



TESIS- SS14 2501

**STUDI SIMULASI PENGARUH OUTLIER TERHADAP  
PENGUJIAN LINIERITAS DAN LONG MEMORY BESERTA  
APLIKASINYA PADA DATA *RETURN SAHAM***

PUSPITA KARTIKASARI  
NRP 1313 201 048

DOSEN PEMBIMBING  
Dr. rer.pol. Heri Kuswanto, S.Si., M.Si.

PROGRAM MAGISTER  
JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2015



THESIS- SS14 2501

## **SIMULATION STUDY OF THE INFLUENCE OF OUTLIER IN LINIERTY AND LONG MEMORY TEST**

**PUSPITA KARTIKASARI**  
**NRP 1313 201 048**

**SUPERVISOR**  
**Dr.rer.pol. Heri Kuswanto, S.Si., M.Si.**

**PROGRAM OF MAGISTER**  
**DEPARTMENT OF STATISTICS**  
**FACULTY OF MATHEMATICS AND NATURAL SCIENCES**  
**INSTITUT TEKNOLOGI SEPULUH NOPEMBER**  
**SURABAYA**  
**2015**

**STUDI SIMULASI PENGARUH OUTLIER TERHADAP  
PENGUJIAN LINIERITAS DAN LONG MEMORY BESERTA  
APLIKASINYA PADA DATA RETURN SAHAM**

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar  
**Magister Sains (M.Si)**

Di  
**Institut Teknologi Sepuluh Nopember**

Oleh:  
**PUSPITA KARTIKASARI**  
**NRP: 1313 201 048**

Tanggal Ujian : 26 Februari 2015  
Periode Wisuda : September 2015

**Disetujui Oleh:**

1. Dr.rei.pol. Heri Kuswanto, S.Si., M.Si.  
NIP. 19820326 200312 1 004

(Pembimbing)

2. Dr. Suhartono, M.Sc.  
NIP 19710929 199512 1 001

(Penguji)

3. Dr. Irhamah, S.Si., M.Si.  
NIP 19780406 200112 2 002

(Penguji)

**Direktur Program Pascasarjana,**

**Prof. Dr. Ir. Adi Soeprijanto, M.T.**  
NIP 19640405 199002 1 001

# **STUDI SIMULASI PENGARUH OUTLIER TERHADAP PENGUJIAN LINIERITAS DAN LONG MEMORY BESERTA APLIKASINYA PADA DATA RETURN SAHAM**

Nama mahasiswa : Puspita Kartiksari

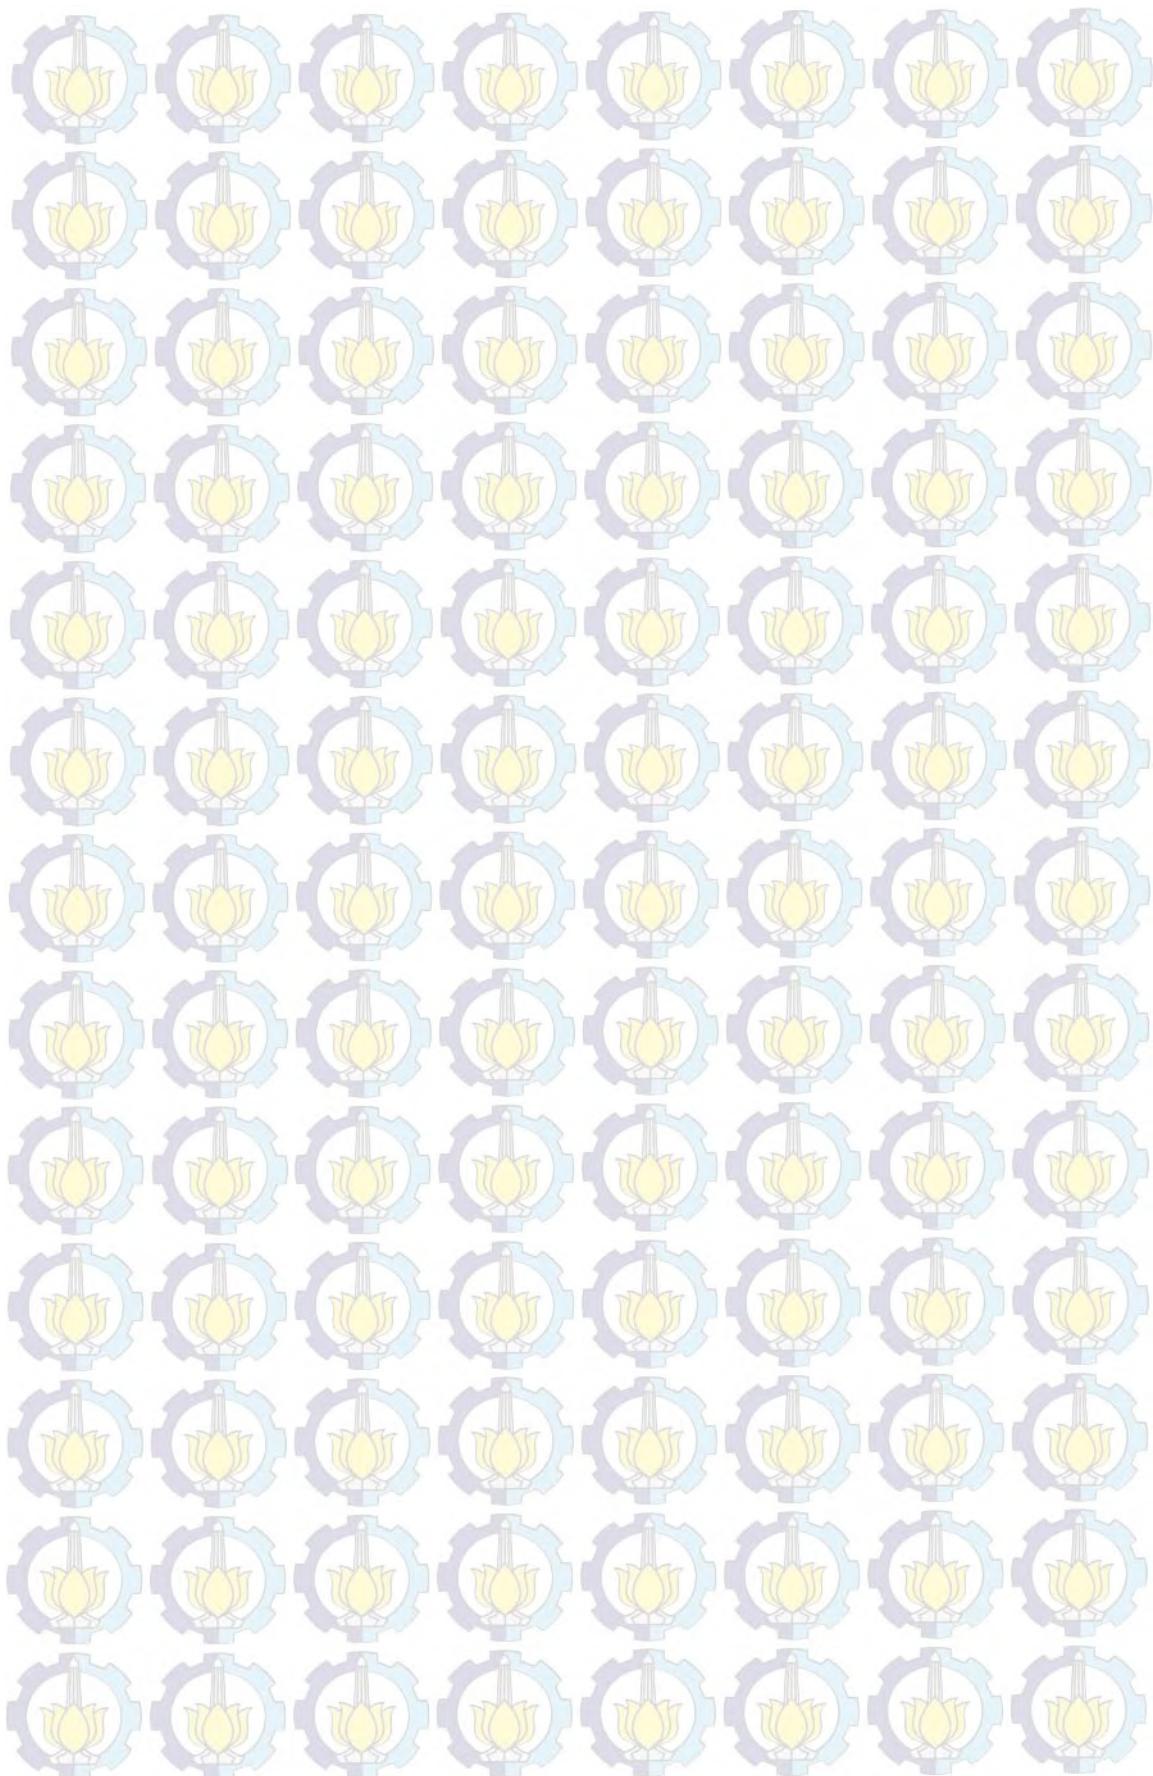
NRP : 1313 201 048

Pembimbing : Dr.rer.pol. Heri Kuswanto, S.Si., M.Si.

## **ABSTRAK**

Peramalan adalah menduga atau memperkirakan suatu keadaan di masa yang akan datang berdasarkan keadaan masa lalu dan sekarang yang diperlukan untuk menetapkan kapan suatu peristiwa akan terjadi. Pada umumnya, pada peramalan data time series terdapat outlier, outlier tersebut akan membuat analisis terhadap serangkaian data menjadi bias, atau tidak mencerminkan fenomena yang sebenarnya. Pada penelitian ini dilakukan simulasi untuk mengetahui performansi dari uji terasvirta, uji white dan uji GPH estimator pada data bangkitan yang mengikuti proses linier short memory yaitu dengan model ARIMA (*Autoregressive Integrated Moving Average*), linier long memory dengan model ARFIMA (*Autoregressive Fractional Integrated Moving Average*), nonlinier short memory dengan model LSTAR (*Logistic Smoothing Transition Autoregressive*) dan nonlinier long memory dengan model FILSTAR (*Fractional Integrated Logistic Smoothing Transition Autoregressive*) dengan dan tanpa melibatkan adanya efek outlier menggunakan jumlah sampel sebanyak 200 dan 1000. Hasil simulasi menunjukkan bahwa uji white memiliki power yang lebih tinggi dibandingkan uji terasvirta dalam mendeteksi kelinieran dari data bangkitan. Selain itu, uji terasvirta, uji white dan uji GPH estimator mampu mendeteksi kelinieran dan kelongmemoryan dari data yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR secara tepat pada parameter-parameter tertentu. Adanya outlier menyebabkan uji terasvirta, uji white dan uji GPH estimator tidak robust lagi digunakan untuk mendeteksi kelinieran dan kelongmemoryan dari data yang mengikuti proses-proses tersebut pada parameter-parameter tertentu. Salah satu penerapan yang dilakukan pada penelitian ini yaitu penerapan pada data *return* saham. Data *return* saham yang dijadikan kasus dalam penelitian ini adalah *return* saham Bank Negara Indonesia karena setelah dilakukan pengujian, *return* saham dari bank tersebut mengikuti fenomena long memory dan nonlinier. Akan tetapi, hasil pengolahan menunjukkan bahwa data *return* saham Bank Negara Indonesia lebih baik dimodelkan dengan ARFIMA daripada LSTAR dan FILSTAR karena menghasilkan forecast yang akurasinya lebih baik, yaitu memiliki nilai RMSE dan MSE sebesar 2,01% dan 0,04%. Hasil tersebut mendukung hasil simulasi dengan menunjukkan bahwa adanya outlier dapat mempengaruhi sifat data, yang seharusnya linier long memory terdeteksi menjadi nonlinier long memory.

