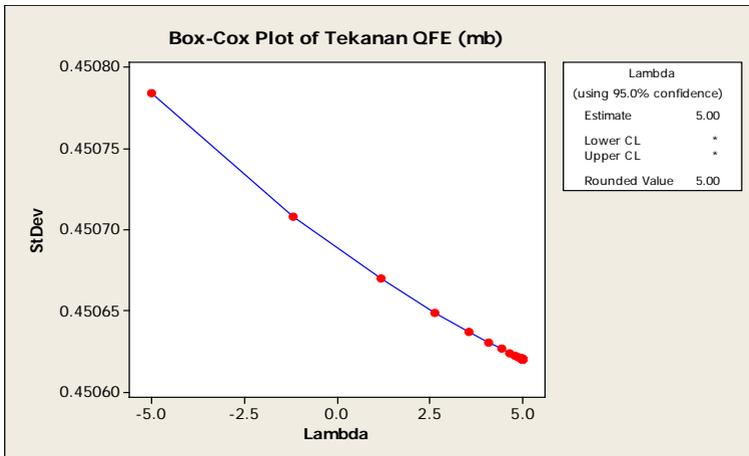
4.2 Pemodelan Kecepatan Angin (atm) dengan Metode Fungsi Transfer

Peramalan dengan metode fungsi transfer menggunakan dua macam data *series* yang terbagi menjadi deret *input* dan deret *output*. Metode fungsi transfer dalam penelitian ini akan digunakan untuk meramalkan kecepatan angin dengan deret *input* tekanan udara. Tahapan-tahapan yang harus dilakukan dalam membentuk model fungsi transfer diantaranya, tahap *prewhitening* deret

input dan output, identifikasi model dugaan fungsi transfer, identifikasi model untuk deret *noise*, dan pemilihan model terbaik.

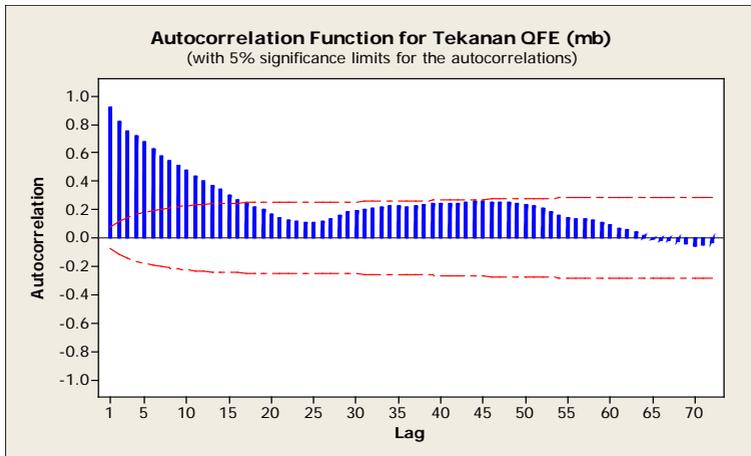
4.2.1. *Prewhitening* deret input dan output

Proses *prewhitening* merupakan suatu tahapan untuk mendapatkan model ARIMA, baik pada deret *input* maupun deret *output*, dengan residual yang telah *white noise*. Langkah dalam proses *prewhitenings* sama dengan proses dalam mendapatkan model terbaik dalam ARIMA. Proses *prewhitening* dimulai dari mencari model ARIMA terbaik dari deret input dan diikuti oleh deret *output*.



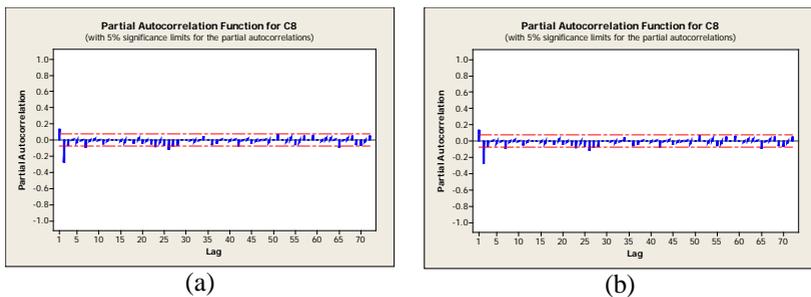
Gambar 4.3 Transformasi Box-cox Tekanan Udara

Hasil uji *Box-Cox* pada Gambar 4.3 menunjukkan nilai *lower control limit* dan *upper control limit* melewati nilai 1 hal ini menunjukkan bahwa data tekanan udara sudah stasioner dalam varians meskipun nilai *rounded value* menunjukkan angka lima. Kestasioneran data tidak hanya dilihat dari variansnya tetapi juga terhadap *mean*. Kestasioneran data terhadap mean dilakukan melalui plot acf. Untuk melihat kestasioneran data terhadap mean dapat dilihat dari plot acf yang ditunjukkan Gambar 4.3.



Gambar 4.4 Plot ACF Tekanan Udara

Plot ACF pada Gambar 4.4 menunjukkan lag-lag yang mengikuti pola menurun lambat, hal ini menunjukkan adanya ketidakstasioneran dalam *mean* pada data tekanan udara dan dapat diatasi dengan melakuk-kan *differencing*.



Gambar 4.5 Plot Tekanan Udara (a) Autocorrelation Function
(b) Partial Autocorrelation Function

Gambar 4.5 (a) merupakan plot ACF dari data tekanan udara yang sudah *didifferencing* 1. Pada gambar tersebut menunjukkan bahwa sudah stasioner terhadap *mean* karena pola data turun

cepat. Berdasarkan plot ACF dan PACF dari data tekanan udara diduga order model ARIMA yang akan terbentuk yaitu ARIMA (2,1,0) dan ARIMA (2,1,1). Orde yang terbentuk digunakan untuk melakukan estimasi parameter dugaan model, uji signifikansi parameter, dan uji asumsi residual *whitenoise* dan berdistribusi normal.

Tabel 4.3 Estimasi dan Uji Signifikansi Parameter Model ARIMA Tekanan Udara

| Model | Parameter | Estimasi | P-value | Keputusan |
|------------------|------------|----------|---------|------------------|
| ARIMA (2,1,0) | μ | 0,00029 | 0,01 | Signifikan |
| | ϕ_1 | 0,1747 | 0,00 | Signifikan |
| | ϕ_2 | -0,2787 | 0,00 | Signifikan |
| ARIMA (2,1,1) | μ | 0,00006 | 0,997 | Tidak Signifikan |
| | ϕ_1 | 0,4010 | 0,001 | Signifikan |
| | ϕ_2 | -0,3099 | 0,000 | Signifikan |
| | θ_1 | 0,2464 | 0,044 | Signifikan |

Suatu model dikatakan baik apabila parameter-parameter dalam model tersebut signifikan. Tabel 4.3 menampilkan hasil estimasi dan uji signifikansi parameter dengan model dugaan ARIMA (2,1,0) dan ARIMA (2,1,1). Taraf signifikansi yang digunakan dalam pemodelan ini adalah sebesar 0,05, sehingga parameter dengan P-value yang lebih kecil dari taraf signifikansi dikatakan telah signifikan. Berdasarkan Tabel 4.3 dapat diketahui bahwa semua parameter dari model dugaan telah signifikan, maka dapat dilanjutkan ke tahap berikutnya, yaitu uji diagnosa terhadap residual untuk mengetahui apakah model yang didapatkan sudah layak. Dalam uji diagnosa, suatu model ARIMA dikatakan telah layak apabila residual memenuhi asumsi *white noise* dan berdistribusi normal. Hasil uji diagnosa residual *white noise* untuk mo-

del dugaan ARIMA (2,1,0) dan ARIMA (2,1,1) disajikan dalam Tabel 4.4 berikut.

