



***AUTOREGRESSIVE FRACTIONALLY INTEGRATED MOVING
AVERAGE (ARFIMA) UNTUK ANALISIS DATA KECEPATAN
ANGIN DI BANDARA INTERNASIONAL AHMAD YANI***

Skripsi

disusun untuk memenuhi salah satu syarat untuk memperoleh gelar
Sarjana Sains Progam Studi Matematika

oleh

Mohammad Jefrie Ilham Akbar

4111415018

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

2020

PERNYATAAN

Dengan ini, saya

nama : Mohammad Jefrie Ilham Akbar

NIM : 4111415018

program studi : Matematika

Menyatakan bahwa skripsi yang berjudul *Autoregressive Fractionally Integrated Moving Average (ARFIMA) untuk Analisis Data Kecepatan Angin di Bandara Internasional Ahmad Yani* ini benar-benar karya saya sendiri dan bukan jiplakan karya orang lain atau pengutipan dengan cara-cara yang tidak sesuai dengan etika keilmuan yang berlaku baik sebagian atau seluruhnya. Pendapat atau temuan orang atau pihak lain yang terdapat dalam skripsi ini telah dikutip atau dirujuk berdasarkan kode etik ilmiah. Atas pernyataan ini, saya secara pribadi siap menanggung resiko/sanksi hukum yang dijatuhkan apabila ditemukan adanya pelanggaran terhadap etika keilmuan dalam karya ini.

Semarang, Agustus 2020



Mohammad Jefrie Ilham Akbar
NIM 4111415018

PENGESAHAN

Skripsi berjudul *Autoregressive Fractionally Integrated Moving Average (ARFIMA) untuk Analisis Data Kecepatan Angin di Bandara Internasional Ahmad Yani* karya Mohammad Jefrie Ilham Akbar 4111415018 ini telah dipertahankan dalam Ujian Skripsi Universitas Negeri Semarang pada tanggal 20 April 2020 dan disahkan oleh Panitia Ujian.

Semarang, Agustus 2020

Panitia,



Ketua,
Dr. Sugianto, M.Si.

NIP 196102191993031001

Sekretaris,

A handwritten signature in black ink, appearing to read "Mulyono".

Dr. Mulyono, M.Si.
NIP 197009021997021001

Pengaji I,

A handwritten signature in black ink, appearing to read "Sugiman".

Drs. Sugiman, M.Si.
NIP 196401111989011001

Pengaji II,

A handwritten signature in black ink, appearing to read "Walid".

Dr. Walid, S.Pd., M.Si.
NIP 197408192001121001

Pengaji III/Pembimbing,

A handwritten signature in black ink, appearing to read "Iqbal Kharisudin".

Dr. Iqbal Kharisudin, S.Pd., M.Sc.
NIP 197908052005011003

MOTTO DAN PERSEMBAHAN

MOTTO

“Sesungguhnya beserta kesulitan ada kemudahan, maka apabila engkau telah selesai (dari suatu urusan), tetaplah bekerja keras (untuk urusan yang lain), dan hanya kepada Tuhanmulah engkau berharap”. (Q.S Al-Insyirah 6-8)

PERSEMBAHAN

1. Untuk kedua orang tua, kakak serta segenap keluarga tercinta yang senantiasa memberikan dukungan dan doa.
2. Untuk teman-teman semua yang tidak bisa disebutkan satu persatu.
3. Untuk Almamaterku Universitas Negeri Semarang.

PRAKATA

Puji syukur kehadirat Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya, sehingga penulis dapat mnyelesaikan penulisan skripsi yang berjudul “*Autoregressive Fractionally Integrated Moving Average (ARFIMA)* untuk Analisis Data Kecepatan Angin di Bandara Internasional Ahmad Yani”. Penulisan skripsi ini sebagai syarat yang harus dipenuhi oleh penulis untuk memperoleh gelar sarjana sains di Universitas Negeri Semarang.

Penulisan skripsi ini dapat terselesaikan karena adanya bimbingan, bantuan, dan dukungan dari berbagai pihak baik secara langsung maupun tidak langsung. Oleh karena itu, penulis mengucapkan terimakasih kepada:

1. Prof. Dr. Fathur Rokhman, M.Hum., Rektor Universitas Negeri semarang.
2. Dr. Sugianto, M.Si., Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Semarang.
3. Dr. Mulyono, M.Si. Ketua Jurusan Matematika FMIPA Universitas Negeri Semarang.
4. Drs. Mashuri, M.Si., Ketua Prodi Matematika Jurusan Matematika FMIPA Universitas Negeri Semarang.
5. Prof. Dr. St. Budi Waluyo, M.Si., Dosen Wali yang telah memberikan arahan dan bimbingan semasa kuliah.
6. Dr. Iqbal Kharisudin, S.Si, M.Sc., Dosen Pembibing yang telah memberikan bimbingan, pengarahan, nasehat, motivasi dan saran selama penyusunan skripsi ini.
7. Drs. Sugiman, M.Si., Dosen Penguji I yang telah memberikan saran kepada penulis dalam penyusunan skripsi ini.
8. Dr. Walid, S.Pd., M.Si., Dosen Penguji II yang telah memberikan saran kepada penulis dalam penyusunan skripsi ini
9. Bapak dan Ibu Dosen Jurusan Matematika, yang telah memberikan bimbingan dan ilmu kepada penulis selama menempuh pendidikan di Universitas Negeri Semarang.

10. Kedua orang tua dan keluarga besar tercinta, atas doa, perjuangan, pengorbanan dan segala macam dukungan hingga penulis dapat menyelesaikan perkuliahan ini.
11. Teman-teman seperjuangan di HIMATIKA, Bina Vokalia dan BPH.
12. Teman-teman seperjuangan Matematika 2015 (Matmur Merah Jambu) yang telah memberikan semangat dan motivasi kepada penulis.
13. Teman-teman semua yang telah memberikan semangat, motivasi, dan bantuan dalam bentuk apapun dalam menyelesaikan skripsi ini.
14. Semua pihak yang telah membantu terselesaiannya penulisan skripsi ini yang tidak dapat disebutkan namanya satu persatu

Hanya ucapan terimakasih dan doa, semoga apa yang telah diberikan tercatat sebagai amal baik dan mendapatkan balasan dari Allah SWT. Semoga skripsi ini dapat memberikan manfaat dan kontribusi dalam kemajuan dunia pendidikan dan kepada semua pihak yang berkepentingan.

Semarang, Juli 2020

Penulis

ABSTRAK

Akbar, Mohammad Jefrie Ilham. 2020. *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk Analisis Data Kecepatan Angin di Bandara Internasional Ahmad Yani. Skripsi, Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang. Pembimbing Dr. Iqbal Kharisudin, S.Pd., M.Sc.

Kata kunci : *Long Memory*, ARFIMA, GPH, R/S

Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) merupakan pengembangan dari model ARIMA dengan nilai *differencing d* adalah bilangan pecahan. Penelitian ini bertujuan untuk pemodelan ARFIMA pada data kecepatan angin di Bandara Internasional Ahmad Yani dalam frekuensi harian. Pada penelitian ini dilakukan identifikasi *long memory* pada data kecepatan angin di Bandara Internasional Ahmad Yani yang memberikan hasil bahwa data diindikasikan mempunyai sifat *long memory*. Selanjutnya dilakukan pembentukan model ARFIMA(p, d, q) dengan menentukan nilai estimasi parameter d menggunakan metode *Geweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S). Model terbaik dipilih berdasarkan nilai AIC terkecil. Model terbaik untuk ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ adalah model ARFIMA(0, d , [2]) dengan nilai AIC -1384,527. Model terbaik untuk ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ adalah model ARFIMA(0, d , 1) dengan nilai AIC -1385,62. Tingkat akurasi peramalan didasarkan pada nilai RMSE, MAE, dan MAPE. Nilai eror validasi peramalan model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ adalah RMSE 0,74966754, MAE 0,593468, dan MAPE 10,45511. Nilai eror pada validasi peramalan model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$ adalah RMSE 0,7898162, MAE 0,6295811, dan MAPE 10,75531. Nilai MAPE pada kedua model menunjukkan kriteria tingkat kemampuan peramalan yang baik. Nilai eror pada validasi peramalan model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ menunjukkan eror yang lebih kecil dibanding model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$.

DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	i
PERNYATAAN.....	ii
PENGESAHAN	iii
MOTTO DAN PERSEMBAHAN	iv
PRAKATA.....	v
ABSTRAK	vii
DAFTAR ISI.....	viii
DAFTAR GAMBAR	xi
DAFTAR TABEL.....	xiii
DAFTAR LAMPIRAN.....	xiv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
1.6 Sistematika Penulisan Skripsi.....	5
BAB II TINJAUAN PUSTAKA.....	6
2.1 Analisis Runtun Waktu	8
2.2 Proses Linear Stasioneritas	8
2.3 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial.....	10
2.3.1 Fungsi Autokorelasi	10
2.3.2 Fungsi Autokorelasi Parsial	11
2.4 Proses <i>White Noise</i>	11
2.5 Model <i>Autoregressive</i>	12
2.6 Model <i>Moving Average</i>	13
2.7 Model <i>Autoregressive Moving Average</i>	14

2.8 Model <i>Autoregressive Integrated Moving Average</i>	14
2.9 Proses <i>Long Memory</i>	15
2.10 Model <i>Autoregressive Fractionally Integrated Moving Average</i>	16
2.11 Pemodelan Runrun Waktu dengan Metode <i>Box-Jenkins</i>	19
2.11.1 Identifikasi Model	20
2.11.2 Estimasi Parameter Model	20
2.11.3 Uji Diagnostik Model	23
2.11.4 Pemilihan Model Terbaik	24
2.12 Akurasi Model Peramalan	25
2.12.1 <i>Root Mean Square Error</i>	25
2.12.2 <i>Mean Absolute Error</i>	25
2.12.3 <i>Mean Absolute Percentage Error</i>	26
2.13 Penelitian Terdahulu	26
2.14 Kecepatan Angin	28
2.15 Program R	30
2.16 Kerangka Berpikir	31
BAB 3 METODE PENELITIAN	35
3.1 Penentuan Masalah	35
3.2 Perumusan Masalah	35
3.3 Studi Pustaka	36
3.4 Jenis dan Sumber Data	36
3.5 Analisis dan Pengolahan Data	36
3.6 Penarikan Kesimpulan	39
BAB 4 HASIL DAN PEMBAHASAN	40
4.1 Deskripsi Data	40
4.2 Identifikasi <i>Long Memory</i>	42
4.3 Pengujian Stasioneritas	43
4.4 Pembentukan Model ARFIMA	46
4.4.1 Estimasi Parameter d	47
4.4.2 Penentuan Beberapa Model ARFIMA(p, d, q) Berdasarkan Plot ACF dan Plot PACF	47

4.4.3 Estimasi Parameter Model Tentatif ARFIMA(p, d, q).....	50
4.5 Uji Diagnostik Model	51
4.6 Pemilihan Model untuk Peramalan.....	54
4.7 Peramalan	55
4.8 Perbandingan dengan Model Lain	59
4.8.1 Model <i>Autoregressive Integrated Moving Average</i>	59
4.8.2 Metode <i>Extreme Learning Machine</i>	62
4.8.3 Perbandingan Model	65
4.9 Pembahasan	67
BAB 5 SIMPULAN DAN SARAN	71
5.1 Simpulan	71
5.2 Saran	72
DAFTAR PUSTAKA	73
LAMPIRAN	78

DAFTAR GAMBAR

Gambar	Halaman
2.1 Pola Data Horizontal	7
2.2 Pola Data Musiman	7
2.3 Pola Data Sikslis	8
2.4 Pola Data Trend.....	8
2.5 Diagram Penelitian Terdahulu	28
2.6 Kerangka Berpikir	34
3.1 Diagram Alir Analisis Data	38
4.1 Plot Data Runtun Waktu Kecepatan Angin di Bandara Internasional Ahmad Yani	41
4.2 Plot Periodogram	43
4.3 Plot <i>Box-Cox</i> Kecepatan Angin di Bandara Internasional Ahmad Yani	44
4.4 Plot <i>Box-Cox</i> Transformasi Kecepatan Angin di Bandara Internasional Ahmad Yani	45
4.5 Plot Runtun Waktu Hasil Transformasi Data Kecepatan Angin di Bandara Internasional Ahmad Yani	45
4.6 Plot ACF dan Plot PACF <i>Differencing</i> ($\hat{d}_{gph} = 0,346$)	48
4.7 Plot ACF dan Plot PACF <i>Differencing</i> ($\hat{d}_{R/S} = 0,224$)	49
4.8 Plot Data <i>Fitting</i> ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$	56
4.9 Plot Data <i>Fitting</i> ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$	57
4.10 Plot Data Aktual dan Ramalan Model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$	58
4.11 Plot Data Aktual dan Ramalan Model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$	59
4.12 Plot Data <i>Fitting</i> ARIMA(1,1,1)	61
4.13 Plot Data Aktual dan Ramalan Model ARIMA(1,1,1)	62
4.14. Plot Model ELM	62
4.15 Plot Data <i>Fitting</i> ELM	63

4.16 Plot Data Aktual dan Ramalan Model ELM	64
4.17 Plot Data Aktual dan <i>Fitting</i> Model ARFIMA, ARIMA, dan ELM	65
4.18 Plot Data Aktual dan Ramalan Model ARFIMA, ARIMA, dan ELM	66

DAFTAR TABEL

Tabel	Halaman
2.1 Tabel Transformasi Box-Cox	10
2.2 Kriteria Nilai MAPE	26
2.3 Skala Beaufort	29
4.1 Deskripsi Data	40
4.2 Nilai <i>Hurst</i>	42
4.3 Hasil Uji Augmented Dickey-Fuller	46
4.4 Estimasi Parameter d	47
4.5 Estimasi Parameter Model Tentatif ARFIMA $\hat{d}_{gph} = 0,346$	50
4.6 Estimasi Parameter Model Tentatif ARFIMA $\hat{d}_{R/S} = 0,224$	51
4.7 Uji Diagnostik Model ARFIMA ($\hat{d}_{gph} = 0,346$).....	54
4.8 Uji Diagnostik Model ARFIMA ARFIMA ($\hat{d}_{R/S} = 0,224$)	54
4.9 Nilai AIC Model ARFIMA	55
4.10 Nilai Akurasi <i>Fitting</i> Model ARFIMA	56
4.11 Nilai Akurasi Peramalan Model ARFIMA	57
4.12 Estimasi Parameter Model ARIMA(1,1,1)	59
4.13 Nilai Akurasi <i>Fitting</i> Model ARIMA	60
4.14. Nilai Akurasi Peramalan Model ARIMA	61
4.15 Nilai Akurasi <i>Fitting</i> Model ELM	63
4.16 Nilai Akurasi Peramalan Model ELM	64
4.17 Nilai Akurasi <i>Fitting</i> Model ARFIMA, ARIMA, dan ELM	65
4.18 Nilai Akurasi Peramalan Model ARFIMA, ARIMA, dan ELM	66

DAFTAR LAMPIRAN

Lampiran	Halaman
1. Data Kecepatan Angin di Bandara Internasional Ahmad Yani	78
2. <i>Script</i> Program R Studio Model ARFIMA	87
3. Data <i>Fitting</i> Model ARFIMA	104
4. Hasil Peramalan Model ARFIMA	111
5. <i>Script</i> Program R Studio Model ARIMA	112
6. <i>Script</i> Program R Studio Metode ELM	113
7. Hasil ramalan Model ARIMA(1,1,1) dan Metode ELM	117

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Data runtun waktu (*time series*) merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap (Wei, 2006). Analisis runtun waktu merupakan salah satu prosedur statistika yang diterapkan untuk memodelkan dan meramalkan struktur probabilitas keadaan yang akan datang dalam rangka pengambilan keputusan. Beberapa metode dalam statistika yang dapat digunakan untuk peramalan suatu data runtun waktu antara lain *Autoregressive* (AR), *Moving Average* (MA), ARIMA, SARIMA, *exponential smoothing* maupun Jaringan Syaraf Tiruan (JST). Metode-metode tersebut biasanya digunakan untuk menyelesaikan masalah data dengan ketergantungan atau dependensi jangka pendek (*short memory*).

Proses *long memory* telah diamati dalam banyak hal seperti dalam bidang industri, meteorologi, ekonomi dan keuangan. *Long memory* merupakan salah satu fenomena dalam runtun waktu, dimana data runtun waktu mempunyai dependensi jangka panjang yang artinya jika di antara pengamatan yang terpisah jauh, masih mempunyai korelasi yang tinggi. Sifat *long memory* pada data juga ditunjukkan oleh plot *Autocorrelation Function* (ACF) dari data tidak turun secara eksponensial melainkan turun secara lambat atau hiperbolik. Salah satu model runtun waktu yang dapat menggabarkan dependensi jangka panjang adalah model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA).

Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) pertama kali dikembangkan oleh Granger dan Joyeux (1980) yang merupakan pengembangan dari model *Autoregressive Integrated Moving Average* (ARIMA). Hosking (1981) memperkenalkan model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk memodelkan data *long memory*. Model ARIMA hanya dapat menjelaskan data *short memory*, sedangkan model ARFIMA mempunyai kelebihan dapat melakukan pembedaan (*differencing*)

untuk nilai yang telah ditentukan meliputi bilangan pecahan, ini berbeda dengan ARIMA yang mempunyai pembeda yaitu bilangan bulat. Dengan demikian ARFIMA mampu menjelaskan data runtun waktu baik *short memory* maupun *long memory*.

Sudah banyak penelitian-penelitian terkait *long memory* dan ARFIMA. Penelitian-penelitian tersebut antara lain, Devianto dkk (2015) mengaplikasikan *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk meramalkan harga saham pembukaan Kedaung Indah Can Tbk dari 02 Mei 2012 sampai dengan 26 Maret 2012 yang menghasilkan model terbaik ARFIMA(5,0.452,4), dimana untuk peramalan jangka pendek menunjukkan hasil yang sangat dekat dengan data aktual dengan *standard error* yang kecil. Ningrum dan Sulandri (2009) menerapkan model ARFIMA dalam peramalan suku bunga Sertifikat Bank Indonesia (SBI). Mohamed (2016) menggunakan model ARFIMA dalam meramalkan total nilai dari *traded securities* di Republik Arab dari Mesir. Bousalam dan Hamzaoui (2017) melakukan peramalan *long memory* menggunakan model ARFIMA dan pengaplikasiannya pada pasar modal syariah. Kharisudin dkk (2017) melakukan penelitian terkait model *long memory* FARIMA dan aplikasinya pada pemodelan data aset returns di Indonesia. Aye dkk (2014) menggunakan model ARFIMA untuk memprediksi *absolute return* saham harian BRICS (*Brazil, Russia, China, and South Africa*). Idris dkk (2014) melakukan pemodelan dan peramalan Indeks Harga Perdagangan Besar (IHPB) dengan menggunakan ARFIMA diperoleh model (0, 4.03, 1) dengan MAPE 7,716%. Safitri dkk (2019) memodelkan harga emas indonesia menggunakan metode ARFIMA yang menghasilkan model terbaik ARFIMA(1,d[3]) dengan d=1,05716. Walid dkk (2015) melakukan identifikasi model *long memory* pada penggunaan beban listrik di Jawa-Bali. Ibrahim dkk (2011) melakukan pemodelan ARFIMA pada data harian rata-rata suhu di kota Sokoto. Caraka dkk (2016) menggunakan model *long memory* dalam prediksi suhu Stasiun Meteorologi Raja Haji Abdullah Tanjung Balai Karimun Provinsi Kepulauan Riau dari Januari 2014 sampai dengan Februari 2016 diperoleh model terbaik ARFIMA(1, 0.170363,2)

dengan nilai AIC 3.10532737. Paul (2017) meneliti terkait model *long memory* pada data minmum dan maksimum temperatur di india.

Cuaca merupakan aspek penting dalam aktivitas penerbangan. Cuaca mempunyai dua sisi dampak yang berbeda bagi operasional penerbangan. Pada satu sisi kondisi cuaca bisa memberi dampak ekonomis berupa efisiensi pada pesawat terbang, Pada sisi lain cuaca memberi ancaman pada keselamatan penerbangan. Adapun faktor cuaca yang mempengaruhi penerbangan antara lain angin, tekanan udara, awan, hujan, kabut dan salju (Day, 2018). Pada bulan januari 2019 puluhan penerbangan maskapai Ahmad Yani Semarang mengalami *delay* atau penundaan akibat cuaca buruk disertai hujan dan angin kencang (iNews.id, 2019). Selain itu cuaca ekstrem berupa hujan dan angin kencang pada tanggal 22 Januari 2019 menjadi penyebab terganggunya lalu lintas penerbangan di Bandara internasional Sultan Hasanuddin. Tercatat ada tiga pesawat tujuan Makassar yang dialihkan ke Balikpapan (SULSELSATU.com, 2019).

Beberapa penelitian berupaya mengetahui informasi terkait pengaruh kecepatan angin dalam berbagai aspek kehidupan dan pentingnya memprediksi kecepatan angin di suatu wilayah seperti yang dilakukan Desvina dan Anggrian (2015) memprediksi kecepatan angin di Kota Pekanbaru. Perdana dan Putra (2017) menganalisis kejadian *crosswind* di landasan pacu Bandara Supadio Pontianak. Informasi kecepatan angin di permukaan landasan pacu merupakan salah satu faktor penting dalam proses lepas landas (*take-off*) dan pendaratan (*landing*) pesawat. Kecepatan angin dapat mempengaruhi daya angkat pesawat serta menghindari pesawat tergelincir dan keluar dari landasan pacu.

Dalam penelitian ini penulis akan mengidentifikasi apakah data kecepatan angin di Bandara Internasional Ahmad Yani diindikasi adanya long memory atau tidak. Selanjutnya penulis menggunakan model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) dalam menganalisis data kecepatan angin di Bandara Internasional Ahmad Yani.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, maka rumusan masalah dalam penelitian ini adalah sebagai berikut.

1. Bagaimana model peramalan dengan metode ARFIMA pada data kecepatan angin di Bandara Internasional Ahmad Yani?
2. Bagaimana hasil peramalan kecepatan angin di Bandara Internasional Ahmad Yani dengan model peramalan ARFIMA?

1.3 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut.

1. Melakukan analisis data kecepatan angin di Bandara Internasional Ahmad Yani dengan menggunakan metode ARFIMA.
2. Identifikasi *long memory* pada data menggunakan plot ACF, statistik *Hurst* (H) dan plot periodogram.
3. Metode estimasi parameter *differencing* (d) yang digunakan adalah *Geweweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S).

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah sebagai berikut.

1. Mengetahui model peramalan dengan metode ARFIMA pada data kecepatan angin di Bandara Internasional Ahmad Yani.
2. Mengetahui bagaimana hasil peramalan dengan model ARFIMA pada data kecepatan angin di Bandara Internasional Ahmad Yani.

1.5 Manfaat Penelitian

Manfaat yang dapat diperoleh dalam penelitian ini adalah sebagai berikut.

1. Manfaat teoritis dari penelitian ini diharapkan dapat memberikan sumbangan pemikiran dalam memperkaya wawasan konsep analisis runtun waktu,

- peramalan, dan ARFIMA terutama tentang analisis data kecepatan angin di Bandara Internasional Ahmad Yani menggunakan model ARFIMA.
2. Manfaat praktis dari penelitian ini diharapkan dapat menyumbangkan pemikiran terhadap pemecahan masalah yang berkaitan dengan peramalan data kecepatan angin. Selanjutnya hasil penelitian ini diharapkan menjadi acuan dalam melakukan analisis data runtun waktu.

1.6 Sistematika Penulisan Skripsi

Secara garis besar sistematika penulisan skripsi ini terdiri dari tiga bagian, yaitu bagian awal, bagian isi, dan bagian akhir, yang masing-masing diuraikan sebagai berikut. Bagian awal terdiri dari halaman judul, pernyataan, motto dan persembahan, prakata, abstrak, daftar isi, daftar tabel, daftar gambar dan daftar lampiran. Bagian isi merupakan bagian pokok skripsi yang terdiri dari 5 bab, sebagai berikut. Bab 1 (Pendahuluan), berisi tentang latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, sistematika penulisan. Bab 2 (Tinjauan Pustaka), membahas teori yang melandasi permasalahan skripsi serta penjelasan yang merupakan landasan teoritis yang diterapkan dalam skripsi, pokok bahasan yang terkait dengan pelaksanaan penelitian serta kerangka berpikir. Bab 3 (Metode Penelitian), berisi tentang prosedur atau langkah-langkah yang dilakukan dalam penelitian ini meliputi fokus penelitian, klasifikasi penelitian berdasarkan tujuan dan pendekatan, populasi, sampel, dan teknik pengambilan sampel, metode pengumpulan data, metode analisis data, dan penarikan kesimpulan. Bab 4 (Hasil Penelitian dan Pembahasan), berisi tentang hasil penelitian dan pembahasannya yang disajikan dalam rangka menjawab permasalahan penelitian. Bab 5 (Simpulan dan Saran), bagian ini berisi tentang simpulan hasil penelitian dan saran-saran dari peneliti. Bagian akhir dari skripsi terdiri dari daftar pustaka dan lampiran-lampiran yang digunakan dalam penelitian.

BAB 2

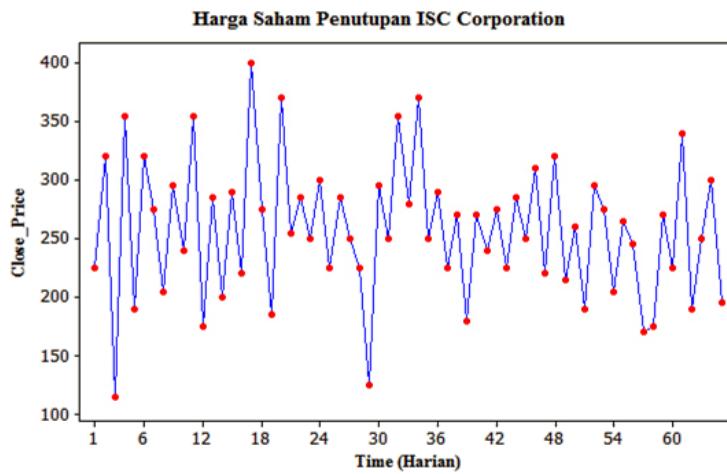
TINJAUAN PUSTAKA

2.1 Analisis Runtun Waktu

Data runtun waktu merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap (Wei, 2006). Analisis runtun waktu (*time series*) merupakan salah satu prosedur statistika yang diterapkan untuk memodelkan dan meramalkan struktur probabilitas keadaan yang akan datang dalam rangka pengambilan keputusan. Dasar runtun waktu adalah pengamatan sekarang (Z_t) dipengaruhi oleh satu atau beberapa pengamatan sebelumnya (Z_{t-k}). Dengan kata lain, model runtun waktu dibuat karena secara statistic dan korelasi antar deret pengamatan. Tujuan analisis runtun waktu antara lain memahami dan menjelaskan mekanisme tertentu, meramalkan suatu nilai di masa depan, dan mengoptimalkan sistem kendali (Makridakis dkk, 1983).

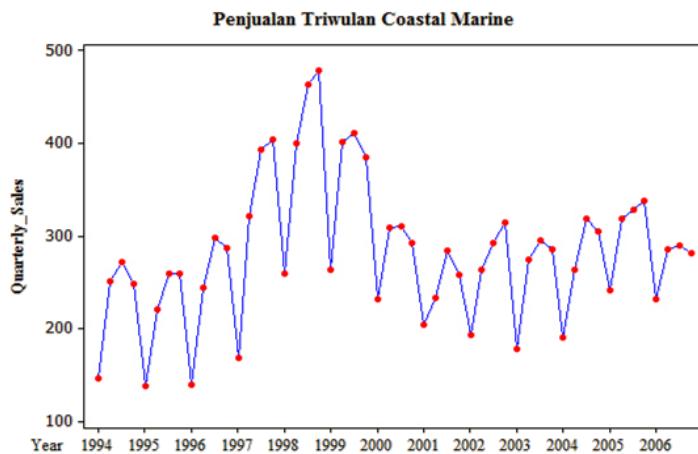
Menurut Makridakis dkk (1983) komponen penting yang harus diperhatikan dalam analisis runtun waktu adalah jenis pola data. Pola data dapat dibedakan menjadi empat, yaitu pola data horizontal, pola data musiman, pola data siklis dan pola data trend.

- (1) Pola data horizontal terjadi pada saat nilai data berfluktuasi di sekitar nilai rata-rata yang konstan (deret seperti itu adalah stasioner terhadap nilai rata-ratanya). Contoh pola data horizontal dapat dilihat pada Gambar 2.1 yang merupakan plot data harga saham penutupan ISC Corporation (Hanke dan Wichern, 2009).



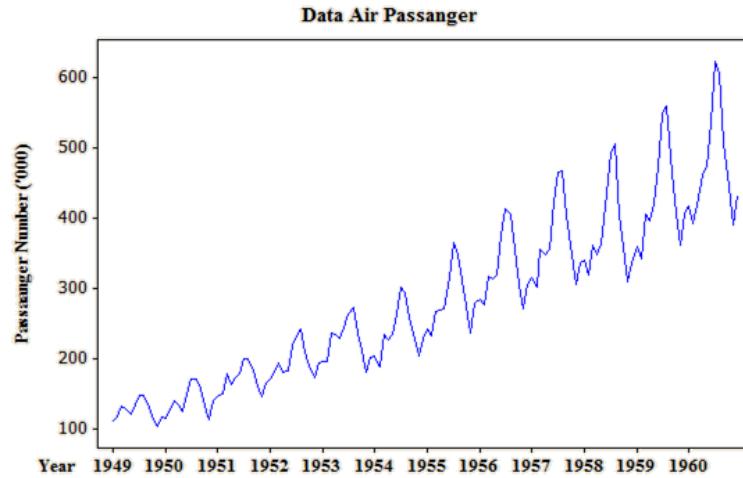
Gambar 2.1 Pola Data Horizontal

- (2) Pola data musiman terjadi jika suatu deret dipengaruhi oleh faktor musiman (misalnya kuartal tahun tertentu, bulanan, atau mingguan). Contoh pola data musiman dapat dilihat pada Gambar 2.2 yang merupakan plot data penjualan triwulan Coastal Marine (Hanke dan Wichern, 2009).



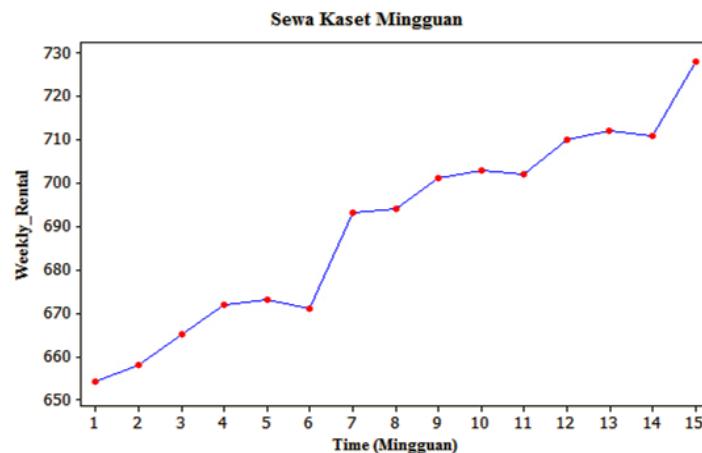
Gambar 2.2 Pola Data Musiman

- (3) Pola data siklis terjadi bila terdapat pola naik turun secara siklis di sekitar *trend* atau kondisi normal. Data yang sering mengalami siklis antara lain data perdagangan, industri, dan keuangan. Gambar 2.3 menunjukkan contoh pola data siklis yaitu plot data penumpang pesawat (*air passanger*) dari ahun 1949 - 1961 (Variwa, 2019).



Gambar 2.3 Pola Data Siklis

- (4) Pola data *trend* terjadi jika suatu pola data pada jangka waktu tertentu cenderung menuju satu arah baik naik atau turun. Gambar 2.4 menunjukkan contoh pola data *trend* yaitu plot data mingguan penyewaan kaset film salah satu perusahaan di Denver, Colorado Hanke dan Wichern (2009).



Gambar 2.4 Pola Data *Trend*

2.2 Proses Linear Stasioneritas

Suatu proses stokastik adalah keluarga peubah acak $Z(\omega, t)$, dengan ω milik ruang sampel dan t milik suatu himpunan indeks. Jika suatu pengamatan Z_1, Z_2, \dots, Z_n sebagai suatu proses stokastik, maka variabel random $Z_{t_1}, Z_{t_2}, \dots, Z_{t_n}$ dengan F adalah suatau fungsi distribusi kumulatif dikatakan *strictly stationary* apabila $F(Z_{t_1}, Z_{t_2}, \dots, Z_{t_m})$ sama dengan $F(Z_{t_1+k}, Z_{t_2+k}, \dots, Z_{t_m+k})$

untuk $m = 1, 2, \dots, n$. Runtun waktu yang bersifat *strictly stationary*, waktu pengamatan tidak terpengaruh terhadap *mean* (μ), varians (σ^2), dan kovarian (γ_k) (Wei, 2006).