**Kata kunci:** ARFIMA, FILSTAR, LSTAR, MSE, RMSE, Simulasi , Uji GPH Estimator, Uji Terasvirta, Uji White.



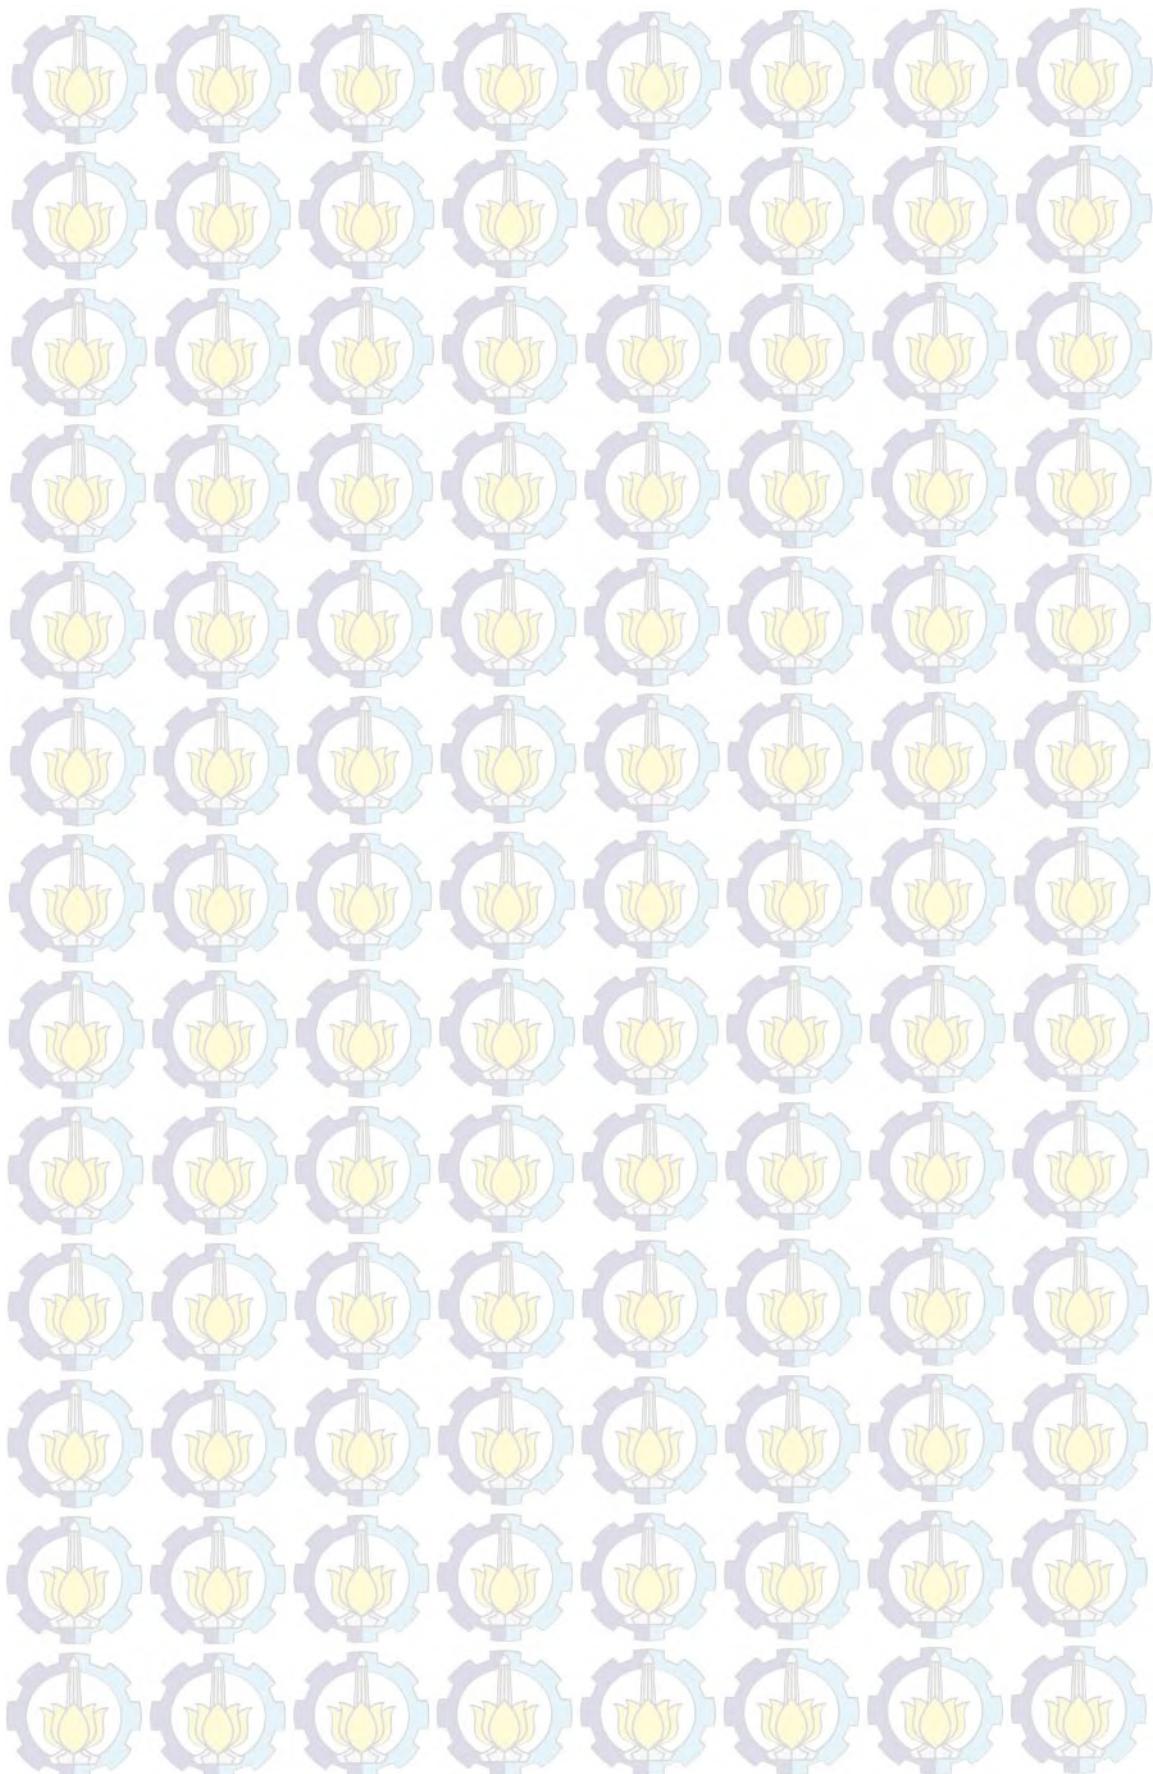
# SIMULATION STUDY OF THE INFLUENCE OF OUTLIER IN LINIERTY AND LONG MEMORY TEST

Name : Puspita Kartikasari  
ID Number : 1313 201 048  
Advisor : Dr.rer.pol. Heri Kuswanto, S.Si., M.Si.

## ABSTRACT

Forecasting is a technique to estimate the condition that will happen in the future based on the condition in the past and the present. In general, there exists the outliers in time series data such that the outliers will make the analysis of the data become biased, or does not reflect the real phenomena. In this study we will conduct a simulation to determine the performance of the terasvirta test, white test and GPH estimator test in generated datathat are followed the linear short memory ARIMA model (Autoregressive Integrated Moving Average), linear long memory ARFIMA model (Fractional AutoregressiveIntegrated Moving Average), nonlinear short memory LSTAR model (Logistic Smoothing Transition Autoregressive) and nonlinear long memory FILSTAR model (Fractionally Integrated Logistic Smoothing Transition Autoregressive) with and without involving the effects of outliers using sample with size 200 and 1000. The simulation results show that the white test has a higher power than terasvirta test in detecting linearity of the data generation. In addition, terasvirta test, white test and GPH estimator test is able to detect long memory and linearity of the data that follow the ARIMA, ARFIMA, LSTAR and FILSTAR model sprecisely on certain parameters. The existence of outliers cause the terasvirta test, the white test and the GPHeimator test become not robust to detect long memory and linearity of the data. One application that is done in this study is the application of the stock return data. Stock return data that isused in this study is the stock return of Bank Negara Indonesia because after testing, the bank stock returns following the long memory and nonlinear phenomena. However, the results indicate that the data processing of Bank Negara Indonesia stock return sare better modeled with ARFIMA than LSTAR and FILSTAR because it produces better forecasts accuracy, which has a value of RMSE and MSE of 2.01% and 0.04%, respectively. These results support the simulation results that indicate the existence of outliers can affect the nature of the data, which issupposed to be linear long memory but detected to be nonlinear long memory.

**Keywords:** Simulation, ARFIMA, LSTAR, FILSTAR, Terasvirta Test, White Test, GPH Estimator Test



## KATA PENGANTAR

Segala puji dan syukur atas kehadiran Allah SWT yang telah memberikan rahmat, hidayah, dan karunia-Nya, shalawat serta salam senantiasa tercurahkan kepada Nabi Muhammad SAW sehingga penulis dapat menyelesaikan Tesis dengan judul **“STUDI SIMULASI PENGARUH OUTLIER TERHADAP PENGUJIAN LINIERITAS DAN LONG MEMORY BESERTA APLIKASINYA PADA DATA RETURN SAHAM”**.

Penulis menyadari bahwa dalam menyelesaikan laporan Tesis ini tidak terlepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada :

1. Kedua orang tua saya, Mama Dwi Krisnaningati, Papa Imam Subagjo tercinta, serta kakakku tersayang Dicky Kriswibiyanto yang tanpa lelah memberikan segenap cinta, doa dan dukungannya yang tiada henti kepada penulis.
2. Bapak Dr. Muhammad Mashuri, M.T., selaku Ketua Jurusan Statistika ITS.
3. Bapak Dr. Suhartono, S.Si., M.Sc., selaku Koorprodi Pascasarjana Statistika ITS.
4. Bapak Dr. rer. pol. Heri Kuswanto, S.Si., M.Si. selaku dosen pembimbing yang telah banyak memberikan waktu, bimbingan, kesabaran, motivasi, inspirasi, ilmu, saran dan banyak hal baru dalam menyelesaikan Tesis ini.
5. Bapak Dr. Suhartono, S.Si., M.Sc. dan Ibu Dr. Irhamah, M.Si selaku dosen penguji atas segala masukan dan arahan yang disampaikan sampai terselesaiannya Tugas Akhir ini.
6. Ibu Ir. Sri Pingit Wulandari, M. Si selaku dosen wali atas bimbingan selama penulis mengikuti perkuliahan.
7. Semua Bapak Ibu dosen pengajar serta seluruh staff dan karyawan di Jurusan Statistika ITS.
8. Sahabat seperjuangan dan sebimbingan Fitri Ayu Kusumawati atas kebersamaan dan ketegarannya yang selalu menguatkan.

9. Keluarga besar S2 Statistika ITS angkatan 2013 Statistika ITS, atas setiap kebersamaan yang telah terlewati dan atas semua dukungannya.

Penulis menyadari bahwa laporan tesis ini masih jauh dari kesempurnaan. Oleh karena itu, kritik dan saran diharapkan dari semua pihak untuk tahap pengembangan selanjutnya. Besar harapan penulis bahwa informasi sekecil apapun dalam Tesis ini akan bermanfaat bagi semua pihak dan dapat menambah pengetahuan.