Tabel 4.4 Uji *White Noise* Model ARIMA Tekanan Udara

| Model | Lag | χ^2_{hitung} | DF | P-value | Keputusan |
|------------------|------------|-------------------|-----------|----------------|--------------------|
| ARIMA (2,1,0) | 12 | 12,2 | 9 | 0,202 | <i>White Noise</i> |
| | 24 | 24,4 | 21 | 0,276 | <i>White Noise</i> |
| | 36 | 38,7 | 33 | 0,228 | <i>White Noise</i> |
| | 48 | 50,6 | 45 | 0,262 | <i>White Noise</i> |
| ARIMA (2,1,1) | 12 | 9,2 | 8 | 0,323 | <i>White Noise</i> |
| | 24 | 24,0 | 20 | 0,241 | <i>White Noise</i> |
| | 36 | 39,3 | 32 | 0,174 | <i>White Noise</i> |
| | 48 | 52,0 | 44 | 0,190 | <i>White Noise</i> |

Taraf signifikansi yang digunakan sebesar 0,05, dimana residual dari suatu model dikatakan telah *white noise* jika memiliki *P-value* lebih besar dari taraf signifikansi yang ditentukan. Berdasarkan Tabel 4.4 diketahui bahwa residual yang diperoleh dari model ARIMA (2,1,0) dan ARIMA (2,1,1) telah memenuhi asumsi *white noise*.

Asumsi berikutnya yang harus terpenuhi adalah residual harus berdistribusi normal. Hasil uji normalitas residual berdasarkan uji *Kolmogorof-Smirnov* dapat dilihat pada Tabel 4.5.

Tabel 4.5 Hasil Uji Normalitas Residual Model ARIMA Tekanan Udara

| Model | KS | P-value | Keputusan |
|------------------|-----------|----------------|----------------------|
| ARIMA (2,1,0) | 0,017 | >0,150 | Berdistribusi Normal |
| ARIMA (2,1,1) | 0,020 | > 0,150 | Berdistribusi Normal |

Residual dikatakan telah memenuhi asumsi berdistribusi normal jika memiliki *P-value* lebih besar dari taraf signifikansi yang telah ditentukan, yaitu 0,05. Berdasarkan tabel 4.5 dapat disimpulkan bahwa residual dari kedua model sudah memenuhi asumsi berdistribusi normal. Selanjutnya analisis dapat dilanjutkan

ke tahap berikutnya yaitu pemilihan model terbaik. Kriteria kebaikan model yang digunakan SBC terkecil.

Tabel 4.6 Kriteria Pemilihan Model ARIMA Terbaik berdasarkan SBC

| Model | SBC |
|---------------|------|
| ARIMA (2,1,0) | 1350 |
| ARIMA (2,1,1) | 1352 |

Berdasarkan Tabel 4.6 menunjukkan bahwa Model ARIMA yang terbaik adalah ARIMA (2,1,0) karena memiliki nilai SBC paling kecil. Pemodelan *prewhitening* deret input tekanan udara dapat dituliskan sebagai berikut.

$$\alpha_t = x_t - 0,16638 x_{t-1} + 0,27101 x_{t-2}$$

Berdasarkan *prewhitening* dari deret input pemodelan *prewhitening* deret output kecepatan angin dapat dituliskan sebagai berikut.

$$\beta_t = y_t - 0,16638 y_{t-1} + 0,27101 y_{t-2}$$

4.2.2. Pembentukan Model Fungsi Transfer

Pembentukan model fungsi transfer dilakukan setelah proses *prewhitening* deret input dan deret output. Identifikasi model awal untuk fungsi transfer dapat dilihat dari *Crosscorrelation Function* (CCF) yang menunjukkan kekuatan hubungan antara deret input dan deret output. Plot dari CCF ditunjukkan pada Gambar 4.6.

Pada Gambar 4.6 menjelaskan bahwa lag-lag yang signifikan yaitu lag-0, lag-14 dan lag-27. Untuk lag-0 berarti bahwa kecepatan angin pada hari ini memiliki keterkaitan secara linear dengan tekanan udara juga pada hari ini. Sedangkan untuk lag-14 berarti kecepatan angin pada hari ini memiliki keterkaitan secara linear dengan tekanan udara pada 14 hari sebelumnya dan begitu juga dengan lag-27. Karena lag-14 dan lag-27 kelihatan tidak masuk akal. Hal ini karena menurut teori yang sudah dijelaskan tentang kecepatan angin terjadi akibat adanya beda tekanan udara. Artinya secara berurutan tekanan udara secara langsung mempe-

ngaruhi kecepatan angin. Apabila tekanan udara terjadi pada 14 hari atau 27 hari sebelumnya maka itu tidak akan mempengaruhi secara langsung dengan tekanan udara pada hari ini. Oleh karena itu lag yang lag-14 dan lag-27 dieliminasi.

Sesuai dugaan awal dari plot CCF lag yang dimasukkan dalam model adalah lag-0. Kecepatan angin pada hari ini memiliki keterkaitan linear dengan tekanan udara pada hari ini juga. Sehingga Berdasarkan plot CCF tersebut dugaan awal model fungsi transfer adalah sebagai berikut.

$$y_t = \omega_0 x_t + \eta_t$$

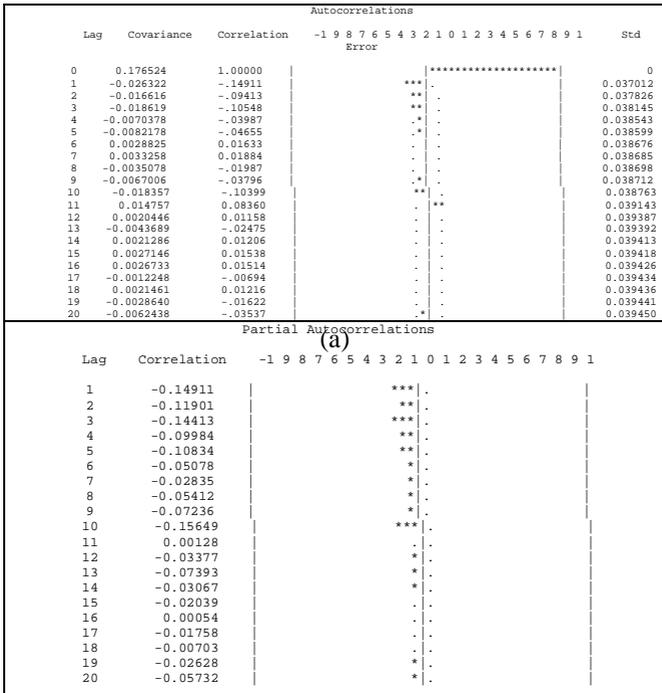
| | | | | | |
|----|------------|---------|---|-------|---|
| 0 | -0.160574 | -.13787 | / | ***./ | / |
| 1 | -0.0002702 | -.00023 | | . . | |
| 2 | -0.049399 | -.04241 | | *. | |
| 3 | -0.021233 | -.01823 | | . . | |
| 4 | 0.015645 | 0.01343 | | . . | |
| 5 | -0.0098518 | -.00846 | | . . | |
| 6 | 0.061169 | 0.05252 | | . * | |
| 7 | 0.028442 | 0.02442 | | . . | |
| 8 | 0.032886 | 0.02824 | | . * | |
| 9 | -0.025977 | -.02230 | | . . | |
| 10 | 0.046223 | 0.03969 | | . * | |
| 11 | 0.011859 | 0.01018 | | . . | |
| 12 | -0.075037 | -.06443 | | * . | |
| 13 | 0.032353 | 0.02778 | | . * | |
| 14 | -0.092706 | -.07960 | | ** . | |
| 15 | 0.028380 | 0.02437 | | . . | |
| 16 | -0.020432 | -.01754 | | . . | |
| 17 | 0.048899 | 0.04198 | | . * | |
| 18 | -0.055068 | -.04728 | | * . | |
| 19 | -0.030576 | -.02625 | | . . | |
| 20 | -0.014049 | -.01206 | | . . | |
| 21 | 0.011320 | 0.00972 | | . . | |
| 22 | 0.027104 | 0.02327 | | . . | |
| 23 | 0.0099973 | 0.00858 | | . . | |
| 24 | -0.031298 | -.02587 | | * . | |
| 25 | 0.065162 | 0.05595 | | . * | |
| 26 | -0.020392 | -.01751 | | . . | |
| 27 | 0.095985 | 0.08241 | | . ** | |
| 28 | -0.050450 | -.04332 | | * . | |
| 29 | 0.056106 | 0.04817 | | . * | |

Gambar 4.6 Plot CCF Tekanan Udara Terhadap Kecepatan Udara

Setelah diketahui model awal dari fungsi transfer selanjutnya pemodelan pada deret noise. Pemodelan dari deret noise dilakukan dengan metode ARIMA Box-Jenkins. Identifikasi model ARIMA dapat dilihat dari plot ACF dan PACF dari pada Gambar 4.7.