Stasioneritas dibedakan menjadi dua yaitu stasioner dalam rata-rata (*mean*) dan stasioner dalam variansi (varians) (Wei, 2006). Stasioner dalam rata-rata adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak bergantung pada waktu dan variansi dari fluktuasi tersebut. Dari bentuk plot data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner. Apabila dilihat dari plot ACF (*Autocorrelation Function*), maka nilai-nilai autokorelasi dari stasioner akan turun menuju nol sesudah time *lag* (selisih waktu) kelima atau keenam. Sebuah data runtun waktu dikatakan stasioner dalam variansi apabila struktur dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan plot runtun waktu, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

Sebelum melakukan pemodelan pada data deret waktu, stasioneritas data dapat diperiksa dengan mengamati apakah apakah ada atau tidak akar unit (*unit root*) dalam suatu data runtun waktu. Uji yang biasa digunakan adalah uji *Augmented Dicky-Fuller* (ADF). Hipotesis yang digunakan dalam uji ADF adalah (Rosadi, 2011):

$$H_0 : \delta = 0 \text{ (terdapat akar unit, data tidak stasioner)}$$

$$H_1 : \delta < 0 \text{ (tidak terdapat akar unit, data stasioner).}$$

Statistik uji ADF adalah sebagai berikut

$$t_{hitung} = \frac{\hat{\delta}}{SE(\hat{\delta})} \quad (2.1)$$

dengan, $\hat{\delta}$ adalah estimator *least square* dan $SE(\hat{\delta})$ merupakan *standart error* dari nilai estimasi δ (koefisien *standart error* dari model). Kriteria pengujian berdasarkan uji ADF adalah tolak H_0 jika $t_{hitung} > t_{tabel}$ atau $p\ value < \alpha$.

Pemodelan data runtun waktunya sering ditemukan kondisi *mean* yang tidak stasioner, sehingga diperlukan suatu cara untuk menstasionerkan data yaitu dengan cara pembedaan (*differencinig*). *Differencing* dilakukan agar dapat

mengatasi korelasi antara Z_t dengan Z_{t-k} , dengan k yang cukup besar. Selain itu, apabila data runtun waktu tidak stasioner dalam varians, maka dilakukan transformasi data. Metode transformasi yang umum digunakan adalah transformasi *Box-Cox*. Secara umum persamaan transformasi *Box-Cox* sebagai berikut (Wei, 2006):

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

dengan λ adalah parameter transformasi. Nilai λ yang dipilih adalah nilai λ yang meminimumkan jumlah kuadrat residual sehingga memiliki varians yang minimum. Secara umum transformasi *Box-Cox* untuk beberapa nilai λ disajikan dalam Tabel 2.1(Wei, 2006).

Tabel 2.1 Tabel Transformasi *Box-Cox*

Nilai Estimasi	Transformasi yang sesuai
-1	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\ln Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t

2.3 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial

2.3.1 Fungsi Autokorelasi

Dari proses stasioner suatu data runtun waktu (Z_t) diperoleh $E(Z_t) = \mu$ dan variansi $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$ yang konstan, dan kovarian $Cov(Z_t, Z_s)$, yang merupakan fungsi dari perbedaan waktu $|t - s|$ (Wei, 2006).

Kovarian antara Z_t dan Z_{t+k} didefinisikan sebagai berikut

$$\gamma_k = Cov(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.3)$$

sedangkan autokorelasi antara Z_t dan Z_{t+k} dapat didefinisikan sebagai berikut

$$\rho_k = \frac{Cov(Z_t, Z_{t+k})}{\sqrt{Var(Z_t)}\sqrt{Var(Z_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad (2.4)$$

dengan notasi $Var(Z_t) = Var(Z_{t+k}) = \gamma_0$. Sebagai fungsi dari k , γ_k disebut fungsi autokovarian dan ρ_k disebut fungsi autokorelasi atau *autocorrelation function* (ACF). Dalam analisis runtun waktu, γ_k dan ρ_k masing-masing menggambarkan kovarian dan korelasi antara Z_t dan Z_{t+k} dari proses yang sama,

hanya dipisahkan oleh *lag* ke- k . Fungsi autokovariansi γ_k dan fungsi autokorelasi ρ_k memiliki sifat-sifat sebagai berikut:

1. $\gamma_0 = \text{Var}(Z_t), \rho_0 = 1,$
2. $|\gamma_k| \leq \gamma_0, |\rho_k| \leq 1,$
3. $\gamma_k = \gamma_{-k}, \rho_k = \rho_{-k}$, untuk semua nilai k , γ_k dan ρ_k adalah fungsi yang sama dan simetrik *lag* $k = 0$.

Sampel ACF didefinisikan dengan persamaan (Wei, 2006)

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (2.5)$$

untuk $k = 0, 1, 2, \dots, n$ dengan $\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t$,

dengan,

Z_t : nilai aktual pada waktu ke- t

k : lag

$\hat{\rho}_k$: nilai estimasi *autocorrelation function* (ACF) lag ke- k .

2.3.2 Fungsi Autokorelasi Parsial

Fungsi autokorelasi parsial atau *partial autocorrelation function* (PACF) digunakan untuk mengukur tingkat keeratan hubungan antara Z_t dan Z_{t+k} setelah dependensi linear dalam variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ dihilangkan (Wei, 2006). Fungsi autokorelasi parsial (PACF) dapat didefinisikan sebagai berikut

$$\phi_{kk} = \text{Corr}(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1}). \quad (2.6)$$

Sampel PACF didefinisikan dengan persamaan

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \hat{\rho}_j} \quad (2.7)$$

dengan $\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j}$, $j = 1, 2, \dots, k-1$.

2.4 Proses *White Noise*

Proses *white noise* suatu proses yang membangun atau menjadi *buliding block* bagi proses runtun waktu yang lainnya. Suatu proses a_t disebut proses *white noise* jika terdiri dari variabel acak yang tidak berkorelasi antar variabel dan

berdistribusi normal dengan rata-rata konstan $E(a_t) = 0$, variansi konstan $Var(a_t) = \sigma^2$ dan $\gamma_k = Cov(a_t, a_{t+k}) = 0$ untuk $k \neq 0$ (Wei, 2006). Dengan demikian proses *white noise* stasioner dengan fungsi autokovariansi

$$\gamma_k = \begin{cases} \sigma_a^2, & k = 0, \\ 0, & k \neq 0, \end{cases} \quad (2.8)$$

fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & k = 0, \\ 0, & k \neq 0, \end{cases} \quad (2.9)$$

dan fungsi autokorelasi parsial

$$\phi_{kk} = \begin{cases} 1, & k = 0, \\ 0, & k \neq 0. \end{cases} \quad (2.10)$$

2.5 Model Autoregressive

Proses representasi model autoregressive (AR) dengan $\pi_1 = \phi_1, \pi_2 = \phi_2, \dots, \pi_p = \phi_p$, dan $\pi_k = 0$ untuk $k > p$ maka bentuk fungsi persamaan AR pada orde p , yang dinotasikan AR(p) adalah sebagai berikut:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.11)$$

atau

$$\phi_p(B) \dot{Z}_t = a_t \quad (2.12)$$

dengan, $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ dan $\dot{Z}_t = Z_t - \mu$

\dot{Z}_t : nilai variabel pada waktu ke- t

B : operator *backshift*

$\phi_p(B)$: polinomial *autoregressive* ke- p

ϕ_p : koefisien atau parameter dari model *autoregressive*

a_t : variabel residual pada waktu ke- t

p : orde AR.

Sebagai contoh, persamaan model AR(1) sebagai berikut

$$(1 - \phi_1 B) \dot{Z}_t = a_t \quad (2.13)$$

atau

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + a_t. \quad (2.14)$$

ACF dari proses AR(1) didapatkan dari autokovarian yang diperoleh sebagai berikut

$$\begin{aligned} E(\dot{Z}_{t-k}\dot{Z}_t) &= E(\phi_1\dot{Z}_{t-k}\dot{Z}_{t-1}) + E(\dot{Z}_{t-k}a_t) \\ \gamma_k &= \phi_1\gamma_{k-1}, \quad k \geq 1, \end{aligned} \quad (2.15)$$

sehingga ACF menjadi

$$\rho_k = \phi_1\rho_{k-1} = \phi_1^k, \quad k \geq 1. \quad (2.16)$$

PACF dari proses AR(1) adalah sebagai berikut

$$\phi_{kk} = \begin{cases} \rho_1 = \phi_1, & \text{untuk } k=1 \\ 0, & \text{untuk } k \geq 2. \end{cases} \quad (2.17)$$

2.6 Model *Moving Average*

Menurut (Wei, 2006), secara umum bentuk model MA dengan order q , yang dinotasikan $\text{MA}(q)$ mempunyai persamaan sebagai berikut:

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \cdots - \theta_q a_{t-q} \quad (2.18)$$

atau

$$\dot{Z}_t = \theta_q(B)a_t \quad (2.19)$$

dengan, $\theta_q(B) = 1 - \theta_1B - \cdots - \theta_qB^q$

Z_t : nilai variabel pada waktu ke- t

B : operator *backshift*

$\theta_q(B)$: polinomial *moving average* ke- q

$a_{t-1}, a_{t-2}, \dots, a_{t-q}$: nilai variabel residual sebelumnya (*lag*)

θ_q : koefisien model MA yang menunjukkan bobot

a_t : variabel residual pada ke- t

q : orde MA.

Perbedaan model AR dengan model MA terletak pada jenis variabel *independent*. Bila variabel pada model MA yang menjadi variabel *independent* adalah nilai residual pada periode sebelumnya, sedangkan variabel pada model AR adalah nilai sebelumnya dari variabel *independent*.

Sebagai contoh, persamaan model MA(1) sebagai berikut

$$\begin{aligned}\dot{Z}_t &= a_t - \theta_1 a_{t-1} \\ &= (1 - \theta_1 B)a_t.\end{aligned}\quad (2.20)$$

ACF dari proses MA(1) didapatkan dari fungsi autokovarian sebagai berikut

$$\gamma_k = \sigma_a^2(1 - \theta_1 B)(1 - \theta_1 B^{-1}) = \sigma_a^2(-\theta_1 B^{-1} + (1 + \theta_1^2) - \theta_1 B),$$

sehingga autokovarian dari MA(1) adalah

$$\gamma_k = \begin{cases} (1 + \theta_1^2)\sigma_a^2, & k = 0, \\ -\theta_1\sigma_a^2, & k = 1, \\ 0, & k > 1, \end{cases} \quad (2.21)$$

sehingga ACF dari MA(1) menjadi

$$\rho_k = \begin{cases} \frac{-\theta_1}{1+\theta_1^2}, & k = 1 \\ 0, & k > 1. \end{cases} \quad (2.22)$$

PACF dari proses MA(1) adalah sebagai berikut

$$\phi_{kk} = \frac{-\theta_1^k(1-\theta_1^2)}{1-\theta_1^{2(k+1)}}, \quad \text{untuk } k \geq 1. \quad (2.23)$$

2.7 Model Autoregressive Moving Average

Model *Autoregressive Moving Average* (ARMA) merupakan model campuran antara AR dan MA, bentuk umum dari model ARMA(p, q) adalah sebagai berikut:

$$\phi_p(B)\dot{Z}_t = \theta_q(B)a_t \quad (2.24)$$

dengan, $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ dan $\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$

Z_t : nilai variabel pada waktu ke- t

B : operator *backshift*

$\phi_p(B)$: polinomial *autoregressive* ke- p

$\theta_q(B)$: polinomial *moving average* ke- q

a_t : variabel residual pada waktu ke- t .

2.8 Model Autoregressive Integrated Moving Average

Jika data deret waktu tidak stasioner, model *Box-Jenkins* ini disebut model *Autoregressive Integrated Moving Average* (ARIMA). Kestasioneran deret data

pada level merupakan syarat utama dari model AR, MA, dan ARMA apabila deret data tidak stasioner pada *mean* maka proses transformasi data dapat dilakukan. Bentuk transformasi data yang dapat dilakukan adalah dengan melakukan proses diferensiasi. Transformasi data dapat dilakukan melalui transformasi logaritma natural (*ln*) dan proses diferensiasi. Secara umum model ARIMA (*Autoregressive Integrated Moving Average*) p, d, q dirumuskan dengan notasi sebagai berikut :

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B)a_t \quad (2.25)$$

dengan, operator stasioner AR $\phi_p(B) = 1 - \phi_1B - \dots - \phi_pB^p$ dan operator *invertible* MA $\theta_q(B) = 1 - \theta_1B - \dots - \theta_qB^q$. Parameter θ_0 memainkan peran yang sangat berbeda untuk $d = 0$ dan $d > 0$. Ketika $d = 0$, proses asli stasioner, dan θ_0 terkait dengan rerata proses dengan $\theta_0 = \mu(1 - \phi_1 - \dots - \phi_p)$.

2.9 Proses *Long Memory*

Long memory memiliki arti bila fungsi autokorelasi antara Z_t dengan Z_{t+k} turun secara hiperbolik dan *lag* yang signifikan semakin banyak maka dapat diidentifikasi adanya dependensi jangka panjang dalam data yang merupakan ciri dari memori jangka panjang (*long memory*). Suatu runtun waktu stasioner $Z_t, t = 1, 2, \dots, N$ tergolong ke dalam *long memory* ketika mempunyai fungsi korelasi $\rho(k)$ berlaku $k \rightarrow \infty$ adalah sebagai berikut

$$\lim_{k \rightarrow \infty} \frac{\rho(k)}{C_p(k)^{2d-1}} = 1. \quad (2.26)$$

Adapun C_p adalah konstanta dan $d \in (0,0.5)$ menunjukkan parameter *long memory*. Korelasi dari suatu proses *long memory* akan cenderung turun perlahan secara hiperbolik (Beran, 1994).

Selain melihat dari plot ACF, adanya *long memory* pada data runtun waktu bisa diketahui melalui nilai *Hurst* (H) yang diperoleh dengan menggunakan statistik R/S (Hurst, 1951). Apabila nilai $H = 0,5$, maka data tersebut memiliki sifat *short memory*. Apabila berada nilai H pada interval $0 < H < 0,5$, maka data tersebut memiliki sifat *intermediate memory*. Dan apabila nilai H pada interval $0,5 < H < 1$, maka data tersebut memiliki sifat *long memory*. Identifikasi *long memory* dengan menentukan nilai *Hurst* (H) diperoleh melalui perhitungan

dengan metode *Rescaled Range Statistics* (R/S) dengan langkah-langkah sebagai berikut (Safitri dkk, 2019):

1. Menghitung *mean* (\bar{Z}).

$$\bar{Z} = \frac{1}{T} \sum_{t=1}^T Z_t, \quad t = 1, 2, \dots, T. \quad (2.27)$$

2. Menghitung *adjusted mean*.

$$Z_t^{adj} = Z_t - \bar{Z}, \quad t = 1, 2, \dots, T. \quad (2.28)$$

3. Menghitung deviasi kumulatif.

$$Z_t^* = \sum_{t=1}^T Z_t^{adj}, \quad t = 1, 2, \dots, T. \quad (2.29)$$

4. Menghitung rentang deviasi kumulatif.

$$R_t = \max(Z_1^*, Z_2^*, \dots, Z_t^*) - \min(Z_1^*, Z_2^*, \dots, Z_t^*), \quad t = 1, 2, \dots, T. \quad (2.30)$$

5. Menghitung standar deviasi.

$$s_t = \sqrt{\frac{1}{T} \sum_{t=1}^T (Z_t - \bar{Z})^2}, \quad t = 1, 2, \dots, T. \quad (2.31)$$

6. Menghitung *Rescaled Range* (R/S).

$$(R/S)_t = R_t / S_t, \quad t = 1, 2, \dots, T. \quad (2.32)$$

7. Menentukan nilai *Hurst* (H) melalui statistik R/S dari data runtun waktu.

$$(R/S)_t = c \cdot t^H, \quad t = 1, 2, \dots, T \quad (2.33)$$

$$\log(R/S)_t = \log c + H \log t \quad (2.34)$$

dengan c suatu konstanta dan H nilai *Hurst*.

8. Selanjutnya nilai *Hurst* (H) dapat diperoleh menggunakan metode *Ordinary Least Square* (OLS).

$$H = \frac{\sum_{j=1}^T (X_j - \bar{X})(Y_j - \bar{Y})}{\sum_{j=1}^T (X_j - \bar{X})^2} \quad (2.35)$$

dengan, $X_j = \log t$ dan $Y_j = \log(R/S)_t$.

2.10 Model Autoregressive Fractionally Integrated Moving Average

Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) pertama kali dikembangkan oleh Granger dan Joyeux (1980) yang merupakan pengembangan dari model *Autoregressive Integrated Moving Average*

(ARIMA). Hosking (1981) memperkenalkan model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk memodelkan data *long memory*. Proses ARFIMA(p, d, q), dengan p dan q adalah bilangan bulat non negatif dan $0 < d < 0,5$, merupakan runtun waktu stasioner dengan fungsi autokorelasi yang mana lagnya turun secara lambat (Brockwell dan Davis, 2016). Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) dapat mengatasi kelemahan model ARIMA, dimana ARIMA hanya dapat menjelaskan data jangka pendek dengan *differencing* (d) bilangan bulat. Moulines dan Soulier (1999) mengungkapkan bahwa model ARFIMA merupakan model yang mampu menjelaskan data runtun waktu baik berupa data jangka pendek maupun jangka panjang dengan *differencing* (d) bernilai pecahan. Bentuk umum dari model ARFIMA(p, d, q) sebagai berikut (Wei, 2006):

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \quad (2.36)$$

dengan,

d : parameter pembeda (bilangan pecahan)

$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ adalah polinomial *autoregressive* ke- p

$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ adalah polinomial *moving average* ke- q

$a_t \sim IIDN(0, \sigma^2)$

$(1 - B)^d = \Delta^d = \sum_k^{\infty} \binom{dk}{k} (k - 1)$ operator pembeda pecahan.

Untuk suatu nilai d bernilai pecahan, operator fraksional diferensi $(1 - B)^d$ didefinisikan sebagai berikut:

$$(1 - B)^d = 1 + \sum_{k=1}^{\infty} \frac{\Gamma(-d+k)}{\Gamma(-d)k!} B^k. \quad (2.37)$$

Pada persamaan (2.36) untuk berbagai nilai k , ekuivalen dengan:

$$\begin{aligned} (1 - B)^d &= 1 + \sum_{k=1}^{\infty} \frac{\Gamma(-d+k)}{\Gamma(-d)k!} B^k \\ &= 1 + \frac{\Gamma(-d+1)}{\Gamma(-d)1!} B^1 + \frac{\Gamma(-d+2)}{\Gamma(-d)2!} B^2 + \frac{\Gamma(-d+3)}{\Gamma(-d)3!} B^3 + \dots \\ &= 1 + \frac{\Gamma(-d)}{\Gamma(-d-1)1!} B^1 + \frac{\Gamma(-d+1)}{\Gamma(-d-1)2!} B^2 + \frac{\Gamma(-d+1)}{\Gamma(-d-1)3!} B^3 + \dots \\ &= 1 - dB - \frac{d(1-d)B^2}{2} - \frac{d(1-d)(2-d)B^3}{6} + \dots. \end{aligned} \quad (2.38)$$

Spectral density adalah sebuah fungsi real positif yang variabel frekuensinya dihubungkan dengan fungsi deterministik dari waktu. Dalam (Palma, 2007) *spectral density* dari (2.38) adalah sebagai berikut:

$$\begin{aligned} f(\lambda_j) &= f_0(\lambda_j) \left[2 \sin \frac{\lambda}{2} \right]^{-2d} \\ &= \frac{\sigma^2}{2\pi} \left[2 \sin \frac{\lambda}{2} \right]^{-2d} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2} \end{aligned} \quad (2.39)$$

dengan $\frac{\sigma^2}{2\pi} \frac{|\theta(e^{-i\lambda})|^2}{|\phi(e^{-i\lambda})|^2}$ adalah *spectral density* dari proses ARMA(p, q) dan λ adalah frekuensi dari periodogram.

Fungsi autokovarian dari proses ARFIMA($0, d, 0$) adalah

$$\gamma_0(k) = \sigma^2 \frac{\Gamma(1-2d)}{\Gamma(1-d)\Gamma(d)} \frac{\Gamma(k+d)}{\Gamma(1+k-d)} \quad (2.40)$$

dengan $\Gamma(\cdot)$ adalah fungsi gamma, dan ACF dari proses ARFIMA($0, d, 0$) adalah

$$\rho_0(k) = \frac{\Gamma(1-d)}{\Gamma(d)} \frac{\Gamma(k+d)}{\Gamma(1+k-d)}. \quad (2.41)$$

PACF dari proses ARFIMA($0, d, 0$) adalah sebagai berikut

$$\phi_{nn} = \frac{d}{(n-d)} \quad (2.42)$$

dengan $\phi_{nn} \approx \frac{d}{n}$ untuk nilai n yang besar.

Ketika memodelkan runtun waktu memori jangka panjang, model ARFIMA memberikan hasil yang tidak dapat diperoleh dengan model tak fraksional ARIMA. Parameter pembedaan fraksional menangkap adanya fenomena jangka panjang tanpa menimbulkan masalah yang berkaitan dengan model ARMA. Menurut Sowell (1992), masalah yang mungkin muncul dalam memodelkan runtun waktu jangka panjang dengan ARMA antara lain:

1. Dengan menggunakan model ARMA untuk menangkap fenomena jangka panjang (*long memory*), apabila parameter AR atau MA mampu menangkap fenomena jangka panjang maka pendekatan untuk jangka pendek akan terabaikan. Sebagai contoh, dengan parameter AR(1) tidak mungkin dapat memodelkan korelasi yang tinggi pada siklus 10 tahunan.
2. Sebaliknya, jika dugaan akan adanya fenomena jangka panjang pada deret waktu diabaikan untuk mendapatkan model yang lebih baik untuk fenomena

jangka pendek, maka tidak ada cara yang tepat untuk menggambarkan parameter AR dan MA untuk menggambarkan karakteristik jangka panjang pada runtun waktu. Walaupun sebenarnya peneliti menemukan fenomena jangka panjang pada deret.

Menurut Hosking (1981) karakteristik utama dari sebuah model ARFIMA(p, d, q) adalah sebagai berikut:

1. Jika $|d| \geq 0,5$, maka proses panjang tidak stasioner.
2. Jika $0 < d < 0,5$, proses berkorelasi panjang stasioner dengan adanya ketergantungan positif antar pengamatan yang terpisah jauh yang ditunjukkan dengan autokorelasi positif dan turun lambat dan mempunyai representasi *moving average* orde tak hingga.
3. Jika $-0,5 < d < 0$, maka proses berkorelasi panjang stasioner dengan memiliki ketergantungan negatif yang dengan autokorelasi negatif dan turun lambat serta mempunyai representasi *autoregressive* orde tak hingga.
4. Jika $d = 0$, maka proses menunjukkan fungsi autokorelasi turun secara eksponensial dengan proses ARMA.

Menurut Sowell (1999), keuntungan yang didapat jika menggunakan model ARFIMA(p, d, q) sebagai berikut:

1. Mampu memodelkan perubahan yang tinggi dalam jangka panjang (*long term persistence*).
2. Mampu menjelaskan struktur korelasi jangka panjang dan jangka pendek sekaligus.
3. Mampu memberikan model dengan parameter yang lebih sedehana (*parsimony*) baik untuk data dengan memori jangka panjang maupun jangka pendek.

2.11 Pemodelan Runtun Waktu dengan Metode *Box-Jenkins*

Tahapan pemodelan pemodelan runtun waktu dengan menggunakan metode *Box-Jenkins* dilakukan melalui tahap identifikasi model, estimasi parameter model, pengujian parameter model, uji diagnostik model, dan pemilihan model terbaik. Berikut akan dijelaskan tahapan pemodelan ARFIMA.

2.11.1 Identifikasi Model

Identifikasi untuk model ARFIMA dilakukan dengan memperhatikan plot data runtun waktu untuk melihat pola data. Model ARFIMA(p, d, q), p merupakan orde untuk proses *autoregressive*, d merupakan orde *differencing*, dan q merupakan orde untuk proses *moving average*. Dalam penetapan p dan q dapat diperoleh dengan mengamati pola *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

2.11.2 Estimasi Parameter Model

Menurut Doornik dan Ooms (1999), salah satu metode estimasi parameter model AR(p) dan MA(q) adalah metode *exact maximum likelihood*. Metode *exact maximum likelihood* atau *maximum likelihood estimation* digunakan dalam pendugaan parameter karena semua informasi yang tersedia dalam data dapat digunakan.

ACF dari proses AR stasioner yaitu

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \cdots + \phi_p \dot{Z}_{t-p} + a_t, \quad (2.43)$$

karena $\dot{Z}_t = Z_t - \mu$, persamaan (2.42) dapat dituliskan juga sebagai berikut

$$Z_t - \mu = \phi_1(Z_{t-1} - \mu) + \cdots + \phi_p(Z_{t-p} - \mu) + a_t. \quad (2.44)$$

Sehingga jumlah kuadrat residual pada persamaan (2.43) adalah

$$S(\mu, \phi_1, \dots, \phi_p) = \sum_{t=p+1}^n a_t^2 = \sum_{t=p+1}^n [(Z_t - \mu) + \phi_1(Z_{t-1} - \mu) + \cdots + \phi_p(Z_{t-p} - \mu) + a_t]^2. \quad (2.45)$$

Proses *white noise* (a_t) merupakan deret dari variabel acak yang saling bebas dan mengikuti distribusi tertentu yang identik dengan $E(a_t) = 0$ serta variansi konstan $Var(a_t) = \sigma^2$, sehingga fungsi kepadatan peluang dari (a_t) adalah

$$f(a_t | \mu, \phi, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{a_t^2}{2\sigma^2}} \quad (2.46)$$

dan fungsi ekspektasi dari $a = (a_1, a_2, \dots, a_t)$ adalah

$$L = (\mu, \phi, \sigma^2 | a) = \prod_{t=1}^n f(a_t | \mu, \phi, \sigma^2) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp \left[-\frac{1}{2\sigma^2} \sum_{t=1}^n a_t^2 \right]. \quad (2.47)$$

Logaritma natural dari fungsi ekspektasi di atas adalah:

$$\ln L(\mu, \phi, \sigma^2 | a) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{S(\mu, \phi_1, \dots, \phi_p)}{2\sigma^2}. \quad (2.48)$$

Bila diperhatikan, parameter $\mu, \phi_1, \dots, \phi_p$ hanya dimuat pada jumlah kuadrat residual $S(\mu, \phi_1, \dots, \phi_p)$ sehingga fungsi $\ln L(\mu, \phi, \sigma^2 | a)$ akan maksimum jika $S(\mu, \phi_1, \dots, \phi_p)$ minimum. Sehingga penduga parameter $\mu, \phi_1, \dots, \phi_p$ dapat diperoleh dengan menyelesaikan persamaan (2.49) dan (2.50) sebagai berikut

$$\frac{\partial}{\partial \mu} S(\mu, \phi_1, \dots, \phi_p) = 0. \quad (2.49)$$

Penyelesaian dari persamaan (2.49) akan diperoleh $\hat{\mu} = \dot{Z}$.

$$\frac{\partial}{\partial \phi_i} S(\mu, \phi_1, \dots, \phi_p) = 0. \quad (2.50)$$

Penyelesaian dari persamaan (2.50) terhadap $\phi_1, \phi_2, \dots, \phi_p$ akan diperoleh estimator sistem persamaan *Yule Walker* sehingga diperoleh estimator AR(p) dengan metode *Exact Maximum Likelihood* (EML) adalah:

$$\hat{\phi}_1 = \frac{\hat{\rho}_1 - \hat{\rho}_1 \hat{\rho}_2}{1 - \hat{\rho}_1^2} \text{ dan } \hat{\phi}_2 = \frac{\hat{\rho}_2 - \hat{\rho}_1^2}{1 - \hat{\rho}_1^2}, \text{ dengan } \hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{h=1}^n (Z_t - \dot{Z})(Z_{t+k} - \dot{Z})}{\sum_{h=1}^n (Z_t - \dot{Z})^2}. \quad (2.51)$$

ACF dari proses MA(q) adalah:

$$\begin{aligned} Z_t &= a_t - \theta_1 a_{t-1} - \cdots - \theta_q a_{t-q} \\ \Leftrightarrow Z_t &= -\theta_1 a_{t-1} - \cdots - \theta_q a_{t-q} + a_t. \end{aligned} \quad (2.52)$$

Estimasi bagi θ bernilai riil dan *invertible* bila $|\rho_1| < 0,5$, sehingga solusi dari estimasi $\theta_1, \theta_2, \dots, \theta_q$ diperoleh dengan cara iteratif atau meminimumkan jumlah kuadrat residual dari model MA yang dihasilkan melalui algoritma optimasi seperti *Algoritma Marquardt*. Estimator parameter MA(q) yaitu:

$$\hat{\rho}_1 = \frac{\hat{\theta}}{1+\theta^2}. \quad (2.53)$$

Metode estimasi parameter d yang akan digunakan adalah metode *Geweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S). Metode GPH pertama kali diusulkan oleh Geweke dan Porter-Hudak pada tahun 1983, dimana parameter *differencing* (d) dapat diestimasi secara konsisten dari regresi kuadrat terkecil yang diperoleh dari penaksiran persamaan logaritma *spectral density*. Kelebihan metode GPH dibandingkan dengan metode yang lain seperti metode Maksimum Likelihood dan Metode *Nonlinear Least Square* adalah fleksibilitas dalam estimasi parameternya. Estimasi parameter pembeda d pada metode GPH dapat dilakukan secara langsung tanpa mengetahui nilai p dan q terlebih dahulu.

Pendekatan dengan maksimum likelihood berkendala pada penurunan fungsi autokovarians dari model ARFIMA (Darmawan, 2008). Tahapan pertama pada metode GPH adalah menentukan nilai frekuensi harmonik ω_j untuk setiap observasi.

$$\omega_j = (2\pi \cdot j/T) \quad (2.54)$$

dengan, $j = 1, 2, \dots, m$.

Bandwidth optimal m dibatasi sampai $m = g(T) = [T^{0.5}]$. Tahap selanjutnya adalah menentukan nilai periodogram dengan metode GPH, yang bentuk periodogramnya ditentukan melalui persamaan berikut

$$I_Z(\omega_j) = \frac{1}{2\pi} \left\{ \gamma_0 + 2 \sum_{t=1}^{T-1} \gamma_t \cos(t \cdot \omega_j) \right\} \quad (2.55)$$

dengan, $\omega_j \in (-\pi, \pi)$ dan γ_t adalah nilai autokovarian dari *lag* ke- t . Kemudian nilai dari logaritma natural periodogramnya dijadikan sebagai variabel respon Y_j untuk regresi spektral

$$Y_j = \ln(I_Z(\omega_j)). \quad (2.56)$$

Selanjutnya, untuk variabel prediktornya ditentukan dari persamaan berikut

$$X_j = \ln\left(\frac{1}{4 \sin^2(\omega_j/2)}\right). \quad (2.57)$$

Berdasarkan persamaan regresi linear $Y_j = \beta_0 + \beta_1 X_j + a_j$, nilai estimasi parameter d ditentukan dengan metode *least square* seperti pada persamaan berikut

$$\hat{\beta}_1 = \hat{d} = \frac{\sum_{j=1}^m (X_j - \bar{X})(Y_j - \bar{Y})}{\sum_{j=1}^m (X_j - \bar{X})^2} \quad (2.58)$$

dengan, $j = 1, 2, \dots, m$.

Metode estimasi *Rescaled Range Statistics* (R/S) juga sering disebut sebagai uji statistik *Hurst* (H). Penentuan nilai *Hurst* (H) dengan menggunakan estimasi R/S bisa dilihat pada persamaan (2.27) sampai dengan (2.35). Selain digunakan untuk melihat indikasi adanya dependensi jangka panjang (*long memory*) pada data runtun waktu, statistik R/S juga dapat digunakan untuk

estimasi parameter d . Setelah nilai *Hurst* (H) diperoleh maka estimasi parameter d menggunakan metode R/S diperoleh dengan persamaan berikut (Beran, 1994)

$$\hat{d} = H - 0,5. \quad (2.59)$$

2.11.3 Uji Diagnostik Model

Pengujian diagnostik model dilakukan untuk membuktikan bahwa model tersebut cukup memadai dan menentukan model mana yang terbaik digunakan untuk prakiraan. Uji diagnostik dilakukan dengan menguji apakah data sudah bersifat *white noise* dan berdistribusi normal atau tidak. Hal itu dilakukan untuk mendapatkan hasil permalan yang baik (Wei, 2006).

Suatu residual yang bersifat *white noise* berarti residual dari model telah memenuhi asumsi identik serta independen. Suatu proses a_t disebut proses *white noise* jika terdiri dari variabel acak yang tidak berkorelasi antar variabel dan berdistribusi normal dengan rata-rata konstan $E(a_t) = 0$, variansi konstan $Var(a_t) = \sigma^2$ dan $\gamma_k = Cov(a_t, a_{t+k}) = 0$ untuk $k \neq 0$ (Wei, 2006).

Pengujian *white noise* dilakukan dengan menggunakan pengujian *L-Jung Box*.

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (Residual data bersifat *white noise*)

$H_1:$ minimal terdapat satu $\rho_k \neq 0$ (residual data tidak bersifat *white noise*) dengan, $k = 1, 2, \dots, K$

Statistik uji *L-Jung Box* adalah sebagai berikut (Wei, 2006):

$$Q = n(n + 2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.60)$$

dengan,

$\hat{\rho}_k$: autokorelasi residual pada *lag* ke- k

n : banyak data

K : banyak maksimum *lag*

$m = p + q$.

Jika taraf signifikan yang digunakan adalah sebesar $\alpha(5\%)$ maka kriteria pengujian yang digunakan adalah tolak H_0 jika, $Q > \chi^2 \alpha, K - m$ atau jika nilai $p\ value < \alpha$.

Uji *Kolmogorov-Smirnov* digunakan untuk mengetahui apakah residual sudah mengikuti distribusi normal. Hipotesis yang digunakan untuk uji *Kolmogorov-Smirnov* adalah.

H_0 : Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal.

Statistik uji *Kolmogorov-Smirnov* adalah sebagai berikut (Wei, 2006):

$$D = \text{Sup}_x |S(x) - F_0(x)| \quad (2.61)$$

dengan,

$S(x)$: nilai berdistribusi kumulatif sampel

$F_0(x)$: nilai berdistribusi kumulatif dari distribusi normal.