Surabaya, Mei 2015

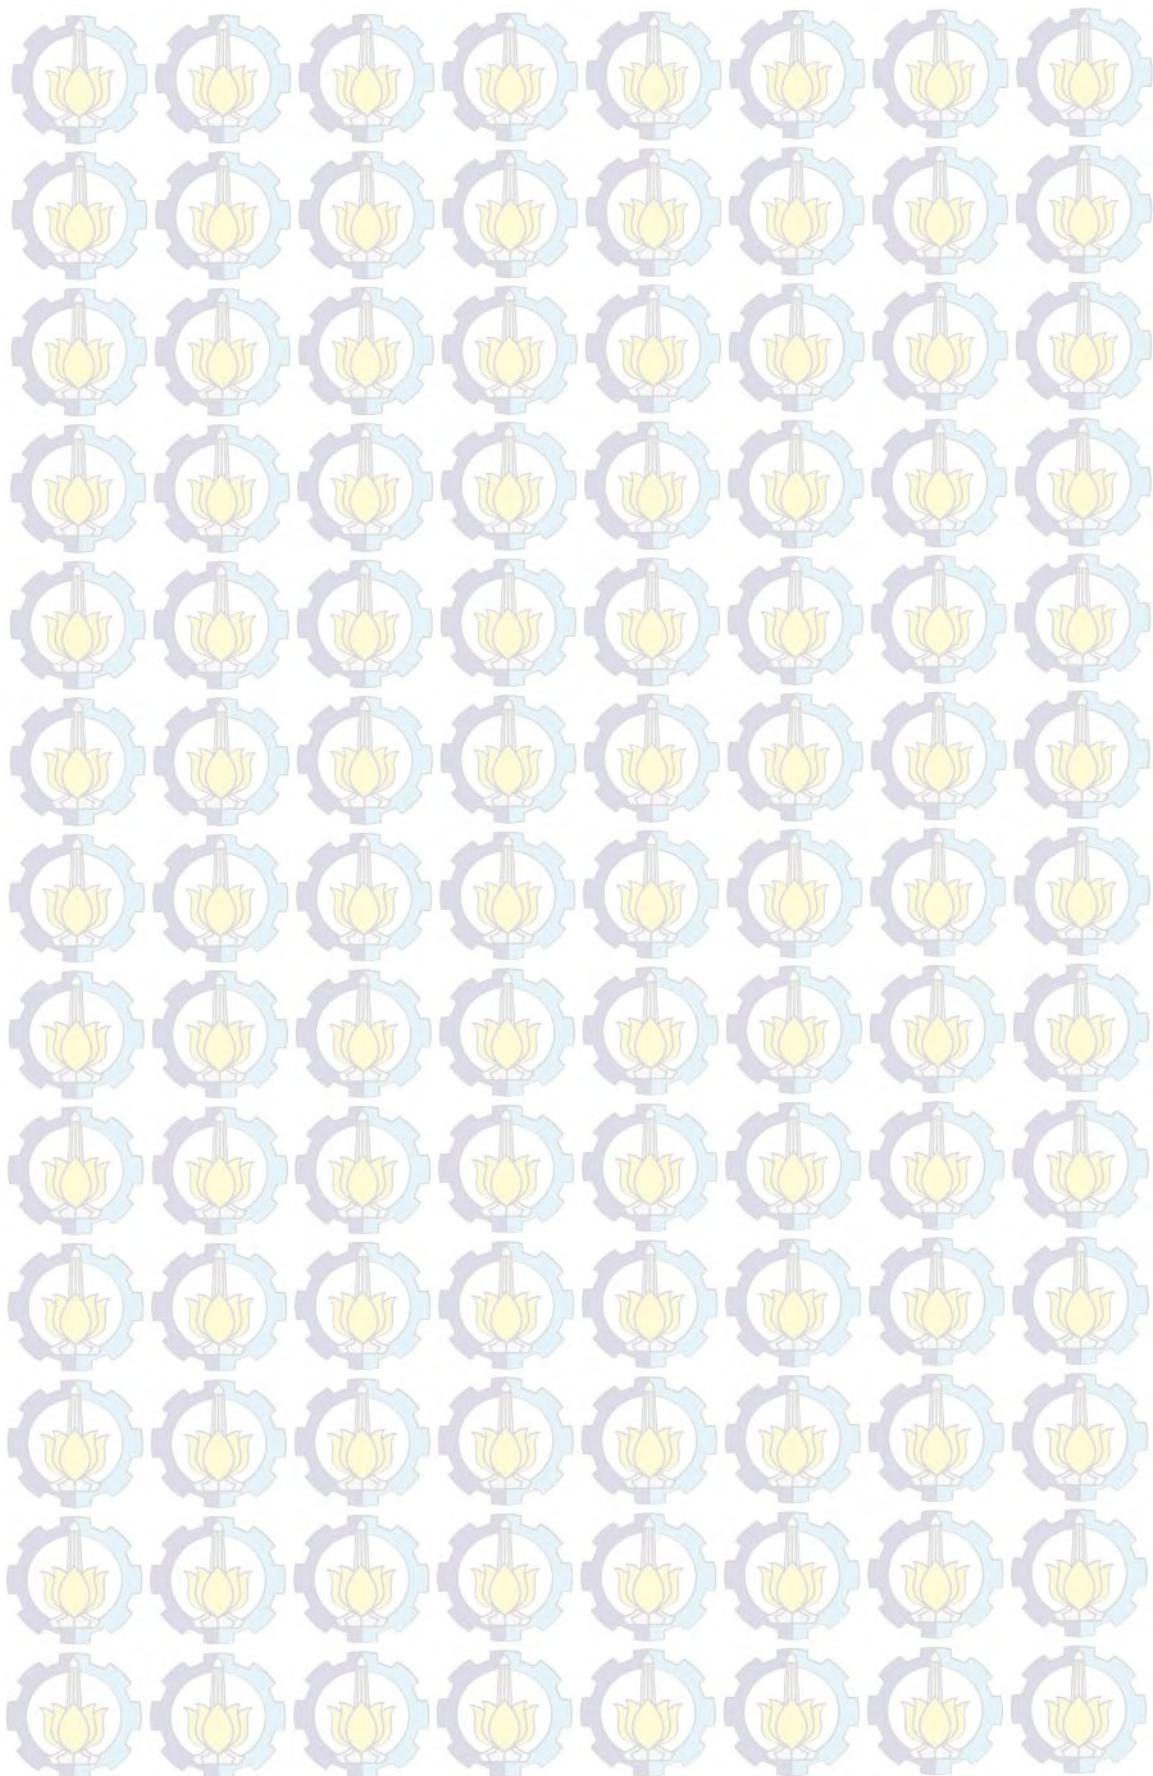
Penulis

## DAFTAR ISI

JUDUL .....	i
JUDUL (BAHASA INGGRIS) .....	iii
LEMBAR PENGESAHAN TESIS.....	v
ABSTRAK .....	vii
ABSTRACT .....	ix
KATA PENGANTAR.....	xi
DAFTAR ISI.....	xiii
DAFTAR TABEL .....	xvii
DAFTAR GAMBAR.....	xxi
DAFTAR LAMPIRAN .....	xxv
<b>BAB 1 PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	7
1.3 Tujuan Penelitian.....	7
1.4 Manfaat Penelitian.....	7
1.5 Batasan Penelitian .....	8
<b>BAB 2 TINJAUAN PUSTAKA .....</b>	<b>9</b>
2.1 Analisis deret Waktu ( <i>Time Series</i> ) .....	9
2.2 <i>Model Autoregressive Integrated Moving Average</i> (ARIMA) .....	9
2.2.1 Model ARIMA Non Musiman .....	9
2.2.2 Model Arima Musiman.....	10
2.3 Identifikasi Model .....	11
2.3.1 Stasioner.....	11
2.3.2 <i>Autocorrelation Function</i> (ACF) .....	12
2.3.3 <i>Partial Autocorrelation Function</i> (PACF) .....	12
2.4 Identifikasi Model ARIMA.....	13
2.5 Penaksiran Parameter Model ARIMA.....	13
2.6 Pengujian Signifikansi Parameter.....	15
2.7 Uji Long Memory.....	15

2.7.1	Estimator GPH .....	15
2.8	Proses Long Memory .....	16
2.8.1	ARFIMA ( $p,d,q$ ).....	17
2.8.2	Proses ARFIMA .....	20
2.8.3	Estimasi Parameter ARFIMA ( $p,d,q$ ) .....	21
2.9	Uji Nonlinieritas .....	23
2.9.1	Uji White .....	23
2.9.2	Uji Terasvirta.....	24
2.10	Nonlinier Time Series .....	25
2.10.1	<i>Logistic Smooth Transition Autoregressive (LSTAR)</i> .....	26
2.11	Kombinasi Peramalan .....	27
2.11.1	<i>Fractionally Integrated Smooth Transition Autoregressive (FILSTAR)</i> .....	27
2.12	Cek Diagnostik.....	31
2.12.1	White Noise .....	31
2.12.2	Distribusi Normal.....	32
2.13	Pemilihan Model Terbaik dan Evaluasi Hasil Peramalan.....	32
2.14	Macam-Macam Outlier .....	33
2.15	Saham LQ 45 .....	34
2.16	<i>Return</i> Saham .....	35
<b>BAB 3</b>	<b>METODOLOGI PENELITIAN .....</b>	<b>37</b>
3.1	Sumber Data dan Variabel Penelitian .....	37
3.2	Struktur Data Penelitian .....	37
3.3	Langkah Penelitian .....	38
<b>BAB 4</b>	<b>HASIL DAN PEMBAHASAN .....</b>	<b>55</b>
4.1	Simulasi Data Time Series .....	55
4.1.1	Simulasi Data Bangkitan ARIMA (1,0,0).....	55
4.1.2	Simulasi Data Bangkitan ARIMA (1,0,0) dengan Penambahan Efek Outlier .....	57
4.1.3	Simulasi Data Bangkitan LSTAR ( <i>Logistic Smoothing Transition Autoregressive</i> ).....	67

4.1.4 Simulasi Data Bangkitan LSTAR ( <i>Logistic Smoothing Transition Autoregressive</i> ) dengan Penambahan Efek Outlier .....	69
4.1.5 Simulasi Data Bagkitan ARFIMA ( <i>Autoregressive Fractionally Integrated Moving Average</i> ).....	77
4.1.6 Simulasi Data Bagkitan ARFIMA ( <i>Autoregressive Fractionally Integrated Moving Average</i> ) dengan Penambahan efek Outlier .....	78
4.1.7 Simulasi Data Bangkitan FILSTAR ( <i>Fractionally Integrated Logistic Smoothing Transition Autoregressive</i> ).....	87
4.1.8 Simulasi Data Bangkitan FILSTAR ( <i>Fractionally Integrated Logistic Smoothing Transition Autoregressive</i> ) dengan Penambahan Efek Outlier .....	89
<b>4.2 Aplikasi pada Saham LQ 45 .....</b>	<b>99</b>
4.2.1 Pemodelan dan Peramalan Data <i>Return</i> Saham Bank Negara Indonesia dengan Menggunakan Model ARFIMA (p,d,q).....	103
4.2.2 Pemodelan dan Peramalan Data Return Saham Bank Negara Indonesia dengan Menggunakan Model LSTAR .....	107
4.2.3 Pemodelan dan Peramalan Data Return Saham Bank Negara Indonesia dengan Menggunakan Model FILSTAR .....	110
<b>BAB 5 KESIMPULAN DAN SARAN.....</b>	<b>119</b>
5.1 Kesimpulan .....	119
5.2 Saran .....	120
<b>DAFTAR PUSTAKA.....</b>	<b>123</b>
<b>LAMPIRAN .....</b>	<b>127</b>
<b>BIOGRAFI PENULIS .....</b>	<b>153</b>