Gambar 4.7 merupakan Plot ACF dan PACF pada dari deret noise dengan $b=0$, $r=0$, dan $s=0$. Berdasarkan gambar tersebut model ARIMA yang diduga adalah ARIMA([3],0,3). Berdasarkan model ARIMA yang diduga maka selanjutnya dilakukan estimasi

dan signifikansi parameter dari model ARIMA deret noise tersebut untuk mencari model terbaik. Hasil dari estimasi parameter dan uji signifikansi parameter ditunjukkan pada tabel 4.7.



Gambar 4.7 Plot deret noise (a) Autocorrelation Function (b) Partial Autocorrelation Function

Tabel 4.8 merupakan pengujian dari parameter model noise. Parameter dikatakan sudah signifikan apabila nilai dari p-value kurang dari $\alpha=0,05$. Pada Tabel tersebut dapat dijelaskan bahwa model ARIMA([3],0,3) dengan b=0, r=0, s=0 sudah signifikan karena nilai dari p-value kurang dari $\alpha=0,05$. Parameter pada model noise ini sudah baik . Karena semua parameter sudah signifikan maka dilanjutkan dengan menguji asumsi residual *white noise*. Hasil pengujian asumsi residual *white noise* ditunjukkan pada Tabel 4.7.

Tabel 4.7 Estimasi dan Signifikansi Parameter ARIMA Deret *Noise* dengan $b=0$, $r=0$, dan $s=0$

| Model | Parameter | T-value | P-value | Keputusan |
|--------------------|------------|---------|---------|------------|
| ARIMA ([3],0,3) | ϕ_3 | 3,96 | 0,0001 | Signifikan |
| | θ_1 | 5,57 | 0,0001 | Signifikan |
| | θ_2 | 5,27 | 0,0001 | Signifikan |
| | θ_3 | 7,11 | 0,0001 | Signifikan |
| | ω_0 | -2,86 | 0,0043 | Signifikan |

Tabel 4.8 merupakan tabel dari hasil pengujian asumsi residual *white noise* untuk model ARIMA([3],0,3) dari orde $b=0$, $r=0$, $s=0$. Berdasarkan tabel tersebut menunjukkan bahwa residual dari deret *noise* untuk $b=0$, $r=0$, $s=0$ sudah *white noise* karena nilai p-value dari setiap kumulatif lag kurang dari $\alpha = 0,05$.

Tabel 4.8 Pengujian *White Noise* untuk Deret *Noise* dengan $b=0$ $r=0$ $s=0$

| ARIMA | Lag | χ^2_{hitung} | DF | P-value | Keputusan |
|--------------------|-----|-------------------|----|---------|--------------------|
| ARIMA ([3],0,3) | 6 | 1,93 | 2 | 0,381 | <i>White Noise</i> |
| | 12 | 14,27 | 8 | 0,075 | <i>White Noise</i> |
| | 18 | 15,15 | 14 | 0,367 | <i>White Noise</i> |
| | 24 | 22,17 | 20 | 0,331 | <i>White Noise</i> |
| | 30 | 29,05 | 26 | 0,308 | <i>White Noise</i> |
| | 36 | 39,72 | 32 | 0,164 | <i>White Noise</i> |
| | 42 | 44,82 | 38 | 0,207 | <i>White Noise</i> |
| | 48 | 48,02 | 44 | 0,313 | <i>White Noise</i> |

Setelah residual dari deret *noise* sudah menunjukkan *white noise* maka selanjutnya cek distribusi normal untuk residual deret *noise*. Pengujian residual distribusi normal dapat dilihat pada Tabel 4.9. Berikut hasil dari analisis dari pengujian residual distribusi normal. Residual dikatakan telah memenuhi asumsi berdistribusi normal jika memiliki P-value lebih besar dari taraf signifikansi yang telah ditentukan, yaitu 0,05. Berdasarkan tabel

4.9 dapat disimpulkan bahwa residual dari $b=0$, $r=0$, $s=0$ belum memenuhi asumsi berdistribusi normal.

Tabel 4.9 Hasil Uji Normalitas Residual Fungsi Transfer

| ARIMA | KS | P-value | Keputusan |
|-----------------------|--------|---------|----------------------------|
| ARIMA([3],0,3) | 0,0569 | 0,0100 | Tidak Berdistribusi Normal |

Untuk mengetahui ukuran kebaikan dari model maka dilakukan perhitungan AIC dari model dan didapatkan nilai AIC sebesar 2896,39. Sehingga model akhir yang didapatkan dari fungsi transfer adalah sebagai berikut.

$$y_t = \omega_0 x_t + \eta_t$$

$$\leftrightarrow y_t = 2,889 x_t + \frac{(1-0,194B-0,188B^2-0,455B^3)}{(1-0,280B)} a_t$$

$$\leftrightarrow (1 - 0,280B)y_t = (1 - 0,280B)2,889 x_t + (1 - 0,194B - 0,188B^2 - 0,455B^3)a_t$$

$$\leftrightarrow y_t - 0,280 y_{t-1} = 2,889 x_t - 0,8089 x_{t-1} + a_t - 0,194a_{t-1} - 0,188a_{t-2} - 0,455a_{t-3}$$

$$\leftrightarrow y_t = 2,889 x_t - 0,8089 x_{t-1} + 0,280 y_{t-1} + a_t - 0,194a_{t-1} - 0,188a_{t-2} - 0,455a_{t-3}$$

Berdasarkan model yang telah ditemukan maka akan diramalkan 30 hari kedepan untuk kecepatan angin. Berikut ini merupakan hasil peramalan dari model fungsi transfer di atas.

Tabel 4.10 Hasil Peramalan Fungsi Transfer

| Observasi | Forecast | STD. Error | 95% Confidence Limits | |
|-----------|----------|---------------|--------------------------|---------|
| 732 | 6,3177 | 1,7616 | 2,865 | 9,7703 |
| 733 | 6,0685 | 2,2672 | 1,6248 | 10,5122 |
| 734 | 5,9464 | 2,5172 | 1,0127 | 10,8801 |
| 735 | 5,8087 | 2,6382 | 0,6379 | 10,9796 |
| 736 | 5,7157 | 2,7291 | 0,3667 | 11,0646 |
| 737 | 5,6858 | 2,7964 | 0,2049 | 11,1667 |
| 738 | 5,6542 | 2,8457 | 0,0767 | 11,2318 |
| 739 | 5,6281 | 2,8896 | -0,0353 | 11,2916 |

Tabel 4.10 Hasil Peramalan Fungsi Transfer (Lanjutan)

| Observasi | Forecast | STD. Error | 95% Confidence Limits | |
|-----------|----------|---------------|--------------------------|---------|
| 740 | 5,6179 | 2,9287 | -0,1222 | 11,3579 |
| 741 | 5,6087 | 2,9637 | -0,2001 | 11,4175 |
| 742 | 5,6018 | 2,9973 | -0,2728 | 11,4765 |
| 743 | 5,5991 | 3,0296 | -0,3387 | 11,5369 |
| 744 | 5,5964 | 3,0606 | -0,4021 | 11,595 |
| 745 | 5,5945 | 3,091 | -0,4637 | 11,6526 |
| 746 | 5,5937 | 3,1208 | -0,523 | 11,7104 |
| 747 | 5,593 | 3,1501 | -0,5812 | 11,7672 |
| 748 | 5,5924 | 3,1791 | -0,6386 | 11,8234 |
| 749 | 5,5922 | 3,2078 | -0,6949 | 11,8794 |
| 750 | 5,592 | 3,2361 | -0,7507 | 11,9347 |
| 751 | 5,5919 | 3,2642 | -0,8058 | 11,9895 |
| 752 | 5,5918 | 3,292 | -0,8604 | 12,044 |
| 753 | 5,5917 | 3,3196 | -0,9145 | 12,098 |
| 754 | 5,5917 | 3,3469 | -0,9681 | 12,1515 |
| 755 | 5,5917 | 3,374 | -1,0212 | 12,2046 |
| 756 | 5,5917 | 3,4009 | -1,0739 | 12,2572 |

Karena analisis dengan menggunakan fungsi transfer tidak menghasilkan peramalan yang baik karena hasil peramalannya memiliki nilai hamper sama sekitar 5,6 atm dan residual tidak berdistribusi normal, maka dilakukan analisis dengan metode lain.