Kriteria pengujian yang digunakan adalah H_0 ditolak jika $D \geq K_{(1-\alpha,n)}$ dengan $K_{(1-\alpha,n)}$ adalah nilai tabel *Kolmogorov-Smirnov* pada kuantil $1 - \alpha$ dan n banyak pengamatan.

2.11.4 Pemilihan Model Terbaik

Suatu model setelah diidentifikasi memungkinkan terbentuknya lebih dari satu model yang sesui, untuk itu diperlukan pemilihan model yang terbaik. Kriteria pemilihan model ARFIMA yang akan digunakan untuk peramalan didasarkan pada nilai *Akaike's Information Criterion* (AIC) terkecil. Untuk menilai suatu kualitas dari pemilihan model, Akaike pada tahun 1973 meperkenalkan kriteria informasi yang mempertimbangkan banyaknya parameter. Kriteria tersebut dinamakan *Akaike's Information Criterion* (AIC). Formulasi nilai AIC dapat dinyatakan sebagai berikut (Wei, 2006):

$$AIC(m) = n \ln \hat{\sigma}_\alpha^2 + 2m \quad (2.62)$$

dengan,

m : banyak parameter yang ditaksir

n : banyak pengamatan

$\hat{\sigma}_\alpha^2$: nilai varian observasi.

2.12 Akurasi Model Peramalan

Suatu model peramalan yang dibangun dengan prosedur dan langkah yang benar belum memastikan model tersebut akan cocok dengan data yang ada secara tepat. Oleh karena itu terdapat beberapa kriteria pembanding yang menilai kecocokan antara model yang dibangun dengan data yang ada. Beberapa cara ini digunakan untuk mengukur kesalahan peramalan sebagai berikut.

2.12.1 Root Mean Square Error

Root Mean Square Error (RMSE) menunjukkan seberapa besar simpangan nilai prediksi dengan nilai aktualnya. Sebuah model dapat dikatakan baik jika RMSE mendekati 0. Formulasi nilai RMSE dapat dinyatakan sebagai berikut (Montgomery dkk, 2015):

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^n (x_t - f_t)^2}{n}} \quad (2.63)$$

dengan,

x_t : nilai aktual pada waktu ke- t

f_t : nilai prediksi pada waktu ke- t

n : banyak data yang diprediksi.

2.12.2 Mean Absolute Error

Mean Absolute Error (MAE) digunakan untuk mengukur kesalahan nilai dugaan model yang dinyatakan dalam bentuk rata-rata absolut kesalahan. Formulasi nilai MAE dapat dinyatakan sebagai berikut (Montgomery dkk, 2015):

$$\text{MAE} = \frac{\sum_{t=1}^n |x_t - f_t|}{n} \quad (2.64)$$

dengan,

x_t : nilai aktual pada waktu ke- t

f_t : nilai prediksi pada waktu ke- t

n : banyak data yang diprediksi.

2.12.3 Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur nilai dugaan model yang dinyatakan dalam bentuk presentase rata-rata *absolute* kesalahan. Formulasi nilai MAPE dinyatakan sebagai berikut (Montgomery dkk, 2015):

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \frac{|x_t - f_t|}{x_t} \times 100 \quad (2.65)$$

dengan,

x_t : nilai aktual pada waktu ke- t

f_t : nilai prediksi pada waktu ke- t

n : banyak data yang diprediksi.

Berikut akan diberikan kriteria nilai MAPE yang akan disajikan dalam Tabel 2.2 sebagai berikut (Chang, Wang dan Liu, 2007).

Tabel 2.2 Kriteria Nilai MAPE

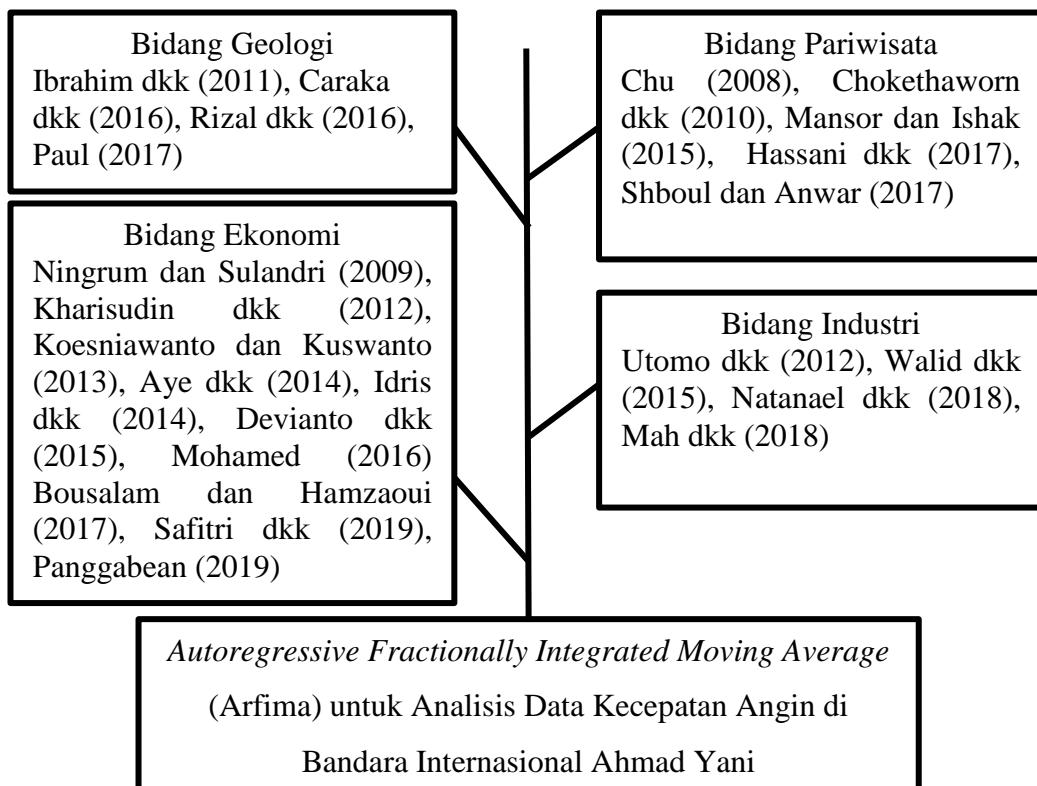
Nilai MAPE	Kriteria
< 10%	Kemampuan Peramalan Sangat Baik
10% – 20%	Kemampuan Peramalan Baik
20% – 50%	Kemampuan Peramalan Cukup Baik
> 50%	Kemampuan Peramalan Buruk

2.13 Penelitian Terdahulu

Penelitian ini mengacu pada penelitian yang pernah dilakukan oleh beberapa peneliti yang selanjutnya dijadikan sebagai referensi, Devianto dkk (2015) mengaplikasikan *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk meramalkan harga saham pembukaan Kedaung Indah Can Tbk dari 02 Mei 2012 sampai dengan 26 Maret 2012 yang menghasilkan model terbaik ARFIMA(5,0.452,4) dimana untuk peramalan jangka pendek menunjukkan hasil yang sangat dekat dengan data aktual dengan *standard error* yang kecil. Ningrum dan Sulandri (2009) menerapkan model ARFIMA dalam peramalan suku bunga Sertifikat Bank Indonesia (SBI). Mohamed (2016) menggunakan model ARFIMA dalam meramalkan total nilai dari *traded securities* di Republik Arab dari Mesir. Bousalam dan Hamzaoui (2017) melakukan peramalan *long memory*

menggunakan model ARFIMA dan pengaplikasiannya pada pasar modal syariah. Kharisudin dkk (2012) melakukan penelitian terkait model *long memory* FARIMA dan aplikasinya pada pemodelan data *asset returns* di Indonesia. Pradina dkk (2014) meneliti pemodelan ARFIMA melalui $\hat{\alpha}_{HILL}$ – stable sebagai penentu d dan aplikasinya dalam estimasi harga saham.

Walid dkk (2015) melakukan identifikasi model *long memory* pada penggunaan beban listrik di Jawa-Bali. Ibrahim dkk (2011) melakukan pemodelan ARFIMA pada data harian rata-rata suhu di Sokoto. Rizal (2016) menggunakan model ARFIMA untuk analisis kejadian gempa bumi tektonik di wilayah Pulau Sumatera. Caraka dkk (2016) menggunakan model *long memory* dalam prediksi suhu Stasiun Meteorologi Raja Haji Abdullah Tanjung Balai Karimun Provinsi Kepulauan Riau dari Januari 2014 sampai dengan Februari 2016 diperoleh model terbaik ARFIMA(1, 0.170363,2) dengan nilai AIC 3.10532737. Paul (2017) meneliti terkait model *long memory* pada data minnum dan maksimum temperatur di india. Aye dkk (2014) menggunakan model ARFIMA untuk memprediksi *absolute return* saham harian BRICS (*Brazil, Russia, China, and South Africa*). Idris dkk (2014) melakukan pemodelan dan peramalan Indeks Harga Perdagangan Besar (IHPB) dengan menggunakan ARFIMA diperoleh model (0, 4.03, 1) dengan MAPE 7,716%. Safitri dkk (2019) memodelkan harga emas indonesia menggunakan metode ARFIMA yang menghasilkan model terbaik ARFIMA(1,d[3]) with d=1,05716. Panggabean (2019) mengidentifikasi *long memory* pada data *absolute return* saham indonesia menggunakan uji statistik *Hurst* (H) dimana data yang diteliti menunjukkan proses *long memory*.



Gambar 2.5 Diagram Penelitian Terdahulu

2.14 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 dipermukaan bumi merupakan sirkulasi umum dari atmosfer. Pemahaman sirkulasi umum atmosfer dapat didekati oleh 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 (Tjasyono, 2004). Kecepatan angin merupakan jarak tempuh angin atau pergerakan udara per satuan waktu yang dinyatakan dalam satuan meter per detik (m/s), kilometer per jam (km/jam), dan mil per jam (mil/jam atau knot). Berikut disajikan skala standar internasional Beaufort kecepatan angin pada Tabel 2.3.

Tabel 2.3 Skala Beaufort

Skala	Tingkatan	Kecepatan (knot)	Kecepatan (km/jam)	Tanda-tanda di Darat (D) dan di Laut (L)
0	Tenang	< 1	< 1	(D) : Tenang, asap mengepul vertikal. (L) : Laut seperti kaca.
1	Teduh	1 – 3	1 – 5	(D) : Asap mengepul miring. (L) : Berombak kecil, tetapi tidak berbuih.
2	Sepoi lemah	4 – 6	6 – 11	(D) : Terpaan angin terasa di muka. (L) : Berombak tetapi tidak terlihat pecah.
3	Sepoi lembut	7 – 10	12 – 19	(D) : Daun-daun kecil di pohon bergerak, bendera dapat berkibar. (L) : Berombak besar dan mulai ada pecah-pecah
4	Sepoi sedang	11 – 16	20 – 28	(D) : Debu dan kertas dapat terbang, ranting pohon bergerak. (L) : Gelombang kecil tetapi periodenya lama, tampak berbuih.
5	Sepoi segar	17 – 21	29 – 38	(D) : Pohon-pohon kecil terlihat condong, Genangan air di tanah terlihat berombak kecil. (L) : Gelombang sedang berbuih agak banyak.
6	Sepoi kuat	22 – 27	39 – 49	(D) : Batang pohon terlihat bergerak, suara berdesing dari kawat telepon dapat terdengar, payung dapat terangkat. (L) : Gelombang besar tampak berbuih dimana-mana.
7	Angin ribut lemah	28 – 33	50 – 61	(D) : Pohon-pohon bergerak, berjalan terasa agak berat. (L) : Gelombang besar, tampak berbuih bergerak searah angin.
8	Angin ribut	34 – 40	62 – 74	(D) : Batang pohon dapat patah, sampai pohon tumbang. (L) : Gelombang tinggi sedang dan panjang, ujung pecah gelombang terlihat seperti hanyut.

9	Angin ribut kuat	41 – 47	75 – 88	(D) : Dapat membawa kerusakan cerobong, pot-pot berterbangan. (L) : Gelombang tinggi, padat, dan berderet sepanjang arah angin.
10	Badai	48 – 55	89 – 102	(D) : Keursakan lebih besar, tetapi di darat jarang terjadi. (L) : Gelombang sangat tinggi dan panjang, hampir semua permukaan laut terlihat putih karena pecah gelombang.
11	Badai amuk	56 – 63	103 – 117	(D) : Kerusakan berat tetapi jarang terjadi di darat. (L) : Gelombang luar biasa tinggi, kapal kecil sampai sedang terombang-ambing dan terlihat timbul-tenggelam di belakang gelombang.
12	Topan	> 63	> 117	(D) : Hampir tidak pernah terjadi. (L) : Gelombang luar biasa besar, udara terlihat gelap oleh adanya pecah-pecah gelombang.

(Sumber: Wirjohamidjojo dan Sugarin (2008))

2.15 Program R

R menyediakan fasilitas untuk membuat fungsi yang didefinisikan oleh *user (user-defined function)*. Fungsi merupakan kumpulan beberapa perintah atau ekspresi yang disusun menurut alur logika tertentu untuk menghasilkan *output* yang dikehendaki (R-Project). Penulisan fungsi dapat dilakukan melalui dua macam cara, yaitu melalui *R-Console* dan *E-Editor*. Fungsi atau *script* terdiri dari beberapa *argument* yaitu *Optional Argument* dan *Required Argument*.

Program R menyediakan fungsi *built-in*, yaitu fungsi-fungsi yang dapat digunakan untuk mengatur tampilan dari *output*, baik dengan menampilkan layar maupun dengan menyimpan data *disk*. Objek-objek di R dikemas dalam bentuk *add-ins* yang disebut dengan *package*. *Package* memberikan kemampuan tambahan, misalnya perhitungan teknik-teknik canggih, *interface*, dan lain sebagainya. Identifikasi nilai *Hurst (H)* untuk indikasi sifat *long memory* pada data

runtun waktu menggunakan *package pracma* dan *package fracdiff* untuk identifikasi nilai estimasi parameter d pada data.

Identifikasi nilai *Hurst* (H) untuk mengetahui adanya indikasi sifat *long memory* pada data runtun waktu menggunakan *package pracma* dengan fungsi sebagai berikut:

$hurstexp(x, d = 50, display = TRUE)$

dengan,

x : data runtun waktu

d : ukuran *box* terkecil dengan *default* 50.

Estimasi parameter d pada ARFIMA(p, d, q) dengan metode GPH bisa dilakukan dengan menggunakan *package fracdiff* dengan fungsi sebagai berikut:

$fdGPH(x, bandw.exp = 0,5)$

dengan,

x : data runtun waktu

bandw.exp : nilai *bandwidth* yang digunakan (*default bandw.exp = 0,5*)

2.16 Kerangka Berpikir

Peramalan (*Forecasting*) muncul karena adanya waktu senjang antara kesadaran akan peristiwa atau kebutuhan mendatang dengan peristiwa itu sendiri. Adanya waktu tenggang merupakan alasan utama dilakukannya kegiatan perencanaan dan peramalan. Peramalan diperlukan untuk menetapkan suatu peristiwa yang akan terjadi sehingga tindakan yang tepat dapat dilakukan. Peramalan merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien (Hendikawati, 2015). Metode peramalan dibagi menjadi dua yaitu secara peramalan secara kualitatif dan peramalan secara kuantitatif. Peramalan secara kualitatif artinya peramalan hanya berdasarkan pada pendapat serta analisis yang deskriptif. Metode peramalan kualitatif diantaranya yaitu metode *delphi*, riset pasar, panel konsumen, juri dan opini eksekutif, dan lainnya. Sedangkan peramalan kuantitatif yaitu merupakan peramalan yang berkaitan dengan perhitungan secara matematis. Metode kuantitatif diantaranya adalah metode runtun waktu (*time series*) dan metode kausal.

Metode kausal merupakan metode yang didasarkan pada keterkaitan antara variabel yang di perkirakan dengan variabel lain yang mempengaruhinya tetapi bukan dalam bentuk variabel waktu. metode ini menggunakan pendekatan sebab akibat dan bertujuan untuk meramalkan keadaan dimasa yang akan datang dengan menemukan dan mengukur beberapa variabel bebas yang penting beserta pengaruhnya terhadap variabel terikat yang akan diramalkan. Metode peramalan yang ada pada metode kausal yaitu metode regresi dan korelasi, metode *input output* dan metode ekonometri.

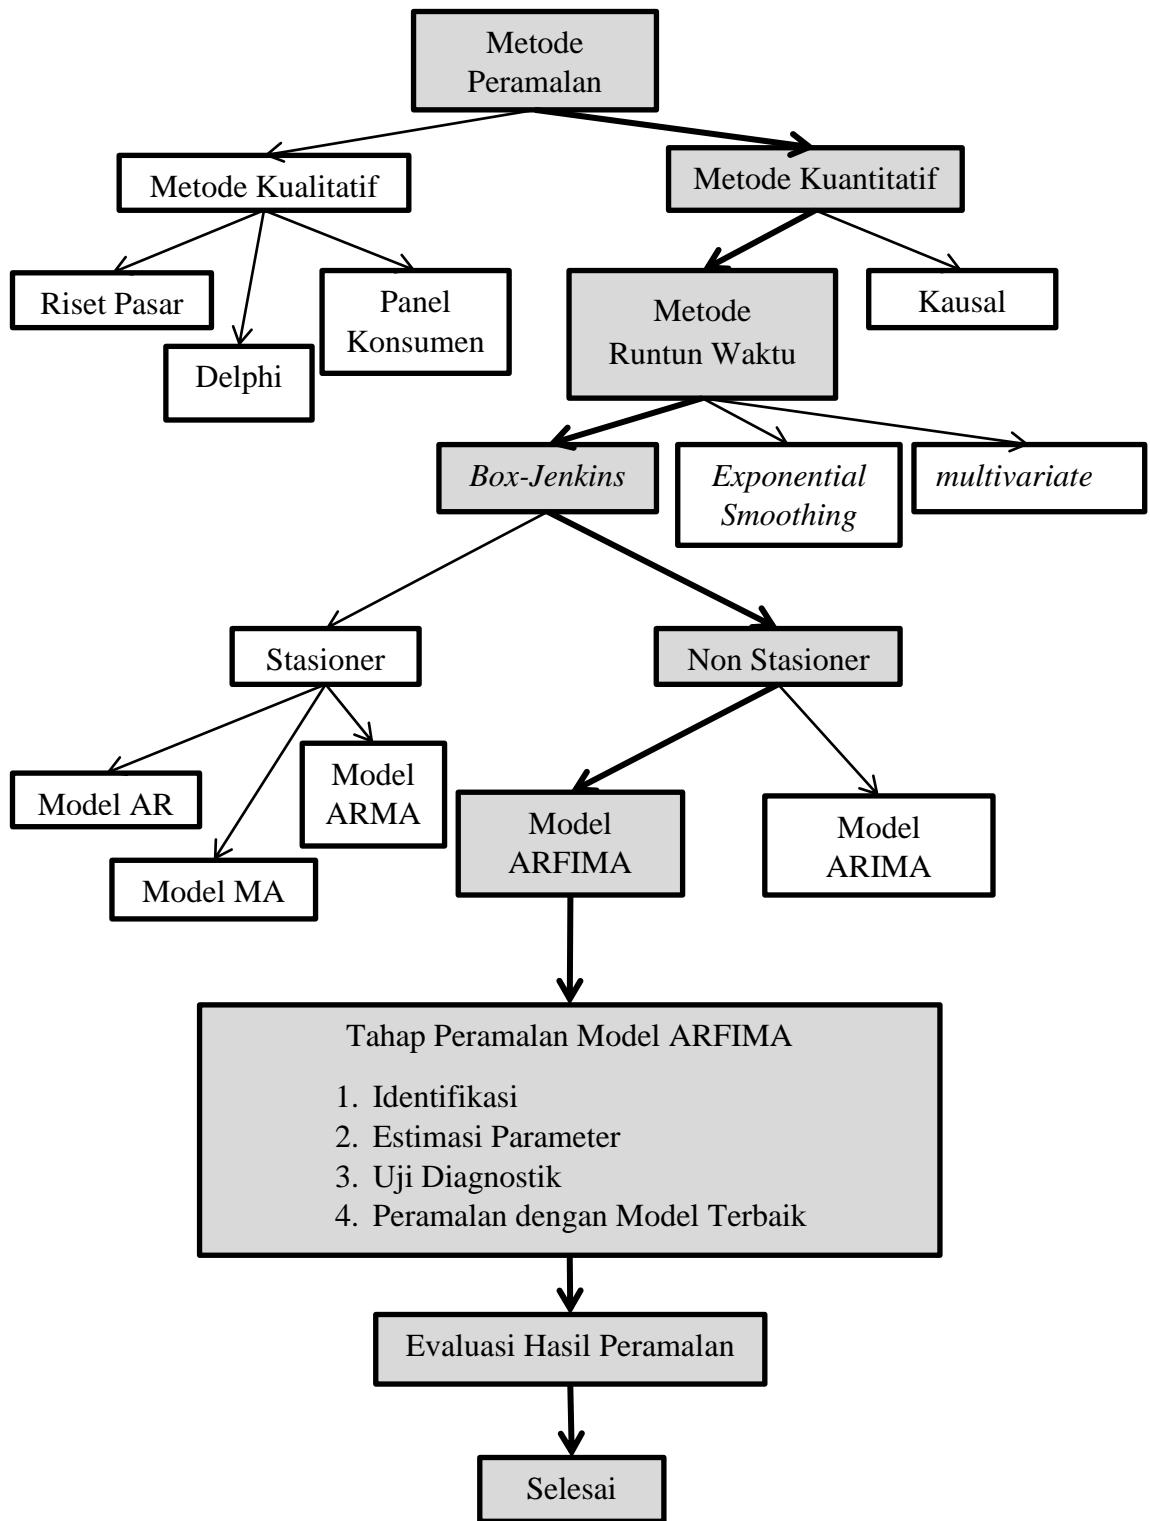
Data runtun waktu (*time series*) merupakan serangkaian observasi terhadap suatu variabel yang diambil secara beruntun berdasarkan interval waktu yang tetap (Wei, 2006). Analisis runtun waktu merupakan salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilitas keadaan yang akan datang dalam rangka pengambilan keputusan. Tujuan analisis runtun waktu antara lain memahami dan menjelaskan mekanisme tertentu, meramalkan suatu nilai di masa depan, dan mengoptimalkan sistem kendali (Makridakis dkk, 1983). Di dalam analisis runtun waktu terdapat keterkaitan antara *variable dependent* dengan *variable independent* yang dihubungkan dengan waktu seperti harian, mingguan, bulanan ataupun tahunan. Metode peramalan dengan analisis runtun waktu diantaranya adalah metode *Box-Jenkins*, metode *exponential smoothing* dan metode *multivariate*.

Salah satu metode yang sering digunakan adalah metode *Box-Jenkins*. Metode *Box-Jenkins* merupakan metode runtun waktu yang sangat memperhatikan faktor kebagusan data runtun waktu dalam membentuk modelnya. Peramalan dengan metode ini didasarkan pada model regresi runtun waktu stasioner. Model time series stasioner diantaranya yaitu model AR (*Autoregresive*), MA (*Moving Average*), dan ARMA (*Autoregresive Moving Average*). Sedangkan deret waktu non stasioner diantaranya yaitu ARIMA dan ARFIMA.

Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) pertama kali dikembangkan oleh Granger dan Joyeux (1980) yang merupakan pengembangan dari model *Autoregressive Integrated Moving Average* (ARIMA). Hosking (1981) memperkenalkan model *Autoregressive Fractionally*

Integrated Moving Average (ARFIMA) untuk memodelkan data *long memory*. *Long memory* merupakan salah satu fenomena dalam *time series*, dimana data runtun waktu ini mempunyai ketergantungan jangka panjang yang artinya jika di antara pengamatan yang terpisah jauh, masih mempunyai korelasi yang tinggi. Sifat long memory pada data juga ditunjukkan oleh plot *Autocorrelation Function* (ACF) dari data tidak turun secara eksponensial melainkan turun secara lambat atau hiperbolik. Model *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) dapat mengatasi kelemahan model ARIMA, dimana ARIMA hanya dapat menjelaskan data jangka pendek dengan *differencing* (d) bilangan bulat.

Penulis menggunakan model ARFIMA untuk menganalisis data runtun waktu. Menentukan model ARFIMA yang selanjutnya digunakan untuk peramalan.



Gambar 2.6 Kerangka Berpikir

BAB 3

METODE PENELITIAN

Dalam metode penelitian, suatu masalah yang dihadapi dapat diatasi dan dipecahkan dari perolehan data atau informasi yang telah dikumpulkan. Pada metode penelitian ini dibahas mengenai penentuan masalah, perumusan masalah, pengumpulan data, tahap analisis data dan penarikan kesimpulan.

3.1 Penentuan Masalah

Penentuan masalah dimulai dari studi pustaka. Studi pustaka merupakan penelaahan sumber yang relevan dan digunakan untuk menemukan informasi yang diperlukan dalam penelitian. Penulis membaca dan menelaah sumber beberapa sumber pustaka terkait analisis runtun waktu, data *long memory*, peramalan (*forecasting*), dan ARFIMA. Dari kajian tersebut muncul ide untuk melakukan penelitian. Permasalahan yang muncul yaitu bagaimana menentukan model peramalan ARFIMA dalam menganalisis data kecepatan angin di Bandara Internasional Ahmad Yani.

3.2 Perumusan Masalah

Perumusan masalah dimaksudkan untuk membatasi permasalahan, sehingga diperoleh bahan kajian yang jelas. Selanjutnya dirumuskan permasalahan sebagai berikut :

1. Bagaimana model peramalan dengan metode ARFIMA pada data kecepatan angin di Bandara Internasional Ahmad Yani?
2. Bagaimana hasil peramalan kecepatan angin di Bandara Internasional Ahmad Yani dengan model peramalan ARFIMA?

3.3 Studi Pustaka

Dalam tahap ini dilakukan kajian sumber-sumber pustaka dengan cara mengumpulkan data atau informasi dari perpustakaan dan internet yang berkaitan dengan model ARFIMA dalam menganalisis data kecepatan angin di Bandara Internasional Ahmad Yani.

3.4 Jenis dan Sumber Data

Data yang digunakan dalam penelitian kali ini merupakan data sekunder. Data yang digunakan adalah data kecepatan angin di Bandara Internasional Ahmad Yani dalam frekuensi harian yang diperoleh dari website NNDC *Climate Data Online*. *Climate Data Online* (CDO) merupakan data iklim dunia yang dikelola oleh National Climatic Data Center (NCDC) milik NOAA. Data iklim dunia yang disediakan CDO-NCDC merupakan hasil kerjasama NOAA dengan penyelenggara cuaca dan iklim di seluruh dunia.

3.5 Analisis dan Pengolahan Data

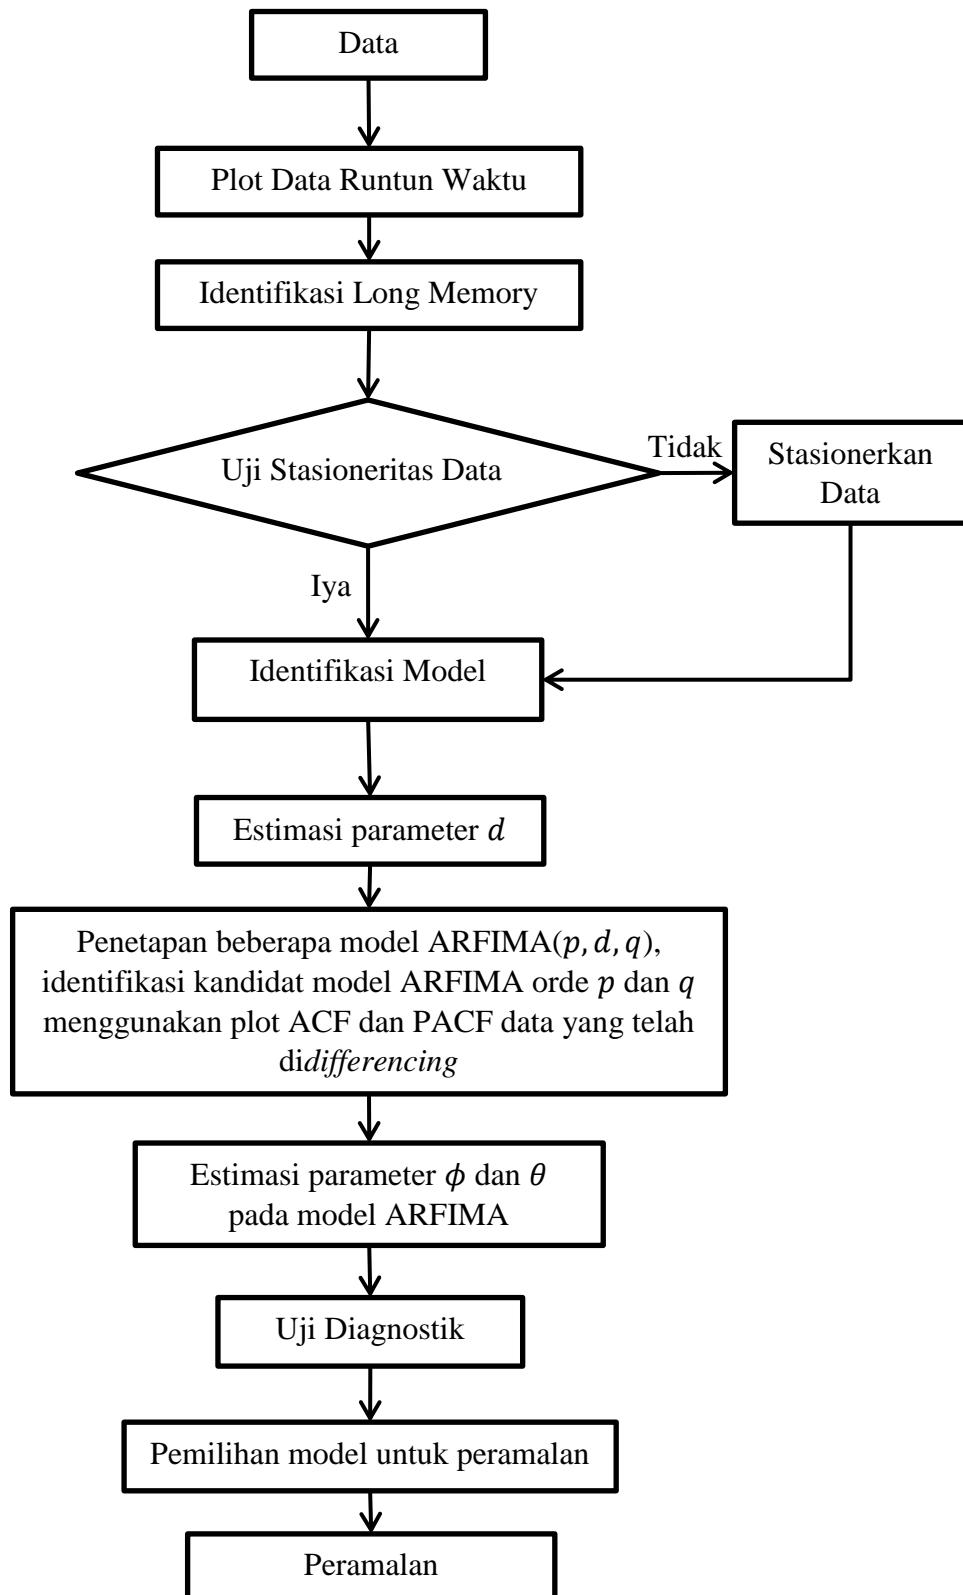
Data yang sudah terkumpul dibagi menjadi dua yaitu data *in sample* untuk penentuan model dan *out sample* untuk validasi peramalan. Penelitian ini menggunakan *software R Studio* dalam pengolahan data. Tahapan analisis dalam penelitian ini adalah sebagai berikut:

1. Mempersiapkan data yang akan digunakan dalam penelitian.
2. Melakukan eksplorasi data dengan melihat plot runtun waktu data awal serta melihat statistika deskriptif dari data.
3. Memeriksa kestasioneran data dengan melihat plot data awal serta melakukan uji *Box-Cox* apabila data tidak stasioner terhadap varians. Selanjutnya melakukan uji *Augmented Dickey-Fuller* (ADF) untuk melihat kestasioneran dalam *mean*.
4. Identifikasi indikasi *long memory* pada data dengan melihat plot ACF. Jika pola plot ACF turun lambat atau hiperbolik, maka terdapat indikasi *long*

memory. Indikasi *long memory* juga bisa diketahui dengan melihat nilai *Hurst* (H). Selain itu juga bisa dilihat dari plot periodogram dari data.

5. Pembentukan model ARFIMA dilakukan dengan metode semiparametrik. Menetapkan estimasi parameter d terlebih dahulu dengan menggunakan metode *Geweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S). Selanjutnya penenetapan beberapa model ARFIMA(p, d, q) berdasarkan plot ACF dan PACF data yang telah dilakukan *differencing* dengan nilai d yang telah diperoleh. Kemudian estimasi parameter ϕ dan θ pada model yang sudah ditetapkan menggunakan metode *Exact Maximum Likelihood*.
6. Melakukan pemilihan model yang signifikan. Suatu parameter model dikatakan signifikan apabila nilai statistik $|z| > z$ tabel (1,96).
7. Pengujian diagnostik untuk menguji kelayakan model meliputi uji asumsi nilai residual *white noise* dan berdistribusi normal. Pengecekan *White Noise* menggunakan uji *L-Jung Box* sedangkan pengecekan distribusi normal menggunakan uji *Kolmogorov Smirnov*.
8. Pemilihan model ARFIMA yang digunakan untuk peramalan berdasarkan nilai *Akaike's Information Criterion* (AIC) terkecil.
9. Model ARFIMA yang telah ditentukan digunakan untuk evaluasi hasil peramalan. Kemudian dicari nilai erornya menggunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE).