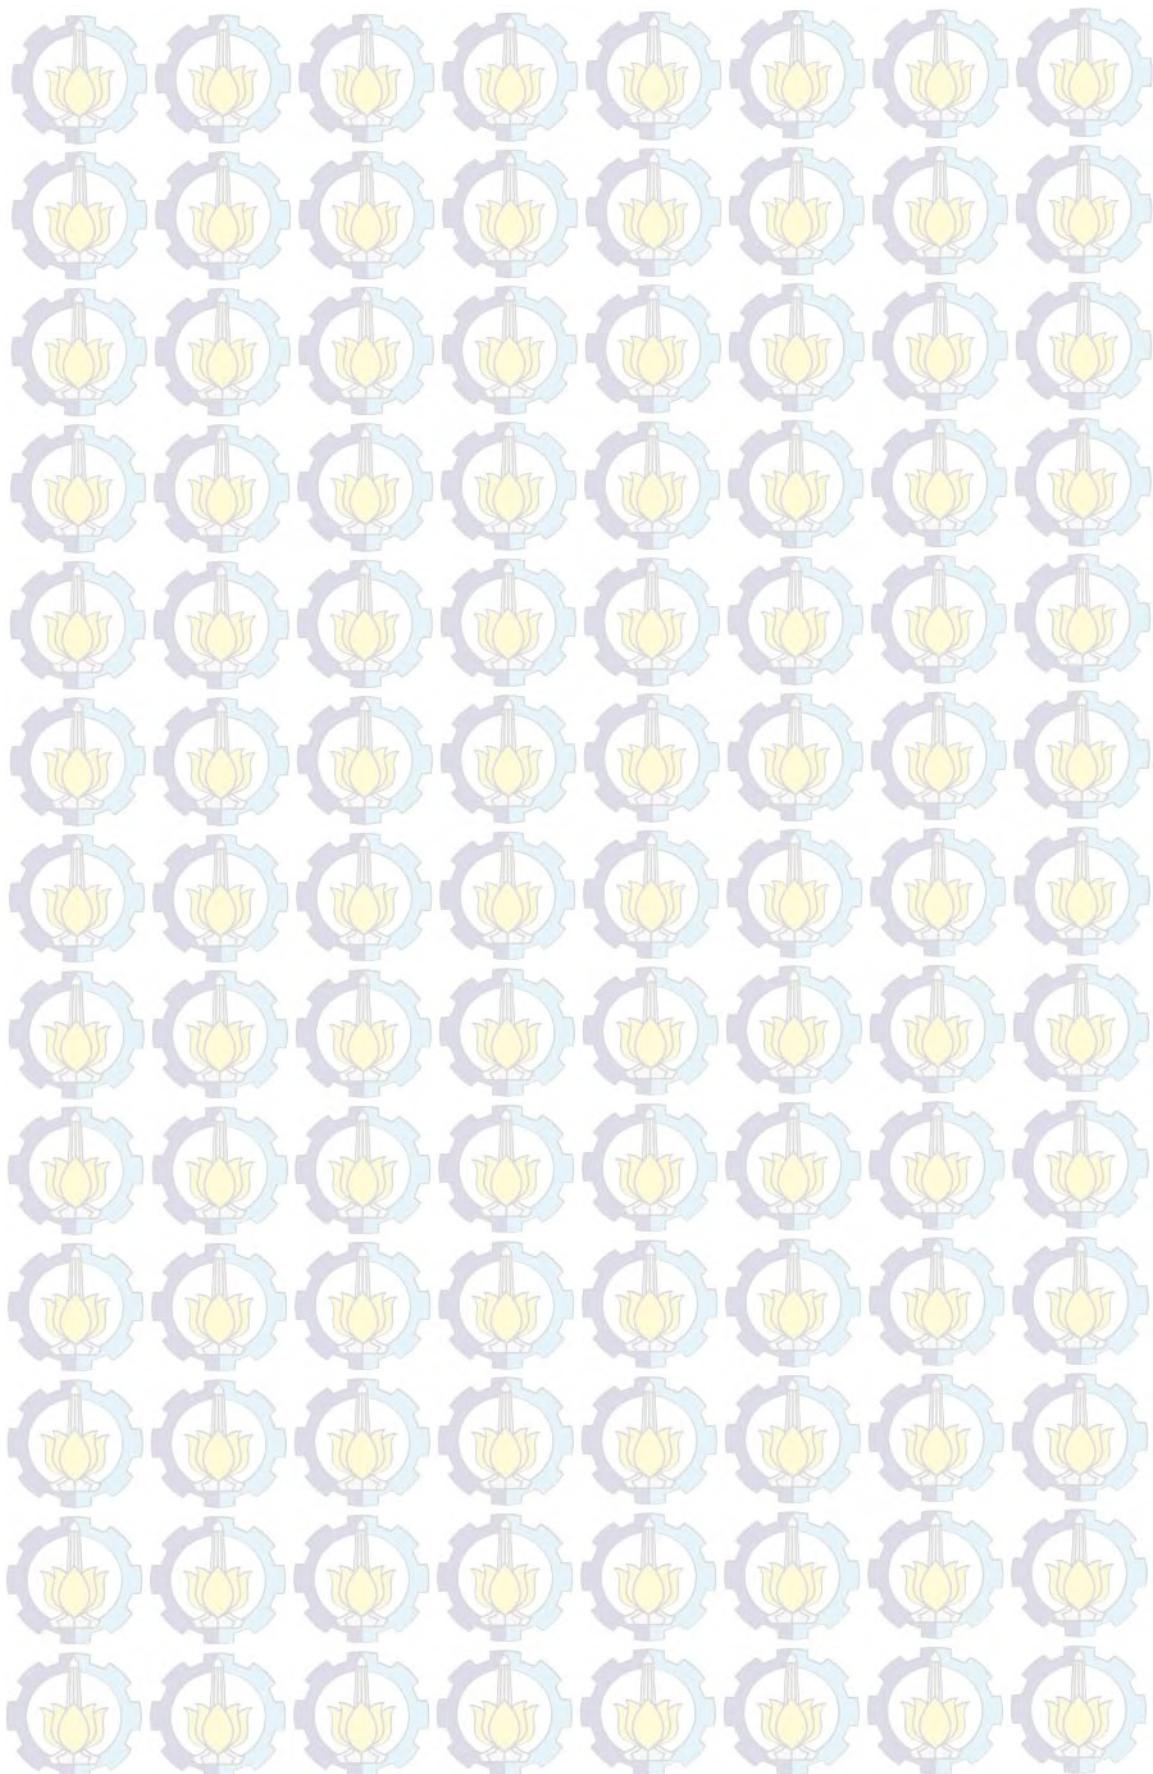


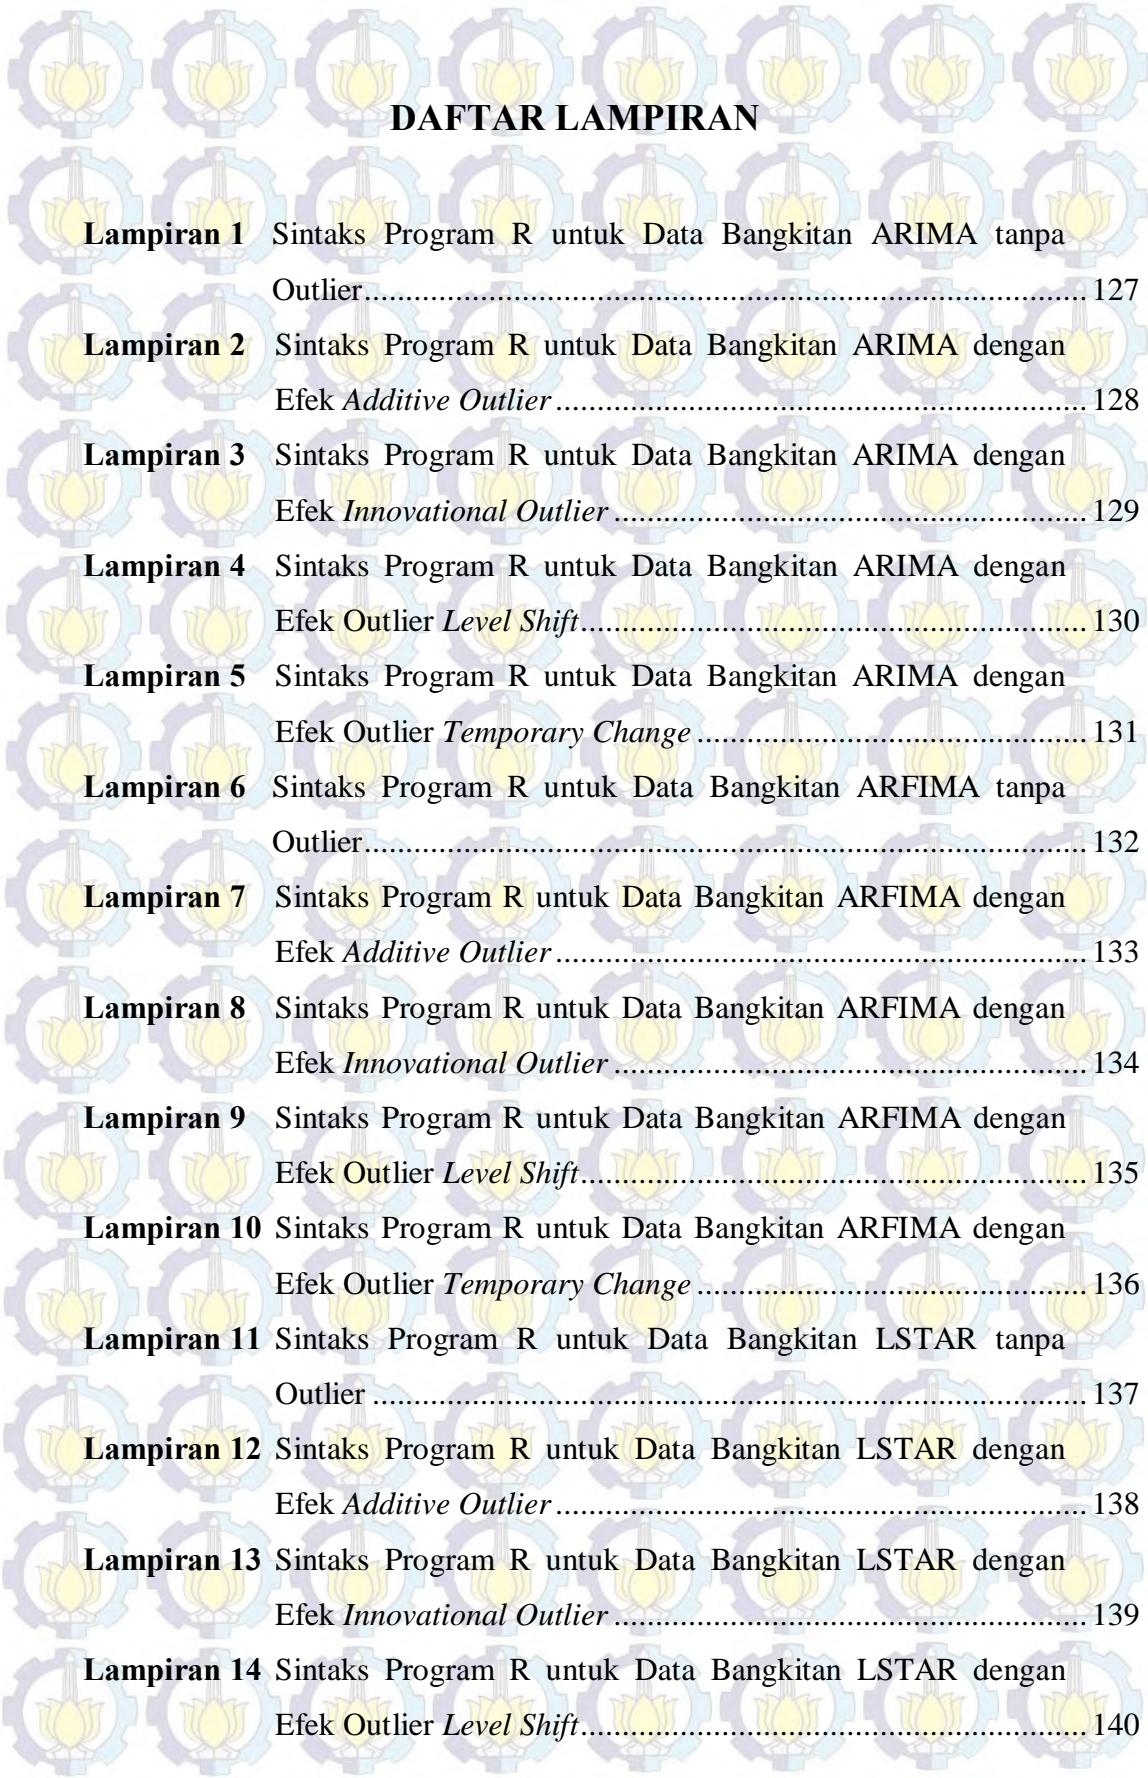
## DAFTAR TABEL

<b>Tabel 2.1</b>	Transformasi Box-Cox .....	11
<b>Tabel 2.2</b>	Bentuk ACF dan PACF untuk model ARIMA Non Musiman .....	13
<b>Tabel 2.3</b>	Bentuk ACF dan PACF untuk model ARIMA Musiman.....	13
<b>Tabel 3.1</b>	Struktur Data Penelitian PT. Bank Negara Indonesia .....	37
<b>Tabel 3.2</b>	Skenario Simulasi Model ARIMA tanpa Outlier .....	38
<b>Tabel 3.3</b>	Skenario Simulasi Model LSTAR tanpa Outlier.....	39
<b>Tabel 3.4</b>	Skenario Simulasi Model ARFIMA tanpa Outlier.....	40
<b>Tabel 3.5</b>	Skenario Simulasi Model FILSTAR tanpa Outlier .....	41
<b>Tabel 4.1</b>	Hasil Simulasi Power dari Uji-uji Data ARIMA (1,0,0) Tanpa Penambahan Outlier pada n=200 dan n=1000 .....	57
<b>Tabel 4.2</b>	Hasil Simulasi Power dari Uji-uji Data ARIMA(1,0,0) dengan Penambahan <i>Additive Outlier</i> pada n=200 dan n=1000 .....	58
<b>Tabel 4.3</b>	Hasil Simulasi Power dari Uji-uji Data ARIMA(1,0,0) dengan Penambahan <i>Innovational Outlier</i> pada n=200 dan n=1000 .....	60
<b>Tabel 4.4</b>	Hasil Simulasi Power dari Uji-uji Data ARIMA(1,0,0) dengan Penambahan Outlier <i>Level Shift</i> pada n=200 dan n=1000 .....	62
<b>Tabel 4.5</b>	Hasil Simulasi Power dari Uji-uji Data ARIMA(1,0,0) dengan Penambahan Outlier <i>Temporary Change</i> pada n=200 dan n=1000 .....	64
<b>Tabel 4.6</b>	Hasil Simulasi Power dari Uji-uji Data LSTAR Tanpa Penambahan Outlier pada n=200 dan n=1000 .....	69
<b>Tabel 4.7</b>	Hasil Simulasi Power dari Uji-uji Data LSTAR dengan Penambahan <i>Additive Outlier</i> pada n=200 dan n=1000 .....	71
<b>Tabel 4.8</b>	Hasil Simulasi Power dari Uji-uji Data LSTAR dengan Penambahan <i>Innovational Outlier</i> pada n=200 dan n=1000 .....	73
<b>Tabel 4.9</b>	Hasil Simulasi Power dari Uji-uji Data LSTAR dengan Penambahan Outlier <i>Level Shift</i> pada n=200 dan n=1000 .....	75
<b>Tabel 4.10</b>	Hasil Simulasi Power dari Uji-uji Data LSTAR dengan Penambahan Outlier <i>Temporary Change</i> pada n=200 dan n=1000 .....	76

<b>Tabel 4.11</b>	Hasil Simulasi Power dari Uji-uji Data ARFIMA Tanpa Penambahan Outlier pada n=200 dan n=1000 .....	66
<b>Tabel 4.12</b>	Hasil Simulasi Power dari Uji-uji Data ARFIMA dengan Penambahan <i>Additive Outlier</i> pada n=200 dan n=1000 .....	80
<b>Tabel 4.13</b>	Hasil Simulasi Power dari Uji-uji Data ARFIMA dengan Penambahan <i>Innovational Outlier</i> pada n=200 dan n=1000 .....	82
<b>Tabel 4.14</b>	Hasil Simulasi Power dari Uji-uji Data ARFIMA dengan Penambahan Outlier <i>Level Shift</i> pada n=200 dan n=1000 .....	84
<b>Tabel 4.15</b>	Hasil Simulasi Power dari Uji-uji Data ARFIMA dengan Penambahan Outlier <i>Temporary Change</i> pada n=200 dan n=1000 .....	86
<b>Tabel 4.16</b>	Hasil Simulasi Power dari Uji-uji Data FILSTAR tanpa Penambahan Outlier pada n=200 dan n=1000 .....	89
<b>Tabel 4.17</b>	Hasil Simulasi Power dari Uji-uji Data FILSTAR dengan Penambahan <i>Additive Outlier</i> pada n=200 dan n=1000 .....	91
<b>Tabel 4.18</b>	Hasil Simulasi Power dari Uji-uji Data FILSTAR dengan Penambahan <i>Innovational Outlier</i> pada n=200 dan n=1000 .....	93