4.3 Pemodelan Kecepatan Angin dengan Model Alternatif yang Lain

Pemodelan dengan fungsi transfer tidak menghasilkan model yang baik sehingga dilakukan pemodelan dengan metode yang lain diantaranya *Vector Autoregressive* (VAR) dan Regresi Time Series. Pada pemodelan pertama dengan menggunakan metode VAR hasil analisisnya sebagai berikut.

Dalam analisis VAR langkah awal yang harus dilakukan yaitu mengidentifikasi kestasioneran data terhadap varians dan mean. Untuk mengidentifikasi kestasioneran data terhadap varians dengan menggunakan box-cox dan ternyata variabel kecepatan angin tidak stasioner terhadap varians dan ditransformasi. Kestasioneran data terhadap mean dilihat dari MACF, ternyata

data belum stasioner terhadap mean sehingga dilakukan *differencing* 1. Setelah data ditransformasi dan *differencing* maka dilakukan identifikasi model. Berikut merupakan identifikasi model dari VAR berdasarkan nilai AIC terkecil dan MPACF.

| Variable/ | Schematic Representation of Partial Cross Correlations | | | | | | | | | | | |
|-----------|--|---|----|----|----|----|----|----|----|----|----|----|
| Lag | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| tek1 | + | - | .. | .. | .. | .. | - | .. | .. | .. | .. | .. |
| kec1 | + | - | .. | .. | .. | .. | .. | .. | .. | - | - | .. |

Gambar 4.8 Plot MPACF Tekanan udara dan kecepatan angin setelah *Differencing*

Pendugaan model awal berdasarkan MPACF dapat dilihat pada Gambar 4.8. Berdasarkan gambar tersebut lag-lag yang bertanda (-) atau (+) berhenti di lag-5 tetapi pada lag-7, 9, dan 10 masih ada tanda (-) atau (+). Untuk memperjelas pendugaan model VAR dapat dilihat dari nilai AIC terkecil yang ditunjukkan pada Tabel 4.11.

Tabel 4.11 Identifikasi Model VAR berdasarkan AIC

| Lag | MA 0 |
|------|-----------|
| AR 0 | -10,98381 |
| AR 1 | -11,02234 |
| AR 2 | -11,10538 |
| AR 3 | -11,12443 |
| AR 4 | -11,13041 |
| AR 5 | -11,13106 |

Berdasarkan Tael 4.11 menunjukkan bahwa untuk model VAR yang didapatkan yaitu VAR(5) karena nilai AIC paling kecil dari yang lain. Berikut merupakan estimasi parameter dari model VAR(5) setelah dilakukan *Restrict*.

Tabel 4.12 Estimasi Parameter Model *Restrict* untuk Model VAR(5)

| Equation | Parameter | Estimate | Std Error | t value | P_value | Variabel |
|---------------|---------------|----------|-----------|---------|---------|----------|
| Tekanan Udara | ϕ_{1_1} | 0,15319 | 0,03702 | 4,14 | 0,0001 | tek(t-1) |
| | ϕ_{1_2} | 0,00255 | 0,00085 | 3,01 | 0,0027 | kec(t-1) |
| | ϕ_{2_1} | -0,25801 | 0,03597 | -7,17 | 0,0001 | tek(t-2) |
| | ϕ_{3_1} | 0,07385 | 0,03707 | -1,99 | 0,0467 | tek(t-2) |

Tabel 4.12 Estimasi Parameter Model *Restrict* untuk Model VAR(5)
(Lanjutan)

| <i>Equation</i> | Parameter | <i>Estimate</i> | Std Error | <i>t value</i> | <i>P_value</i> | Variabel |
|-----------------|----------------|-----------------|-----------|----------------|----------------|----------|
| Kecepatan | $\phi_{1,2,2}$ | -0,21468 | 0,03698 | -5,81 | 0,0001 | kec(t-1) |
| Angin | $\phi_{2,2,2}$ | -0,17370 | 0,03718 | -4,67 | 0,0001 | kec(t-2) |

Berdasarkan Tabel 4.12 diketahui bahwa tekanan udara cenderung dipengaruhi oleh tekanan udara sehari sebelumnya dua hari sebelumnya dan kecepatan angin sehari sebelumnya. Sedangkan untuk kecepatan angin dipengaruhi oleh kecepatan angin sehari sebelumnya dan dua hari sebelumnya. Selanjutnya dilakukan pengujian kausal *granger* untuk memastikan pengaruh antar kedua variabel. Hipotesis tekanan udara adalah sebagai berikut.

H_0 : kecepatan angin tidak berpengaruh signifikan terhadap tekanan udara.

H_1 : kecepatan angin berpengaruh signifikan terhadap tekanan udara.

untuk kecepatan angin hipotesis yang digunakan yaitu

H_0 : tekanan udara tidak berpengaruh signifikan terhadap kecepatan angin.

H_1 : tekanan udara berpengaruh signifikan terhadap kecepatan angin.

Tabel 4.13 *Granger Causality Test* antara kecepatan angin dan Tekanan Udara

| Var1(t) | Var2(t-5) | DF | Chi-Square | Pr > ChiSq |
|---------|-----------|----|------------|------------|
| tek | kec | 5 | 11,54 | 0,0416 |
| kec | tek | 5 | 4,98 | 0,4183 |

Kecepatan angin tidak dipengaruhi oleh tekanan udara hal ini terlihat pula pada uji kausal *granger* dimana nilai P-value untuk tekanan udara terhadap kecepatan angin sebesar 0,4183 kurang

dari $\alpha=0,05$ berarti tekanan udara tidak mempengaruhi kecepatan angin. Berikut merupakan model dari hasil estimasi parameter.

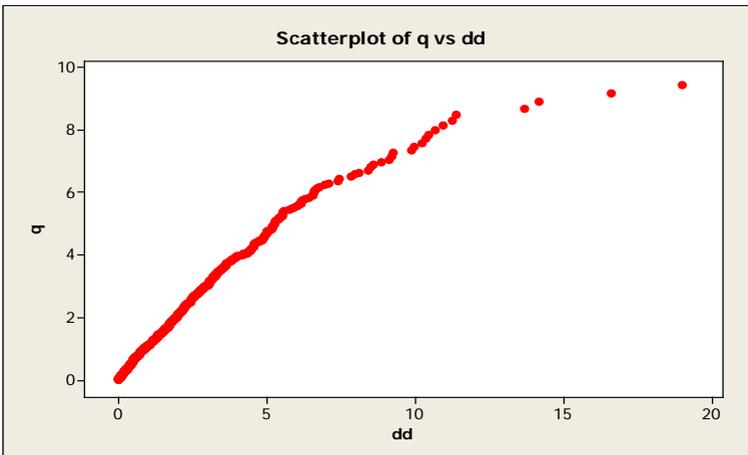
$$\begin{aligned} \text{tekanan}_t &= 0,15319 \text{ tekanan}_{t-1} + 0,00255 \text{ kecepatan}_{t-2} - 0,25801 \\ &\quad \text{tekanan}_{t-2} + 0,07385 \text{ t-3} \\ \text{kecepatan}_t &= -0,21468 \text{ kecepatan}_{t-1} - 0,17370 \text{ kecepatan}_{t-2} \end{aligned}$$

Selanjutnya dilakukan pengujian terhadap residual *white noise* pada model VAR(5). Hasil dari pengujian *white noise* ditunjukkan pada Gambar 4.9.

| Schematic Representation of Cross Correlations of Residuals | | | | | | | | | | | | | |
|---|----|----|----|----|----|----|----|----|----|----|----|----|----|
| Variable/ Lag | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| tekl | +- | .. | .. | .. | .. | .. | .. | .. | .. | .. | .. | .. | .. |
| kecl | -+ | .. | .. | .. | .. | .. | - | .. | .. | .. | .. | - | .. |

Gambar 4.9 Plot MACF Residual VAR(5)

Berdasarkan Gambar 4.9 diketahui bahwa Pengujian Residual menunjukkan bahwa residual dari VAR(5) belum *white noise* karena masih terdapat tanda (+) dan (-) pada lag-lag tertentu, maka dengan menggunakan model ini tidak menunjukkan hasil yang baik. Selanjutnya dilakukan pengujian residual berdistribusi normal multivariate. Hasil pengujiannya ditunjukkan pada Gambar 4.10.