Diagram alir tahapan analisis data ditunjukkan pada Gambar 3.1.



Gambar 3.1 Diagram Alir Analisis Data

3.6 Penarika Kesimpulan

Langkah terakhir dalam metode penelitian adalah penarikan kesimpulan. Hasil analisis dan pembahasan dituangkan dalam bentuk simpulan akhir yang menyimpulkan secara umum pemecahan masalah tersebut. Simpulan ini dijadikan sebagai kajian akhir dan merupakan hasil akhir dari penelitian ini.

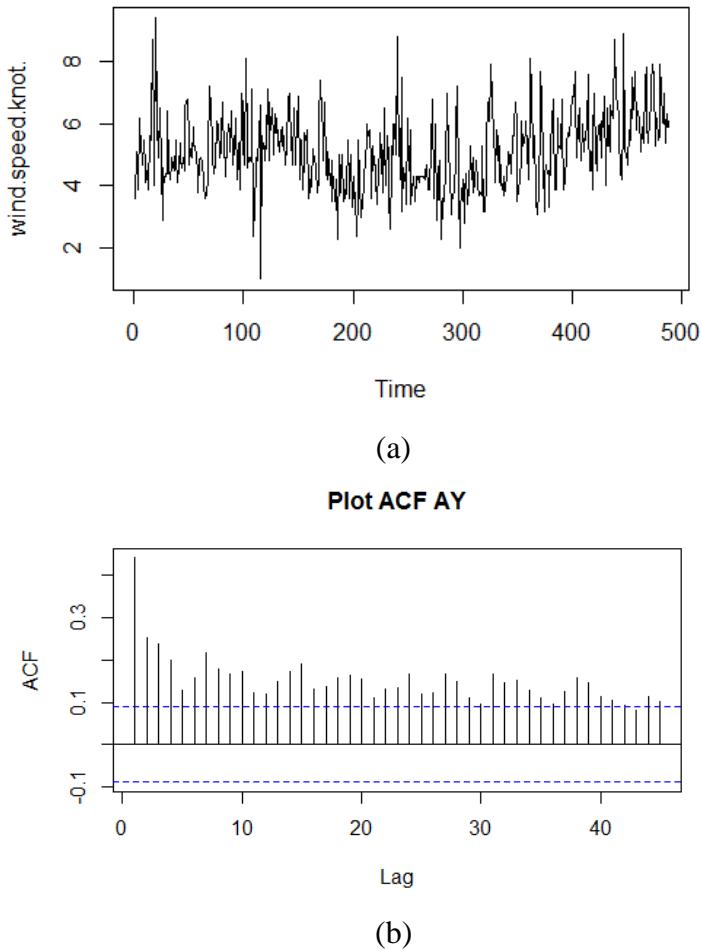
BAB 4

HASIL DAN PEMBAHASAN

Pada bagian hasil dan pembahasan memaparkan bagaimana proses untuk analisis data kecepatan angin di Bandara Internasional Ahmad Yani. menggunakan metode *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) dalam frekuensi harian yang diperoleh dari website *NNDC Climate Data Online*. *Climate Data Online* (CDO) merupakan data iklim dunia yang dikelola oleh *National Climatic Data Center* (NCDC) milik NOAA. Data iklim dunia yang disediakan CDO-NCDC merupakan hasil kerjasama NOAA dengan penyelenggara cuaca dan iklim di seluruh dunia.

4.1 Deskripsi Data

Data yang digunakan dalam penelitian kali ini merupakan data sekunder. Data yang digunakan adalah data kecepatan angin di Bandara Internasional Ahmad Yani dalam frekuensi harian. Periode data kecepatan angin yang diambil mulai awal bulan Juni 2018 hingga akhir Oktober 2019, sehingga terdapat 518 data. Data dibagi menjadi dua bagian yaitu data *in sample* dan data *out sample*. Pembagian data sekitar 95% untuk data *in sample* dan sisanya untuk data *out sample*. Jadi sebanyak 487 *in sample* dan 31 data *out sample*. Data *in sample* digunakan untuk membentuk model dan data *out sample* untuk menguji validitas hasil peramalan dari model yang terpilih. Berikut adalah deskripsi runtun waktu data *in sample* kecepatan angin di Bandara Internasional Ahmad Yani yang disajikan dalam Gambar 4.1 dan Tabel 4.1.



Gambar 4.1 Plot Data Runtun Waktu Kecepatan Angin di Bandara Internasional
Ahmad Yani

Tabel 4.1 Deskripsi Data

Rata-rata	Standar Deviasi	Nilai Minimum	Nilai Maksimum
Kecepatan Angin	5,125	1,220	1 9,4

Berdasarkan Tabel 4.1 menunjukkan bahwa data *in sample* kecepatan angin di Bandara Internasional Ahmad Yani memiliki nilai rata-rata 5,125. Nilai standar deviasi yaitu 1,220 sehingga nilai variansinya 1.489. Nilai minimum 1 dan nilai maksimum 9,4.

4.2 Identifikasi *Long Memory*

Identifikasi *long memory* dilakukan untuk melihat pola data, apakah data mempunyai sifat *long memory* atau tidak. Identifikasi *long memory* dilakukan dengan melihat plot ACF yang turun lambat secara hiperbolik. Identifikasi *Long memory* juga dapat diidentifikasi dengan menggunakan uji statistik nilai *Hurst* (H) (Hurst, 1951). nilai *Hurst* (H) diperoleh dari perhitungan menggunakan metode *Rescaled Range Statistics* (R/S). Dengan kondisi, apabila nilai $H = 0,5$, maka data tersebut memiliki sifat *short memory*. Apabila nilai H berada pada interval $0 < H < 0,5$, maka data tersebut memiliki sifat *intermediate memory*. Dan apabila nilai H berada pada interval $0,5 < H < 1$, maka data tersebut memiliki sifat *long memory* (Walid dkk, (2015). Selain itu pola *long memory* juga dapat dilihat melalui plot periodogram yang mana untuk frekuensi yang mendekati nol meningkat menuju nilai yang sangat besar tetapi berhingga (Prafitia dkk, 2010).

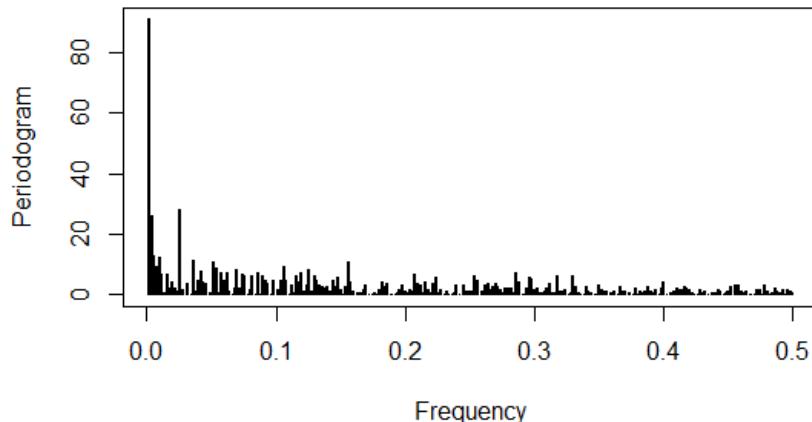
Berdasarkan Gambar 4.1 (b) data kecepatan angin di Bandara Internasional Ahmad Yani menunjukkan autokorelasi yang *lagnya* turun pelan menuju 0 atau tidak turun secara eksponensial, namun belum begitu terlihat turun secara hiperbolik. Sehingga *long memory* pada data masih cukup sulit untuk diidentifikasi (Rizal dkk, 2016). Selanjutnya dilakukan uji *Hurst* untuk melihat adanya indikasi *long memory*. Nilai *Hurst* diperoleh dari perhitungan menggunakan metode *Rescaled Range Statistics* (R/S). Dengan bantuan aplikasi R Studio nilai *Hurst* untuk data kecepatan angin di Bandara Internasional Ahmad Yani tersebut disajikan dalam Tabel 4.2.

Tabel 4.2 Nilai *Hurst*

Nilai	
<i>Hurst</i>	0,724

Berdasarkan Tabel 4.2 diketahui bahwa nilai *Hurst* (H) dari ketiga data berada pada selang 0,5 sampai dengan 1 ($0,5 < H < 1$). Hal ini mengindikasikan bahwa data mempunyai pola dependensi jangka panjang atau *long memory*.

Selanjutnya identifikasi pola *long memory* dengan melihat plot periodogram dari data. Plot periodogram untuk data kecepatan angin di Bandara Internasional Ahmad Yani ditunjukkan pada Gambar 4.2.

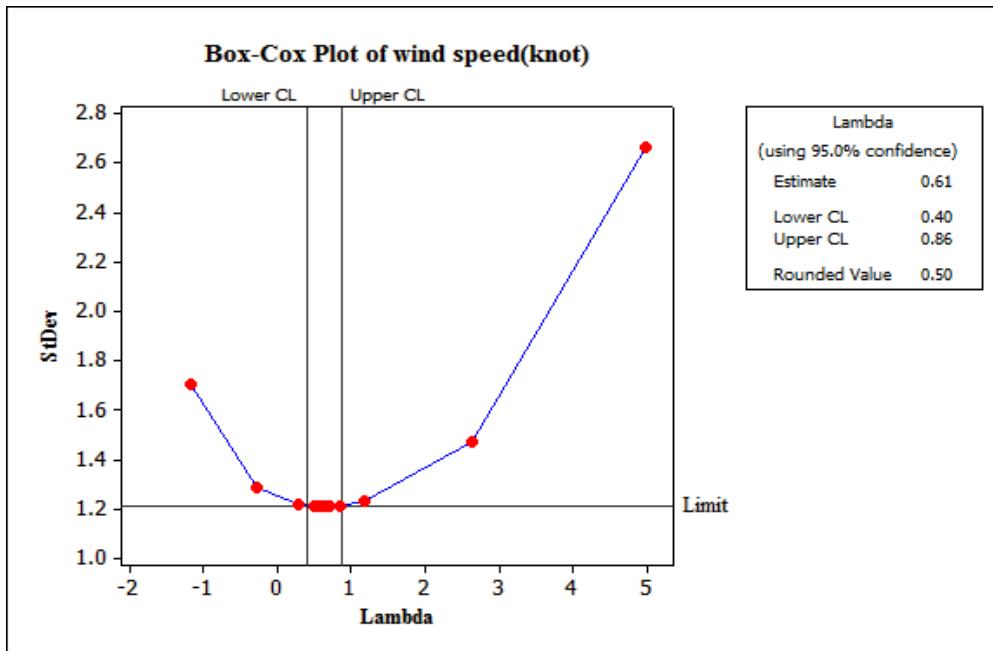


Gambar 4.2 Plot Periodogram

Gambar 4.2 Plot Periodogram Data Kecepatan Angin di Bandara Ahmad Yani Berdasarkan Gambar 4.2, dapat diketahui bahwa plot periodogram untuk frekuensi yang mendekati nol meningkat menuju nilai yang sangat besar tetapi berhingga (Prafitia dkk, 2010). Oleh sebab itu, dapat diindikasikan data mempunyai pola *long memory*.

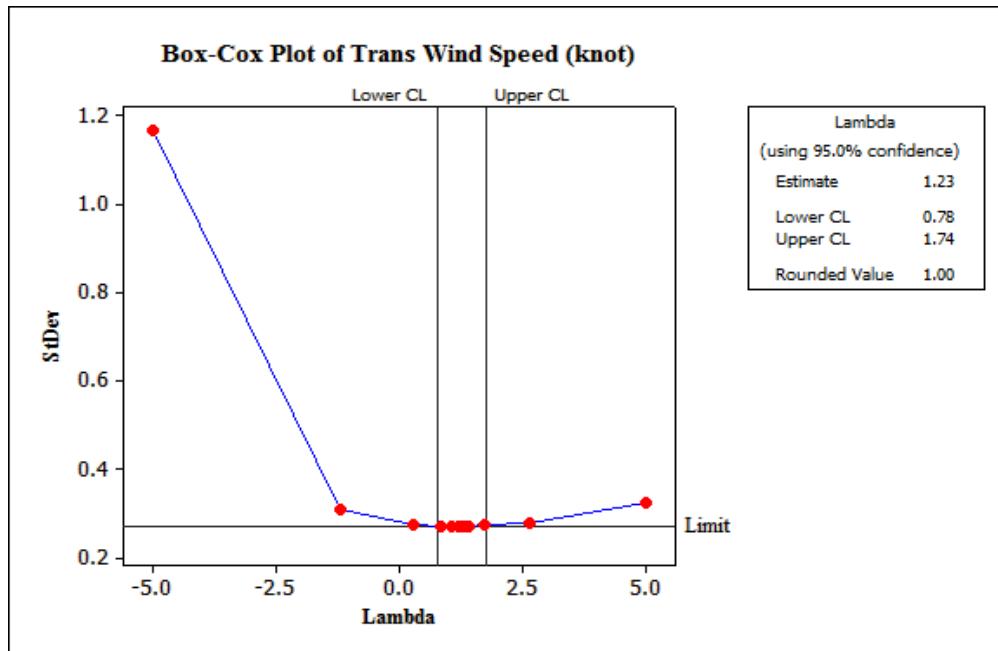
4.3 Pengujian Stasioneritas

Stasioneritas berarti fluktuasi data deret waktu berada di sekitar suatu nilai rata-rata yang konstan dan variansinya tetap konstan sepanjang waktu. Langkah awal yang dilakukan adalah membuat plot runtun waktu. Secara visual dari plot data runtun waktu kecepatan angin pada Gambar 4.1 (a) mengindikasikan bahwa data kecepatan angin tidak stasioner dalam varians karena fluktuasi data yang cenderung berubah dan tidak konstan. Untuk memperkuat dugaan, data kecepatan angin yang tidak stasioner terhadap varians bisa dilihat pada plot *Box-Cox* yang disajikan dalam Gambar 4.3.



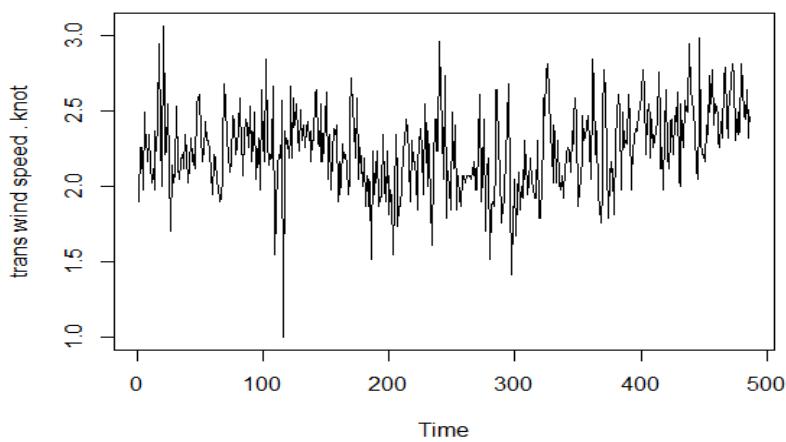
Gambar 4.3 Plot *Box-Cox* Kecepatan Angin di Bandara Internasional Ahmad Yani

Berdasarkan plot *Box-Cox* yang ditunjukkan pada Gambar 4.2, terlihat bahwa *rounded value*-nya bernilai 0,50 dengan batas bawah bernilai 0,40 dan batas atas 0,86 yang tidak melewati nilai 1 sehingga dapat dikatakan bahwa data belum stasioner terhadap varians. Untuk membuat data memenuhi asumsi stasioner terhadap varians maka dilakukan transformasi *Box-Cox* dengan menggunakan transformasi $\sqrt{Z_t}$. Hasil transformasi *Box-Cox* ditunjukkan pada Gambar 4.4.



Gambar 4.4 Plot *Box-Cox* Transformasi Kecepatan Angin di Bandara Internasional Ahmad Yani

Gambar 4.4 menunjukkan plot *Box-Cox* setelah data dilakukan transformasi. Lihat kembali bahwa nilai *rounded value*-nya 1 dengan batas bawah 0,78 dan batas atas 1,74. Sehingga bisa dikatakan bahwa data telah memenuhi asumsi stasioner terhadap varians. Plot runtun waktu data kecepatan angin di Bandara Internasional Ahmad Yani setelah ditransformasi disajikan dalam Gambar 4.5



Gambar 4.5 Plot Runtun Waktu Hasil Transformasi Data Kecepatan Angin di Bandara Internasional Ahmad Yani

Analisis selanjutnya melakukan uji kestasioneran data dalam *mean*. Uji *Augmented Dickey-Fuller* digunakan untuk mengetahui kestasioneran pada data. Uji ini didasarkan pada uji hipotesis untuk melakukan pemeriksaan terhadap kestasioneran data deret waktu. Hipotesis pengujian *Augmented Dickey-Fuller* adalah sebagai berikut :

H_0 : data *time series* tidak stasioner

H_1 : data *time series* stasioner

Hasil uji kestasioneran data transformasi kecepatan angin di Bandara Internasional Ahmad Yani dengan menggunakan *Augmented Dickey-Fuller* ditunjukkan pada Tabel 4.3.

Tabel 4.3 Hasil Uji *Augmented Dickey-Fuller*

	Nilai
Dickey-Fuller	-5,165
p-value	0,01

Berdasarkan Tabel 4.3, uji *Augmented Dickey-Fuller* diperoleh *p-value* 0,01 yang kurang dari taraf nyata yang digunakan sebesar 0,05 ($\alpha = 5\%$), sehingga keputusan menolak H_0 , kesimpulan menyatakan bahwa data stasioner dalam *mean*.

4.4 Pembentukan Model ARFIMA

Pembentukan model ARFIMA dilakukan dengan metode semiparametrik. Menetapkan estimasi parameter d terlebih dahulu dengan menggunakan metode *Geweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S). Selanjutnya penenetapan beberapa model ARFIMA(p, d, q) berdasarkan plot ACF dan PACF pada data yang telah dilakukan *differencing* dengan nilai d yang telah diperoleh. Kemudian estimasi parameter ϕ dan θ pada model yang sudah ditetapkan menggunakan metode *Exact Maximum Likelihood*

4.4.1 Estimasi Parameter d

Nilai parameter *differencing* d ditentukan dengan metode *Geweke Porter-Hudak* (GPH) dan *Rescaled Range Statistic* (R/S). Estimasi parameter d dengan metode estimasi GPH dan R/S dihitung dengan bantuan aplikasi R Studio. Parameter d dari data kecepatan angin di Bandara Internasional Ahmad Yani ditunjukkan pada tabel 4.4 sebagai berikut.

Tabel 4.4 Estimasi Parameter d

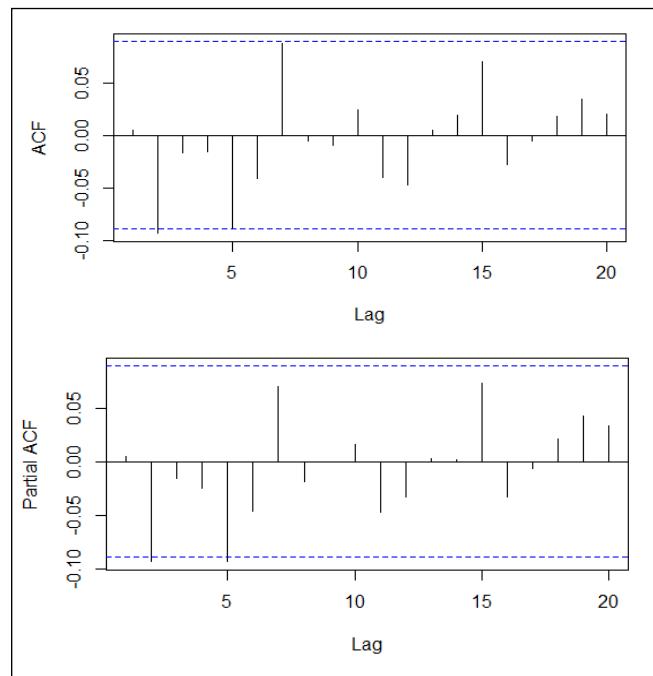
Estimasi Parameter d
<i>Geweke and Porter-Hudak</i> (GPH)
0,346
<i>Rescaled Range Statistics</i> (R/S)
0,224

Dari hasil estimasi parameter d yang ditunjukkan pada Tabel 4.4 menunjukkan bahwa data mempunyai nilai d yang terletak pada selang $0 < d < 0,5$, menyatakan bahwa proses berkorelasi panjang stasioner dengan adanya ketergantungan positif antar pengamatan yang terpisah jauh yang ditunjukkan dengan autokorelasi positif dan turun lambat serta mempunyai representasi *moving average* orde tak hingga.

4.4.2 Identifikasi Beberapa Model ARFIMA(p, d, q) Berdasarkan Plot ACF dan Plot PACF

Identifikasi Model ARFIMA(p, d, q) ditetapkan berdasarkan plot ACF dan PACF setelah *didifferencing* sesuai nilai d dari perhitungan menggunakan estimasi GPH dan R/S. Penentuan beberapa model ARFIMA(p, d, q) ditentukan dengan melihat *lag* yang melewati batas dari plot ACF dan PACF.

Plot ACF dan PACF setelah *didifferencing* dengan $\hat{d}_{gph} = 0,346$ dari perhitungan menggunakan estimasi GPH ditunjukkan pada Gambar 4.6.

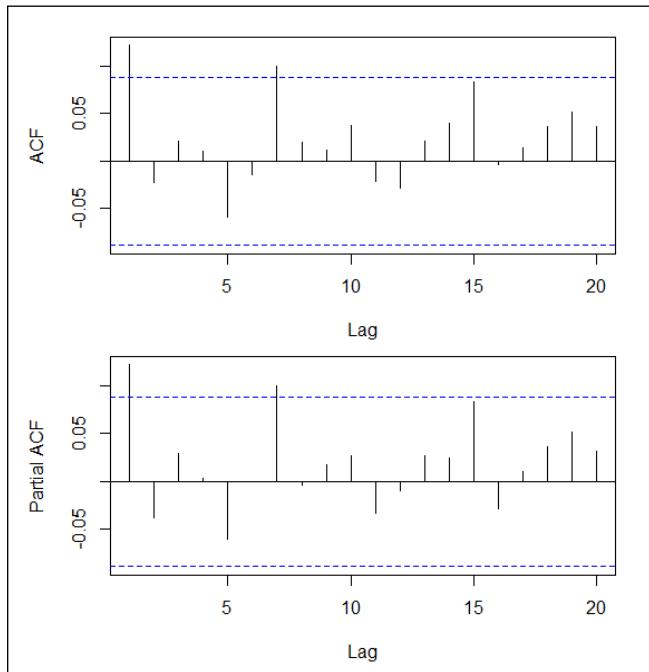


Gambar 4.6 Plot ACF dan Plot PACF *Differencing* ($\hat{d}_{gph} = 0,346$)

Berdasarkan Gambar 4.6 pada plot ACF *lag* yang terlihat jelas melewati batas adalah *lag* ke-2 sehingga dapat diidentifikasi model MA yang terbentuk adalah MA([2]). Kemudian berdasarkan plot PACF *lag* yang melewati batas adalah *lag* *lag* ke-2 dan *lag* ke-5, sehingga dapat diidentifikasi model AR yang terbentuk adalah AR([2]), AR([5]), dan AR([2,5]). Dengan demikian model tentatif ARFIMA dengan $d_{gph} = 0,346$ yang dapat terbentuk adalah:

1. ARFIMA ([2], $d,0$)
2. ARFIMA ([5], $d,0$)
3. ARFIMA ([2,5], $d,0$)
4. ARFIMA (0, $d,[2]$)
5. ARFIMA ([2], $d,[2]$)
6. ARFIMA([5], $d,[2]$)
7. ARFIMA ([2,5], $d,[2]$)

Plot ACF dan PACF setelah *didifferencing* dengan $\hat{d}_{R/S} = 0,224$ dari perhitungan menggunakan estimasi R/S ditunjukkan pada Gambar 4.7.



Gambar 4.7 Plot ACF dan Plot PACF *Differencing* ($\hat{d}_{R/S} = 0,224$)

Berdasarkan Gambar 4.7 pada plot ACF *lag* yang terlihat jelas melewati batas adalah *lag* ke-1 dan *lag* ke-7 sehingga dapat diidentifikasi model MA yang terbentuk adalah MA(1), MA([7]), dan MA([1,7]). Kemudian berdasarkan plot PACF *lag* yang melewati batas adalah *lag lag* ke-2 dan *lag* ke-5, sehingga dapat diidentifikasi model AR yang terbentuk adalah AR(1), AR([7]), dan AR([1,7]). Dengan demikian model tentatif ARFIMA dengan $d_{R/S} = 0,224$ yang dapat terbentuk adalah:

1. ARFIMA(1, d ,0)
2. ARFIMA([7], d ,0)
3. ARFIMA([1,7], d ,0)
4. ARFIMA(1, d ,1)
5. ARFIMA([7], d ,1)
6. ARFIMA([1,7], d ,1)
7. ARFIMA(1, d ,[7])
8. ARFIMA([7], d ,[7])
9. ARFIMA([1,7], d ,[7])
10. ARFIMA(1, d ,[1,7])
11. ARFIMA([7], d ,[1,7])
12. ARFIMA([1,7], d ,[1,7])
13. ARFIMA(0, d ,1)
14. ARFIMA(0, d ,[7])
15. ARFIMA(0, d ,[1,7])

4.4.3 Estimasi Parameter Model Tentatif ARFIMA(p, d, q)

Selanjutnya estimasi parameter ϕ dan θ pada model tentatif ARFIMA(p, d, q) yang sudah ditetapkan. Hasil estimasi parameter model ARFIMA untuk data kecepatan angin di Bandara Internasional Ahmad Yani berdasarkan model tentatif yang telah ditentukan dengan menetapkan estimasi parameter d menggunakan metode GPH ditunjukkan pada Tabel 4.5.

Tabel 4.5 Estimasi Parameter Model Tentatif ARFIMA $\hat{d}_{gph} = 0,346$

Tentatif Model	Parameter	SE	Z	Keterangan
ARFIMA([2], $d, 0$)	$\phi_2 = -0,0934$	0,0451	-2,0699	Signifikan
ARFIMA([5], $d, 0$)	$\phi_5 = -0,0898$	0,0452	-1,9873	Signifikan
ARFIMA ([2,5], $d, 0$)	$\phi_2 = -0,0952$	0,0449	-2,1199	Signifikan
	$\phi_5 = -0,0917$	0,0450	-2,0386	Signifikan
ARFIMA(0, $d, [2]$)	$\theta_2 = 0,0983$	0,0463	2,1218	Signifikan
ARFIMA([2], $d, [2]$)	$\phi_2 = 0,4302$	0,3806	1,1302	Tidak Signifikan
	$\theta_2 = 0,5231$	0,3598	1,4536	Tidak Signifikan
ARFIMA([5], $d, [2]$)	$\phi_5 = -0,0851$	0,0453	-1,8804	Tidak Signifikan
	$\theta_2 = 0,0938$	0,0464	2,0207	Signifikan
ARFIMA([2,5], $d, [2]$)	$\phi_5 = -0,3700$	0,2632	-1,4057	Tidak Signifikan
	$\phi_2 = -0,0991$	0,0421	-2,3514	Signifikan
	$\theta_2 = -0,2908$	0,2805	-1,0367	Tidak Signifikan

Berdasarkan Tabel 4.5 dapat diketahui dari uji signifikansi parameter model yaitu apabila nilai statistik $|z| > z$ tabel (1,96), maka parameter model dinyatakan signifikan. Dari estimasi model tentatif ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ yang ditentukan, model yang menghasilkan semua parameter yang signifikan adalah model ARFIMA([2], $d, 0$), ARFIMA([5], $d, 0$), ARFIMA ([2,5], $d, 0$), dan ARFIMA (0, $d, [2]$).

Hasil estimasi parameter model ARFIMA untuk data kecepatan angin di Bandara Internasional Ahmad Yani berdasarkan model tentatif yang telah ditentukan dengan menetapkan estimasi parameter d menggunakan metode R/S ditunjukkan pada Tabel 4.6.

Tabel 4.6 Estimasi Parameter Model Tentatif ARFIMA $\hat{d}_{R/S} = 0,224$

Tentatif Model	Parameter	SE	Z	Keterangan
ARFIMA(1, d,0)	$\phi_1 = 0,1232$	0,0450	2,7374	Signifikan
ARFIMA([7], d,0)	$\phi_7 = 0,0997$	0,0450	2,212	Signifikan
ARFIMA([1,7], d,0)	$\phi_1 = 0,1243$	0,0447	2,7790	Signifikan
	$\phi_7 = 0,1012$	0,0447	2,2628	Signifikan
ARFIMA(1, d,1)	$\phi_1 = -0,0190$	0,3000	-0,6349	Tidak Signifikan
	$\theta_1 = -0,3194$	0,2891	1,1048	Tidak Signifikan
ARFIMA([7], d,1)	$\phi_7 = 0,1012$	0,0451	2,2450	Signifikan
	$\theta_1 = -0,132$	0,0459	-2,8815	Signifikan
ARFIMA([1,7], d,1)	$\phi_1 = -0,0803$	0,2599	-0,3090	Tidak Signifikan
	$\phi_7 = 0,0995$	0,0456	2,1806	Signifikan
	$\theta_1 = -0,2122$	0,2586	-0,8207	Tidak Signifikan
ARFIMA(1, d,[7])	$\phi_1 = 0,1257$	0,0450	2,7938	Signifikan
	$\theta_7 = -0,0968$	0,0436	-2,2205	Signifikan
ARFIMA([7], d,[7])	$\phi_7 = 0,3429$	0,4121	0,8320	Tidak Signifikan
	$\theta_7 = 0,2453$	0,4254	0,5767	Tidak Signifikan
ARFIMA([1,7], d,[7])	$\phi_1 = 0,1183$	0,0461	2,5622	Signifikan
	$\phi_7 = 0,2937$	0,3943	0,7449	Tidak Signifikan
	$\theta_7 = 0,1971$	0,4111	0,4795	Tidak Signifikan
ARFIMA(1, d,[1,7])	$\phi_1 = -0,0808$	0,2432	-0,3325	Tidak Signifikan
	$\theta_1 = -0,2124$	0,2385	-0,8906	Tidak Signifikan
	$\theta_7 = -0,0967$	0,0445	-2,1709	Signifikan
ARFIMA([7], d,[1,7])	$\phi_7 = 0,2530$	0,5764	0,4389	Tidak Signifikan
	$\theta_1 = -0,1289$	0,0485	-2,6552	Signifikan
	$\theta_7 = 0,1555$	0,5999	0,2593	Tidak Signifikan

	$\phi_1 = -0,0706$	0,2834	-0,2491	Tidak Signifikan
ARFIMA ([1,7], d,[1,7])	$\phi_7 = 0,02182$	0,6421	0,3399	Tidak Signifikan
	$\theta_1 = -0,2013$	0,2896	-0,6953	Tidak Signifikan
	$\theta_7 = 0,1214$	0,6643	0,1827	Tidak Signifikan
ARFIMA(0, d,1)	$\theta_1 = -0,1320$	0,0463	-2,8529	Signifikan
ARFIMA(0, d,[7])	$\theta_7 = -0,0926$	0,0472	-2,1466	Signifikan
ARFIMA(0, d,[1,7])	$\theta_1 = -0,1333$	0,0456	-2,9192	Signifikan
	$\theta_7 = -0,0981$	0,0441	-2,7551	Signifikan

Berdasarkan Tabel 4.6 dapat diketahui dari uji signifikansi parameter model yaitu apabila nilai statistik $|z| > z$ tabel (1,96), maka parameter model dinyatakan signifikan. Dari estimasi model tentatif ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ yang ditentukan, model yang menghasilkan semua parameter yang signifikan adalah model ARFIMA(1, d,0), ARFIMA([7], d,0), ARFIMA([1,7], d,0), ARFIMA([7], d,1), ARFIMA(1,d,[7]), ARFIMA(0,d,1), ARFIMA(0,d,[7]), dan ARFIMA(0, d,[1,7]).

4.5 Uji Diagnostik Model

Uji kelayakan model (diagnostik model) untuk mengetahui apakah residual model berdistribusi normal dan bersifat *white noise* atau tidak. Pengujian asumsi *white noise* digunakan untuk mengetahui ada tidaknya korelasi antar series sisaan/residual yang dihasilkan dari model ARFIMA yang signifikan. Uji *L-Jung Box* digunakan untuk mengetahui residual model bersifat *white noise* atau tidak, dengan hipotesis sebagai berikut:

H_0 : Residual data bersifat *white noise*

H_1 : Residual data tidak bersifat *white noise*.

Taraf signifikan yang digunakan sebesar $\alpha(5\%)$ maka kriteria pengujian yang digunakan adalah tolak H_0 jika nilai *p value* < *level of significant* ($\alpha = 0,05$).

Uji asumsi kenormalan pada residual apakah residual berdistribusi normal atau tidak, dapat dilihat melalui uji *Kolmogorov-Smirnov*. Hipotesis yang digunakan untuk uji *Kolmogorov-Smirnov* adalah.

H_0 : Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal.

Taraf signifikan yang digunakan sebesar $\alpha(5\%)$ maka kriteria pengujian yang digunakan adalah tolak H_0 jika nilai $p \text{ value} < \text{level of significant}$ ($\alpha = 0,05$). Uji diagnostik residual model ARFIMA yang signifikan untuk data kecepatan angin di Bandara Internasional Soekarno Hatta sebagai berikut.

Berikut hasil uji diagnostik model ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ ditunjukkan pada Tabel 4.7.