<b>Tabel 4.19</b>	Hasil Simulasi Power dari Uji-uji Data FILSTAR tanpa Penambahan Outlier <i>Level Shift</i> pada n=200 dan n=1000 .....	96
<b>Tabel 4.20</b>	Hasil Simulasi Power dari Uji-uji Data FILSTAR tanpa Penambahan Outlier <i>Temporary Change</i> pada n=200 dan n=1000 .....	99
<b>Tabel 4.21</b>	Pengujian Long Memory dan Nonlinieritas Return Saham .....	100
<b>Tabel 4.22</b>	Pengujian Outlier pada Return Saham Bank Negara Indonesia.....	101
<b>Tabel 4.23</b>	Estimasi Parameter Model ARFIMA .....	104
<b>Tabel 4.24</b>	Pengujian <i>White Noise</i> Residual Model ARFIMA (1,0.098,1).....	104
<b>Tabel 4.25</b>	Pengujian Normalitas dengan Statistik Uji Kolmogorov-Smirnov .....	105
<b>Tabel 4.26</b>	Hasil Ramalan Model ARFIMA (1,0.098,1) .....	107
<b>Tabel 4.27</b>	Hasil Estimasi Parameter Model LSTAR .....	108
<b>Tabel 4.28</b>	Pengujian <i>White Noise</i> Residual Model LSTAR .....	108

<b>Tabel 4.29</b>	Pengujian Normalitas Residual Model LSTAR dengan Statistik Uji Kolmogorov-Smirnov .....	109
<b>Tabel 4.30</b>	Hasil Ramalan Model LSTAR .....	110
<b>Tabel 4.31</b>	Differencing Fractional Data <i>Return Saham BNI</i> .....	111
<b>Tabel 4.32</b>	Estimasi Parameter Model FILSTAR.....	111
<b>Tabel 4.33</b>	Pengujian <i>White Noise</i> Residual Model FILSTAR .....	112
<b>Tabel 4.34</b>	Pengujian Normalitas Residual Model FILSTAR dengan Statistik Uji Kolmogorov-Smirnov .....	113
<b>Tabel 4.35</b>	Hasil Ramalan Model FILSTAR.....	114
<b>Tabel 4.36</b>	Perbandingan Antara Model ARFIMA, LSTAR dan FILSTAR ...	115





## DAFTAR LAMPIRAN

<b>Lampiran 1</b>	Sintaks Program R untuk Data Bangkitan ARIMA tanpa Outlier.....	127
<b>Lampiran 2</b>	Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek <i>Additive Outlier</i> .....	128
<b>Lampiran 3</b>	Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek <i>Innovational Outlier</i> .....	129
<b>Lampiran 4</b>	Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek Outlier <i>Level Shift</i> .....	130
<b>Lampiran 5</b>	Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek Outlier <i>Temporary Change</i> .....	131
<b>Lampiran 6</b>	Sintaks Program R untuk Data Bangkitan ARFIMA tanpa Outlier.....	132
<b>Lampiran 7</b>	Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek <i>Additive Outlier</i> .....	133
<b>Lampiran 8</b>	Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek <i>Innovational Outlier</i> .....	134
<b>Lampiran 9</b>	Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek Outlier <i>Level Shift</i> .....	135
<b>Lampiran 10</b>	Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek Outlier <i>Temporary Change</i> .....	136
<b>Lampiran 11</b>	Sintaks Program R untuk Data Bangkitan LSTAR tanpa Outlier .....	137
<b>Lampiran 12</b>	Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek <i>Additive Outlier</i> .....	138
<b>Lampiran 13</b>	Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek <i>Innovational Outlier</i> .....	139
<b>Lampiran 14</b>	Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek Outlier <i>Level Shift</i> .....	140