Gambar 4.10 Plot Pengujian Multinormal Residual VAR (5)

Setelah residual model tidak memenuhi asumsi *white noise*, selanjutnya dilakukan pengujian asumsi kenormalan residual.

Hasil uji multinormal menunjukkan bahwa nilai *chi-square* residual diatas 50% yaitu sebesar 0,517, artinya residual telah memenuhi asumsi kenormalan (multinormal).

Pemodelan alternative yang lain yaitu dengan menggunakan metode regresi time series. Pada metode ini dilakukan dua penaksiran parameter yaitu dengan OLS dan regresi robust. Kecepatan angin ditransformasi karena dilihat dari *box-cox transformation* memiliki nilai lambda sebesar 0,5 sehingga ditransformasi dengan akar. variabel prediktor berdasarkan teori kecepatan angin dapat dipengaruhi oleh tekanan udara sehingga penentuan variabel prediktor melalui uji korelasi antara kecepatan angin dengan tekanan udara. Berdasarkan pengujian parameter dari model VAR(5) menunjukkan kecepatan angin dipengaruhi oleh dua lag sebelumnya, sehingga pengujian korelasi hanya dilakukan dengan dua lag sebelumnya. Hasil uji korelasi antara kecepatan angin pada waktu t (kec_t) dengan tekanan udara waktu $t-i$ (tek_{t-i}) dan kecepatan angin waktu $t-k$ (kec_{t-k}) ditunjukkan pada Tabel 4.14.

Tabel 4.14. Uji korelasi antara kecepatan angin (t) dengan tekanan udara ($t-k$) dan kecepatan angin ($t-i$)

| Variabel1 | Variabel2 | Korelasi | P-value |
|-----------|-------------|----------|---------|
| | tek_{t-1} | 0,236 | 0,000 |
| kec_t | tek_{t-2} | 0,237 | 0,000 |
| | kec_{t-1} | 0,795 | 0,000 |
| | kec_{t-2} | 0,649 | 0,000 |

Variabel dinyatakan berkorelasi apabila nilai dari P-value kurang $\alpha = 0,05$. Berdasarkan Tabel 4.13 dapat dijelaskan bahwa semua variabel independen memiliki korelasi dengan kecepatan angin. selanjutnya dilakukan estimasi parameter *least square*..

Berdasarkan Tabel 4.14 dapat dijelaskan bahwa parameter dari model ada yang tidak signifikan. Tekanan udara lag-1, tekanan udara lag-2, dan kecepatan angin lag-2 tidak signifikan karena nilai P-value lebih besar dari $\alpha=0,05$. hasil pengujian secara parsial dari regresi time series ditunjukkan pada Tabel 4.15

Tabel 4.15 Estimasi parameter dan Uji signifikansi parameter

| Predictor | Coef | SE Coef | T | P |
|-----------|----------|----------|-------|-------|
| Constant | -23,31 | 10,02 | -2,33 | 0,020 |
| tek_1 | -0,01311 | 0,02426 | -0,54 | 0,589 |
| tek_2 | 0,03746 | 0,02404 | 1,56 | 0,120 |
| kec_1 | 0,170844 | 0,008445 | 20,23 | 0,000 |
| Kec_2 | 0,004540 | 0,008545 | 0,53 | 0,595 |

Karena masih ada parameter yang tidak signifikan, maka akan dilakukan eliminasi dengan menggunakan pengujian *step-wise*. Berikut ini merupakan hasil eliminasi dengan menggunakan *stepwise*.

Tabel 4.16 Estimasi Parameter dan Uji Signifikansi Parameter

| Prediktor | Coef | SE Coef | T | P |
|--------------------|----------|----------|-------|-------|
| Constant | -21,225 | 9,702 | -2,19 | 0,029 |
| Tek _{t-2} | 0,021496 | 0,009626 | 2,23 | 0,026 |
| Kec _{t-1} | 0,78558 | 0,02297 | 34,20 | 0,000 |

Tabel 4.16 Menunjukkan bahwa parameter dari model regresi sudah signifikan karena nilai P-value dari setiap parameter kurang dari $\alpha = 0,05$. Artinya tekanan angin hari ini dipengaruhi oleh tekanan udara dua hari yang lalu dan kecepatan angin satu hari yang lalu. Pengujian secara serentak ditunjukkan pada Tabel 4.17.

Tabel 4.17 ANOVA Regresi time series

| Source | DF | SS | MS | F | P |
|----------------|-----|--------|--------|--------|-------|
| Regression | 2 | 203,41 | 101,71 | 641,08 | 0,000 |
| Residual Error | 726 | 115,18 | 0,16 | | |
| Total | 728 | 318,59 | | | |

Berdasarkan Tabel 4.17 Pengujian secara serentak menghasilkan kesimpulan model sudah signifikan karena nilai P-value sebesar 0,00 kurang dari $\alpha = 0,05$. Nilai *R-Sq* dari model regresi sebesar 63,7 % cukup baik karena variabilitas data yang bisa dijelaskan oleh model lebih besar dari 60%. Ada tiga asumsi residual yang harus dipenuhi dalam regresi. Hasil pengujian dari asumsi residual menunjukkan bahwa dari pengujian glejser menun-

ukkan bahwa residual identik. Plot acf dari residual menunjukkan tidak ada lag yang keluar sehingga residual identik dan begitu juga dengan hasil uji kolmogorov smirnov menunjukkan bahwa residual berdistribusi normal. Banyak *unusual observation* dari model regresi cukup banyak yaitu sebanyak 41 data, maka dilakukan analisis regresi robust untuk mengatasi adanya pencilan pada data. Model regresi robust dengan menggunakan metode MM, LTS, dan S ditunjukkan pada Tabel 4.18

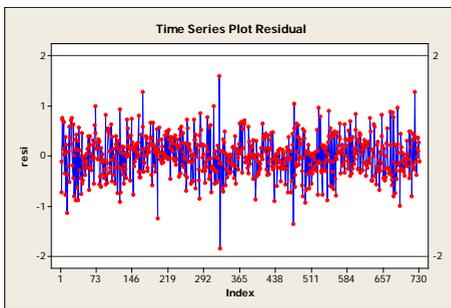
Tabel 4.18 Pemodelan dengan Metode Regresi Robust

| Model | Parameter | R-sq |
|-------|------------|--------|
| MM | Signifikan | 0,5615 |
| LTS | Signifikan | 0,7729 |
| S | Signifikan | 0,6987 |

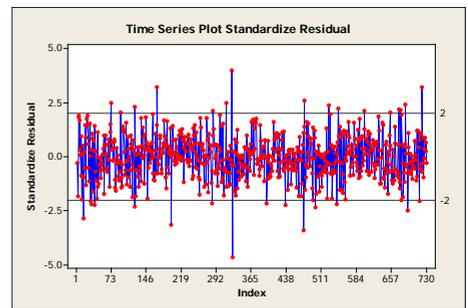
Berdasarkan Tabel 4.18 metode MM, LTS, dan S sama-sama menghasilkan parameter yang signifikan artinya model sudah baik. Berdasarkan nilai R-sq regresi robust yang paling baik yaitu menggunakan metode LTS karena memiliki R-sq paling besar. Sehingga model yang didapatkan adalah sebagai berikut.

$$\text{Kec}_t = -19,6429 + 0,0199 \text{ Tek}_{t-1} + 0,7966 \text{ Kec}_{t-2}.$$

Untuk mengetahui masih ada *outlier* atau tidak dapat dilihat dari *scatterplot standardize* residual model. Data dikatakan *outlier* apabila berada diluar nilai 2 dan -2. Berikut ini adalah *standardize* residual dan residual murni dari model LTS.