Tabel 4.7 Uji Diagnostik Model ARFIMA ($\hat{d}_{gph} = 0,346$)

Model ARFIMA	Uji White Noise		Uji Normalitas	
	Chi Square	p value	KS	p value
ARFIMA([2], $d, 0$)	14,172	0,8216	0,046695	0,013
ARFIMA([5], $d, 0$)	15,588	0,7418	0,041013	0,048
ARFIMA([2,5], $d, 0$)	11,112	0,9433	0,041348	0,045
ARFIMA(0, $d, [2]$)	13,836	0,8387	0,044398	0,022

Berdasarkan Tabel 4.7 hasil pengujian *white noise*, statistik uji *Ljung-Box* menunjukkan bahwa semua model menghasilkan nilai $p \text{ value} > \text{level of significant}$ ($\alpha = 0,05$), sehingga keputusan menerima H_0 . Artinya residual pada model-model tersebut dinyatakan *white noise*. Hasil pengujian asumsi normalitas menggunakan uji *Kolmogorov-Smirnov* menunjukkan bahwa semua model menghasilkan nilai $p \text{ value} < \text{level of significant}$ ($\alpha = 0,05$), sehingga keputusan menolak H_0 . Kesimpulan menyatakan residual pada model-model tersebut dinyatakan tidak berdistribusi normal. Dengan demikian asumsi normalitas tidak terpenuhi.

Berikut hasil uji diagnostik model ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ ditunjukkan pada Tabel 4.8.

Tabel 4.8 Uji Diagnostik Model ARFIMA ARFIMA ($\hat{d}_{R/S} = 0,224$)

Model ARFIMA	Uji White Noise		Uji Normalitas	
	Chi Square	p value	KS	p value
ARFIMA(1, $d, 0$)	15,968	0,7186	0,043737	0,026
ARFIMA([7], $d, 0$)	18,115	0,5798	0,047773	0,009
ARFIMA([1,7], $d, 0$)	10,227	0,9639	0,04345	0,0284
ARFIMA([7], $d, 1$)	9,5625	0,9754	0,04574	0,016
ARFIMA(1, $d, [7]$)	10,458	0,9591	0,043672	0,026
ARFIMA(0, $d, 1$)	15,216	0,7539	0,0419	0,040
ARFIMA(0, $d, [7]$)	18,654	0,5444	0,047259	0,011
ARFIMA(0, $d, [1,7]$)	9,6974	0,9733	0,044398	0,022

Berdasarkan Tabel 4.8 hasil pengujian *white noise*, statistik uji *Ljung-Box* menunjukkan bahwa semua model menghasilkan nilai *p value* $> \text{level of significant}$ ($\alpha = 0,05$), sehingga keputusan menerima H_0 . Artinya residual pada model-model tersebut dinyatakan *white noise*. Hasil pengujian asumsi normalitas menggunakan uji *Kolmogorov-Smirnov* menunjukkan bahwa semua model menghasilkan nilai *p value* $< \text{level of significant}$ ($\alpha = 0,05$), sehingga keputusan menolak H_0 . Kesimpulan menyatakan residual pada model-model tersebut dinyatakan tidak berdistribusi normal. Dengan demikian asumsi normalitas tidak terpenuhi.

4.6 Pemilihan Model untuk Peramalan

Pemilihan model ARFIMA yang akan digunakan untuk peramalan menggunakan kriteria nilai *Akaike's Information Criterion* (AIC) terekekil. Model ARFIMA akan dipilih untuk masing-masing dari metode estimasi GPH dan R/S. Nilai AIC dari model ARFIMA untuk data kecepatan angin di bandara internasional Ahmad Yani ditunjukkan pada Tabel 4.9 berikut.

Tabel 4.9 Nilai AIC Model ARFIMA

Estimasi Parameter d	Model ARFIMA	AIC
$\hat{d}_{gph} = 0,346$	ARFIMA([2], $d,0$)	-1384,319
	ARFIMA([5], $d,0$)	-1377,984
	ARFIMA([2,5], $d,0$)	-1382,458
	ARFIMA(0, $d,[2]$)	-1384,527
$\hat{d}_{R/S} = 0,224$	ARFIMA(1, $d,0$)	-1385,107
	ARFIMA([7], $d,0$)	-1370,539
	ARFIMA([1,7], $d,0$)	-1378,198
	ARFIMA([7], $d,1$)	-1376,641
	ARFIMA(1, $d,[7]$)	-1375,941
	ARFIMA(0, $d,1$)	-1385,629
	ARFIMA(0, $d,[7]$)	-1370,200
	ARFIMA(0, $d,[1,7]$)	-1378,464

Berdasarkan Tabel 4.9, untuk model ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ model yang terpilih adalah diperoleh model ARFIMA(0, $d,[2]$) dengan nilai AIC terkecil yaitu -1384,527. Untuk model ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ model yang terpilih adalah model ARFIMA(0, $d,1$) dengan nilai AIC terkecil yaitu -1385,629. Model-model terpilih tersebut selanjutnya digunakan akan digunakan untuk proses peramalan. Persamaan model ARFIMA(0, $d,[2]$) dengan $\hat{d}_{gph} = 0,346$ adalah sebagai berikut:

$$\begin{aligned} \phi_p(B)(1-B)^d Z_t &= \theta_q(B) a_t \\ \Leftrightarrow (1-B)^{0.346} Z_t &= (1 + 0,098B) a_t. \end{aligned} \quad (4.1)$$

Persamaan model ARFIMA(0, $d,1$) dengan $\hat{d}_{R/S} = 0,224$ adalah sebagai berikut:

$$\begin{aligned} \phi_p(B)(1-B)^d Z_t &= \theta_q(B) a_t \\ \Leftrightarrow (1-B)^{0.224} Z_t &= (1 - 0,132) a_t. \end{aligned} \quad (4.2)$$

4.8 Peramalan

Model ARFIMA yang terpilih selanjutnya digunakan untuk melakukan penyesuaian (*fitting*) dengan data *in sample*. Pada penelitian ini digunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan *Mean Absolute*

Percentage Error (MAPE) untuk menghitung akurasi model yang signifikan. Data hasil *fitting* model bisa dilihat pada Lampiran 3. Hasil perhitungan tingkat akurasi data *fitting* disajikan dalam Tabel 4.9.

Tabel 4.10 Nilai Akurasi *Fitting* Model ARFIMA

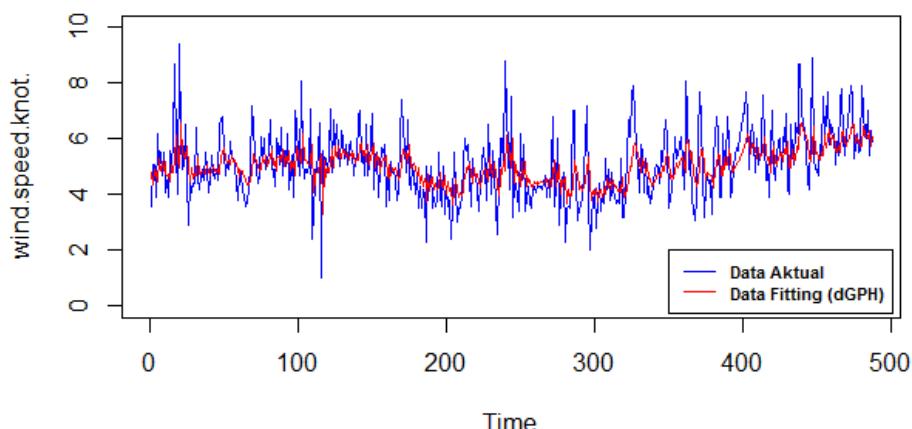
Estimasi Parameter d	Model ARFIMA	RMSE	MAE	MAPE
$\hat{d}_{gph} = 0,346$	ARFIMA(0, d , [2])	1,072906	0,8101154	17,20635
$\hat{d}_{R/S} = 0,224$	ARFIMA(0, d , 1)	1,074054	0,8123931	17,30652

Berdasarkan Tabel 4.10, nilai eror pada *fitting* model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ adalah RMSE 1,072906, MAE 0,8101154, dan MAPE 17,20635.

Nilai eror pada *fitting* model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$ adalah RMSE 1,074054, MAE 0,8123931, dan MAPE 17,30652. Nilai MAPE pada kedua model berdasarkan kriteria pada Tabel 2.2 yaitu $< 20\%$, hal ini menunjukkan tingkat kemampuan peramalan yang baik. Nilai eror pada *fitting* model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ menunjukkan eror yang lebih kecil dibanding model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data aktual dan data *fitting*. Plot dari data aktual dan data *fitting* menggunakan model terpilih ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ disajikan pada Gambar 4.8 berikut.

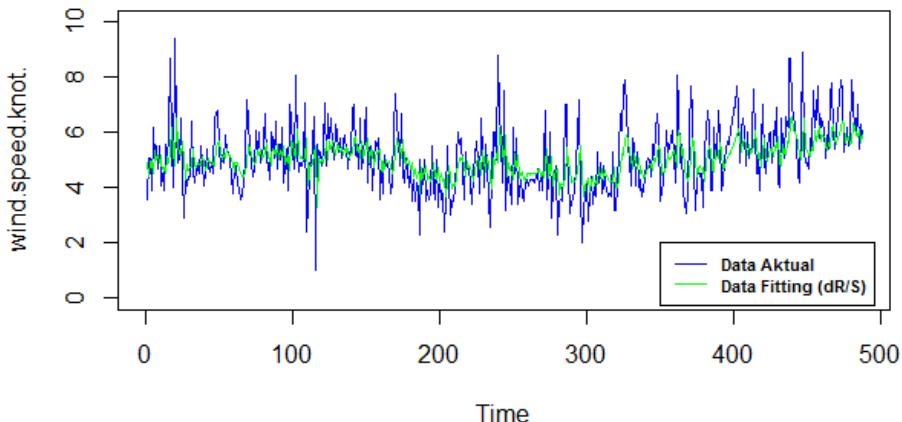
Data Aktual VS Data Fitting ARFIMA dengan $d = 0,346$



Gambar 4.8 Plot Data *Fitting* ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$

Plot dari data aktual dan data *fitting* menggunakan model terpilih ARFIMA(0, d ,1) dengan $\hat{d}_{R/S} = 0,224$ disajikan pada Gambar 4.9 berikut.

Data Aktual VS Data Fitting ARFIMA dengan $d = 0,224$



Gambar 4.9 Plot Data *Fitting* ARFIMA(0, d ,1) dengan $\hat{d}_{R/S} = 0,224$

Berdasarkan Gambar 4.8 dan Gambar 4.9, terlihat hasil dari data *fitting* kecepatan angin di Bandara Internasional Ahmad Yani cukup mengikuti pola data aktual.

Selanjutnya model ARFIMA yang terpilih akan digunakan dalam peramalan dan validasi pada data *out sample*. Hasil peramalan bisa dilihat pada Lampiran 4. Hasil perhitungan nilai akurasi peramalan kecepatan angin di Bandara Internasional Ahmad Yani disajikan dalam Tabel 4.11.

Tabel 4.11 Nilai Akurasi Peramalan Model ARFIMA

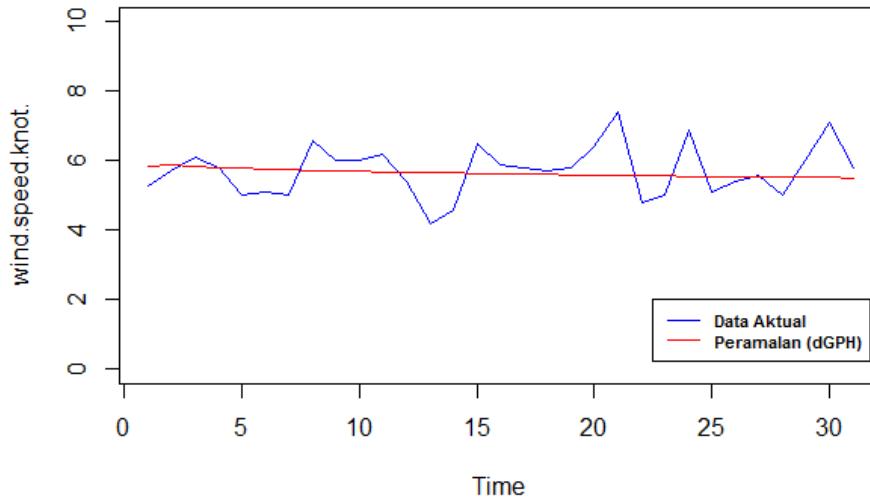
Estimasi Parameter d	Model ARFIMA	RMSE	MAE	MAPE
$\hat{d}_{gph} = 0,346$	ARFIMA(0, d ,[2])	0,74966754	0,593468	10,45511
$\hat{d}_{R/S} = 0,224$	ARFIMA(0, d ,1)	0,7898162	0,6295811	10,75531

Berdasarkan Tabel 4.9, nilai eror validasi peramalan model ARFIMA (0, d ,[2]) dengan $\hat{d}_{gph} = 0,346$ adalah RMSE 0,74966754, MAE 0,593468, dan MAPE 10,45511. Nilai eror pada validasi peramalan model ARFIMA(0, d ,1) dengan $\hat{d}_{R/S} = 0,224$ adalah RMSE 0,7898162, MAE 0,6295811, dan MAPE 10,75531. Nilai MAPE pada kedua model berdasarkan kriteria pada Tabel 2.2 yaitu < 20%, hal ini menunjukkan tingkat kemampuan peramalan yang baik. Nilai eror pada validasi peramalan model ARFIMA (0, d ,[2]) dengan $\hat{d}_{gph} = 0,346$

menunjukkan eror yang lebih kecil dibanding model ARFIMA(0, d,1) dengan $\hat{d}_{R/S} = 0,224$.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data peramalan dan *out sample*. Plot dari data aktual dan ramalan menggunakan model terpilih ARFIMA(0, d,[2]) dengan $\hat{d}_{gph} = 0,346$ disajikan pada Gambar 4.10 berikut.

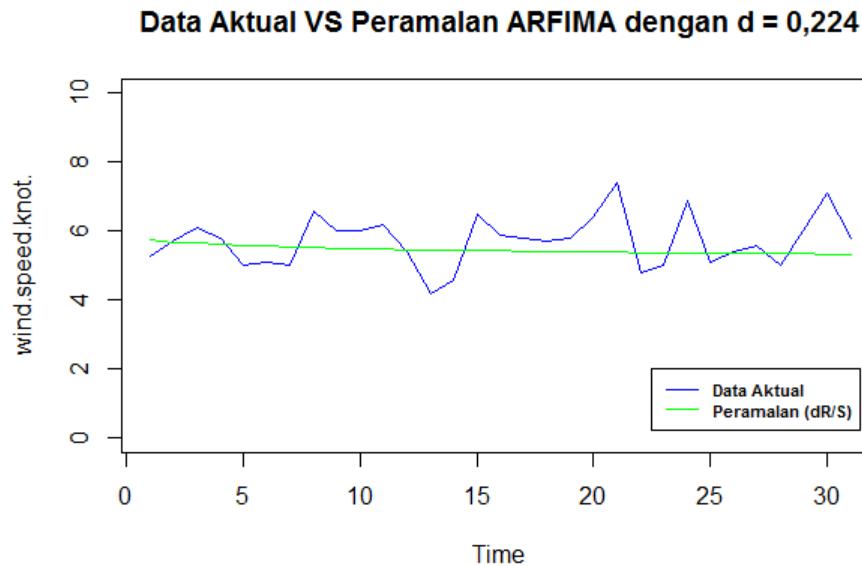
Data Aktual VS Peramalan ARFIMA dengan d = 0,346



Gambar 4.10 Plot Data Aktual dan Ramalan Model ARFIMA(0, d,[2]) dengan

$$\hat{d}_{gph} = 0,346$$

Plot dari data aktual dan ramalan menggunakan model terpilih ARFIMA(0, d,1) dengan $\hat{d}_{R/S} = 0,224$ disajikan pada Gambar 4.11 berikut.



Gambar 4.11 Plot Data Aktual dan Ramalan Model ARFIMA($0, d, 1$) dengan
 $\hat{d}_{R/S} = 0,224$

4.8 Perbandingan dengan Model Lain

Dalam Penelitian ini penulis menambahkan model lain untuk perbandingan dan sebagai pelengkap dalam penelitian. Penulis menggunakan model *Autoregressive Integrated Moving Average* (ARIMA) dan *Extreme Learning Machine* (ELM) sebagai komparasi atau perbandingan. Dalam perhitungan penulis menggunakan fungsi yang tersedia dalam program R Studio.

4.8.1 Model *Autoregressive Integrated Moving Average*

Model ARIMA(p, d, q) untuk data kecepatan Angin di Bandara Internasional Ahmad Yani ditentukan dengan menggunakan fungsi auto.arima pada program R Studio. Dari pengolahan data diperoleh model yaitu ARIMA(1,1,1) dengan estimasi parameter yang disajikan pada Tabel 4.12 berikut.

Tabel 4.12 Estimasi Parameter Model ARIMA(1,1,1)

Model	Parameter	SE	Z	Keterangan
ARIMA(1,1,1)	$\phi_1 = 0,2964$	0,0460	6,4434	Signifikan
	$\theta_1 = -0,9554$	0,0143	-66,811	Signifikan

Persamaan model ARIMA(1,1,1) adalah sebagai berikut:

$$\begin{aligned} \phi_p(B)(1 - B)^d Z_t &= \theta_q(B)a_t \\ \Leftrightarrow (1 - 0,296B)(1 - B)^d Z_t &= (1 + 0,955B)a_t \\ \Leftrightarrow (1 - B)Z_t &= \frac{(1 + 0,955B)}{(1 - 0,296B)} a_t. \end{aligned} \quad (4.3)$$

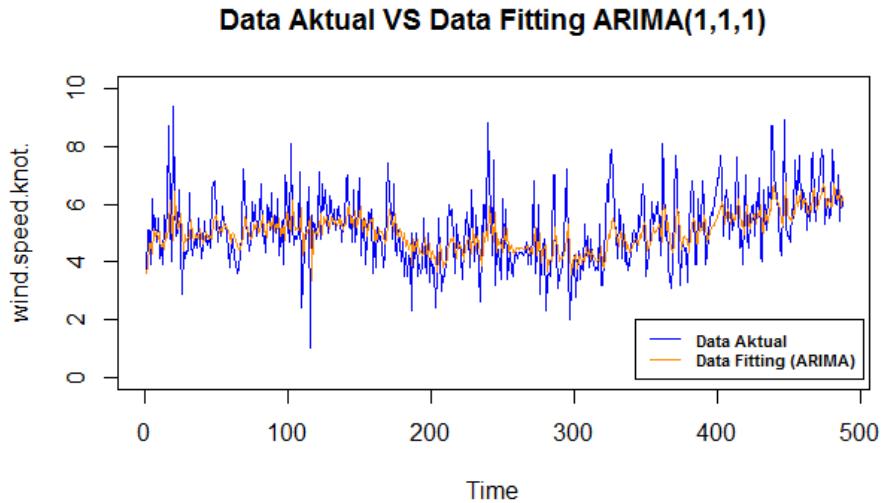
Selanjutnya, model yang telah terpilih digunakan digunakan untuk melakukan penyesuaian (*fitting*) dengan data *in sample*. Pada penelitian ini digunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) untuk menghitung akurasi peramalan. Hasil perhitungan tingkat akurasi *fitting* data menggunakan model ARIMA(1,1,1) disajikan dalam Tabel 4.13 berikut.

Tabel 4.13 Nilai Akurasi *Fitting* Model ARIMA

ARIMA(1,1,1)	
RMSE	1,069348
MAE	0,802783
MAPE	16,99219

Berdasarkan Tabel 4.13, nilai eror pada *fitting* model ARIMA(1,1,1) adalah RMSE 1,069348, MAE 0,802783, dan MAPE 16,99219. Nilai MAPE pada *fitting* model berdasarkan kriteria pada Tabel 2.2 yaitu $< 20\%$, hal ini menunjukkan tingkat kemampuan peramalan yang baik.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data aktual dan data *fitting*. Plot dari data aktual dan data *fitting* menggunakan model ARIMA(1,1,1) disajikan pada Gambar 4.12 berikut.



Gambar 4.12 Plot Data *Fitting* ARIMA(1,1,1)

Berdasarkan Gambar 4.12, terlihat hasil dari data *fitting* kecepatan angin di Bandara Internasional Ahmad Yani dengan Model ARIMA(1,1,1) cukup mengikuti pola data aktual.

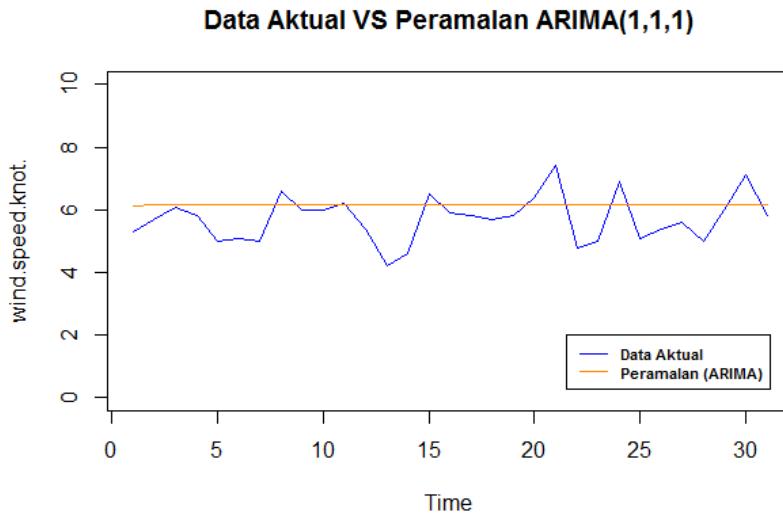
Selanjutnya model ARIMA yang terpilih akan digunakan dalam peramalan dan validasi pada data *out sample*. Hasil ramalan menggunakan model ARIMA(1,1,1) bisa dilihat pada Lampiran 7. Hasil perhitungan nilai akurasi peramalan kecepatan angin di Bandara Internasional Ahmad Yani disajikan dalam Tabel 4.14 berikut.

Tabel 4.14. Nilai Akurasi Peramalan Model ARIMA

ARIMA(1,1,1)	
RMSE	0,8605522
MAE	0,7110627
MAPE	13,41102

Berdasarkan Tabel 4.14, nilai eror validasi peramalan model ARIMA(1,1,1) adalah RMSE 0,8605522, MAE 0,7110627, dan MAPE 13,41102. Nilai MAPE pada model berdasarkan kriteria pada Tabel 2.2 yaitu < 20%, hal ini menunjukkan tingkat kemampuan peramalan yang baik.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data peramalan dan *out sample*. Plot dari data aktual dan ramalan menggunakan model terpilih ARIMA(1,1,1) disajikan pada Gambar 4.13 berikut.

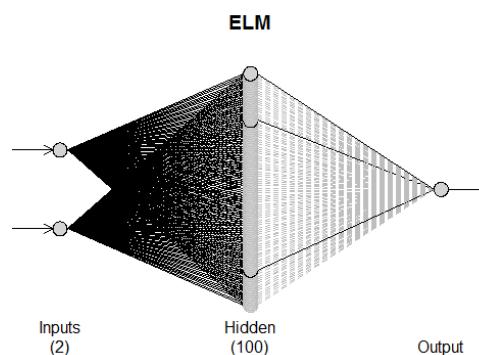


Gambar 4.13 Plot Data Aktual dan Ramalan Model ARIMA(1,1,1)

4.8.2 Metode *Extreme Learning Machine*

Extreme Learning Machine (ELM) pertama kali diperkenalkan oleh Huang pada tahun 2004. ELM merupakan salah satu metode pembelajaran dari jaringan syaraf tiruan. ELM merupakan jaringan syaraf tiruan *feedforward* dengan *single hidden layer* atau biasa disebut *Single Hidden Layer Feedforward Neural Networks* (SLFNs). Metode pembelajaran ELM dibuat untuk mengatasi kelamahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed* (Huang dkk, 2004).

Model *Extreme Learning Machine* (ELM) dari data kecepatan angin di Bandara Internasional Ahmad Yani ditentukan dengan fungsi *elm* dari *package nnfor* pada program R Studio. Plot dari model ELM disajikan pada Gambar 4.14 berikut.



Gambar 4.14. Plot Model ELM

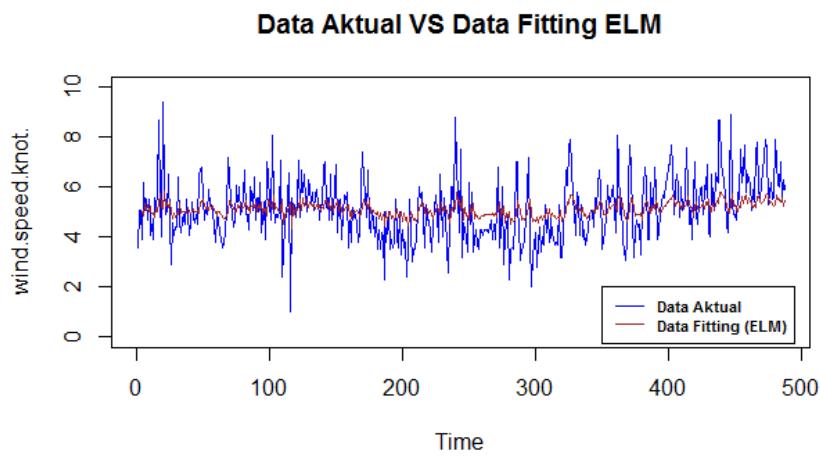
Pada penelitian ini digunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) untuk menghitung akurasi peramalan. Hasil perhitungan tingkat akurasi *fitting* data menggunakan model ELM disajikan dalam Tabel 4.15 berikut.

Tabel 4.15 Nilai Akurasi *Fitting* Model ELM

Nilai Akurasi ELM	
RMSE	1,121014
MAE	0,874623
MAPE	19,0393

Berdasarkan Tabel 4.15, nilai eror pada *fitting* model ELM adalah RMSE 1,121014, MAE 0,874623, dan MAPE 19,0393. Nilai MAPE pada *fitting* model berdasarkan kriteria pada Tabel 2.2 yaitu $< 20\%$, hal ini menunjukkan tingkat kemampuan peramalan yang baik.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data aktual dan data *fitting*. Plot dari data aktual dan data *fitting* menggunakan model ELM disajikan pada Gambar 4.15 berikut.



Gmbar 4.15 Plot Data *Fitting* ELM

Berdasarkan Gambar 4.15, terlihat hasil dari data *fitting* kecepatan angin di Bandara Internasional Ahmad Yani dengan Model ELM cukup mengikuti pola data aktual.

Selanjutnya model ELM yang terpilih akan digunakan dalam peramalan dan validasi pada data *out sample*. Hasil Peramalan menggunakan model ELM

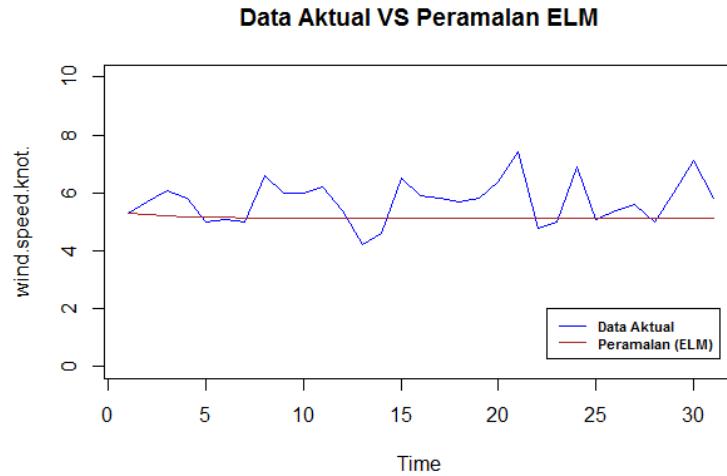
bisa dilihat pada Lampiran 7. Hasil perhitungan nilai akurasi peramalan kecepatan angin di Bandara Internasional Ahmad Yani disajikan dalam Tabel 4.16 berikut.

Tabel 4.16 Nilai Akurasi Peramalan Model ELM

Nilai Akurasi ELM	
RMSE	0,9197016
MAE	0,7235949
MAPE	11,90351

Berdasarkan Tabel, nilai eror validasi peramalan model ELM adalah RMSE 0,9197016, MAE 0,7235949, dan MAPE 11,90351. Nilai MAPE pada model berdasarkan kriteria pada Tabel 2.2 yaitu $< 20\%$, hal ini menunjukkan tingkat kemampuan peramalan yang baik.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data peramalan dan *out sample*. Plot dari data aktual dan ramalan menggunakan model ELM disajikan pada Gambar 4.16 berikut.



Gambar 4.16 Plot Data Aktual dan Ramalan Model ELM

4.8.3 Perbandingan Model

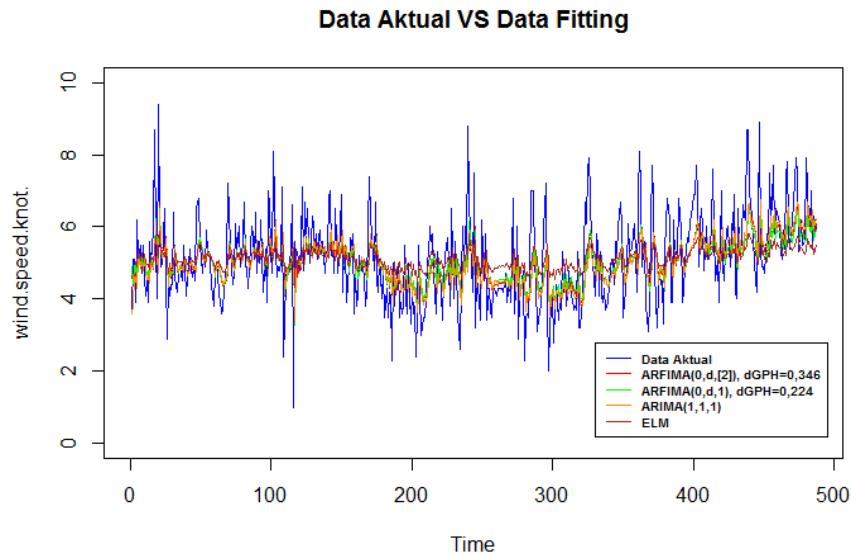
Model-model yang sudah terpilih, selanjutnya akan digunakan untuk komparasi. Berikut adalah nilai akurasi dari hasil *fitting* model masing-masing model disajikan pada Tabel 4.17.

Tabel 4.17 Nilai Akurasi *Fitting* Model ARFIMA, ARIMA, dan ELM

Model	RMSE	MAE	MAPE
ARFIMA(0, d , [2]), $\hat{d}_{gph} = 0,346$	1,072906	0,8101154	17,20635
ARFIMA(0, d , 1), $\hat{d}_{R/S} = 0,224$	1,074054	0,8123931	17,30652
ARIMA(1,1,1)	1,069348	0,802783	16,99219
ELM	1,121014	0,874623	19,0393

Berdasarkan Tabel 4.17, nilai akurasi model ARIMA(1,1,1) untuk *fitting* data kecepatan angin di Bandara Internasional Ahmad Yani menunjukkan nilai eror yang paling kecil dibanding model yang lain.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data aktual dan data *fitting*. Plot dari data aktual dan data *fitting* menggunakan model menggunakan model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$, ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$, ARIMA(1,1,1), dan model ELM disajikan pada Gambar 4.17 berikut.

Gambar 4.17 Plot Data Aktual dan *Fitting* Model ARFIMA, ARIMA, dan ELM

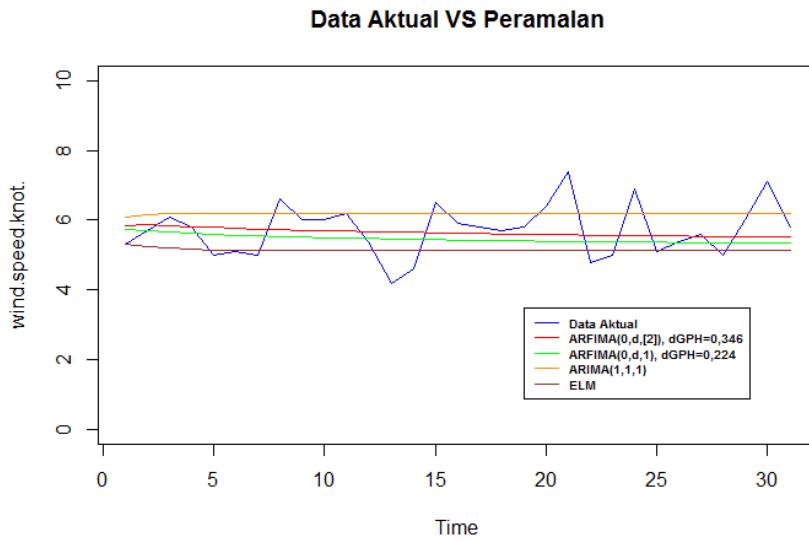
Selanjutnya akan dilihat nilai akurasi hasil peramalan untuk masing-masing model. Nilai akurasi hasil peramalan dari masing-masing model disajikan pada Tabel 4.18.

Tabel 4.18 Nilai Akurasi Peramalan Model ARFIMA, ARIMA, dan ELM

Model ARFIMA	RMSE	MAE	MAPE
ARFIMA(0, d , [2]), $\hat{d}_{gph} = 0,346$	0,74966754	0,593468	10,45511
ARFIMA(0, d , 1), $\hat{d}_{R/S} = 0,224$	0,7898162	0,6295811	10,75531
ARIMA(1,1,1)	0,8605522	0,7110627	13,41102
ELM	0,9197016	0,7235949	11,90351

Berdasarkan Tabel 4.18, nilai akurasi model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ untuk peramalan data kecepatan angin di Bandara Internasional Ahmad Yani menunjukkan nilai eror yang paling kecil dibanding model yang lain.