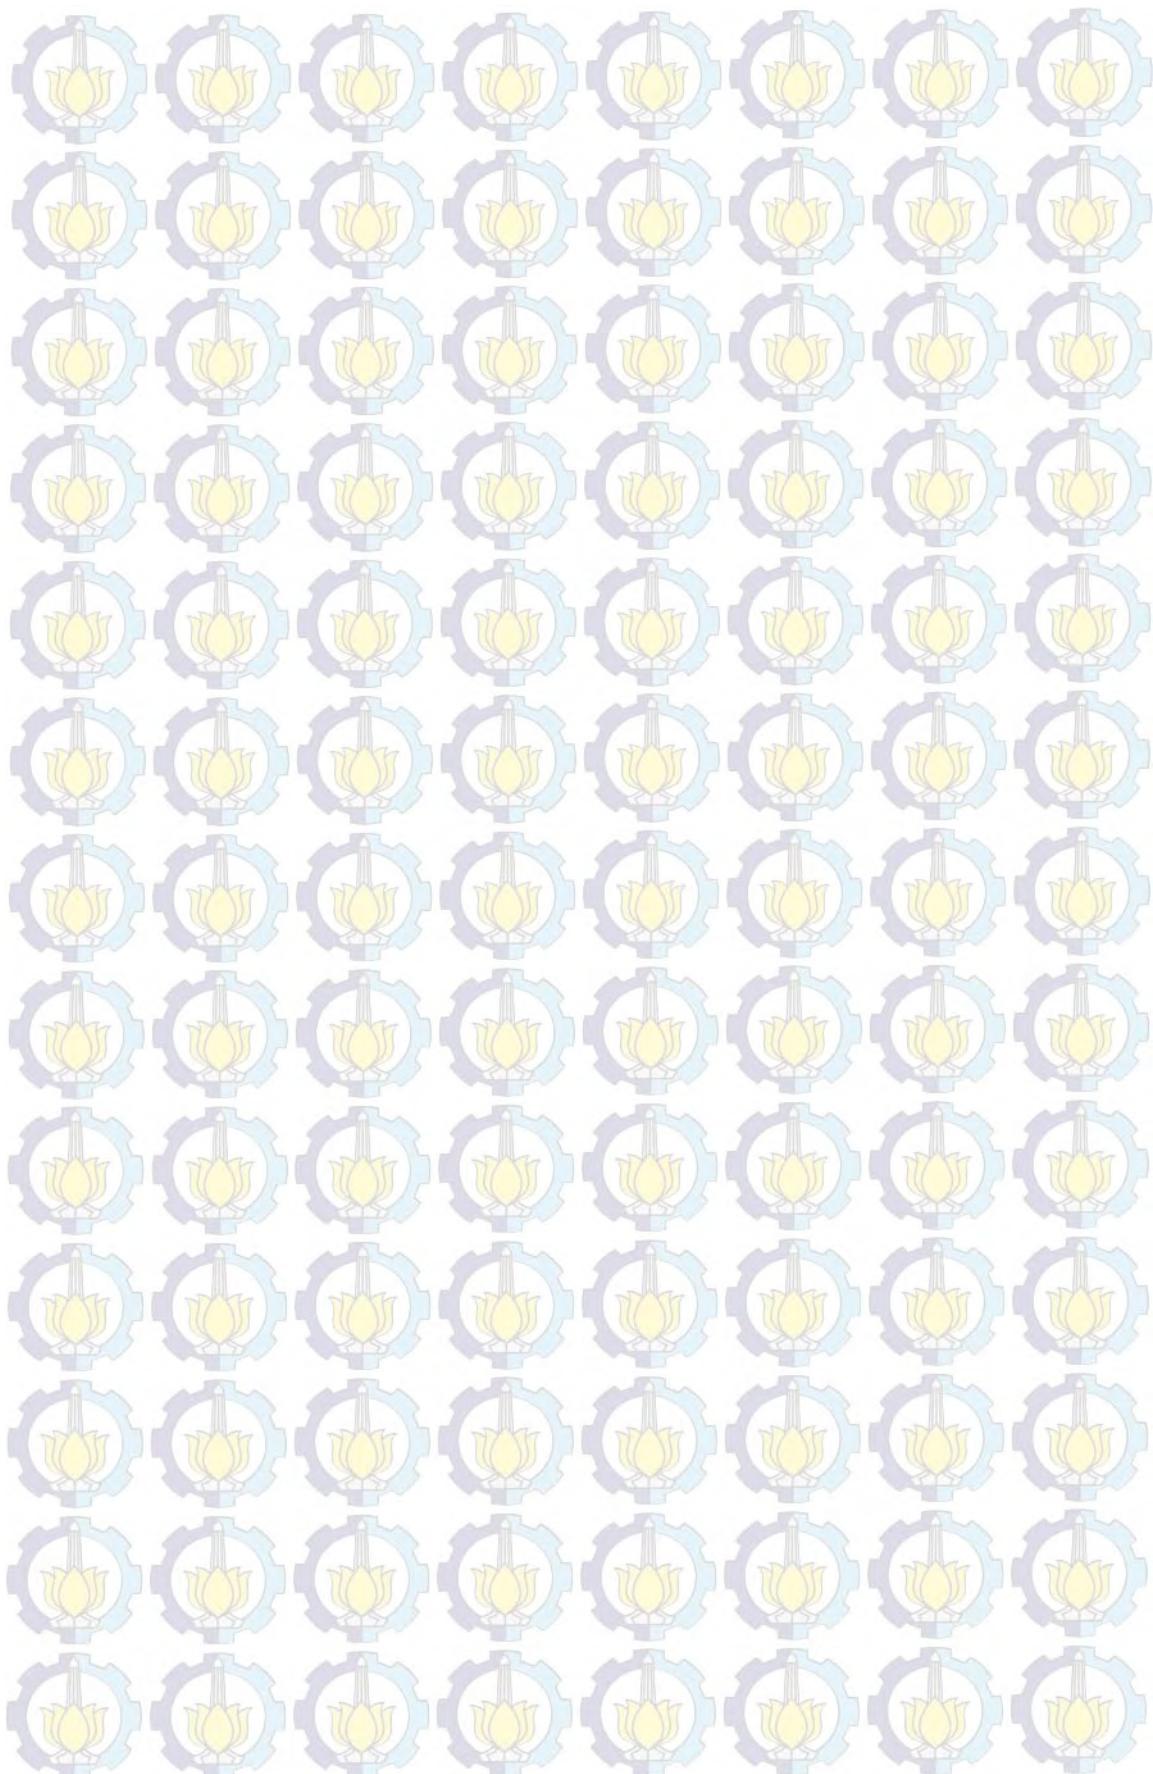
<b>Lampiran 15</b> Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek Outlier <i>Temporary Change</i> .....	141
<b>Lampiran 16</b> Sintaks Program R untuk Data Bangkitan FILSTAR tanpa Outlier.....	142
<b>Lampiran 17</b> Sintaks Program R untuk Data Bangkitan FILSTAR dengan Efek <i>Additive Outlier</i> .....	143
<b>Lampiran 18</b> Sintaks Program R untuk Data Bangkitan FILSTAR dengan Efek <i>Innovational Outlier</i> .....	144
<b>Lampiran 19</b> Sintaks Program R untuk Data Bangkitan FILSTAR dengan Efek Outlier <i>Level Shift</i> .....	145
<b>Lampiran 20</b> Sintaks Program R untuk Data Bangkitan FILSTAR dengan Efek Outlier <i>Temporary Change</i> .....	146
<b>Lampiran 21</b> Data Return Saham Bank negara Indonesia .....	147
<b>Lampiran 22</b> Pengujian Stasioneritas Data <i>Return</i> Saham Bank Indonesia dengan Dickey Fuller Test dengan Software R versi 3.0.0 .....	147
<b>Lampiran 23</b> Pendekripsi Tipe Outlier Data <i>Return</i> Saham Bank Negara Indonesia dengan Dickey Fuller Test dengan Software R versi 3.0.0 .....	148
<b>Lampiran 24</b> Estimasi Model ARFIMA (R versi 3.0.0) .....	149
<b>Lampiran 25</b> Pengujian Residual Model ARFIMA (R versi 3.0.0) .....	149
<b>Lampiran 26</b> Estimasi Model LSTAR (R versi 3.0.0).....	149
<b>Lampiran 27</b> Pengujian Residual Model LSTAR (R versi 3.0.0) .....	150
<b>Lampiran 28</b> Estimasi Model FILSTAR (R versi 3.0.0) .....	151
<b>Lampiran 29</b> Pengujian Residual Model FILSTAR (R versi 3.0.0).....	152

## DAFTAR GAMBAR

<b>Gambar 4.1</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA Tanpa Tambahan Outlier .....	56
<b>Gambar 4.2</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan Outlier <i>Additive</i> .....	58
<b>Gambar 4.3</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan <i>Innovational Outlier</i> .....	60
<b>Gambar 4.4</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan Outlier <i>Level Shift</i> .....	61
<b>Gambar 4.5</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan Outlier <i>Temporary Change</i> .....	63
<b>Gambar 4.6</b>	Perbandingan Uji Terasvirta dan Uji White saat n=200 pada Data Bangkitan ARIMA tanpa outlier (a), ARIMA dengan <i>Additive Outlier</i> (b), ARIMA dengan outlier <i>Level Shift</i> (c), ARIMA dengan outlier <i>Temporary Change</i> (d) dan ARIMA dengan <i>Innovational Outlier</i> (e).....	65
<b>Gambar 4.7</b>	Perbandingan Uji Terasvirta dan Uji White saat n=1000 pada Data Bangkitan ARIMA tanpa outlier (a), ARIMA dengan <i>Additive Outlier</i> (b), ARIMA dengan outlier <i>Level Shift</i> (c), ARIMA dengan outlier <i>Temporary Change</i> (d) dan ARIMA dengan <i>Innovational Outlier</i> (e).....	66
<b>Gambar 4.8</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR Tanpa Adanya Efek Outlier .....	68
<b>Gambar 4.9</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek Outlier <i>Additive</i> .....	70
<b>Gambar 4.10</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek <i>Innovational Outlier</i> .....	72
<b>Gambar 4.11</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek Outlier <i>Level Shift</i> .....	74

<b>Gambar 4.12</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek Outlier <i>Temporary Change</i> .....	75
<b>Gambar 4.13</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA Tanpa Adanya Efek Outlier .....	77
<b>Gambar 4.14</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek Outlier <i>Additive</i> .....	79
<b>Gambar 4.15</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek <i>Innovational Outlier</i> .....	81
<b>Gambar 4.16</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek Outlier <i>Level Shift</i> .....	83
<b>Gambar 4.17</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek Outlier <i>Temporary Change</i> .....	85
<b>Gambar 4.18</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR tanpa Adanya Efek Outlier .....	88
<b>Gambar 4.19</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek Outlier <i>Additive</i> .....	90
<b>Gambar 4.20</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek <i>Innovational Outlier</i> .....	93
<b>Gambar 4.21</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek Outlier <i>Level Shift</i> .....	95
<b>Gambar 4.22</b>	Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek Outlier <i>Temporary Change</i> .....	98
<b>Gambar 4.23</b>	Jenis Outlier pada Data Return Saham Bank Negara Indonesia.....	101
<b>Gambar 4.24</b>	Plot Time Series Return Saham Bank Negara Indonesia .....	102

<b>Gambar 4.25</b>	Plot ACF (a) dan PACF (b) Return Saham Bank Negara Indonesia.....	102
<b>Gambar 4.26</b>	Plot Periodogram <i>Return Saham Bank Negara Indonesia</i> .....	103
<b>Gambar 4.27</b>	Histogram Residual Model ARFIMA (1,0.098,1) .....	105
<b>Gambar 4.28</b>	<i>Graphycal Summary</i> dari Residual Model ARFIMA (1,0.098,1).....	106
<b>Gambar 4.29</b>	Hasil Ramalan Model ARFIMA (1,0.098,1) .....	106
<b>Gambar 4.30</b>	Histogram Residual Model LSTAR .....	109
<b>Gambar 4.31</b>	<i>Graphycal Summary</i> dari Residual Model LSTAR .....	110
<b>Gambar 4.32</b>	Histogram Residual Model FILSTAR .....	113
<b>Gambar 4.33</b>	<i>Graphycal Summary</i> dari Residual Model FILSTAR .....	114
<b>Gambar 4.34</b>	RMSE per Tahap pada Model ARFIMA.....	115
<b>Gambar 4.35</b>	RMSE per Tahap pada Model LSTAR .....	116
<b>Gambar 4.36</b>	RMSE per Tahap pada Model FILSTAR .....	116



# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang

Analisis *time series* merupakan salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilitas keadaan yang akan datang dalam rangka pengambilan keputusan. Pemodelan time series seringkali dikaitkan dengan proses peramalan (*forecasting*) suatu nilai karakteristik tertentu pada periode mendatang. Peramalan adalah menduga atau memperkirakan suatu keadaan di masa yang akan datang berdasarkan keadaan masa lalu dan sekarang yang diperlukan untuk menetapkan kapan suatu peristiwa akan terjadi, sehingga tindakan yang tepat dapat dilakukan (Makridakis dan Hibdon, 1999). Pada umumnya peramalan time series dilakukan dengan menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA), *exponential smoothing*, dekomposisi atau regresi. Meskipun pendekatan semacam ini efisien untuk peramalan time series, namun masih menunjukkan kekurangan ketika terjadi gangguan noise atau data-data yang berfluktuasi ekstrim. Data yang berfluktuasi ekstrim dapat mengindikasikan adanya suatu outlier. Fluktuasi yang ekstrim tersebut dapat disebabkan oleh berbagai faktor baik faktor eksternal maupun faktor internal, seperti bencana alam, peraturan pemerintah, kestabilan ekonomi, kerusuhan, dan terorisme. Terdapat empat macam jenis outlier yaitu Outlier *Additive* (AO), Outlier *Level Shift* (LS), Outlier *Innovational* (IO) dan Outlier *Temporary Change* (TC). Adanya data outlier ini akan membuat analisis terhadap serangkaian data menjadi bias, atau tidak mencerminkan fenomena yang sebenarnya. Istilah outlier juga sering dikaitkan dengan nilai ekstrim, baik ekstrim besar maupun ekstrim kecil. Salah satu analisa sifat yang seringkali dipengaruhi oleh nilai ekstrim adalah power dari uji-uji statistik untuk identifikasi.

*Long memory* adalah salah satu fenomena dalam *time series* yang merupakan kondisi dimana setiap observasi memiliki korelasi yang cukup kuat dengan observasi lainnya meskipun jarak waktu antar observasi cukup jauh.

Kasus yang memiliki kecenderungan bersifat *long memory* salah satunya adalah pada *return* saham. *Long memory* dicirikan oleh plot *Autocorrelation Function* (ACF) yang turun lambat secara *hyperbolic* atau juga dari nilai *difference* yang tidak bulat (*fractional*). Plot ACF *Short Memory* dapat menyerupai *Long Memory*, hal ini dikemukakan oleh Diebold dan Inoue (2001), kemudian banyak model *nonlinier* dapat dengan mudah digolongkan ke dalam *Long Memory*, dikemukakan oleh Kuswanto dan Sibertsen (2008), yang dikenal sebagai *Spurious Long Memory*. Parameter *differencing* ini biasanya diestimasi menggunakan GPH estimator yang diperkenalkan oleh Geweke dan Hudak (1983). Statistik uji yang dikembangkan untuk mendeteksi adanya *long memory* pada data, dapat dilakukan estimasi *d* dengan menggunakan *Hurst Exponent* maupun uji *Rescaled Range Statistics* (R/S) dan *Modified Rescaled Range Statistics* (MR/S), *Rescaled Variance* (V/S), GPH (*Geweke Poter Hudak*) Estimator dan lain sebagainya. Pada kenyataannya, indikator parameter *fractionally differencing* maupun uji-uji statistika seperti V/S test, R/S test mempunyai kekuatan yang lemah untuk bisa mendeteksi fenomena *long memory* yang sesungguhnya (Kuswanto, 2011).