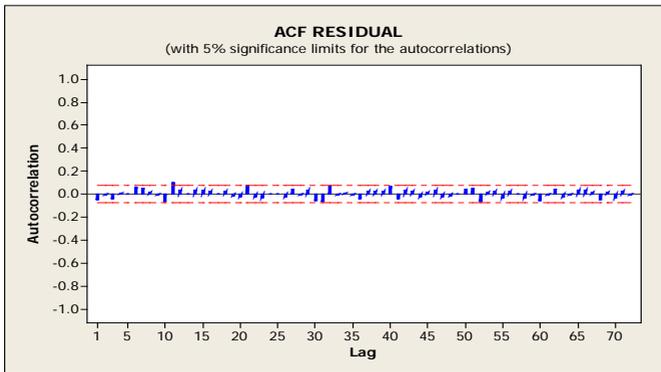
(a)



(b)

Gambar 4.11 Time Series Plot (a) Residual Murni (b) Standardize Residual

Berdasarkan Gambar 4.11 dapat dijelaskan bahwa plot-plot dari standardize residual banyak yang melewati angka 2 dan -2. Hal ini menunjukkan adanya pencilan dari data. Tetapi dilihat dari nilai residualnya tidak ada yang melewati angka 2 dan -2. Seharusnya nilai dari standardize residual lebih kecil dari nilai residual, karena nilai residual yang terlalu kecil dan jumlah data yang banyak menyebabkan nilai standar residual lebih besar dari residual murni. Sehingga dapat disimpulkan bahwa terjadinya pencilan disebabkan oleh jumlah data yang terlalu besar. Selanjutnya pengujian asumsi dari residual IIDN.



Gambar 4.12 ACF Residual Regresi Time Series

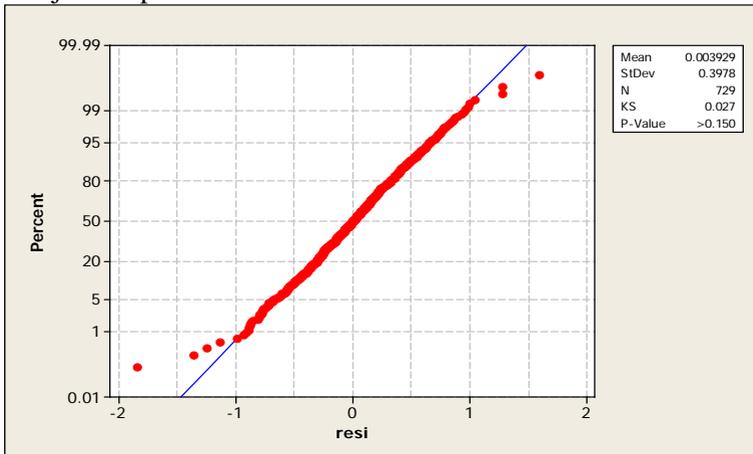
Gambar 4.12 Merupakan plot ACF dari residual model LTS dimana Gambar 4.12 merupakan Gambar residual. Berdasarkan gambar tersebut dapat diketahui bahwa hanya ada satu lag yang melewati batas. Hal ini menunjukkan bahwa residual tidak independen model LTS.

Selanjutnya residual diuji dengan menggunakan uji *Glejser* untuk mengetahui apakah residual identik atau tidak. Pengujian *glejser* yaitu melakukan pemodelan pada nilai *absolute* residual dengan variabel prediktor dan dilakukan pengujian pada parameternya. Hasil dari pengujian parameternya ditunjukkan pada Tabel 4.19.

Tabel 4.19 Uji Parameter pada pengujian *Glejser*

| Predictor | Coef | SE Coef | T | P |
|-----------|-----------|----------|-------|-------|
| Constant | 10,288 | 6,119 | 1,68 | 0,093 |
| tek_2 | -0,009895 | 0,006071 | -1,63 | 0,104 |
| kec_1 | 0,00240 | 0,01449 | 0,17 | 0,869 |

Pada Tabel 4.19 menunjukkan bahwa nilai p-value dari semua parameter lebih besar dari $\alpha = 0,05$ maka parameter tidak signifikan. Karena semua parameter tidak signifikan maka residual menunjukkan identik atau asumsi residual identik terpenuhi. Setelah residual independen dan identik selanjutnya pengujian terhadap distribusi normal. Pengujian residual distribusi normal ditunjukkan pada Gambar 4.13.

**Gambar 4.13** Pengujian Kolmogorv-Smirnov Residual model Regresi

Gambar 4.13 merupakan gambar dari pengujian asumsi residual berdistribusi normal dengan menggunakan Uji kolmogorov-smirnov. Dari gambar tersebut dapat diketahui bahwa nilai dari p-value adalah $>0,150$ hal ini menunjukkan bahwa residual sudah berdistribusi normal.

4.4 Pemilihan Model Terbaik

Pemilihan model terbaik dari ketiga metode analisis yang dilakukan berdasarkan pada data outsample yaitu sebanyak 15

data. Kriteria pemilihan model terbaik didasarkan pada RMSE outsampel terkecil dari data. Hal ini karena kriteria berdasarkan data outsampel lebih akurat terhadap nilai peramalan. Hasil dari pemilihan model terbaik berdasarkan nilai RMSE terkecil ditunjukkan pada Tabel 4.20.

Tabel 4.20 Pemilihan model terbaik berdasarkan RMSE outsampel

| Metode | RMSE outsampel |
|---------------------------------------|----------------|
| Fungsi transfer | 2,858 |
| VAR | 3,614 |
| Regresi time series dengan robust LTS | 2,413 |

Tabel 4.17 merupakan kriteria pemilihan model terbaik dari ketiga metode yang telah dilakukan. Berdasarkan tabel tersebut metode yang paling baik yaitu metode regresi time series dengan robust LTS karena model dari metode tersebut menghasilkan RMSE outsampel paling kecil yaitu 2,413. Ketiga metode di atas menghasilkan model yang kurang baik karena sama-sama tidak memenuhi asumsi residual. Pemodelan dengan menggunakan fungsi transfer residual tidak memenuhi asumsi normal. Sedangkan untuk pemodelan dengan metode VAR, residual tidak *white noise*. Untuk pemodelan dengan menggunakan regresi time series robust LTS, residual tidak memenuhi asumsi identik.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Kesimpulan yang dapat diambil dalam penelitian ini adalah sebagai berikut.

1. karakteristik dari kecepatan angin rata-rata harian yaitu rata-rata untuk kecepatan angin tertinggi terjadi pada tahun 2012 dan nilai deviasi standar paling besar terjadi pada tahun 2012 sedangkan untuk kecepatan angin paling maksimum terjadi pada tahun 2013 dan untuk kecepatan angin paling rendah juga terjadi pada tahun 2013. Rata-rata tekanan udara paling tinggi dan deviasi standar paling besar terjadi pada tahun 2012 sedangkan untuk tekanan udara tertinggi dan dan terendah terjadi pada tahun 2012.
2. Model yang dihasilkan untuk peramalan adalah
$$y_t = 2,889 x_t - 0,8089 x_{t-1} + 0,280 y_{t-1} + a_t - 0,194a_{t-1} - 0,188a_{t-2} - 0,455a_{t-3}$$
3. Model alternative terbaik dari data kecepatan angin dan tekanan udara dengan metode regresi robust LTS yaitu
Kecepatan angin (t) = -19,6429 + 0,0199 tekanan udara (t-1) + 0,7966 kecepatan angin (t-2).

5.2 Saran

Adapun saran-saran yang dapat diberikan adalah Dalam menentukan variabel input diperlukan referensi yang lebih banyak lagi karena ada kemungkinan variabel-variabel lain yang mempengaruhi kecepatan angin.

(Halaman Sengaja Dikосongkan)

DAFTAR PUSTAKA

- Candra, A.(2010). Tugas Akhir: Perancangan Model Adaptive Neuro Fuzzy Inference System untuk Memprediksi Cuaca Maritim. Teknik Fisika-FTI-ITS Surabaya
- Daniel, W.(1989). *Statistika Non Parametrika*. Gramedia. Jakarta.
- Syamsul, A.(2009). Sistem Logika Fuzzy sebagai Peramal Cuaca di Indonesia, studi kasus: Kota Surabaya
- Faulina, R.(2011). Adaptive Neuro Fuzzy Inference System untuk Peramalan Ke-cepatan Angin Harian di Sumenep. Laporan Tugas Akhir Jurusan Statistika. Surabaya : ITS
- Kresnawan, A.(2009). Penerapan Model Jaringan Syaraf Tiruan untuk Memprediksi Gangguan Cuaca maritim.Laporan Tugas Akhir Teknik Fisika-FTI-ITS Surabaya
- Makridakis, Wheel W., Mc Gee. (1999). Metode Dan Aplikasi Peramalan, Edisi Kedua. Bina Rupa Aksara. Jakarta.
- Nurvitasari, Y.(2012). Pendekatan Fungsi Transfer Sebagai Input Adaptive Neuro Fuzzy Inference System (ANFIS) dalam Peramalan Kecepatan Angin Rata-rata. Laporan tugas AkhirJurusan Statistika. Surabaya : ITS
- Tjasjono, B. (1999). Klimatologi Umum. Bandung: ITB Bandung.
- Wei, W.W.S. (2006). Time Series Analysis, Univariate and Multivariate Methods. Canada: Addison Wesley Publishing Company.