Berikut akan disajikan plot untuk mempermudah melihat perbedaan dari data peramalan dan *out sample* masing-masing model. Plot dari data aktual dan ramalan menggunakan model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$, ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$, ARIMA(1,1,1), dan model ELM disajikan pada Gambar 4.18 berikut.



Gambar 4.18 Plot Data Aktual dan Ramalan Model ARFIMA, ARIMA, dan ELM

4.9 Pembahasan

Data yang digunakan dalam penelitian kali ini merupakan data sekunder. Data yang digunakan adalah data kecepatan angin di Bandara Internasional Ahmad Yani dalam frekuensi harian. Periode data kecepatan angin yang diambil mulai awal bulan Juni 2018 hingga akhir Oktober 2019, sehingga terdapat 518 data. Data dibagi menjadi dua bagian yaitu data *in sample* dan data *out sample*. Pembagian data sekitar 95% untuk data *in sample* dan sisanya untuk data *out sample*. Sebanyak 487 data *in sample* dan 31 data *out sample*. Data *in sample* digunakan untuk pembentukan model dan data *out sample* untuk validasi model. Berdasarkan Tabel 4.1 menunjukkan bahwa data *in sample* kecepatan angin di Bandara Internasional Ahmad Yani memiliki nilai rata-rata 5,125. Nilai standar deviasi yaitu 1,220 sehingga nilai variansnya 1.489. Nilai minimum 1 dan nilai maksimum 9,4. Pengujian long memory dilakukan dengan cara melihat plot ACF, nilai *Hurst* (*H*), dan plot periodogram dari data kecepatan angin di Bandara Internasional Ahmad Yani. Dengan melihat plot ACF pada Gambar 4.1, nilai *Hurst* (*H*) pada Tabel 4.2, dan plot periodogram pada Gambar 4.2, pengujian *long memory* memberikan hasil bahwa data kecepatan angin di Bandara Internasional Ahmad Yani memiliki sifat *long memory*. Oleh sebab data kecepatan angin di Bandara Internasional Ahmad Yani memiliki sifat *long memory*, untuk selanjutnya dilakukan pembentukan model ARFIMA.

Pada pembentukan model ARFIMA dilakukan uji kestaisonaran terlebih dahulu, apakah data stasioner terhadap varians dan *mean*. Untuk mengetahui apakah data stasioner terhadap varians dilihat plot *Box-Cox* pada Gambar 4.3, yang mana memperlihatkan bahwa data belum stasioner dalam varians. Oleh sebab data belum stasioner dalam varians maka dilakukan transformasi. Selanjutnya data yang sudah ditransformasi dilakukan uji *Augmented Dickey-Fuller* untuk mengetahui apakah data stasioner dalam *mean* atau belum . Bedasarkan hasil uji *Augmented Dickey-Fuller* pada Tabel 4.3 dapat diketahui ketiga data *in sample* stasioner dalam *mean*.

Dalam pembentukan model ARFIMA dilakukan dengan metode semiparametrik. Menetapkan estimasi parameter *d* terlebih dahulu dengan

menggunakan metode *Geweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S), yang memberikan hasil pada Tabel 4.4 yaitu $\hat{d}_{gph} = 0,346$ dan $\hat{d}_{R/S} = 0,224$. Oleh sebab parameter d untuk data telah dipunyai, selanjutnya penetapan beberapa model ARFIMA(p, d, q) berdasarkan plot ACF dan PACF data yang telah dilakukan *differencing* dengan nilai d yang telah diperoleh. Untuk model ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ model tentatif yang terbentuk adalah ARFIMA([2], $d,0$), ARFIMA([5], $d,0$), ARFIMA([2,5], $d,0$), ARFIMA(0, $d,[2]$), ARFIMA([2], $d,[2]$), ARFIMA([5], $d,[2]$), dan ARFIMA([2,5], $d,[2]$). Untuk model ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ model tentatif yang terbentuk adalah ARFIMA(1, $d,0$), ARFIMA([7], $d,0$), ARFIMA([1,7], $d,0$), ARFIMA(1, $d,1$), ARFIMA([7], $d,1$), ARFIMA([1,7], $d,1$), ARFIMA(1, $d,[7]$), ARFIMA([7], $d,[7]$), ARFIMA([1,7], $d,[7]$), ARFIMA(1, $d,[1,7]$), ARFIMA([7], $d,[1,7]$), ARFIMA([1,7], $d,[1,7]$), ARFIMA(0, $d,1$), ARFIMA(0, $d,[7]$), dan ARFIMA(0, $d,[1,7]$). Setelah penetapan beberapa model ARFIMA, kemudian dilakukan estimasi parameter parameter ϕ dan θ dari model tentatif ARFIMA yang telah ditetapkan. Dalam estimasi parameter, dipilih model yang signifikan yaitu model yang memiliki nilai statistik $|z| > z$ tabel (1,96). Dari estimasi model tentatif ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ yang ditentukan, model yang menghasilkan semua parameter yang signifikan adalah model ARFIMA([2], $d,0$), ARFIMA([5], $d,0$), ARFIMA([2,5], $d,0$), dan ARFIMA(0, $d,[2]$). Sedangkan dari estimasi model tentatif ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ yang ditentukan, model yang menghasilkan semua parameter yang signifikan adalah model ARFIMA(1, $d,0$), ARFIMA([7], $d,0$), ARFIMA([1,7], $d,0$), ARFIMA([7], $d,1$), ARFIMA(1, $d,[7]$), ARFIMA(0, $d,1$), ARFIMA(0, $d,[7]$), dan ARFIMA(0, $d,[1,7]$). Dari model signifikan yang telah diperoleh, selanjutnya dilakukan uji diagnostik yang memberikan hasil pada Tabel 4.7 dan Tabel 4.8. Hasil uji diagnostik pada model ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ yang signifikan, memberikan hasil bahwa residual model-model tersebut dinyatakan *white noise*. Demikian juga hasil uji diagnostik pada model

ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ yang signifikan, memberikan hasil bahwa model-model tersebutdinyatakan *white noise*. Namun asumsi normalitas belum terpenuhi untuk semua model yang signifikan. Model ARFIMA masih layak digunakan untuk peramalan karena memenuhi asumsi *white noise*.

Pemilihan model terbaik ARFIMA ditentukan berdasarkan kriteria nilai *Akaike's Information Criterion* (AIC) terekecil. Nilai AIC untuk model ARFIMA bisa dilihat pada Tabel 4.9. Untuk model ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ model yang terpilih adalah diperoleh model ARFIMA(0, d , [2]) dengan nilai AIC terkecil yaitu -1384,527. Untuk model ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ model yang terpilih adalah model ARFIMA(0, d , 1) dengan nilai AIC terkecil yaitu -1385,629. Model-model terpilih tersebut selanjutnya digunakan akan digunakan untuk proses *fitting* model dan peramalan.

Model ARFIMA yang terpilih selanjutnya digunakan untuk melakukan penyesuaian (*fitting*) dengan data *in sample*. Pada penelitian ini digunakan *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) untuk menghitung nilai akurasi model. Nilai eror pada *fitting* model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ adalah RMSE 1,072906, MAE 0,8101154, dan MAPE 17,20635. Nilai eror pada *fitting* model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$ adalah RMSE 1,074054, MAE 0,8123931, dan 17,30652. Nilai MAPE pada kedua model menunjukkan kriteria tingkat kemampuan peramalan yang baik. Nilai eror pada *fitting* model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ menunjukkan eror yang lebih kecil dibanding model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$.

Selanjutnya model ARFIMA yang telah terpilih digunakan untuk peramalan dan validasi dengan data *out sample*. Nilai eror validasi peramalan model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ adalah RMSE 0,74966754, MAE 0,593468, dan MAPE 10,45511. Nilai eror pada validasi peramalan model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$ adalah RMSE 0,7898162, MAE 0,6295811, dan MAPE 10,75531. Nilai MAPE pada kedua model menunjukkan kriteria tingkat kemampuan peramalan yang baik. Nilai eror pada validasi

peramalan model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ menunjukkan eror yang lebih kecil dibanding model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$.

Dalam penelitian ini penulis juga menambahkan model lain untuk pembanding dan sebagai pelengkap dalam penelitian. Penulis menggunakan model *Autoregressive Integrated Moving Average* (ARIMA) dan metode *Extreme Learning Machine* (ELM) sebagai komparasi atau pembanding. Dalam perhitungan penulis menggunakan fungsi yang tersedia dalam program R Studio. Model ARIMA yang terpilih adalah ARIMA(1,1,1) memberikan nilai akurasi pada *fitting* model yaitu RMSE 1,069348, MAE 0,802783, dan MAPE 16,99219. Nilai akurasi *fitting* model dengan metode ELM adalah RMSE 1,121014, MAE 0,874623, dan MAPE 19,0393. Selanjutnya model digunakan untuk peramalan dan validasi dengan data *outsample*. Nilai eror validasi peramalan model ARIMA(1,1,1) adalah RMSE 0,8605522, MAE 0,7110627, dan MAPE 13,41102. Nilai eror validasi peramalan model ELM adalah RMSE 0,9197016, MAE 0,7235949, dan MAPE 11,90351.

Perbandingan tingkat akurasi *fitting* model bisa dilihat pada Tabel 4.17, memberikan hasil bahwa nilai eror dari *fitting* model ARIMA(1,1,1) yaitu RMSE 1,069348, MAE 0,802783, dan MAPE 16,99219 lebih kecil dibanding model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$, ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$, dan model ELM. Sedangkan perbandingan tingkat akurasi peramalan bisa dilihat pada Tabel 4.18, memberikan hasil bahwa nilai eror model ARFIMA(0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ yaitu RMSE 0,74966754, MAE 0,593468, dan MAPE 10,45511 lebih kecil dibanding model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$, ARIMA(1,1,1), dan model ELM.

BAB 5

SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan hasil analisis data kecepatan angin di Bandara Internasional Ahmad Yani periode data awal bulan Juni 2018 hingga akhir Oktober 2019 menggunakan model ARFIMA diperoleh kesimpulan sebagai berikut:

1. Hasil estimasi parameter d pada ARFIMA untuk data kecepatan angin di Bandara Internasional Ahmad Yani dengan metode *Geweke and Porter-Hudak* (GPH) dan *Rescaled Range Statistics* (R/S), memberikan hasil yaitu $\hat{d}_{gph} = 0,346$ dan $\hat{d}_{R/S} = 0,224$. Model ARFIMA terbaik untuk masing-masing metode estimasi sebagai berikut:
 - a. Model terbaik untuk ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$ adalah model ARFIMA(0, d , [2]) dengan nilai AIC -1384,527 yang mempunyai persamaan:

$$(1 - B)^{0,346} Z_t = (1 + 0,098B) a_t.$$

- b. Model terbaik untuk ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$ adalah model ARFIMA(0, d , 1) dengan nilai AIC -1385,629 yang mempunyai persamaan:

$$(1 - B)^{0,224} Z_t = (1 - 0,132) a_t.$$

2. Hasil dari data model *fitting* kecepatan angin di Bandara Internasional Ahmad Yani cukup mengikuti pola data aktual. Nilai eror pada *fitting* model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ menunjukkan nilai eror yang lebih kecil dibanding model ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$ yaitu RMSE 1,072906, MAE 0,8101154, dan MAPE 17,20635. Hasil peramalan menunjukkan nilai di sekitar 5 knot. Ini berarti pada periode tersebut aman untuk melakukan aktivitas penerbangan.. Nilai eror pada validasi peramalan model ARFIMA (0, d , [2]) dengan $\hat{d}_{gph} = 0,346$ adalah RMSE 0,74966754, MAE 0,593468, dan MAPE 10,45511. Nilai eror pada validasi peramalan

model ARFIMA(0, d,1) dengan $\hat{d}_{R/S} = 0,224$ adalah RMSE 0,7898162, MAE 0,6295811, dan MAPE 10,75531. Nilai MAPE pada kedua model menunjukkan kriteria tingkat kemampuan peramalan yang baik. Nilai eror pada validasi peramalan model ARFIMA (0, d,[2]) dengan $\hat{d}_{gph} = 0,346$ menunjukkan eror yang lebih kecil dibanding model ARFIMA(0, d,1) dengan $\hat{d}_{R/S} = 0,224$.

3. Hasil komparasi dengan model ARIMA dan ELM memberikan hasil bahwa, nilai eror dari *fitting* model ARIMA(1,1,1) yaitu RMSE 1,069348, MAE 0,802783, dan MAPE 16,99219 lebih kecil dibanding model ARFIMA(0, d,[2]) dengan $\hat{d}_{gph} = 0,346$, ARFIMA(0, d,1) dengan $\hat{d}_{R/S} = 0,224$, dan model ELM. Sedangkan nilai eror validasi peramalan model ARFIMA(0, d,[2]) dengan $\hat{d}_{gph} = 0,346$ yaitu RMSE 0,74966754, MAE 0,593468, dan MAPE 10,45511 lebih kecil dibanding model ARFIMA(0, d,1) dengan $\hat{d}_{R/S} = 0,224$, ARIMA(1,1,1), dan model ELM.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan dan keterbatasan-keterbatasan yang diperoleh dalam penelitian ini, maka peneliti memberikan beberapa saran sebagai berikut:

1. Pada penelitian ini residual dari model yang terpilih memenuhi asumsi *white noise*, namun residual belum memenuhi asumsi normalitas. Pada penelitian selanjutnya, lebih baik apabila melakukan pengolahan data dengan menambah metode lain yang dapat mengatasi masalah distribusi yang tidak normal pada residual.
2. Aktivitas penerbangan di Bandara Internasional Ahmad Yani untuk periode bulan Oktober 2019 bisa dikatakan aman dilakukan karena hasil peramalan nilai kecepatan angin yang dilakukan peneliti dan data aktual di lapangan menunjukkan nilai kecepatan angin yang normal untuk aktivitas penerbangan. Namun perlu dilihat juga terkait faktor-faktor lain yang mempengaruhi dalam aktivitas penerbangan, seperti .

DAFTAR PUSTAKA

- Aye, G. C. dkk. 2014. Predicting BRICS Stock Returns using ARFIMA Models. *Journal Applied Financial Economics*, 24(17): 1159 – 1166.
- Beran, J. 1994. *Statistics for Long-Memory Processes: Monographs on statistics and applied probability*. New York: Chapman & Hall.
- _____, Feng, Y., Ghos, S. dan Kulik R. 2013. *Long Memory Processe : Probabilistic Properties and Statistical Methods*. Verlag Berlin Heidelberg: Springer.
- Box, G. E. P dkk. 2016. *Time Series Analysis: Forecasting and Control (Fifth Edition)*. New Jersey: John Wiley & Sons.
- Brockwell, P. J. dan Davis, R. A. 2016. *Introduction to Time Series and Forecasting (Third Edition)*. Switzerland: Springer.
- Bousalam, I. dan Hamzaoui, M. 2017. Long Memory Forecasting of Yield Spreads Using a Fractionally Integrated ARMA Model and its Application in Islamic Capital Market. *International Journal of Bonds and Derivatives*, 3(1): 71 – 91.
- Boutahar, M. dan Khalfaoui, R. 2011. Estimation of The Long Memory Parameter in Non-Stationary Models: A Simulation Study. *GREQAM Version*: 1 –23.
- Caraka, R. E. dkk. 2016 . Model Long Memory dalam Prediksi Suhu. *Prosiding Seminar Hari Metorologi Dunia 2016*: 222–236.
- Chang, P. C., Wang Y. W. dan Liu C. H. 2007. The Development of a Weighted Evolving Fuzzy Neural Network for PCB Sales Forecasting. *Expert Systmes with Applications*, 32: 86 – 89.
- Darmawan, Gungum. 2008. Perbandingan Metode Peramalan Pada Model Arfima. *Seminar Nasional Matematika*.
- Day, B. 2018. *Pengantar Cuaca dan Iklim dalam Aktivitas Penerbangan*. Available at: <https://www.climate4life.info/2018/09/pengaruh-cuaca-dan-iklim-pada-penerbangan.html>.
- Devianto, D., Maiyastri dan Damayanti, S. 2015. Forecasting Long Memory Time Series for Stock Price with Autoregressive Fractionally Integrated Moving Average. *International Journal of Applied Mathematics and Statistics*, 53(5).

- Granger, C. W. J. dan Joyeux, R. 1980. An Introduction to Long-Memory Time Series Models and Fractional Differencing. *Journal of Time Series Analysis*, 1(1): 15 – 29.
- Geweke, J dan Porter Hudak, S. 1983. The Estimation and Application of Long Memory Time Series Models. *Journal of Time Series Analysis*, 4: 221 – 238.
- Hanke, J. E. dan Wichern, D. W. 2009. *BUSINESS FORECASTING*. 9th ed. New Jersey: Paerson.
- Hassani, H., Silva, E. S., Antonakakis, N. Fils, G. dan Gupta, R. 2017. Forecasting Accuracy Evaluation of Tourist Arrivals. *Annals of Tourism Research*: 112 – 127.
- Hosking, J. R. M. 1981. Fractional Differencing. *Biometrika* , 68(1): 165 – 176.
- Huang, G. B., Zhu, Q. Y. dan Siew, C. K. 2004. Extrme Learning Machine: A New Learning Scheme of Feedforward Neural Networks. *IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541)*, 2: 985 – 990.
- Hurst, H. E. 1951. Long-Term Storage of Reservoirs: An Experimental Study. *Transaction on the American Society Civil Engineers*, (116): 770 – 799.
- Ibrahim, L. K., Asare, B. K., Yakubu, M. dan Dauda, U. 2011. Modeling of Sokoto Daily Average Temperature: A Fractional Integrated Approach. *Nigerian Journal of Basic and Applied Science* (2011), 19(1): 21 – 30.
- Idris, S., Goejantoro, R. dan Nasution, Y. N. 2014. Pemodelan dan Peramalan Indeks Harga Perdagangan Besar (IHPB) dengan Menggunakan ARFIMA (Studi Kasus : IHPB Provinsi Kalimantan Timur bulan Januari 2002 – Desember 2006 dan Januari 2009 - September 2013). *Jurnal EKSPONENSIAL*, 5(2): 137–146.
- iNews. 2019. *Cuaca Buruk, Puluhan Penerbangan di Bandara Ahmad Yani Semarang Delay*. Available at: <https://jateng.inews.id/berita/cuaca-buruk-puluhan-penerbangan-di-bandara-ahmad-yani-semarang-delay>
- Kharisudin, I., Rosadi, D., Abdurakhman, dan Suhartono. 2012. Model Long-Memory FARIMA dan Aplikasinya Pada Pemodelan Data Asset Returns di Indonesia. *KNM XVI UNPAD*: 705 – 712.
- Koesniawanto, M. dan Kuswanto, H. 2013. Pengaruh Aggregasi terhadap Parameter Long Memory Time Series (Studi Kasus : Data Saham LQ 45). *Jurnal Sains dan Seni POMITS*, 2(1): 7 – 12.

- Mah, P. J. W., Zali, N. N. M., Ihwal, N. A M. dan Azizan, N. Z. 2018. Forecasting Fresh Water and Marine Fish Production in Malaysia using ARIMA dan ARFIMA Models. *Malaysia Journal of Computing*, 3(2): 81 – 92.
- Makridakis, S., Wheelwright, S. C. dan Mcgee, V. E. 1983. *Forecasting Methods and Applications (2nd Edition)*. New York: John Wiley & Sons.
- Mansor, K. A. dan Ishak, W. I. 2015. Forecasting Tourist Arrivals to Langkawi Island Malaysia. *Cross-Cultural Management Journal*, 17(7): 69 – 76.
- Mohamed, R. A. H. 2016. Using ARFIMA Models in Forecasting The Total Value of Traded Securities on The Arab Republic of Egypt. *IJRRAS*, 27(1): 26 – 34.
- Montgomery, D. C., Jennings, C. L. dan Kulahci, M. 2008. *Introduction to Time Series Analysis and Forecasting*. New Jersey (US): John Wiley & Sons.
- _____. 2015. *Introduction to Time Series Analysis and Forecasting (Second edition)*. New Jersey (US): John Wiley & Sons.
- Moulines, E. dan Soulier, P. 1999. Broadband Log-Periodogram Regression of Time Series with Longrange dependence. *Annals of Statistics*, 27(4): 1415 – 1439.
- Natanael, D. K., Safitri, D. dan Suparti. 2018. Prediksi Harga Minyak Dunia dengan Metode Autoregressive Fractionally Integrated Moving Average (ARFIMA). *Statistika*, 6(1): 65 – 72.
- Ningrum, L. K. dan Sulandri, W. 2009. Penerapan Model ARFIMA (Autoregressive Fractionally Integrated Moving Average) dalam Peramalan Suku Bunga Sertifikat Bank Indonesia (SBI). *Prosiding Seminar Nasional Matematika dan Pendidikan Matematika*: 582 – 590.
- Palma, Wilfredo. 2007. *Long-Memory Time Series Theory and Methods*. United States of America: John Wiley & Sons.
- Panggabean, M. P. H. 2019. Long Memory in the Indonesia Stock Exchange. *Indonesian Capital Market Review*, 10(2): 59 – 68.
- Paul, R. K. 2017. Modelling Long Memory in Maximum and Minimum Temperature Series in India. *MAUSAM*, 68(2): 317 – 326.
- Pradina, P. D., Mariani, S. dan Sugiman. 2014. Pemodelan ARFIMA Melalui $\hat{\alpha}_{HILL}$ – Stable Sebagai Penentu d dan Aplikasinya dalam Estimasi Harga Saham. *Unnes Journal of Mathematics*, 3(2).
- Prafitia, H. A. dkk. 2010. Long Memory pada Data Nilai Tukar Rupiah terhadap Dollar Amerika Serikat. *Jurnal*. Surabaya: ITS.

- Rizal, J., Nugroho, S., Irwanto, A. dan Debora. 2016. Analisis Kejadian Gempa Bumi Tektonik di wilayah Pulau Sumatera. *Jurnal Matematika*, 6(1): 1 – 14.
- Rosadi, D. 2011. *Analisis Ekonometrika & Runtun Waktu Terapan dengan R: Aplikasi untuk Bidang Ekonomi, Bisnis, dan Keuangan*. Yogyakarta: ANDI.
- R-Project. 2019. *The R Project for Statistical Computer*. Available at: <https://www.r-project.org/>.
- Safitri, D., Mustafid, Ispriyanti, D., dan Sugito. 2019. Gold Price Modeling in Indonesia using ARFIMA Method, *IOP Conf. Series: Journal of Physics: Conf Series*: 1 – 11.
- Shboul, A. M. dan Anwar, S. 2017. Long Memory Behavior in Singapore's Tourism Market. *International Journal Tourism Research*: 1 – 11.
- SULSELSATU.com. 2019. Cuaca Buruk, Tiga Pesawat Gagal Landing di Bandara Sultan Hasanuddin. Available at: <https://www.sulselsatu.com/2019/01/22/makassar/cuaca-buruk-tiga-pesawat-gagal-landing-di-bandara-sultan-hasanuddin.html>
- Tjasyono, B. 2004. *Klimatologi*. Bandung: ITB.
- Utomo, P. D., Kuswanto, H. dan Suhartono. 2012. Penerapan Model DSARFIMA untuk Peramalan beban Konsumsi Listrik Jangka Pendek di Jawa timur dan Bali. *Jurnal Sains dan Seni ITS*, 1: 242 – 247.
- Variwa, R. 2019. *Time Series Analysis*. Available at: <https://rpubs.com/Ryder/555527>.
- Walid dkk. 2015. Identification Model of Long Memory in Use Electricity Charges in Java-Bali. *International Conference on Mathematics, Science, and Education 2015 (ICMSE 2015)*: 13 – 23.
- Wirjohamidjojo, S. dan Sugarin. 2008. *Praktek Meteorologi Kelautan*. Jakarta: Badan Meteorologi dan geofisika.
- Wei, W. W. S. 2006. *Time Series Analysis Univariate and Multivariate Methods Second Edition*. New York: Pearson Addison Wesley.

LAMPIRAN

Lampiran 1

Data Kecepatan Angin di Bandara Internasional Ahmad Yani

Periode ke-	Tanggal	Wind speed (knot)
1	01/06/18	3.6
2	02/06/18	5.1
3	03/06/18	5.1
4	04/06/18	3.9
5	05/06/18	6.2
6	06/06/18	5.1
7	07/06/18	5.5
8	08/06/18	4.7
9	09/06/18	5.5
10	10/06/18	4.6
11	11/06/18	4.1
12	12/06/18	4.5
13	13/06/18	3.9
14	14/06/18	5.6
15	15/06/18	5
16	16/06/18	5.9
17	17/06/18	8.7
18	18/06/18	5.5
19	19/06/18	4
20	20/06/18	9.4
21	21/06/18	6
22	22/06/18	4.9
23	23/06/18	5
24	24/06/18	6.5
25	25/06/18	4.6
26	26/06/18	2.9
27	27/06/18	4.6
28	28/06/18	4.1
29	29/06/18	4.4
30	30/06/18	4.4
31	01/07/18	6.4
32	02/07/18	4.6
33	03/07/18	4.2
34	04/07/18	4.7

Periode ke-	Tanggal	Wind speed (knot)
35	05/07/18	4.9
36	06/07/18	4.7
37	07/07/18	4.5
38	08/07/18	5.5
39	09/07/18	4.9
40	10/07/18	4.1
41	11/07/18	4.6
42	12/07/18	5.4
43	13/07/18	4.8
44	14/07/18	4.6
45	15/07/18	4.9
46	16/07/18	4.5
47	17/07/18	6.5
48	18/07/18	6.7
49	19/07/18	6.8
50	20/07/18	5.5
51	21/07/18	4.7
52	22/07/18	5.2
53	23/07/18	4.9
54	24/07/18	5.9
55	25/07/18	5.3
56	26/07/18	5.3
57	27/07/18	5
58	28/07/18	4.4
59	29/07/18	3.8
60	30/07/18	4.8
61	31/07/18	4.9
62	01/08/18	4.8
63	02/08/18	4.1
64	03/08/18	4
65	04/08/18	3.6
66	05/08/18	3.7
67	06/08/18	4.3
68	07/08/18	5

Periode ke-	Tanggal	Wind speed (knot)	Periode ke-	Tanggal	Wind speed (knot)
69	08/08/18	7.2	106	14/09/18	4.8
70	09/08/18	6.5	107	15/09/18	5
71	10/08/18	5.4	108	16/09/18	7.1
72	11/08/18	4.9	109	17/09/18	2.4
73	12/08/18	4.4	110	18/09/18	3.3
74	13/08/18	4.7	111	19/09/18	4.6
75	14/08/18	6.1	112	20/09/18	4.9
76	15/08/18	5.4	113	21/09/18	4.8
77	16/08/18	6	114	22/09/18	5.6
78	17/08/18	4.9	115	23/09/18	6.6
79	18/08/18	5.1	116	24/09/18	1
80	19/08/18	5.7	117	25/09/18	5.6
81	20/08/18	6.7	118	26/09/18	5.2
82	21/08/18	4.9	119	27/09/18	5.3
83	22/08/18	4.9	120	28/09/18	4.8
84	23/08/18	4.3	121	29/09/18	5.5
85	24/08/18	5.5	122	30/09/18	7.1
86	25/08/18	6	123	01/10/18	4.8
87	26/08/18	5.8	124	02/10/18	6.7
88	27/08/18	5.1	125	03/10/18	5.8
89	28/08/18	6.4	126	04/10/18	6.5
90	29/08/18	4.7	127	05/10/18	5.5
91	30/08/18	5.6	128	06/10/18	5
92	31/08/18	5	129	07/10/18	6.3
93	01/09/18	6.2	130	08/10/18	6.1
94	02/09/18	4.2	131	09/10/18	5.3
95	03/09/18	4.8	132	10/10/18	5.8
96	04/09/18	5.4	133	11/10/18	5.1
97	05/09/18	3.9	134	12/10/18	5.7
98	06/09/18	7	135	13/10/18	5.9
99	07/09/18	6.6	136	14/10/18	5.3
100	08/09/18	5.3	137	15/10/18	5.6
101	09/09/18	4.7	138	16/10/18	4.7
102	10/09/18	8.1	139	17/10/18	5.3
103	11/09/18	5.3	140	18/10/18	5.3
104	12/09/18	4.6	141	19/10/18	6.8
105	13/09/18	4.9	142	20/10/18	7

Periode ke-	Tanggal	Wind speed (knot)
143	21/10/18	5.2
144	22/10/18	5.6
145	23/10/18	4.7
146	24/10/18	6.5
147	25/10/18	4.7
148	26/10/18	5.1
149	27/10/18	6
150	28/10/18	6.9
151	29/10/18	4.2
152	30/10/18	5.4
153	31/10/18	5.5
154	01/11/18	3.9
155	02/11/18	4.9
156	03/11/18	5.7
157	04/11/18	5.5
158	05/11/18	5.8
159	06/11/18	3.6
160	07/11/18	4.7
161	08/11/18	3.8
162	09/11/18	4.1
163	10/11/18	5.2
164	11/11/18	4.8
165	12/11/18	4.9
166	13/11/18	4.6
167	14/11/18	3.8
168	15/11/18	4.2
169	16/11/18	6.1
170	17/11/18	7.4
171	18/11/18	6.3
172	19/11/18	5.8
173	20/11/18	4.8
174	21/11/18	6.7
175	22/11/18	4.5
176	23/11/18	4.2
177	24/11/18	5.1
178	25/11/18	4.7
179	26/11/18	4

Periode ke-	Tanggal	Wind speed (knot)
180	27/11/18	4.8
181	28/11/18	3.5
182	29/11/18	4.3
183	30/11/18	3.5
184	01/12/18	4.2
185	02/12/18	4.1
186	03/12/18	2.3
187	04/12/18	5
188	05/12/18	3.8
189	06/12/18	4.4
190	07/12/18	5
191	08/12/18	3.5
192	09/12/18	3.9
193	10/12/18	3.6
194	11/12/18	3.8
195	12/12/18	5.5
196	13/12/18	4
197	14/12/18	3.6
198	15/12/18	5
199	16/12/18	3.3
200	17/12/18	4.3
201	18/12/18	3.6
202	19/12/18	3.8
203	20/12/18	2.4
204	21/12/18	3.7
205	22/12/18	5.5
206	23/12/18	4.2
207	24/12/18	3
208	25/12/18	3.5
209	26/12/18	3.5
210	27/12/18	4
211	28/12/18	5.1
212	29/12/18	5.2
213	30/12/18	6
214	31/12/18	5.6
215	01/01/19	5.8
216	02/01/19	4.7

Periode ke-	Tanggal	Wind speed (knot)	Periode ke-	Tanggal	Wind speed (knot)
217	03/01/19	3.6	254	09/02/19	3.9
218	04/01/19	5.3	255	10/02/19	4.3
219	05/01/19	4.7	256	11/02/19	3.7
220	06/01/19	4.7	257	12/02/19	3.5
221	07/01/19	4.2	258	13/02/19	4.3
222	08/01/19	3.4	259	14/02/19	4.3
223	09/01/19	4.6	260	15/02/19	4.1
224	10/01/19	5.2	261	16/02/19	4.3
225	11/01/19	5.7	262	17/02/19	4.3
226	12/01/19	5	263	18/02/19	4.3
227	13/01/19	3.8	264	19/02/19	4.3
228	14/01/19	6.5	265	20/02/19	4.2
229	15/01/19	5.3	266	21/02/19	4.4
230	16/01/19	4	267	22/02/19	4.7
231	17/01/19	5.6	268	23/02/19	3.9
232	18/01/19	4.9	269	24/02/19	4.5
233	19/01/19	3.6	270	25/02/19	3.9
234	20/01/19	2.6	271	26/02/19	5.2
235	21/01/19	4.6	272	27/02/19	6.8
236	22/01/19	6	273	28/02/19	3.6
237	23/01/19	5	274	01/03/19	4.3
238	24/01/19	6	275	02/03/19	6
239	25/01/19	5	276	03/03/19	2.9
240	26/01/19	8.8	277	04/03/19	4.1
241	27/01/19	6.9	278	05/03/19	4.5
242	28/01/19	5.7	279	06/03/19	4.8
243	29/01/19	4.2	280	07/03/19	2.3
244	30/01/19	7.5	281	08/03/19	3.5
245	31/01/19	3.2	282	09/03/19	3.6
246	01/02/19	4.6	283	10/03/19	3.5
247	02/02/19	4.3	284	11/03/19	4.6
248	03/02/19	4	285	12/03/19	7
249	04/02/19	3.4	286	13/03/19	7
250	05/02/19	6.2	287	14/03/19	5
251	06/02/19	4.5	288	15/03/19	4.5
252	07/02/19	5.8	289	16/03/19	3.1
253	08/02/19	3.4	290	17/03/19	3.5