Penelitian dengan pendekatan *long memory* telah banyak dilakukan oleh peneliti sebelumnya terutama pada data *return* saham. Kuswanto dan Koesniawanto (2013) melakukan peramalan pada data *return* saham Bank Mandiri, Bank BRI dan Bank BNI, penelitian tersebut menghasilkan bahwa tiga saham yang dijadikan studi kasus lebih baik dimodelkan dengan ARFIMA daripada ESTAR karena menghasilkan *forecast* yang akurasinya lebih baik. Wojtowicz dan Gurgul (2009) menganalisis hubungan antara varians parameter *long memory* dan estimasi parameter *long memory* dengan menggunakan simulasi FIGARCH (0,d,0) dan FIGARCH (1,d,1), hasilnya menunjukkan terdapat perbedaan. Danilenko (2009) meneliti indeks saham pada pasar saham dengan menggunakan analisis R/S dan *Hurst Exponential*, penelitian ini difokuskan pada perhitungan dan evaluasi parameter Hurst. Ding *et al.* (1993) meneliti tentang *return* saham, hasil dari penelitian ini adalah tidak adanya hubungan substantial antara absolut *return* saham dengan *return* saham itu sendiri, akan tetapi transformasi dari absolut *return* memiliki autokorelasi yang cukup tinggi pada lag panjang. Caporale dan Gil-Alana (2010) menganalisis tentang peristiwa *long*

*memory* dan *fractionally integration* pada data saham, penelitian ini membuktikan bahwa tingkat integrasi rendah berkaitan dengan frekuensi data yang rendah. Cont (2005) menganalisis tentang penggunaan *long memory* pada harga saham, nilai tukar valuta asing, indeks pasar dan harga komoditas, penelitian ini membahas mengenai relevansi konsep-konsep tersebut dalam konteks pemodelan keuangan, hubungan dengan prinsip-prinsip dasar teori keuangan dan penjelasan ekonomi. Eitelman dan Vitanza (2008) menguji *short memory* dan *long memory* pada harga aset di 44 negara berkembang dan industri, menggunakan metodologi Contraryto (1996) analisis *long memory* yang dilakukan menunjukkan bahwa pemotongan lag yang dilakukan tidak mempunyai pengaruh yang signifikan. Liu (2000) melakukan pemodelan *long memory* pada volatilitas pasar saham, didapatkan hasil bahwa fitur dari proses yang menghasilkan memori panjang adalah distribusi durasi berat ekor dan volatilitas stokastik rezim switching (RSSV) merupakan model yang terbaik. Lo (1991) mengembangkan metode modifikasi dari uji R/S dengan membahas uji R/S klasik menggunakan analisis varians R/S. Lo (1991) meneliti tentang kasus *long memory* pada *return* saham di US menggunakan *R/S statistic test*, didapatkan hasil bahwa percobaan mengindikasikan bahwa modifikasi *R/S test* mempunyai power yang lemah untuk model long memory pada data *return* saham di US menggunakan data CRSP. Cheung dan Lai (1995) menemukan bukti persisten dalam beberapa seri *return* saham internasional. Crato (1994) menunjukkan bukti persisten untuk *return* saham negara G-7 yang menggunakan estimasi maksimum. Fokus utama dari studi ini adalah perilaku *long memory* stokastik *return* saham dalam pasar modal utama. Sewell (2011) meneliti tentang karakteristik *time series* keuangan, didapatkan hasil terdapat sekitar 30% bahwa *return* saham menunjukkan kejadian *long memory*, 50% menunjukkan bahwa *return* valuta asing menunjukkan kejadian *long memory* dan 80% kemungkinan bahwa volatilitas pasar menunjukkan kejadian *long memory*. Barkoulas *et al.* (2000) meneliti mengenai fenomena *long memory* pada data saham di Yunani, pada penelitian ini estimasi parameter *fractionally differencing* menggunakan metode regresi spektral, didapatkan hasil bahwa long memory mempengaruhi secara signifikan positif pada saham Yunani, parameter *fractionally differencing* memberikan peningkatan pada akurasi *out-of-sample* dari

peramalan. Fama dan French (1988) menemukan bahwa autokorelasi *return* saham membentuk pola berbentuk U. Nilai autokorelasi menjadi negatif untuk *return* saham 2 tahun, mencapai nilai minimum untuk *return* saham 3-5 tahun, dan kemudian bergerak kembali ke nilai 0.

Selain mengikuti fenomena *long memory*, return saham juga mengikuti fenomena nonlinier. Penelitian menggunakan model *nonlinier time series* telah banyak dilakukan sebelumnya, penelitian tersebut sebagian besar menggunakan data *return* saham. Isfan *et al.* (2007) membahas mengenai jaringan syaraf tiruan yang dapat digunakan untuk mengungkap nonlinieritas yang ada di pasar saham, uji nonlinieritas yang digunakan yaitu uji BDS, empat jenis jaringan syaraf digunakan pada pasar saham untuk mendapat model ramalan dengan menggunakan beberapa algoritma optimasi nonlinier heuristik yang bertujuan untuk meminimalkan kesalahan prediksi, didapatkan 4 model yang mirip dengan hasil. Hinich dan Patterson (1985) menganalisis bahwa korelasi nol dalam *return* saham menyiratkan independensi statistik jika dan hanya jika memiliki distribusi probabilitas gabungan normal, kurangnya ketergantungan linear (autokorelasi serial) tidak mengesampingkan ketergantungan nonlinier dalam *return* saham yang bahkan dapat menjadi prediksi. Aranda dan Jaramilo (2008) menyelidiki kemungkinan adanya dinamika nonlinier untuk pengembalian indeks saham dan volume perdagangan di bursa pasar saham Chili, untuk menangkap fenomena nonlinier digunakan model STAR (*Smooth Transition Autoregressive*) dan menguji terhadap alternatif linear, hasil menunjukkan bahwa pasar saham Chili ditandai dengan adanya model nonlinier di kedua seri (volume perdagangan dan *return* saham) serta dalam hubungan antara keduanya. Schmidt-Mohr (1996) meramalkan volatilitas dengan menggunakan model linier dan nonlinier *time series*, dalam penelitian ini kualitas dari perkiraan sampel yang diperoleh dari berbagai model volatilitas nonlinier dievaluasi dan dibandingkan dengan peramalan model nonlinier yang lebih tua dan model linier standar. Suhartono (2008) menganalisis dua prosedur baru untuk pemilihan model di Neural Networks (NN) untuk peramalan time series, yaitu pada data *return* saham, hasil penelitian menunjukkan bahwa kombinasi antara inferensi statistik  $R^2$  tambahan

dan uji Wald adalah prosedur yang efektif untuk model NN pada peramalan *time series* data *return* saham.

Dalam perkembangannya, telah dikembangkan model yang mampu menangkap pola pada data *return* saham yaitu *long memory* dan nonlinier. Salah satu penelitian menggunakan metode kombinasi antara model *Long Memory* dan *Nonlinier* yaitu dengan menggunakan model FISTAR (*Fractional Integrated Smooth Transition Autoregressive*), di mana penelitian tersebut juga telah banyak dilakukan. Antara lain Boutahar *et al.* (2007) meneliti tentang nilai tukar efektif riil AS, model FISTAR diusulkan oleh Van Dijk, Franses dan Paap (2002) untuk kasus ketika fungsi transisi merupakan fungsi eksponensial dan dalam penelitian tersebut dikembangkan prosedur estimasi. Model ini dapat memperhitungkan proses yang ditandai fenomena yang dinamis dan persisten. Shittu dan Yaya (2010) mengkaji dinamika dan penerapan model FILSTAR (*Fractional Integrated Logistic Smooth Transition Autoregressive*) pada tingkat inflasi dengan maksud untuk memperoleh estimasi parameter yang lebih baik. Hasil yang lebih baik dibandingkan dengan Van Dijk, *et al.* (2002) memperoleh beberapa inflasi dengan atribut yang menarik di negara maju dan berkembang. Benamar (2009) menguji validitas daya beli di negara-negara Afrika Utara (PPP). Model FISTAR yang digunakan dalam penelitian tersebut memberikan informasi lebih lanjut kepada para pembuat kebijakan untuk menghadapi guncangan nilai tukar, terutama, ketika guncangan ini ditandai dengan proses *long memory*. Smallwood (2008) meneliti data tentang nilai tukar riil dari G-7 negara AS, terutama di negara-negara Uni Eropa. Perkiraan penyimpangan dari PPP menggunakan koreksi median *unbiased* untuk model *autoregressive* linier konvensional menguatkan bukti yang ada terkait dengan paradoks PPP selama empat tahun untuk jumlah tahun yang tak terbatas. Sebaliknya, untuk setiap negara Uni Eropa, perhitungan untuk threshold hasil non-linearitas dalam estimasi kurang dari tiga tahun untuk model *fractional long memory*.

Pada penelitian ini akan dilakukan simulasi terhadap data time series untuk mengetahui performansi dari uji Terasvirta, uji White dan uji GPH estimator. Data time series yang digunakan dalam penelitian ini yaitu data yang memiliki sifat long memory dan short memory dimana untuk kedua data tersebut

dibangkitkan sifat linier dan nonlinier. Untuk data yang mengikuti proses linier short memory menggunakan model ARIMA (*Autoregressive Integrated Moving Average*), untuk data yang mengikuti proses linier long memory menggunakan model ARFIMA (*Autoregressive Fractional Integrated Moving Average*), untuk data yang mengikuti proses nonlinier short memory menggunakan model LSTAR (*Logistic Smoothing Transition Autoregressive*) dan untuk data yang mengikuti proses nonlinier long memory menggunakan model FILSTAR (*Fractional Integrated Logistic Smoothing Transition Autoregressive*) dengan dan tanpa melibatkan adanya efek outlier. Pada penelitian ini akan dipelajari power dari ketiga pengujian tersebut apakah dengan adanya outlier mempengaruhi kerobustan hasil pengujian sehingga dapat mempengaruhi kesimpulan dari pendekripsi awal. Penelitian tentang performansi dari ketiga uji tersebut jika ditambahkan dengan adanya efek outlier pada data bangkitan dengan mengikuti proses-proses tersebut belum pernah dilakukan. Salah satu penerapan yang dilakukan pada penelitian ini yaitu penerapan pada data *return* saham. Sebagaimana yang telah banyak diteliti pada penelitian-penelitian sebelumnya, Ding et al. (1993) menyatakan bahwa volatilitas *return* saham baik dijelaskan dengan proses *Long Memory*. Dependensi jangka panjangnya secara umum terdeteksi dalam kuadrat atau harga mutlak dari nilai balik modal (*return*). Di sisi lain, model-model nonlinier seperti LSTAR juga sering digunakan untuk pemodelan *return* saham. Oleh karena itu, pada penelitian ini akan diidentifikasi apakah data *return* saham tergolong data linier long memory, nonlinier short memory, linier short memory ataukah nonlinier long memory. Data *return* saham yang dijadikan kasus dalam penelitian ini adalah saham yang tergolong dalam indeks LQ 45.

Hasil simulasi yang dihasilkan kemudian dikonfirmasi dengan data empiris yang diperoleh dari kejadian riil. Ramalan yang digunakan merupakan ramalan titik dengan menggunakan model ARFIMA, LSTAR dan FILSTAR dengan menggunakan kriteria pemilihan model terbaik MSE dan RMSE. Dimana semakin kecil nilai MSE dan RMSE maka semakin baik metode tersebut dalam melakukan peramalan. Hasil dari pengolahan data *return* saham Bank Negara

Indonesia akan dikonfirmasi kembali apakah sesuai dengan hasil simulasi yang telah dilakukan sebelumnya.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang, rumusan masalah yang akan dibahas dalam penelitian ini adalah sebagai berikut.