(Halaman sengaja dikosongkan)

Biodata Penulis



Penulis di lahirkan di Gresik, 19 Febraril 1990. Merupakan anak ketiga dari tiga bersaudara. Penulis telah menempuh pendidikan formal yaitu SDN Sawah Mulya II, SMPN 1 Sangkapura dan dilanjutkan di SMAN 1 Sangkapura. Setelah lulus dari SMAN 1 Sangkapura, penulis melanjutkan studi di jurusan Statistika FMIPA-ITS program studi Diploma III. Di jurusan Statistika, penulis terdaftar dengan NRP 1308 030 011. Setelah lulus dari diploma tiga penulis melanjutkan ke program lintas jalur jurusan Statistika ITS yang setara dengan S1. Penulis pernah melaksanakan kerja praktek di PT. Sejahtera Usaha Bersama dan PT. Pertamina Bitumen Plan Gresik. Beberapa kegiatan yang diikuti penulis selama kuliah aktif di Forum Studi islam Statistika sebagai Kepala Departemen Tablighul Islam dan Himpunan Mahasiswa Statistika ITS sebagai Staf Ahli Departemen Kesejahteraan Mahasiswa. Dengan beraneka-ragamnya ilmu yang didapatkan oleh penulis sejak berkuliah, menjadikan motivasi tersendiri oleh penulis dalam menjalani hidup yang berkontribusi, baik kepada diri sendiri, keluarga, orang sekitar, masyarakat, bangsa dan negara. Komunikasi dengan penulis dapat dilakukan melalui email muhammad.tayyib19@gmail.com.

DAFTAR LAMPIRAN

| | | |
|------------|---|----|
| Lampiran A | Data Kecepatan Angin dan Tekanan udara harian periode 1 Januari 2012 - 31 Desember 2013 | 59 |
| Lampiran B | Program SAS Model ARIMA, Fungsi Transfer, VAR, dan Regresi Time Series Robust..... | 60 |
| Lampiran C | <i>Output</i> SAS Model ARIMA Tekanan Udara | 64 |
| Lampiran D | <i>Output</i> Fungsi Transfer Kecepatan Angin | 65 |
| Lampiran E | <i>Output</i> SAS Model VAR Kecepatan Angin dan Tekanan Udara | 66 |

(Halaman ini sengaja dikosongkan)

Lampiran A. Data Kecepatan Angin dan Tekanan udara harian periode 1 Januari 2012 - 31 Desember 2013

| Tanggal | Tahun | Bulan | Tanggal_1 | Tekanan Udara (mb) | Kecepatan Angin Rata-Rata (knot) |
|------------|-------|-------|-----------|--------------------|----------------------------------|
| 1/01/2012 | 2012 | 1 | 1 | 1009.0 | 2.6 |
| 2/01/2012 | 2012 | 1 | 2 | 1009.3 | 4.6 |
| 3/01/2012 | 2012 | 1 | 3 | 1009.9 | 4.1 |
| 4/01/2012 | 2012 | 1 | 4 | 1009.5 | 1.8 |
| 5/01/2012 | 2012 | 1 | 5 | 1009.1 | 5.2 |
| 6/01/2012 | 2012 | 1 | 6 | 1009.4 | 9.0 |
| 7/01/2012 | 2012 | 1 | 7 | 1009.5 | 8.8 |
| 8/01/2012 | 2012 | 1 | 8 | 1008.3 | 12.1 |
| 9/01/2012 | 2012 | 1 | 9 | 1007.7 | 10.5 |
| 10/01/2012 | 2012 | 1 | 10 | 1007.2 | 7.1 |
| . | . | . | . | . | . |
| . | . | . | . | . | . |
| . | . | . | . | . | . |
| 18/12/2013 | 2013 | 12 | 18 | 1007.6 | 5.0 |
| 19/12/2013 | 2013 | 12 | 19 | 1007.7 | 3.8 |
| 20/12/2013 | 2013 | 12 | 20 | 1007.9 | 5.7 |
| 21/12/2013 | 2013 | 12 | 21 | 1007.8 | 4.2 |
| 22/12/2013 | 2013 | 12 | 22 | 1008.5 | 11.0 |
| 23/12/2013 | 2013 | 12 | 23 | 1009.1 | 8.7 |
| 24/12/2013 | 2013 | 12 | 24 | 1009.0 | 9.8 |
| 25/12/2013 | 2013 | 12 | 25 | 1009.7 | 6.5 |
| 26/12/2013 | 2013 | 12 | 26 | 1009.0 | 6.9 |
| 27/12/2013 | 2013 | 12 | 27 | 1008.0 | 6.3 |
| 28/12/2013 | 2013 | 12 | 28 | 1007.4 | 7.8 |
| 29/12/2013 | 2013 | 12 | 29 | 1007.9 | 7.5 |
| 30/12/2013 | 2013 | 12 | 30 | 1008.9 | 8.2 |
| 31/12/2013 | 2013 | 12 | 31 | 1009.7 | 6.7 |

Lampiran B. Program SAS Model ARIMA, Fungsi Transfer, VAR, dan Regresi Time Series Robust

1. Program SAS Model ARIMA (2,1,0) Tekanan Udara

```
data tekanan;
input x;
datalines;
1009.0
1009.3
1009.9
1009.5
1009.1
1009.4
1009.5
1008.3
1007.7
1007.2
1007.5
1007.8
1007.9
1007.4
1006.6
1006.5
1007.0.
.
.
1010.0
1009.7
1010.0
1010.8
1010.9
1011.0.
.
.
1009.0
1008.0
1007.4
1007.9
1008.9
1009.7
;
proc arima data=tekanan;
identify var=x (1);
estimate p=2 q=(0) noconstant method=ml;
forecast out=ramalan lead=31;
outlier maxnum=54;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

2. Program SAS Model Fungsi Transfer Kecepatan angin

```

data kecepatan;
input x y;
datalines;
1009.0 2.6
1009.3 4.6
1009.9 4.1
1009.5 1.8
1009.1 5.2
1009.4 9.0
1009.5 8.8
1008.3 12.1
.
.
.
1008.7 1.6
1008.6 2.0
1007.8 3.0
1007.2 3.2
1006.5 6.2
1006.7 5.4
.
.
.
1009.0 9.8
1009.7 6.5
1009.0 6.9
1008.0 6.3
1007.4 7.8
1007.9 7.5
;
data kecepatan;
set kecepatan;

/*---identifikasi ARIMA deret Input----*/
proc arima data=kecepatan;
identify var= x(1);
run;
estimate p=2 q=(1) noint method=ml;
run;
/*---identifikasi plot CCF-----*/
identify var=y(1) crosscorr=(x(1)) nlags=30;
run;
/*---estimasi model deret noise orde b,r,s,-----*/
estimate p=(3) q=3 input=(0 $ (0)/ (0) zt ) noconstant method=ml;
run;
forecast lead=12 out=ramalan ;
run;
/*---uji residual berdistribusi normal-----*/
proc univariate data=ramalan normal;
var residual;
run;

```

3. Program SAS Model VAR Kecepatan Angin dan Tekanan Udara