Periode ke-	Tanggal	Wind speed (knot)	Periode ke-	Tanggal	Wind speed (knot)
291	18/03/19	3.6	328	24/04/19	5.5
292	19/03/19	3.9	329	25/04/19	5
293	20/03/19	4.8	330	26/04/19	4.1
294	21/03/19	5.9	331	27/04/19	5.8
295	22/03/19	7.2	332	28/04/19	5.5
296	23/03/19	3.9	333	29/04/19	4.1
297	24/03/19	2	334	30/04/19	5.3
298	25/03/19	3.3	335	01/05/19	4.1
299	26/03/19	3.7	336	02/05/19	3.9
300	27/03/19	4.2	337	03/05/19	4.3
301	28/03/19	2.8	338	04/05/19	3.7
302	29/03/19	3.8	339	05/05/19	3.9
303	30/03/19	4.4	340	06/05/19	4.4
304	31/03/19	3.4	341	07/05/19	4.9
305	01/04/19	4	342	08/05/19	5.1
306	02/04/19	3.7	343	09/05/19	5
307	03/04/19	5.3	344	10/05/19	4.4
308	04/04/19	4.2	345	11/05/19	5.6
309	05/04/19	4.9	346	12/05/19	5.2
310	06/04/19	3.8	347	13/05/19	6
311	07/04/19	4.1	348	14/05/19	6.7
312	08/04/19	4.8	349	15/05/19	6
313	09/04/19	4.1	350	16/05/19	3.5
314	10/04/19	4	351	17/05/19	3.9
315	11/04/19	3.7	352	18/05/19	4.2
316	12/04/19	3.8	353	19/05/19	4.9
317	13/04/19	3.7	354	20/05/19	6.1
318	14/04/19	5.3	355	21/05/19	5.3
319	15/04/19	3.2	356	22/05/19	5.4
320	16/04/19	3.2	357	23/05/19	5.8
321	17/04/19	4.1	358	24/05/19	6.1
322	18/04/19	5.4	359	25/05/19	5.2
323	19/04/19	6.7	360	26/05/19	4.2
324	20/04/19	6.1	361	27/05/19	6.9
325	21/04/19	7.6	362	28/05/19	8.1
326	22/04/19	7.9	363	29/05/19	7.1
327	23/04/19	6.9	364	30/05/19	4.9

Periode ke-	Tanggal	Wind speed (knot)	Periode ke-	Tanggal	Wind speed (knot)
365	31/05/19	5.6	402	07/07/19	7.7
366	01/06/19	3.8	403	08/07/19	6.9
367	02/06/19	3.5	404	09/07/19	4.9
368	03/06/19	3.1	405	10/07/19	6.1
369	04/06/19	3.9	406	11/07/19	6.5
370	05/06/19	6.1	407	12/07/19	6
371	06/06/19	7.7	408	13/07/19	4.8
372	07/06/19	6.8	409	14/07/19	6
373	08/06/19	4.7	410	15/07/19	5.1
374	09/06/19	3.2	411	16/07/19	5.3
375	10/06/19	4.3	412	17/07/19	5.6
376	11/06/19	4.7	413	18/07/19	5.9
377	12/06/19	4.4	414	19/07/19	7.6
378	13/06/19	4.5	415	20/07/19	5.9
379	14/06/19	3.3	416	21/07/19	4.5
380	15/06/19	5.3	417	22/07/19	5.1
381	16/06/19	6.1	418	23/07/19	3.9
382	17/06/19	6.8	419	24/07/19	5.6
383	18/06/19	6.2	420	25/07/19	7
384	19/06/19	3.9	421	26/07/19	4.9
385	20/06/19	3.9	422	27/07/19	4.5
386	21/06/19	6.2	423	28/07/19	5.4
387	22/06/19	5.1	424	29/07/19	5.9
388	23/06/19	5.3	425	30/07/19	6
389	24/06/19	5.2	426	31/07/19	4.9
390	25/06/19	6.8	427	01/08/19	6.1
391	26/06/19	5.9	428	02/08/19	5.9
392	27/06/19	3.9	429	03/08/19	6.9
393	28/06/19	4.2	430	04/08/19	4.2
394	29/06/19	5	431	05/08/19	4
395	30/06/19	5.4	432	06/08/19	6.5
396	01/07/19	5.7	433	07/08/19	5.5
397	02/07/19	5.6	434	08/08/19	5.1
398	03/07/19	6.2	435	09/08/19	6.6
399	04/07/19	6.3	436	10/08/19	6.3
400	05/07/19	6.9	437	11/08/19	6.2
401	06/07/19	6.9	438	12/08/19	8.7

Periode ke-	Tanggal	Wind speed (knot)
439	13/08/19	8.7
440	14/08/19	7
441	15/08/19	6.6
442	16/08/19	6.3
443	17/08/19	5.6
444	18/08/19	4.5
445	19/08/19	4.2
446	20/08/19	6.1
447	21/08/19	8.9
448	22/08/19	5.3
449	23/08/19	4.9
450	24/08/19	4.9
451	25/08/19	4.7
452	26/08/19	5.8
453	27/08/19	5.5
454	28/08/19	7.5
455	29/08/19	6.2
456	30/08/19	6.7
457	31/08/19	7.7
458	01/09/19	5.8
459	02/09/19	6.5
460	03/09/19	6.4
461	04/09/19	6.1
462	05/09/19	5.3
463	06/09/19	5.1
464	07/09/19	5.9
465	08/09/19	5.4
466	09/09/19	7.4
467	10/09/19	7.8
468	11/09/19	6
469	12/09/19	5.4
470	13/09/19	6.2
471	14/09/19	6.6
472	15/09/19	7.3
473	16/09/19	7.9
474	17/09/19	7.5
475	18/09/19	5.3

Periode ke-	Tanggal	Wind speed (knot)
476	19/09/19	5.8
477	20/09/19	6.2
478	21/09/19	5.5
479	22/09/19	5.6
480	23/09/19	7.9
481	24/09/19	7.1
482	25/09/19	6.1
483	26/09/19	6
484	27/09/19	7
485	28/09/19	5.4
486	29/09/19	6.3
487	30/09/19	5.9
488	01/10/19	5.3
489	02/10/19	5.7
490	03/10/19	6.1
491	04/10/19	5.8
492	05/10/19	5
493	06/10/19	5.1
494	07/10/19	5
495	08/10/19	6.6
496	09/10/19	6
497	10/10/19	6
498	11/10/19	6.2
499	12/10/19	5.4
500	13/10/19	4.2
501	14/10/19	4.6
502	15/10/19	6.5
503	16/10/19	5.9
504	17/10/19	5.8
505	18/10/19	5.7
506	19/10/19	5.8
507	20/10/19	6.4
508	21/10/19	7.4
509	22/10/19	4.8
510	23/10/19	5
511	24/10/19	6.9
512	25/10/19	5.1

Periode ke-	Tanggal	Wind speed (knot)
513	26/10/19	5.4
514	27/10/19	5.6
515	28/10/19	5

Periode ke-	Tanggal	Wind speed (knot)
516	29/10/19	6
517	30/10/19	7.1
518	31/10/19	5.8

Lampiran 2

Script Program R Studio Model ARFIMA

1. Package Library yang Digunakan

```
library(arfima)
library(forecast)
library(fracdiff)
library(pracma)
library(tseries)
library(TSA)
library(nortest)
```

2. Import Data

```
inAY = read.csv("E:/FILE SKRIPSI/AHYANI_INSAMPLE.csv")
outAY = read.csv("E:/FILE SKRIPSI/AHYANI_OUTSAMPLE.csv", header =
TRUE)
inAY = ts(inAY)
outAY = ts(outAY)
```

3. Uji Hurst

```
hurstexp(inAY)
Simple R/S Hurst estimation: 0.7241278
Corrected R over S Hurst exponent: 0.901847
Empirical Hurst exponent: 0.9589336
Corrected empirical Hurst exponent: 0.9094449
Theoretical Hurst exponent: 0.5465102
```

4. Import Data Hasil Transformasi

```
trans.inAY = read.csv("E:/FILE SKRIPSI/AHYANI_TRANS.csv")
trans.inAY = ts(trans.inAY)
```

5. Estimasi Parameter d dengan GPH

```
fdGPH(inAY, bandw.exp)
$d
[1] 0.3462528

$sd.as
[1] 0.1703889

$sd.reg
[1] 0.1417428
```

6. Differencing Data In Sample dengan $\hat{d}_{gph} = 0,346$ dan $\hat{d}_{R/S} = 0,224$

```
#diff data trans.inAY dengan d GPH
dgph = diffseries(trans.inAY, 0.346)
acf(dx, lag.max = 20)
```

```

pacf(dx, lag.max = 20)
#diff data trans.inAY dengan d R/S
drs = diffseries(insample, 0.224)
acf(dy, lag.max = 20)
pacf(dy, lag.max = 20)

```

7. Estimasi Model Tentatif ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,203$

a. ARFIMA ([2], $d, 0$)

```

Call:
arfima::arfima(z = trans.inAY, order = c(2, 0, 0), dmean = FALSE,
fixed = list(phi = c(0,
NA), frac = 0.346))

```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0	
phi(2)	-0.0934007	0.045118
d.f	0.346	
zbar	2.24769	
logl	697.159	
sigma^2	0.0573099	
phi_p(1)	0	
phi_p(2)	-0.0934007	

Call:

b. ARFIMA([5], $d, 0$)

```

Call:
arfima::arfima(z = trans.inAY, order = c(5, 0, 0), dmean = FALSE,
fixed = list(phi = c(0,
0, 0, 0, NA), frac = 0.346))

```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0	
phi(2)	0	
phi(3)	0	
phi(4)	0	
phi(5)	-0.089824	0.0452034
d.f	0.346	
zbar	2.24769	
logl	696.992	
sigma^2	0.057704	
phi_p(1)	0	
phi_p(2)	0	
phi_p(3)	0	
phi_p(4)	0	
phi_p(5)	-0.089824	

c. ARFIMA ([2,5], d,0)

```
Call:
arfima::arfima(z = trans.inAY, order = c(5, 0, 0), dmean = FALSE,
fixed = list(phi = c(0,
NA, 0, 0, NA), frac = 0.346))

Coefficients for fits:
            Coef.1:      SE.1:
phi(1)      0
phi(2)    -0.0952582   0.0449364
phi(3)      0
phi(4)      0
phi(5)    -0.0917632   0.0450082
d.f        0.346
zbar       2.24769
logl      699.229
sigma^2     0.0571809
phi_p(1)   -0.000772702
phi_p(2)   -0.0960746
phi_p(3)    0.00881543
phi_p(4)      0
phi_p(5)   -0.0917632
```

d. ARFIMA (0, d,[2])

```
Call:
arfima::arfima(z = trans.inAY, order = c(0, 0, 2), dmean = FALSE,
fixed = list(theta = c(0,
NA), frac = 0.346))

Coefficients for fits:
            Coef.1:      SE.1:
theta(1)      0
theta(2)    0.0983603   0.0463618
d.f        0.346
zbar       2.24769
logl      697.264
sigma^2     0.0572863
theta_p(1)    0
theta_p(2)   0.0983603
```

e. ARFIMA ([2], d,[2])

```
Call:
arfima::arfima(z = trans.inAY, order = c(2, 0, 2), dmean = FALSE,
fixed = list(phi = c(0,
NA), theta = c(0, NA), frac = 0.346))

Coefficients for fits:
            Coef.1:      SE.1:
phi(1)      0
phi(2)    0.430229   0.380645
theta(1)      0
theta(2)   0.523113   0.359814
```

d.f	0.346
zbar	2.24769
logl	697.595
sigma^2	0.0574507
phi_p(1)	0
phi_p(2)	0.430229
theta_p(1)	0
theta_p(2)	0.523113

f. ARFIMA([5], d,[2])

Call:
`arfima::arfima(z = trans.inAY, order = c(5, 0, 2), dmean = FALSE,
fixed = list(phi = c(0,
0, 0, 0, NA), theta = c(0, NA), frac = 0.346))`

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0	
phi(2)	0	
phi(3)	0	
phi(4)	0	
phi(5)	-0.0851604	0.0452922
theta(1)	0	
theta(2)	0.0938714	0.0464592
d.f	0.346	
zbar	2.24769	
logl	699.025	
sigma^2	0.0574693	
phi_p(1)	0	
phi_p(2)	0	
phi_p(3)	0	
phi_p(4)	0	
phi_p(5)	-0.0851604	
theta_p(1)	0	
theta_p(2)	0.0938714	

g. ARFIMA ([2,5], d,[2])

Call:
`arfima::arfima(z = trans.inAY, order = c(5, 0, 2), dmean = FALSE,
fixed = list(phi = c(0,
NA, 0, 0, NA), theta = c(0, NA), frac = 0.346))`

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0	
phi(2)	-0.370008	0.263203
phi(3)	0	
phi(4)	0	
phi(5)	-0.0990944	0.0421391
theta(1)	0	
theta(2)	-0.290859	0.280553
d.f	0.346	
zbar	2.24769	
logl	699.613	

```

sigma^2      0.0573238
phi_p(1)    -0.010083
phi_p(2)    -0.37419
phi_p(3)     0.0370293
phi_p(4)      0
phi_p(5)   -0.0990944
theta_p(1)      0
theta_p(2)  -0.290859

```

8. Estimasi Model Tentatif ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$

a. ARFIMA (1, d,0)

```

Call:
arfima::arfima(z = trans.inAY, order = c(1, 0, 0), dmean = FALSE,
fixed = list(frac = 0.224))

Coefficients for fits:
  Coef.1:    SE.1:
phi(1)    0.123184  0.0450033
d.f       0.224
zbar      2.24769
logl     696.554
sigma^2   0.05741

```

b. ARFIMA ([7], d ,0)

```

Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 0), dmean = FALSE,
fixed = list(phi = c(0,
0, 0, 0, 0, 0, NA), frac = 0.224))

Coefficients for fits:
  Coef.1:    SE.1:
phi(1)    0
phi(2)    0
phi(3)    0
phi(4)    0
phi(5)    0
phi(6)    0
phi(7)   0.0997118  0.0450821
d.f       0.224
zbar      2.24769
logl     695.269
sigma^2   0.0584313
phi_p(1)   0
phi_p(2)   0
phi_p(3)   0
phi_p(4)   0
phi_p(5)   0
phi_p(6)   0
phi_p(7)   0.0997118

```

c. ARFIMA ([1,7], d,0)

```
Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 0), dmean = FALSE,
fixed = list(phi = c(NA,
0, 0, 0, 0, 0, NA), frac = 0.224))
```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0.124374	0.0447584
phi(2)	0	
phi(3)	0	
phi(4)	0	
phi(5)	0	
phi(6)	0	
phi(7)	0.101195	0.0447223
d.f	0.224	
zbar	2.24769	
logl	699.099	
sigma^2	0.0575094	
phi_p(1)	0.125682	
phi_p(2)	3.17279e-06	
phi_p(3)	2.52447e-05	
phi_p(4)	0.000200862	
phi_p(5)	0.00159819	
phi_p(6)	0.0127162	
phi_p(7)	0.101195	

d. ARFIMA (1, d,1)

```
Call:
arfima::arfima(z = trans.inAY, order = c(1, 0, 1), dmean = FALSE,
fixed = list(frac = 0.224))
```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	-0.190523	0.300079
theta(1)	-0.319466	0.289159
d.f	0.224	
zbar	2.24769	
logl	696.993	
sigma^2	0.057426	

e. ARFIMA ([7], d ,1)

```
Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 1), dmean = FALSE,
fixed = list(phi = c(0,
0, 0, 0, 0, 0, NA), frac = 0.224))
```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0	
phi(2)	0	
phi(3)	0	
phi(4)	0	

```

phi(5)      0
phi(6)      0
phi(7)      0.101251   0.0451026
theta(1)    -0.132489   0.0459829
d.f         0.224
zbar        2.24769
logl        699.32
sigma^2     0.0575785
phi_p(1)    0
phi_p(2)    0
phi_p(3)    0
phi_p(4)    0
phi_p(5)    0
phi_p(6)    0
phi_p(7)    0.101251

```

f. ARFIMA ([1,7], d,1)

```

Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 1), dmean = FALSE,
fixed = list(phi = c(NA,
0, 0, 0, 0, 0, NA), frac = 0.224))

```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	-0.0803412	0.25999
phi(2)	0	
phi(3)	0	
phi(4)	0	
phi(5)	0	
phi(6)	0	
phi(7)	0.0995466	0.045646
theta(1)	-0.212298	0.25867
d.f	0.224	
zbar	2.24769	
logl	699.365	
sigma^2	0.0575691	
phi_p(1)	-0.0811506	
phi_p(2)	-3.50313e-07	
phi_p(3)	4.31683e-06	
phi_p(4)	-5.31953e-05	
phi_p(5)	0.000655513	
phi_p(6)	-0.00807774	
phi_p(7)	0.0995466	

g. ARFIMA (1, d,[7])

```

Call:
arfima::arfima(z = trans.inAY, order = c(1, 0, 7), dmean = FALSE,
fixed = list(theta = c(0,
0, 0, 0, 0, 0, NA), frac = 0.224))

```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0.125755	0.0450129

```

theta(1)      0
theta(2)      0
theta(3)      0
theta(4)      0
theta(5)      0
theta(6)      0
theta(7)      -0.096793   0.0435871
d.f          0.224
zbar         2.24769
logl         698.971
sigma^2       0.0576624
theta_p(1)    0
theta_p(2)    0
theta_p(3)    0
theta_p(4)    0
theta_p(5)    0
theta_p(6)    0
theta_p(7)    -0.096793

```

h. ARFIMA ([7], d ,[7])

```

Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 7), dmean = FALSE,
fixed = list(phi = c(0,
          0, 0, 0, 0, NA), theta = c(0, 0, 0, 0, 0, 0, NA), frac = 0
.224))

Coefficients for fits:
            Coef.1:      SE.1:
phi(1)      0
phi(2)      0
phi(3)      0
phi(4)      0
phi(5)      0
phi(6)      0
phi(7)      0.342958   0.412195
theta(1)    0
theta(2)    0
theta(3)    0
theta(4)    0
theta(5)    0
theta(6)    0
theta(7)    0.245364   0.425385
d.f          0.224
zbar         2.24769
logl         695.447
sigma^2       0.0592515
phi_p(1)    0
phi_p(2)    0
phi_p(3)    0
phi_p(4)    0
phi_p(5)    0
phi_p(6)    0
phi_p(7)    0.342958
theta_p(1)  0
theta_p(2)  0

```

```

theta_p(3)    0
theta_p(4)    0
theta_p(5)    0
theta_p(6)    0
theta_p(7)    0.245364

```

i. ARFIMA ([1,7], d , [7])

```

Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 7), dmean = FALSE,
fixed = list(phi = c(NA,
0, 0, 0, 0, 0, NA), theta = c(0, 0, 0, 0, 0, 0, NA), frac = 0
.224))

```

Coefficients for fits:

	Coef.1:	SE.1:
phi(1)	0.118334	0.0461896
phi(2)	0	
phi(3)	0	
phi(4)	0	
phi(5)	0	
phi(6)	0	
phi(7)	0.293763	0.394335
theta(1)	0	
theta(2)	0	
theta(3)	0	
theta(4)	0	
theta(5)	0	
theta(6)	0	
theta(7)	0.197127	0.411057
d.f	0.224	
zbar	2.24769	
logl	699.203	
sigma^2	0.058333	
phi_p(1)	0.129703	
phi_p(2)	1.07664e-05	
phi_p(3)	8.30088e-05	
phi_p(4)	0.00064	
phi_p(5)	0.00493442	
phi_p(6)	0.0380454	
phi_p(7)	0.293763	
theta_p(1)	0	
theta_p(2)	0	
theta_p(3)	0	
theta_p(4)	0	
theta_p(5)	0	
theta_p(6)	0	
theta_p(7)	0.197127	

j. ARFIMA (1, d , [1,7])

```

Call:
arfima::arfima(z = trans.inAY, order = c(1, 0, 7), dmean = FALSE,
fixed = list(theta = c(NA,
0, 0, 0, 0, 0, NA), frac = 0.224))

```

```

Coefficients for fits:
            Coef.1:      SE.1:
phi(1)      -0.0808644    0.243206
theta(1)     -0.212401    0.238504
theta(2)      0
theta(3)      0
theta(4)      0
theta(5)      0
theta(6)      0
theta(7)     -0.0967488    0.0445636
d.f          0.224
zbar         2.24769
logl        699.284
sigma^2      0.0575894
theta_p(1)   -0.214514
theta_p(2)   4.39164e-05
theta_p(3)   -0.000204734
theta_p(4)   0.000954448
theta_p(5)   -0.00444954
theta_p(6)   0.0207437
theta_p(7)   -0.0967488

```

k. ARFIMA ([7], d ,[1,7])

```

Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 7), dmean = FALSE,
fixed = list(phi = c(0,
0, 0, 0, 0, 0, NA), theta = c(NA, 0, 0, 0, 0, 0, NA), frac =
0.224))

```

```

Coefficients for fits:
            Coef.1:      SE.1:
phi(1)      0
phi(2)      0
phi(3)      0
phi(4)      0
phi(5)      0
phi(6)      0
phi(7)     0.25303    0.576476
theta(1)   -0.12899    0.0485815
theta(2)      0
theta(3)      0
theta(4)      0
theta(5)      0
theta(6)      0
theta(7)     0.15557    0.59988
d.f          0.224
zbar         2.24769
logl        699.362
sigma^2      0.0582982
phi_p(1)     0
phi_p(2)     0
phi_p(3)     0
phi_p(4)     0
phi_p(5)     0
phi_p(6)     0

```

```

phi_p(7)      0.25303
theta_p(1)    -0.132245
theta_p(2)    -6.29006e-06
theta_p(3)    4.75632e-05
theta_p(4)    -0.000359656
theta_p(5)    0.00271959
theta_p(6)    -0.0205647
theta_p(7)    0.15557

```

1. ARFIMA ([1,7], d,[1,7])

```

Call:
arfima::arfima(z = trans.inAY, order = c(7, 0, 7), dmean = FALSE,
fixed = list(phi = c(0,
0, 0, 0, 0, NA), theta = c(NA, 0, 0, 0, 0, 0, NA), frac =
0.224))

Coefficients for fits:
          Coef.1:      SE.1:
phi(1)      0
phi(2)      0
phi(3)      0
phi(4)      0
phi(5)      0
phi(6)      0
phi(7)      0.25303     0.576476
theta(1)    -0.12899     0.0485815
theta(2)      0
theta(3)      0
theta(4)      0
theta(5)      0
theta(6)      0
theta(7)      0.15557     0.59988
d.f         0.224
zbar        2.24769
logl       699.362
sigma^2     0.0582982
phi_p(1)    0
phi_p(2)    0
phi_p(3)    0
phi_p(4)    0
phi_p(5)    0
phi_p(6)    0
phi_p(7)    0.25303
theta_p(1)  -0.132245
theta_p(2)  -6.29006e-06
theta_p(3)  4.75632e-05
theta_p(4)  -0.000359656
theta_p(5)  0.00271959
theta_p(6)  -0.0205647
theta_p(7)  0.15557

```

m. ARFIMA (0, d,1)

```
Call:
arfima::arfima(z = trans.inAY, order = c(0, 0, 1), dmean = FALSE,
fixed = list(frac = 0.224))

Coefficients for fits:
            Coef.1:      SE.1:
theta(1)   -0.132071    0.0462977
d.f        0.224
zbar       2.24769
logl       696.815
sigma^2    0.0573486
```

n. ARFIMA (0, d ,[7])

```
Call:
arfima::arfima(z = trans.inAY, order = c(0, 0, 7), dmean = FALSE,
fixed = list(theta = c(0,
          0, 0, 0, 0, NA), frac = 0.224))

Coefficients for fits:
            Coef.1:      SE.1:
theta(1)     0
theta(2)     0
theta(3)     0
theta(4)     0
theta(5)     0
theta(6)     0
theta(7)   -0.0926314    0.0431567
d.f        0.224
zbar       2.24769
logl       695.1
sigma^2    0.058474
theta_p(1)   0
theta_p(2)   0
theta_p(3)   0
theta_p(4)   0
theta_p(5)   0
theta_p(6)   0
theta_p(7)   -0.0926314
```

o. ARFIMA (0, d ,[1,7])

```
Call:
arfima::arfima(z = trans.inAY, order = c(0, 0, 7), dmean = FALSE,
fixed = list(theta = c(NA,
          0, 0, 0, 0, 0, NA), frac = 0.224))

Coefficients for fits:
            Coef.1:      SE.1:
theta(1)   -0.13333    0.0456737
theta(2)     0
theta(3)     0
theta(4)     0
theta(5)     0
```

```

theta(6)      0
theta(7)    -0.0981099    0.0441133
d.f         0.224
zbar        2.24769
logl       699.232
sigma^2     0.0574807
theta_p(1)   -0.134651
theta_p(2)   4.3418e-06
theta_p(3)   -3.2245e-05
theta_p(4)   0.000239472
theta_p(5)   -0.00177848
theta_p(6)   0.0132082
theta_p(7)   -0.0981099

```

9. Uji Diagnostik Model Signifikan ARFIMA(p, d, q) dengan $\hat{d}_{gph} = 0,346$

a. ARFIMA ([2], $d, 0$)

Box-Ljung test

```

data: residual1x
X-squared = 14.172, df = 20, p-value = 0.8216

Lilliefors (Kolmogorov-Smirnov) normality test

data: residual1x
D = 0.046695, p-value = 0.01301

```

b. ARFIMA ([5], $d, 0$)

Box-Ljung test

```

data: residual2x
X-squared = 15.588, df = 20, p-value = 0.7418

Lilliefors (Kolmogorov-Smirnov) normality test

data: residual2x
D = 0.041013, p-value = 0.0487

```

c. ARFIMA ([2,5], $d, 0$)

Box-Ljung test

```

data: residual3x
X-squared = 11.112, df = 20, p-value = 0.9433

Lilliefors (Kolmogorov-Smirnov) normality test

data: residual3x
D = 0.041348, p-value = 0.04533

```

d. ARFIMA ([2,5], d,0)

Box-Ljung test

```
data: residual4x
X-squared = 13.836, df = 20, p-value = 0.8387
```

Lilliefors (Kolmogorov-Smirnov) normality test

```
data: residual4x
D = 0.044398, p-value = 0.02278
```

10. Uji Diagnostik Model Signifikan ARFIMA(p, d, q) dengan $\hat{d}_{R/S} = 0,224$

a. ARFIMA (1, d,0)

Box-Ljung test

```
data: residual1y
X-squared = 15.968, df = 20, p-value = 0.7186
```

Lilliefors (Kolmogorov-Smirnov) normality test

```
data: residual1y
D = 0.043737, p-value = 0.02658
```

b. ARFIMA ([7], d ,0)

Box-Ljung test

```
data: residual2y
X-squared = 18.115, df = 20, p-value = 0.5798
```

Lilliefors (Kolmogorov-Smirnov) normality test

```
data: residual2y
D = 0.047773, p-value = 0.009879
```

c. ARFIMA ([1,7], d,0)

Box-Ljung test

```
data: residual3y
X-squared = 10.227, df = 20, p-value = 0.9639
```

Lilliefors (Kolmogorov-Smirnov) normality test

```
data: residual3y
D = 0.04345, p-value = 0.0284
```

d. ARFIMA ([7], d ,1)

Box-Ljung test

```
data: residual5y
```

```

X-squared = 9.5625, df = 20, p-value = 0.9754
Lilliefors (Kolmogorov-Smirnov) normality test
data: residual5y
D = 0.04574, p-value = 0.01649

e. ARFIMA (1, d,[7])
    Box-Ljung test
    data: residual7y
    X-squared = 10.458, df = 20, p-value = 0.9591
    Lilliefors (Kolmogorov-Smirnov) normality test
    data: residual7y
    D = 0.043672, p-value = 0.02698

f. ARFIMA (0, d,1)
    Box-Ljung test
    data: residual13y
    X-squared = 15.216, df = 20, p-value = 0.7639
    Lilliefors (Kolmogorov-Smirnov) normality test
    data: residual13y
    D = 0.0419, p-value = 0.0402

g. ARFIMA (0, d ,[7])
    Box-Ljung test
    data: residual14y
    X-squared = 18.654, df = 20, p-value = 0.5444
    Lilliefors (Kolmogorov-Smirnov) normality test
    data: residual14y
    D = 0.047259, p-value = 0.01127

h. ARFIMA (0, d ,[1,7])
    Box-Ljung test
    data: residual15y
    X-squared = 9.6974, df = 20, p-value = 0.9733
    Lilliefors (Kolmogorov-Smirnov) normality test
    data: residual15y
    D = 0.044398, p-value = 0.02277

```

11. Nilai AIC

```
#Nilai AIC (d GPH)
cbind(AIC(modelarfima1x), AIC(modelarfima2x), AIC(modelarfima3x),
AIC(modelarfima4x))
[,1]      [,2]      [,3]      [,4]
[1,] -1384.319 -1377.984 -1382.458 -1384.527

#Nilai AIC (d R/S)
cbind(AIC(modelarfima1y), AIC(modelarfima2y), AIC(modelarfima3y), AIC(modelarfima5y), AIC(modelarfima7y), AIC(modelarfima13y), AIC(modelarfima14y), AIC(modelarfima15y))
[,1]      [,2]      [,3]      [,4]      [,5]
[1,] -1385.107 -1370.539 -1378.198 -1376.641 -1375.941
[,6]      [,7]      [,8]
[1,] -1385.629 -1370.2 -1378.464
```

12. Peramalan

a. Dengan model yang terpilih yaitu ARFIMA(0, d, [2]) dengan $\hat{d}_{gph} = 0,346$

```
$`Mode 1`
$`Mode 1`$`Forecasts and SDs`  

          1      2      3      4  

Forecasts 2.418222 2.423100 2.415842 2.410636  

Exact SD   0.239375 0.253318 0.255365 0.257825  

Limiting SD 0.239346 0.253267 0.255305 0.257753  

          5      6      7      8  

Forecasts 2.405970 2.401715 2.397804 2.394189  

Exact SD   0.259691 0.261144 0.262315 0.263286  

Limiting SD 0.259607 0.261050 0.262211 0.263173  

          9      10     11     12  

Forecasts 2.390830 2.387694 2.384755 2.381990  

Exact SD   0.264110 0.264822 0.265446 0.265999  

Limiting SD 0.263988 0.264691 0.265306 0.265851  

          13     14     15     16  

Forecasts 2.379382 2.376914 2.374573 2.372348  

Exact SD   0.266495 0.266943 0.267351 0.267724  

Limiting SD 0.266339 0.266779 0.267179 0.267545  

          17     18     19     20  

Forecasts 2.370228 2.368205 2.366271 2.364419  

Exact SD   0.268069 0.268387 0.268683 0.268960  

Limiting SD 0.267882 0.268194 0.268483 0.268753  

          21     22     23     24  

Forecasts 2.362642 2.360937 2.359296 2.357718  

Exact SD   0.269219 0.269462 0.269692 0.269908  

Limiting SD 0.269005 0.269242 0.269465 0.269675  

          25     26     27     28  

Forecasts 2.356196 2.354728 2.353311 2.351941  

Exact SD   0.270114 0.270309 0.270494 0.270671  

Limiting SD 0.269874 0.270063 0.270243 0.270413  

          29     30     31
Forecasts 2.350616 2.349334 2.348091
```

```
Exact SD      0.270839 0.271000 0.271155
Limiting SD  0.270576 0.270732 0.270880
```

b. Dengan model yang terpilih yaitu ARFIMA(0, d, 1) dengan $\hat{d}_{R/S} = 0,224$

```
$`Mode 1`  
$`Mode 1`$`Forecasts and SDs`  
      1      2      3      4  
Forecasts 2.397596 2.385548 2.377023 2.370273  
Exact SD   0.239488 0.254225 0.257345 0.258942  
Limiting SD 0.239476 0.254204 0.257318 0.258911  
      5      6      7      8  
Forecasts 2.364638 2.359784 2.35551 2.351704  
Exact SD   0.259950 0.260658 0.26119 0.261608  
Limiting SD 0.259916 0.260621 0.26115 0.261566  
      9     10     11     12  
Forecasts 2.348262 2.345125 2.342246 2.339587  
Exact SD   0.261947 0.262229 0.262469 0.262675  
Limiting SD 0.261902 0.262182 0.262420 0.262625  
      13    14    15    16  
Forecasts 2.337118 2.334816 2.332660 2.330636  
Exact SD   0.262856 0.263015 0.263157 0.263285  
Limiting SD 0.262803 0.262961 0.263101 0.263227  
      17    18    19    20  
Forecasts 2.328728 2.326926 2.325218 2.323598  
Exact SD   0.263400 0.263505 0.263602 0.263690  
Limiting SD 0.263341 0.263445 0.263540 0.263627  
      21    22    23    24  
Forecasts 2.322057 2.320588 2.319187 2.317847  
Exact SD   0.263772 0.263848 0.263918 0.263984  
Limiting SD 0.263707 0.263782 0.263851 0.263916  
      25    26    27    28  
Forecasts 2.316564 2.315334 2.314154 2.313020  
Exact SD   0.264046 0.264104 0.264159 0.264210  
Limiting SD 0.263977 0.264033 0.264087 0.264137  
      29    30    31  
Forecasts 2.311929 2.310878 2.309866  
Exact SD   0.264259 0.264305 0.264349  
Limiting SD 0.264185 0.264230 0.264273
```

13. Akurasi Peramalan dengan data Outsample

a. Akurasi peramalan ARFIMA(0, d, [2]) dengan $\hat{d}_{gph} = 0,346$

	ME	RMSE	MAE	MPE
Test set	0.06507099	0.7496675	0.593468	-0.4939136
	MAPE	ACF1	Theil's U	
Test set	10.45511	0.1299475	0.7983728	

b. Akurasi peramalan ARFIMA(0, d, 1) dengan $\hat{d}_{R/S} = 0,224$

	ME	RMSE	MAE	MPE
Test set	0.2538115	0.7898162	0.6295811	2.861129
	MAPE	ACF1	Theil's U	
Test set	10.75531	0.1273712	0.8348473	

Lampiran 3

Data Fitting Model ARFIMA

Hasil data *fitting* dari model kecepatan angin di Bandara Internasional

Ahmad Yani menggunakan model ARFIMA terpilih yaitu ARFIMA(0, d , [2]).

dengan $\hat{d}_{gph} = 0,346$ dan ARFIMA(0, d , 1) dengan $\hat{d}_{R/S} = 0,224$.