```

data kecepatan;
input tek kec;
tek1=sqrt(tek);
kec1=sqrt(kec);
datalines;
1009.0 2.6
1009.3 4.6
1009.9 4.1
1009.5 1.8
1009.1 5.2
1009.4 9.0
1009.5 8.8
1008.3 12.1
.
.
.
1007.1 5.6
1007.9 3.1
1008.6 3.3
1008.0 2.5
1008.5 3.1
1008.6 1.7
1008.8 2.0
.
.
.
1008.0 6.3
1007.4 7.8
1007.9 7.5
1008.9 8.2
1009.7 6.7
;
proc varmax data=kecepatan printall;
model tek1 kec1 /p=5 diffy(1) noint;
causal group1=(tek1) group2=(kec1);
causal group1=(kec1) group2=(tek1);
restrict
AR(5,1,2)=0,AR(3,1,2)=0,AR(4,1,1)=0,AR(2,2,1)=0,AR(2,1,2)=0,AR(5,1,1)=0
,AR(4,1,2)=0,AR(1,2,1)=0;
output lead=15 out=hasil;
run;

proc print data=hasil;
run;
proc export data=WORK.HASIL
outfile='D:\ramalan.xls'
dbms=excel
replace;
run;

```

4. Program SAS Time Series Regresi Robust LTS

```

data Robust;
  input y x1 x2;
  datalines;

1.620185175
2.150581317
2.031009601      1009.0  2.150581317
1.338531534      1009.3  2.031009601
2.282177323      1009.9  1.338531534
2.993047499      1009.5  2.282177323
2.958039892      1009.1  2.993047499
3.476108936      1009.4  2.958039892
3.24679329       1009.5  3.476108936.
.
.
2.449489743      1008.6  2.915475947
1.779513042      1007.9  2.449489743
1.020620726      1007.3  1.779513042
1.755942292      1007.4  1.020620726
1.802775638      1008.9  1.755942292
2.354074482      1008.8  1.802775638
2.653613888      1008.4  2.354074482
1.594260539      1007.9  2.653613888
1.814295088      1009.3  1.594260539
1.190238071      1008.6  1.814295088
1.414213562      1008.1  1.190238071
1.632993162      1008.0  1.414213562
1.369306394      1008.9  1.632993162
1.620185175      1009.6  1.369306394
1.957890021      1009.8  1.620185175
1.354006401      1009.1  1.957890021
1.354006401      1009.5  1.354006401
1.554563176      1009.7  1.354006401
.
.
.
2.950988535      1007.8  3.32290034
3.13581462       1008.5  2.950988535
2.557668209      1009.1  3.13581462
2.62202212       1009.0  2.557668209
2.516611478      1009.7  2.62202212
2.798809271      1009.0  2.516611478
2.746209509      1008.0  2.798809271
2.865018906      1007.4  2.746209509
2.590045045      1007.9  2.865018906

;

proc robustreg data=Robust fwls method=lts;
  model y = x1 x2 / diagnostics leverage;
run;

```

Lampiran C. Output SAS Model ARIMA Tekanan Udara

1. Model ARIMA (2,1,0) tekanan Udara

| Maximum Likelihood Estimation | | | | | | | | | | |
|------------------------------------|------------|---------------|------------|----------------------------|---------|----------------|--------|--------|--------|--|
| | | Parameter | Estimate | Standard Error | t Value | Approx Pr > t | Lag | | | |
| | | AR1,1 | 0.16660 | 0.03570 | 4.67 | <.0001 | 1 | | | |
| | | AR1,2 | -0.27104 | 0.03576 | -7.58 | <.0001 | 2 | | | |
| Autocorrelation Check of Residuals | | | | | | | | | | |
| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- | | | | | | |
| 6 | 5.63 | 4 | 0.2283 | -0.020 | 0.011 | -0.077 | -0.005 | -0.033 | 0.004 | |
| 12 | 12.25 | 10 | 0.2688 | -0.066 | -0.037 | 0.025 | 0.021 | -0.042 | -0.020 | |
| 18 | 14.45 | 16 | 0.5650 | 0.009 | 0.006 | -0.008 | -0.043 | 0.002 | -0.030 | |
| 24 | 23.50 | 22 | 0.3740 | 0.027 | -0.040 | -0.034 | -0.049 | -0.068 | -0.037 | |
| Tests for Normality | | | | | | | | | | |
| Test | | --Statistic-- | | ----p Value---- | | | | | | |
| Shapiro-Wilk | | W | 0.998664 | Pr < W | 0.8681 | | | | | |
| Kolmogorov-Smirnov | | D | 0.019166 | Pr > D | >0.1500 | | | | | |
| Cramer-von Mises | | W-Sq | 0.033363 | Pr > W-Sq | >0.2500 | | | | | |
| Anderson-Darling | | A-Sq | 0.220577 | Pr > A-Sq | >0.2500 | | | | | |

2. Model ARIMA (2,1,1) Tekanan Udara

| Maximum Likelihood Estimation | | | | | | | | | | |
|------------------------------------|------------|---------------|------------|----------------------------|---------|----------------|--------|--------|--------|--|
| | | Parameter | Estimate | Standard Error | t Value | Approx Pr > t | Lag | | | |
| | | MA1,1 | 0.26347 | 0.12368 | 2.13 | 0.0331 | 1 | | | |
| | | AR1,1 | 0.40937 | 0.11826 | 3.46 | 0.0005 | 1 | | | |
| | | AR1,2 | -0.30320 | 0.03597 | -8.43 | <.0001 | 2 | | | |
| Autocorrelation Check of Residuals | | | | | | | | | | |
| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- | | | | | | |
| 6 | 1.73 | 3 | 0.6301 | 0.000 | 0.004 | -0.016 | 0.016 | -0.042 | -0.008 | |
| 12 | 9.06 | 9 | 0.4321 | -0.068 | -0.041 | 0.024 | 0.017 | -0.047 | -0.022 | |
| 18 | 11.41 | 15 | 0.7228 | 0.009 | 0.003 | -0.013 | -0.042 | -0.001 | -0.033 | |
| 24 | 23.12 | 21 | 0.3374 | 0.018 | -0.046 | -0.040 | -0.055 | -0.079 | -0.046 | |
| Tests for Normality | | | | | | | | | | |
| Test | | --Statistic-- | | ----p Value---- | | | | | | |
| Shapiro-Wilk | | W | 0.998244 | Pr < W | 0.6734 | | | | | |
| Kolmogorov-Smirnov | | D | 0.021257 | Pr > D | >0.1500 | | | | | |
| Cramer-von Mises | | W-Sq | 0.044149 | Pr > W-Sq | >0.2500 | | | | | |
| Anderson-Darling | | A-Sq | 0.295304 | Pr > A-Sq | >0.2500 | | | | | |

Lampiran E. Output SAS Model VAR Kecepatan Angin dan Tekanan Udara

1. MACF Model VAR setelah differencing dan transformasi

| Conditional Least Squares Estimation | | | | | | | | | |
|---|------------|----------------|------------|----------------------------|--------|----------|--------|--------|--------|
| Parameter | Estimate | Standard Error | t Value | Approx Pr > t | Lag | Variable | Shift | | |
| MA1,1 | 0.87802 | 0.04229 | 20.76 | <.0001 | 1 | y8 | 0 | | |
| NUM1 | 9.67993 | 1.37058 | 7.06 | <.0001 | 0 | bbm1 | 0 | | |
| NUM2 | 28.32543 | 1.37065 | 20.67 | <.0001 | 0 | bbm2 | 0 | | |
| Variance Estimate | | | | 1.999105 | | | | | |
| Std Error Estimate | | | | 1.413897 | | | | | |
| AIC | | | | 465.4706 | | | | | |
| SBC | | | | 474.0962 | | | | | |
| Number of Residuals | | | | 131 | | | | | |
| * AIC and SBC do not include log determinant. | | | | | | | | | |
| Autocorrelation Check of Residuals | | | | | | | | | |
| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- | | | | | |
| 6 | 10.72 | 5 | 0.0572 | 0.201 | 0.016 | -0.022 | 0.025 | -0.082 | -0.173 |
| 12 | 17.42 | 11 | 0.0961 | -0.185 | -0.029 | 0.030 | 0.093 | 0.042 | 0.028 |
| 18 | 21.09 | 17 | 0.2224 | 0.015 | -0.089 | -0.019 | -0.090 | -0.085 | -0.022 |
| 24 | 22.63 | 23 | 0.4827 | -0.032 | 0.029 | -0.023 | 0.085 | -0.007 | -0.001 |

2. Model Intervensi Inflasi Umum Berdasarkan Kenaikan TDL