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
1	3.6	4.802468224	4.893349255	32	4.6	5.347684609	5.411248979
2	5.1	4.355161681	4.430952725	33	4.2	4.759308946	4.858337821
3	5.1	4.886021068	4.942632469	34	4.7	4.763322934	4.721535078
4	3.9	4.791396267	4.942842572	35	4.9	4.845717415	4.860617472
5	6.2	4.477621213	4.540749765	36	4.7	4.876991195	4.920732392
6	5.1	5.289878242	5.329302188	37	4.5	4.819386212	4.858011221
7	5.5	4.872579399	5.001581328	38	5.5	4.760925719	4.784585474
8	4.7	5.176668513	5.177841261	39	4.9	5.090736682	5.126038583
9	5.5	4.868985483	4.907877328	40	4.1	4.877252689	4.941889917
10	4.6	5.191216315	5.182009792	41	4.6	4.663092331	4.660034639
11	4.1	4.824804453	4.868534957	42	5.4	4.807444244	4.808468074
12	4.5	4.688348137	4.669725772	43	4.8	5.015313052	5.073925653
13	3.9	4.753184426	4.770680381	44	4.6	4.834591528	4.893438232
14	5.6	4.477856459	4.524980314	45	4.9	4.821317793	4.830140957
15	5	5.062581177	5.106158111	46	4.5	4.89770923	4.922999728
16	5.9	4.814415649	4.931325109	47	6.5	4.745814936	4.779289821
17	8.7	5.253946216	5.279625378	48	6.7	5.427234375	5.459954578
18	5.5	6.118680559	6.212181006	49	6.8	5.484791137	5.589616029
19	4	5.260991704	5.324859936	50	5.5	5.701749856	5.713288174
20	9.4	4.956990842	4.804644198	51	4.7	5.36408484	5.336716182
21	6	6.581856918	6.509590606	52	5.2	5.148821136	5.048757719
22	4.9	5.451969523	5.552652781	53	4.9	5.255162436	5.179644198
23	5	5.415581488	5.224377998	54	5.9	5.075644976	5.050506983
24	6.5	5.306924454	5.19553683	55	5.3	5.417355087	5.3866108
25	4.6	5.738014191	5.669219711	56	5.3	5.187751832	5.200435
26	2.9	5.049967117	5.031153856	57	5	5.257674241	5.211324939
27	4.6	4.452282948	4.324555033	58	4.4	5.12290778	5.097767273
28	4.1	4.952078907	4.870014147	59	3.8	4.905700406	4.863999589
29	4.4	4.573796945	4.640272993	60	4.8	4.639660714	4.596123074
30	4.4	4.731812394	4.740026493	61	4.9	4.92476856	4.908894187
31	6.4	4.667954706	4.724438701	62	4.8	4.873626595	4.932347939

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
63	4.1	4.882176561	4.910960165	100	5.3	5.513257477	5.630001355
64	4	4.634709121	4.65367982	101	4.7	5.321610169	5.275068827
65	3.6	4.585693503	4.584878448	102	8.1	5.134872517	5.052618019
66	3.7	4.363621061	4.391140327	103	5.3	6.19138397	6.147005024
67	4.3	4.353079713	4.385635712	104	4.6	5.262986036	5.310666068
68	5	4.497916208	4.575340725	105	4.9	5.23553777	5.075085339
69	7.2	4.717138646	4.827624853	106	4.8	5.19531388	5.117010777
70	6.5	5.458109931	5.59377351	107	5	5.08992066	5.044469617
71	5.4	5.34998735	5.490321598	108	7.1	5.129726403	5.095519255
72	4.9	5.215876414	5.210775727	109	2.4	5.786710464	5.795179894
73	4.4	5.083878226	5.039104209	110	3.3	4.099839825	4.10435975
74	4.7	4.87202255	4.828701602	111	4.6	4.579191158	4.389855143
75	6.1	4.928385796	4.898247154	112	4.9	4.695590527	4.764917814
76	5.4	5.334877992	5.362099467	113	4.8	4.793150147	4.878638339
77	6	5.117157775	5.170222663	114	5.6	4.80543019	4.874861923
78	4.9	5.423518635	5.40528119	115	6.6	5.116918296	5.170935091
79	5.1	5.044061015	5.047777551	116	1	5.461575564	5.542578782
80	5.7	5.171272234	5.110308449	117	5.6	3.297577239	3.284876797
81	6.7	5.30625522	5.30187687	118	5.2	5.262102563	5.06924465
82	4.9	5.645289976	5.656943522	119	5.3	4.620168475	4.898049614
83	4.9	5.102481635	5.098926053	120	4.8	4.988681629	5.027050374
84	4.3	5.186480787	5.088046871	121	5.5	4.809540845	4.884333849
85	5.5	4.865300425	4.827268876	122	7.1	5.117789335	5.139334896
86	6	5.257525974	5.216630625	123	4.8	5.618346029	5.693532213
87	5.8	5.350025181	5.393737176	124	6.7	4.961509334	5.005607636
88	5.1	5.368107444	5.373509384	125	5.8	5.736536855	5.661380238
89	6.4	5.187868412	5.157350784	126	6.5	5.350438593	5.392975424
90	4.7	5.639241671	5.594099897	127	5.5	5.732965428	5.664093107
91	5.6	5.035390838	5.031702098	128	5	5.377483316	5.352469668
92	5	5.43149299	5.335524837	129	6.3	5.275941472	5.175743548
93	6.2	5.117502193	5.113422257	130	6.1	5.654446276	5.592136086
94	4.2	5.573078204	5.523225562	131	5.3	5.554423659	5.547067168
95	4.8	4.838005762	4.835828355	132	5.8	5.371144132	5.302714526
96	5.4	5.125759382	5.022992953	133	5.1	5.544728283	5.46344283
97	3.9	5.183042418	5.195879907	134	5.7	5.262102745	5.214785152
98	7	4.668674007	4.659063714	135	5.9	5.489373286	5.410896468
99	6.6	5.734450586	5.699477258	136	5.3	5.503020284	5.478609404

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
137	5.6	5.3397764	5.289870897	174	6.7	5.160024247	5.095786166
138	4.7	5.457316669	5.387907829	175	4.5	5.789991954	5.716819351
139	5.3	5.108476651	5.060928738	176	4.2	4.97727118	4.981313414
140	5.3	5.324236526	5.247355645	177	5.1	4.972026726	4.84468201
141	6.8	5.246439333	5.232955947	178	4.7	5.135467312	5.104163387
142	7	5.769039095	5.747134446	179	4	4.939116895	4.949456614
143	5.2	5.846813829	5.87070361	180	4.8	4.704772997	4.679998325
144	5.6	5.391561505	5.328400661	181	3.5	4.944023954	4.931659322
145	4.7	5.582403854	5.452406498	182	4.3	4.394713313	4.42703946
146	6.5	5.16985997	5.102936132	183	3.5	4.706214969	4.688196046
147	4.7	5.78517664	5.695182142	184	4.2	4.286247318	4.352780276
148	5.1	5.092540018	5.089495228	185	4.1	4.561301309	4.586191552
149	6	5.33751199	5.218627387	186	2.3	4.434201276	4.531657048
150	6.9	5.517874324	5.49965787	187	5	3.751607926	3.792427756
151	4.2	5.832134044	5.826668856	188	3.8	4.723970327	4.757935865
152	5.4	4.97625248	4.937324267	189	4.4	4.139480586	4.337121116
153	5.5	5.478143375	5.331163108	190	5	4.523726809	4.581290315
154	3.9	5.332224324	5.331932225	191	3.5	4.657112823	4.79742249
155	4.9	4.812132262	4.752776639	192	3.9	4.195284648	4.284041805
156	5.7	5.151062817	5.068727918	193	3.6	4.383275432	4.411988488
157	5.5	5.289529549	5.319619219	194	3.8	4.171326807	4.266036994
158	5.8	5.269616495	5.284757156	195	5.5	4.245922384	4.321432082
159	3.6	5.426996123	5.412587887	196	4	4.777586608	4.910290969
160	4.7	4.650763787	4.618903926	197	3.6	4.291509442	4.438941654
161	3.8	5.072275774	4.971682161	198	5	4.267540605	4.296684785
162	4.1	4.561751057	4.588844336	199	3.3	4.678764098	4.766795198
163	5.2	4.696143025	4.666167855	200	4.3	4.046963929	4.161206885
164	4.8	4.971913292	5.027568583	201	3.6	4.486000028	4.515954036
165	4.9	4.837953047	4.910721834	202	3.8	4.114677893	4.239781143
166	4.6	4.941711871	4.964275046	203	2.4	4.239151712	4.303062108
167	3.8	4.827078412	4.858697041	204	3.7	3.624400455	3.713703706
168	4.2	4.546839608	4.549782401	205	5.5	4.11245216	4.172020738
169	6.1	4.658188934	4.658036279	206	4.2	4.566530574	4.783743216
170	7.4	5.219737743	5.295965308	207	3	4.234193485	4.419742744
171	6.3	5.648666595	5.782697512	208	3.5	3.928648729	3.988980452
172	5.8	5.490143628	5.55308954	209	3.5	4.067993591	4.131623879
173	4.8	5.49453944	5.445430948	210	4	3.968129218	4.096373099

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
211	5.1	4.146019742	4.273543099	248	4	4.673966794	4.716286283
212	5.2	4.501504884	4.671905725	249	3.4	4.610394449	4.584670482
213	6	4.591227009	4.766109344	250	6.2	4.304425279	4.311017997
214	5.6	4.968550154	5.097919127	251	4.5	5.216571542	5.254563092
215	5.8	4.922622526	5.038920508	252	5.8	4.58563731	4.725262605
216	4.7	5.111260739	5.159251375	253	3.4	5.215046859	5.206490071
217	3.6	4.780150044	4.814666853	254	3.9	4.295836971	4.354901905
218	5.3	4.424400774	4.394103455	255	4.3	4.571365738	4.503018475
219	4.7	4.951318367	4.949210077	256	3.7	4.52720796	4.592656887
220	4.7	4.649076887	4.74636956	257	3.5	4.306876436	4.359978922
221	4.2	4.745083674	4.764705308	258	4.3	4.21728291	4.255276376
222	3.4	4.535118483	4.577538501	259	4.3	4.441703853	4.515415179
223	4.6	4.238035955	4.25050305	260	4.1	4.400526128	4.515942212
224	5.2	4.612267916	4.645110627	261	4.3	4.371998435	4.456264529
225	5.7	4.728546534	4.852072532	262	4.3	4.444991151	4.526037096
226	5	4.969643162	5.069660971	263	4.3	4.436703279	4.526791357
227	3.8	4.810048991	4.885809876	264	4.3	4.450084836	4.530743423
228	6.5	4.459424417	4.463909065	265	4.2	4.452036486	4.531775506
229	5.3	5.34691692	5.361464371	266	4.4	4.419117571	4.495238802
230	4	4.888220562	5.014761407	267	4.7	4.488515838	4.563820567
231	5.6	4.619719927	4.589468344	268	3.9	4.585070497	4.674101288
232	4.9	5.124580902	5.114758247	269	4.5	4.32199503	4.398593894
233	3.6	4.812078092	4.88418696	270	3.9	4.555747115	4.603541568
234	2.6	4.433506374	4.414622221	271	5.2	4.290309223	4.379944173
235	4.6	3.975479357	3.942405881	272	6.8	4.770461431	4.834429849
236	6	4.601214143	4.618524148	273	3.6	5.238209481	5.391791599
237	5	4.912647319	5.091014828	274	4.3	4.298068117	4.380030419
238	6	4.726004898	4.846600543	275	6	4.681318591	4.617258885
239	5	5.184028985	5.228645664	276	2.9	5.066104928	5.159046752
240	8.8	4.862304151	4.93187844	277	4.1	4.013064087	4.07595382
241	6.9	6.155326082	6.17310354	278	4.5	4.549809971	4.490318382
242	5.7	5.593313774	5.71698918	279	4.8	4.468506261	4.585650639
243	4.2	5.519345059	5.410714908	280	2.3	4.627093063	4.709848814
244	7.5	4.957965654	4.850765553	281	3.5	3.690720554	3.746340994
245	3.2	6.012562838	5.907548995	282	3.6	4.178102462	4.159277266
246	4.6	4.400609822	4.423476545	283	3.5	3.992107803	4.140477971
247	4.3	5.094790295	4.900664903	284	4.6	3.994178506	4.100736533

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
285	7	4.354492087	4.491999162	322	5.4	4.169613327	4.284876257
286	7	5.1097905	5.315292779	323	6.7	4.577871914	4.742201829
287	5	5.24577857	5.453693921	324	6.1	5.046421213	5.236580977
288	4.5	4.86345733	4.920163828	325	7.6	5.022085423	5.164205897
289	3.1	4.790963753	4.75146577	326	7.9	5.664859141	5.723501855
290	3.5	4.192564545	4.171281408	327	6.9	5.839182251	5.920218146
291	3.6	4.282489964	4.248934385	328	5.5	5.741690498	5.720439048
292	3.9	4.15580751	4.223491906	329	5	5.399637896	5.300231304
293	4.8	4.229803411	4.309699615	330	4.1	5.228292459	5.097830381
294	5.9	4.506113836	4.625542829	331	5.8	4.814274968	4.715522923
295	7.2	4.882210185	5.032627254	332	5.5	5.32755581	5.253000218
296	3.9	5.381211484	5.531911166	333	4.1	5.119185171	5.154834909
297	2	4.448063838	4.519247594	334	5.3	4.720134377	4.675388753
298	3.3	3.787340593	3.68794511	335	4.1	5.115692445	5.061385017
299	3.7	4.135457072	4.098154423	336	3.9	4.59220125	4.617782389
300	4.2	4.049656667	4.178317521	337	4.3	4.562102232	4.514467679
301	2.8	4.240617934	4.363485428	338	3.7	4.594601467	4.610310458
302	3.8	3.721219307	3.838902395	339	3.9	4.3256097	4.362887611
303	4.4	4.121962203	4.1899931	340	4.4	4.382194749	4.405782863
304	3.4	4.214550654	4.391116931	341	4.9	4.487403433	4.560683578
305	4	3.924502813	4.056166336	342	5.1	4.649576233	4.742669375
306	3.7	4.178448055	4.270868122	343	5	4.748665467	4.841558163
307	5.3	4.014524442	4.154432521	344	4.4	4.771542745	4.840579295
308	4.2	4.594056815	4.721055292	345	5.6	4.607564611	4.646721997
309	4.9	4.22175897	4.39065119	346	5.2	5.027175421	5.056853465
310	3.8	4.592766504	4.664023305	347	6	4.87119428	4.949595141
311	4.1	4.17615557	4.285713491	348	6.7	5.231471131	5.252146894
312	4.8	4.344375851	4.385380958	349	6	5.465816134	5.523942949
313	4.1	4.50889728	4.617987724	350	3.5	5.350618526	5.366285707
314	4	4.290143894	4.393167857	351	3.9	4.553110898	4.486993574
315	3.7	4.299509522	4.357424543	352	4.2	4.678441645	4.560143651
316	3.8	4.150999424	4.226860789	353	4.9	4.582633308	4.592720106
317	3.7	4.167648082	4.241068379	354	6.1	4.786692698	4.819823024
318	5.3	4.088760783	4.185382	355	5.3	5.160153431	5.240817949
319	3.2	4.62109809	4.739787583	356	5.4	4.963614225	5.035287935
320	3.2	3.886295767	4.024253202	357	5.8	5.109303305	5.102230552
321	4.1	3.986812626	4.002127367	358	6.1	5.23414921	5.248747809

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
359	5.2	5.368783675	5.378697266	396	5.7	5.072159313	5.103864095
360	4.2	5.121814691	5.108954697	397	5.6	5.206114952	5.234155827
361	6.9	4.809180425	4.742649861	398	6.2	5.219700517	5.233665726
362	8.1	5.661702383	5.620979245	399	6.3	5.46811653	5.461027614
363	7.1	5.955149481	6.052290636	400	6.9	5.531261055	5.532533997
364	4.9	5.877415005	5.872990432	401	6.9	5.803074842	5.773715656
365	5.6	5.296946573	5.185554777	402	7.7	5.861655199	5.82855687
366	3.8	5.548733869	5.385434772	403	6.9	6.210183653	6.138579507
367	3.5	4.758337062	4.683640093	404	4.9	6.023569947	5.946293856
368	3.1	4.627027367	4.490189895	405	6.1	5.444020189	5.283511886
369	3.9	4.273404709	4.229356383	406	6.5	5.834355052	5.646104351
370	6.1	4.468357329	4.461063712	407	6	5.822033714	5.756187443
371	7.7	5.094351179	5.197717632	408	4.8	5.712179522	5.615012361
372	6.8	5.622359649	5.786313502	409	6	5.31414346	5.190590913
373	4.7	5.562915406	5.650736762	410	5.1	5.697087993	5.564281852
374	3.2	5.065014047	5.01369246	411	5.3	5.286947313	5.239600768
375	4.3	4.515900426	4.393823193	412	5.6	5.405349648	5.296382944
376	4.7	4.798543271	4.710998524	413	5.9	5.430109045	5.378478445
377	4.4	4.75988746	4.803361667	414	7.6	5.533077296	5.4847189
378	4.5	4.669821602	4.699585525	415	5.9	6.094493134	6.062826338
379	3.3	4.704458125	4.727501421	416	4.5	5.601962097	5.578762368
380	5.3	4.234408586	4.257468166	417	5.1	5.245794486	5.092155491
381	6.1	4.930625487	4.940902984	418	3.9	5.374958118	5.240823111
382	6.8	5.08173333	5.227977272	419	5.6	4.811794722	4.747023877
383	6.2	5.460556792	5.543528042	420	7	5.39455177	5.307175802
384	3.9	5.389076855	5.438401127	421	4.9	5.717375923	5.772556461
385	3.9	4.715033774	4.66474507	422	4.5	5.143246201	5.13990348
386	6.2	4.710333835	4.601733461	423	5.4	5.102127379	4.986355654
387	5.1	5.328826339	5.337224494	424	5.9	5.304252572	5.252857231
388	5.3	4.928549869	5.006702507	425	6	5.42195413	5.421137014
389	5.2	5.137590396	5.106410066	426	4.9	5.500335782	5.488424165
390	6.8	5.061978037	5.072259657	427	6.1	5.17508229	5.132324363
391	5.9	5.616464807	5.616932014	428	5.9	5.609335626	5.532179704
392	3.9	5.343905836	5.381456504	429	6.9	5.480928269	5.477167122
393	4.2	4.772503189	4.694076885	430	4.2	5.894572348	5.840381144
394	5	4.843922291	4.73907236	431	4	4.98149606	4.934665552
395	5.4	4.967528577	4.96461079	432	6.5	4.972716195	4.805442553

Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)	Periode ke-	Aktual	ARFIMA (0, 0, 346,[2])	ARFIMA (0,0, 224,1)
433	5.5	5.638211885	5.601679644	461	6.1	5.985895024	5.879170772
434	5.1	5.255631448	5.302032044	462	5.3	5.928582147	5.785990621
435	6.6	5.26515111	5.194098668	463	5.1	5.636920549	5.494598072
436	6.3	5.725535143	5.690368708	464	5.9	5.534732822	5.382083923
437	6.2	5.626800215	5.632347506	465	5.4	5.726619614	5.618513079
438	8.7	5.712841768	5.644761724	466	7.4	5.505990264	5.43917665
439	8.7	6.521934752	6.46943524	467	7.8	6.197103487	6.109168883
440	7	6.586176087	6.579163906	468	6	6.3037845	6.296612472
441	6.6	6.296351044	6.153816124	469	5.4	5.896137962	5.78723537
442	6.3	6.256024007	6.037493946	470	6.2	5.759699543	5.570636782
443	5.6	6.107181274	5.912496138	471	6.6	5.94822124	5.799102978
444	4.5	5.833743704	5.644075367	472	7.3	6.020340264	5.926899022
445	4.2	5.381408022	5.194979922	473	7.9	6.285805859	6.186254641
446	6.1	5.169831869	4.99731453	474	7.5	6.525864214	6.430593684
447	8.9	5.692216405	5.596939762	475	5.3	6.497267427	6.369421317
448	5.3	6.478180836	6.507634599	476	5.8	5.841476377	5.649570499
449	4.9	5.47569118	5.464943846	477	6.2	6.017776498	5.770711606
450	4.9	5.538752001	5.321249186	478	5.5	5.993494215	5.855940344
451	4.7	5.358030711	5.243456287	479	5.6	5.740732816	5.604775436
452	5.8	5.220584255	5.122261578	480	7.9	5.764744598	5.614394579
453	5.5	5.538393645	5.474329637	481	7.1	6.455262671	6.358796279
454	7.5	5.39172688	5.37908385	482	6.1	6.211566337	6.16980281
455	6.2	6.1081734	6.062968742	483	6	6.05390272	5.887540584
456	6.7	5.704241869	5.707888856	484	7	6.013075029	5.835089639
457	7.7	6.041628084	5.916357937	485	5.4	6.297628351	6.149134233
458	5.8	6.332057587	6.263151287	486	6.3	5.735558836	5.61451012
459	6.5	5.791797104	5.69088983	487	5.9	6.096337984	5.903513495
460	6.4	6.115475028	5.924448338				

Lampiran 4

Hasil Peramalan Model ARFIMA

Hasil ramalan kecepatan angin di Bandara Internasional Ahmad Yani menggunakan model ARFIMA yang terpilih.

Periode ke -	Aktual	ARFIMA(0, 0, 346,[2])	ARFIMA(0,0, 224,1)
488	5,3	5,847797641	5,748466579
489	5,7	5,87141361	5,69083926
490	6,1	5,836292569	5,650238343
491	5,8	5,811165924	5,618194095
492	5	5,788691641	5,591512871
493	5,1	5,768234941	5,568580527
494	5	5,749464022	5,54842736
495	6,6	5,732140968	5,530511704
496	6	5,716068089	5,514334421
497	6	5,701082638	5,499611266
498	6,2	5,68705641	5,486116325
499	5,4	5,67387636	5,473667331
500	4,2	5,661458702	5,462120546
501	4,6	5,649720163	5,451365754
502	6,5	5,638596932	5,441302676
503	5,9	5,628035033	5,431864164
504	5,8	5,617980772	5,422974098
505	5,7	5,608394922	5,414584609
506	5,8	5,599238445	5,406638748
507	6,4	5,590477208	5,399107666
508	7,4	5,58207722	5,391948711
509	4,8	5,574023518	5,385128666
510	5	5,566277616	5,378628341
511	6,9	5,558834168	5,372414715
512	5,1	5,55165959	5,366468766
513	5,4	5,544743954	5,360771532
514	5,6	5,538072663	5,355308736
515	5	5,531626467	5,35006152
516	6	5,525395579	5,345015701
517	7,1	5,519370244	5,340157131
518	5,8	5,513531344	5,335480938

Lampiran 5

Script Program R Studio Model ARIMA

1. Package Library yang digunakan

```
library(forecast)
library(tseries)
```

2. Estimasi Model Terpilih

```
ARIMA(1,1,1)

Coefficients:
            ar1      ma1
            0.2964 -0.9554
s.e.    0.0469  0.0143

sigma^2 estimated as 0.05687: log likelihood=7.15
AIC=-8.31   AICC=-8.26   BIC=4.25
```

3. Akurasi Fitting

```
accuracy(arimafit, inAY)
               ME      RMSE      MAE      MPE      MAPE      AC
F1 Theil's U
Test set 0.1003411 1.069348 0.8027873 -3.007873 16.99219 0.018455
09 0.7093392
```

4. Peramalan ARIMA

```
Time Series:
Start = 488
End = 518
Frequency = 1
[1] 6.100624 6.160737 6.178612 6.183916 6.185488 6.185954 6.1860
93 6.186134
[9] 6.186146 6.186149 6.186150 6.186151 6.186151 6.186151 6.1861
51 6.186151
[17] 6.186151 6.186151 6.186151 6.186151 6.186151 6.186151 6.1861
51 6.186151
[25] 6.186151 6.186151 6.186151 6.186151 6.186151 6.186151 6.1861
51
```

5. Akurasi Peramalan

```
ME      RMSE      MAE      MPE      MAPE
ACF1 Theil's U
Test set -0.4660974 0.8605522 0.7110627 -9.908822 13.41102
0.08350853 0.924902
```

Lampiran 6

Script Program R Studio Metode ELM

1. Package Library yang Digunakan

```
library(nnfor)
```

2. Fitting Model ELM

```
fit.elm
ELM fit with 100 hidden nodes and 20 repetitions.
Univariate lags: (1,3)
Forecast combined using the median operator.
Output weight estimation using: lasso.
MSE: 1.2567.
```

3. Data Fitting Model

```
fcstfit = fitted(fit.elm)

Time Series:
Start = 4
End = 487
Frequency = 1
[1] 5.035533 4.875004 5.355802 5.057181 5.281676 5.049046 5.239
727 4.999690
[9] 4.947917 4.972545 4.810700 5.197194 5.033577 5.328889 5.769
599 5.262933
[17] 5.129499 5.871328 5.247757 5.350570 5.166540 5.399080 5.021
008 4.753380
[25] 4.993403 4.777645 4.950583 4.918782 5.350956 4.980817 5.031
285 5.014258
[33] 5.031621 5.020537 4.991032 5.189232 5.051434 4.947917 5.013
605 5.133458
[41] 5.035884 5.047811 5.072402 4.972545 5.399080 5.410893 5.541
285 5.312460
[49] 5.153457 5.176418 5.065249 5.301798 5.160252 5.221423 5.125
197 4.997401
[57] 4.845763 5.022546 5.003796 5.049537 4.904913 4.876385 4.745
541 4.761616
[65] 4.865409 5.019497 5.491381 5.405937 5.322162 5.176799 5.005
689 5.035239
[73] 5.293219 5.167974 5.374564 5.112230 5.186950 5.243637 5.448
649 5.129306
[81] 5.188416 4.947485 5.202745 5.266801 5.301800 5.186950 5.433
514 5.049046
[89] 5.314051 5.087805 5.386768 4.932046 5.138250 5.140368 4.854
492 5.516716
[97] 5.359187 5.289888 5.140716 5.696092 5.149361 5.210872 5.106
029 5.035884
[105] 5.101176 5.503243 4.548977 4.883003 4.848004 4.970305 5.035
884 5.223369
[113] 5.410785 4.338902 5.325907 4.889480 5.203638 5.077069 5.226
149 5.503243
```

[121] 5.096700 5.555637 5.258046 5.498046 5.257122 5.197507 5.399
675 5.328899
[129] 5.246726 5.335769 5.142544 5.299624 5.294980 5.209575 5.284
187 5.061870
[137] 5.203638 5.149361 5.476966 5.511634 5.257149 5.349456 5.055
461 5.440438
[145] 5.020537 5.217926 5.292020 5.484075 5.004955 5.304881 5.160
765 4.898694
[153] 5.118357 5.181331 5.202745 5.314412 4.840533 5.094847 4.758
591 4.891753
[161] 5.071064 5.002874 5.099346 5.006186 4.839215 4.907153 5.255
322 5.522496
[169] 5.430597 5.411179 5.144131 5.485479 4.984802 5.052818 5.095
978 4.988435
[177] 4.897005 5.042717 4.717198 4.941262 4.686522 4.888290 4.816
332 4.492277
[185] 5.048026 4.674545 4.975494 5.026336 4.741816 4.867616 4.708
610 4.777555
[193] 5.123751 4.814220 4.840533 5.040808 4.648701 4.953712 4.696
333 4.800548
[201] 4.476219 4.749270 5.047034 4.850803 4.708255 4.729499 4.655
974 4.794871
[209] 5.028710 5.084927 5.315380 5.240237 5.330453 5.082871 4.861
297 5.149361
[217] 4.946963 5.061870 4.913737 4.739956 4.967161 5.045928 5.224
951 5.120264
[225] 4.897659 5.405937 5.093268 4.996644 5.246919 5.017466 4.847
459 4.579344
[233] 4.926406 5.157500 5.080491 5.369378 5.107635 5.821005 5.478
873 5.476037
[241] 5.067788 5.620401 4.663327 5.174670 4.838988 4.863245 4.713
496 5.288130
[249] 4.892833 5.341070 4.726320 4.924957 4.852196 4.755441 4.735
655 4.872016
[257] 4.858802 4.866184 4.910204 4.897815 4.910204 4.910204 4.888
290 4.931804
[265] 4.988435 4.828281 4.978644 4.799144 5.117851 5.395339 4.816
984 5.080369
[273] 5.223440 4.604091 4.982666 4.859769 5.002874 4.507629 4.767
780 4.630992
[281] 4.686522 4.926406 5.409222 5.473358 5.227039 5.124918 4.694
559 4.748412
[289] 4.684075 4.773485 4.968477 5.220977 5.520284 4.931246 4.607
727 4.666973
[297] 4.632135 4.824913 4.553262 4.794785 4.832859 4.682849 4.850
114 4.724616
[305] 5.106621 4.850803 5.106029 4.794785 4.904913 4.982246 4.854
472 4.876385
[313] 4.767537 4.783288 4.743101 5.093268 4.632941 4.738696 4.796
969 5.075696
[321] 5.388551 5.355858 5.681975 5.699190 5.615189 5.383656 5.221
035 4.947917
[329] 5.269324 5.154653 4.968395 5.197691 4.854472 4.891130 4.897
815 4.755441
[337] 4.822291 4.892337 5.010636 5.089174 5.101176 4.981937 5.229
003 5.111233

```
[345] 5.348474 5.453962 5.369378 4.898402 4.937619 4.837853 5.010
636 5.280636
[353] 5.160252 5.254754 5.288154 5.355858 5.194554 5.012015 5.489
259 5.644311
[361] 5.614645 5.272062 5.355309 4.839215 4.825159 4.617248 4.773
485 5.211402
[369] 5.557065 5.519507 5.206867 4.840707 4.935042 4.920488 4.931
804 4.978644
[377] 4.697538 5.138603 5.225873 5.476966 5.412215 4.994841 4.952
024 5.281833
[385] 5.057181 5.240391 5.151174 5.476966 5.301798 4.994841 4.997
879 5.033577
[393] 5.140368 5.249234 5.253812 5.391922 5.405052 5.542858 5.548
260 5.703254
[401] 5.580373 5.248290 5.437435 5.399080 5.374564 5.155898 5.369
378 5.115923
[409] 5.227697 5.234626 5.308603 5.632040 5.344787 5.162288 5.180
733 4.834829
[417] 5.234626 5.431823 5.123836 5.124918 5.181056 5.259258 5.335
692 5.140216
[425] 5.388418 5.283748 5.537442 4.997879 5.021726 5.357925 5.148
690 5.217926
[433] 5.451973 5.375399 5.438475 5.820287 5.816523 5.677997 5.618
564 5.480508
[441] 5.325907 5.088614 4.976548 5.299492 5.763081 5.234048 5.320
323 5.106029
[449] 5.035239 5.263766 5.189232 5.625567 5.381301 5.575938 5.676
810 5.369907
[457] 5.550920 5.433514 5.414657 5.253054 5.193157 5.308603 5.193
839 5.613854
[465] 5.654983 5.449102 5.357166 5.407167 5.446908 5.612470 5.719
669 5.691641
[473] 5.342585 5.417343 5.369206 5.257122 5.302142 5.676301 5.545
049 5.495137
[481] 5.430751 5.555188 5.248427 5.480508
```

4. Akurasi Fitting

```
accuracy(fcstfit, inAY)
               ME      RMSE      MAE      MPE      MAPE
ACF1 Theil's U
Test set -0.0002158665 1.121014 0.8746293 -5.988371 19.0393 0.227
2629 0.7058789
```

5. Peramalan

```
fcst.elm = predict(fit.elm, 31)
  Point Forecast
488      5.315398
489      5.249649
490      5.210895
491      5.167909
492      5.152968
493      5.148006
494      5.143542
495      5.142370
```

496	5.141920
497	5.141715
498	5.141622
499	5.141582
500	5.141563
501	5.141554
502	5.141550
503	5.141548
504	5.141548
505	5.141547
506	5.141547
507	5.141547
508	5.141547
509	5.141547
510	5.141547
511	5.141547
512	5.141547
513	5.141547
514	5.141547
515	5.141547
516	5.141547
517	5.141547
518	5.141547

6. Akurasi Peramalan

```
accuracy(predAY.elm, outAY)
      ME      RMSE      MAE      MPE      MAPE      AC
F1 Theil's U
Test set 0.5617098 0.9197016 0.7235949 8.358662 11.90351 0.085859
97 0.9655992
```

Lampiran 7

Hasil Ramalan Model ARIMA(1,1,1) dan Metode ELM

Hasil ramalan kecepatan angin di Bandara Internasional Ahmad Yani menggunakan model ARIMA(1,1,1) dan Metode ELM.

Periode ke -	Aktual	ARIMA(1,1,1)	ELM
488	5,3	6,100624	5,315398
489	5,7	6,160737	5,249649
490	6,1	6,178612	5,210895
491	5,8	6,183916	5,167909
492	5	6,185488	5,152968
493	5,1	6,185954	5,148006
494	5	6,186093	5,143542
495	6,6	6,186134	5,14237
496	6	6,186146	5,14192
497	6	6,186149	5,141715
498	6,2	6,18615	5,141622
499	5,4	6,186151	5,141582
500	4,2	6,186151	5,141563
501	4,6	6,186151	5,141554
502	6,5	6,186151	5,14155
503	5,9	6,186151	5,141548
504	5,8	6,186151	5,141548
505	5,7	6,186151	5,141547
506	5,8	6,186151	5,141547
507	6,4	6,186151	5,141547
508	7,4	6,186151	5,141547
509	4,8	6,186151	5,141547
510	5	6,186151	5,141547
511	6,9	6,186151	5,141547
512	5,1	6,186151	5,141547
513	5,4	6,186151	5,141547
514	5,6	6,186151	5,141547
515	5	6,186151	5,141547
516	6	6,186151	5,141547
517	7,1	6,186151	5,141547
518	5,8	6,186151	5,141547