1. Bagaimana performansi uji Terasvirta, uji White dan uji GPH Estimator dari hasil simulasi untuk data bangkitan yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR dengan dan tanpa melibatkan adanya outlier ?
2. Bagaimana model yang sesuai untuk data *return* saham yang didalamnya terdapat banyak outlier?

## 1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dalam penelitian ini adalah untuk memecahkan masalah yang telah diidentifikasi sebelumnya. Adapun tujuan penelitian ini sebagai berikut.

1. Mendapatkan performansi uji Terasvirta, uji White dan uji GPH Estimator dari hasil simulasi untuk data bangkitan yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR dengan dan tanpa melibatkan adanya outlier.
2. Mendapatkan hasil dari model yang sesuai untuk data *return* saham yang didalamnya terdapat banyak outlier.

## 1.4 Manfaat Penelitian

Hasil penelitian ini diharapkan dapat menambah dan mengembangkan wawasan keilmuan dan pengetahuan mengenai performansi uji Terasvirta, uji White dan uji GPH estimator berdasarkan simulasi yang dilakukan pada data bangkitan yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR dengan dan tanpa penambahan outlier. Selain itu, dapat mengetahui konsisten hasil simulasi untuk aplikasi terhadap data real (*return* saham LQ 45).

## 1.5 Batasan Penelitian

Studi simulasi yang digunakan dalam penelitian ini dibatasi pada model AR (1), sedangkan jenis outlier yang digunakan yaitu outlier *Additive outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC). Terdapat banyak jenis perusahaan yang masuk ke dalam saham LQ 45 seperti yang dijelaskan pada Bab 2. Penelitian ini dibatasi pada data *return* saham PT Bank Negara Indonesia, hal ini karena berdasarkan penelitian terdahulu saham bank tersebut merupakan yang memiliki pola data nonlinier dan long memory. Data yang digunakan merupakan data harian dari tanggal 8 Juni 2004 sampai dengan 28 November 2014. Model yang digunakan dalam penelitian ini dibatasi pada model *long memory* yang digunakan yaitu model ARFIMA (*Autoregressive Fractionally Integrated Moving Average*), model *nonlinier* yaitu model LSTAR (*Logistic Smooth Transition Autoregressive*) dan juga model kombinasi antara model *long memory* dan *nonlinier* yaitu model simultan FILSTAR (*Fractionally Integrated Logistic Smoothing Transition Autoregressive*).

## BAB 2

### TINJAUAN PUSTAKA

#### 2.1 Analisis Deret Waktu (*Time Series*)

*Time series* merupakan serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadianya dengan interval waktu yang tetap. Tujuan mempelajari time series adalah pemahaman dan gambaran untuk membuat suatu mekanisme, peramalan nilai masa depan dan optimalisasi sistem kontrol (Wei, 2006).

#### 2.2 Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ARIMA merupakan penggabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) serta proses *differencing* (orde  $d$  untuk data non musiman, orde  $D$  untuk data musiman) terhadap data *time series* (Wei, 2006).

##### 2.2.1 Model ARIMA Non Musiman

Secara umum, model ARIMA non musiman dapat dituliskan sebagai ARIMA  $(p,d,q)$  dengan model matematis sebagai berikut (Wei, 2006).

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B)a_t \quad (2.1)$$

dengan,

$(p,d,q)$  : orde AR ( $p$ ), orde *differencing* ( $d$ ), orde MA ( $q$ ) untuk data non musiman.

$\phi_p(B)$  : koefisien komponen AR non musiman dengan derajat  $p$ , penjabarannya sebagai berikut.

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

$\theta_q(B)$  : koefisien komponen MA non musiman dengan derajat  $q$ , penjabarannya sebagai berikut.

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

$\theta_0$  : koefisien trend deterministik

$a_t$

: nilai residual pada saat  $t$

### 2.2.2 Model ARIMA Musiman

Secara umum, model ARIMA musiman multiplicative dapat dituliskan sebagai ARIMA  $(P,D,Q)^S$ . Model *Box-Jenkins multiplicative* untuk pemodelan ARIMA musiman adalah sebagai berikut (Wei, 2006).

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D Z_t = \theta_q(B)\Theta_Q(B^S)a_t \quad (2.2)$$

dengan,

$(p,d,q)$  : orde AR ( $p$ ), orde *differencing* ( $d$ ), orde MA ( $q$ ) untuk data non musiman.

$(P,D,Q)^S$  : orde AR ( $P$ ), orde *differencing* ( $D$ ), orde MA ( $Q$ ), orde musiman ( $S$ ) untuk data musiman

$\phi_p(B)$  : koefisien komponen AR non musiman dengan derajat  $p$ , penjabarannya sebagai berikut.

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

$\Phi_P(B^S)$  : koefisien komponen AR musiman  $S$  dengan derajat  $P$ , penjabarannya sebagai berikut.

$$\Phi_P(B^S) = (1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_p B^{pS})$$

$\theta_q(B)$  : koefisien komponen MA non musiman dengan derajat  $q$ , penjabarannya sebagai berikut.

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

$\Theta_Q(B^S)$  : koefisien komponen MA musiman  $S$  dengan derajat  $Q$ , penjabarannya sebagai berikut.

$$\Theta_Q(B^S) = (1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS})$$

$a_t$  : nilai residual pada saat  $t$

$(1-B)^d$  : operator untuk *differencing* orde  $d$

$(1-B^S)^D$  : operator untuk *differencing* Musiman  $S$  orde  $D$

Pembentukan model ARIMA biasanya dilakukan dengan menggunakan prosedur yang diungkapkan oleh Box-Jenkins. Prosedur tersebut

antara lain identifikasi model, estimasi parameter, pemilihan model terbaik, cek diagnosa dan peramalan.

### 2.3 Identifikasi Model

Identifikasi model ARIMA yang dimulai dengan mengidentifikasi kestasioneran data, *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF).

#### 2.3.1 Stasioner

Langkah pertama yang dilakukan dalam identifikasi model adalah membuat plot *time series*, ACF dan PACF untuk mengidentifikasi kestasioneran secara mean maupun varians. Jika data yang diolah tidak stasioner dalam mean, maka dapat diatasi dengan melakukan *differencing* (pembedaan) yang menghasilkan *series* (deret) yang stasioner. Proses *differencing* orde ke-*d* dapat dituliskan sebagai berikut

$$\Delta^d Y_t = (1 - B)^d Y_t \quad (2.3)$$

Data yang tidak stasioner dalam varians diatasi dengan menggunakan transformasi Box-Cox yang dituliskan sebagai berikut.

$$T(Y_t) = Y_t^{(\lambda)} = \frac{Y_t^\lambda - 1}{\lambda} \quad (2.4)$$

Tabel 2.1 berikut menyajikan beberapa bentuk transformasi Box-Cox berdasarkan nilai  $\lambda$  yang bersesuaian.

**Tabel 2.1** Transformasi Box-Cox

Nilai Estimasi $\lambda$	Transformasi
-1,0	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	$Y_t$ (tidak ada transformasi)

### 2.3.2 Autocorrelation Function (ACF)

ACF merupakan suatu koefisien yang menunjukkan hubungan linier pada data time series antara  $Y_t$  dengan  $Y_{t+k}$ . ACF dapat digunakan untuk mendeteksi ketidakacakannya dalam data dan untuk mengidentifikasi model time series yang tepat jika data tidak acak. Dalam suatu proses stasioner  $\{Y_t\}$  diketahui bahwa nilai  $E(Y_t) = \mu$  dan nilai  $\text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$ , dimana nilai mean dan varians tersebut konstan. Persamaan dari kovarians antara  $\{Y_t\}$  dengan  $\{Y_{t+k}\}$  adalah sebagai berikut.

$$\gamma_k = \text{cov}(Y_t, Y_{t+k}) = E(Y_t - \mu)(Y_{t+k} - \mu) \quad (2.5)$$

dan korelasi antara  $\{Y_t\}$  dengan  $\{Y_{t+k}\}$  adalah sebagai berikut (Wei, 2006).

$$\rho_k = \text{corr}(Y_t, Y_{t+k}) = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} = \frac{\gamma_k}{\gamma_0} \quad (2.6)$$

$\gamma_k$  merupakan fungsi autokovarians dan  $\rho_k$  merupakan fungsi autokorelasi karena menjelaskan kovarians dan korelasi antara  $Y_t$  dan  $Y_{t+k}$  dari proses yang sama dan hanya terpisah oleh lag waktu ke  $k$ .

### 2.3.3 Partial Autocorrelation Function (PACF)

PACF berfungsi untuk mengukur tingkat keeratan hubungan (korelasi) antara pasangan data  $Y_t$  dan  $Y_{t+k}$  setelah pengaruh variabel  $Y_{t+1}, Y_{t+2}, \dots, Y_{t+k-1}$  dihilangkan. Perhitungan nilai PACF sampai lag ke  $k$  dimulai dari menghitung  $\hat{\phi}_1 = \rho_1$ , sedangkan untuk menghitung  $\hat{\phi}_{kk}$  dilakukan dengan menggunakan rumus sebagai berikut.

$$\hat{\phi}_{kk} = \text{corr}(Y_t, Y_{t+k} | Y_{t+1}, \dots, Y_{t+k-1}) \quad (2.7)$$

sehingga didapatkan perhitungan PACF sampai lag ke  $k$  sebagai berikut.

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{k-1,j} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \text{ dengan} \quad (2.8)$$

$$\hat{\rho}_k = \begin{cases} \hat{\rho}_1 & \text{jika } k = 1 \\ \frac{\hat{\rho}_k - \sum_{j=1}^k \hat{\rho}_{k-j} \hat{\rho}_{k-j}}{1 - \sum_{j=1}^k \hat{\rho}_{k-j} \hat{\rho}_{k-j}} & \text{jika } k = 2, 3, \dots \end{cases}$$

## 2.4 Identifikasi Model ARIMA

Identifikasi model ARIMA dapat dilakukan dengan melihat plot *time series*, plot ACF dan PACF. Plot ACF dan PACF digunakan untuk menentukan orde p dan q dari model ARIMA non musiman serta P dan Q dari model ARIMA musiman. Secara teoritis, bentuk-bentuk plot ACF dan PACF dari model ARIMA adalah seperti pada Tabel 2.2 (Wei, 2006).

**Tabel 2.2** Bentuk ACF dan PACF Teoritis untuk Model ARIMA Non Musiman

Model	ACF	PACF
AR( $p$ )	turun cepat secara eksponensial ( <i>dies down</i> )	terputus setelah lag ke- $p$
MA( $q$ )	terputus setelah lag ke- $q$	turun cepat secara eksponensial ( <i>dies down</i> )
ARMA( $p,q$ )	Turun cepat secara eksponensial menuju nol	Turun cepat secara eksponensial menuju nol

**Tabel 2.3** Bentuk ACF dan PACF untuk model ARIMA Musiman

Model	ACF	PACF
AR( $P$ )	Turun cepat secara eksponensial menuju nol ( <i>dies down</i> ) pada level musiman	Signifikan pada lag $S, 2S, 3S, \dots, PS$
MA( $Q$ )	Terputus setelah lag ke- $Q$ pada level musiman	turun cepat secara eksponensial ( <i>dies down</i> ) pada level musiman
ARMA( $P,Q$ )	Turun cepat secara eksponensial pada level musiman	Turun cepat secara eksponensial pada level musiman

## 2.5 Penaksiran Parameter Model ARIMA

Metode estimasi parameter yang digunakan adalah metode *Least Square Estimation* atau biasa disebut dengan metode *Least Square Estimation*. Untuk model AR(1) model ini dapat dilihat sebagai model regresi. Metode ini merupakan suatu metode yang dilakukan dengan cara mencari nilai parameter

yang meminimumkan jumlah kuadrat kesalahan (selisih antara nilai aktual dengan ramalan) yang dinyatakan dalam persamaan berikut.

$$S(\phi, \mu) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2 \quad (2.9)$$

Berdasarkan prinsip dari metode *Least Square*, penaksiran  $\phi$  dan  $\mu$  dilakukan dengan meminimumkan  $S(\phi, \mu)$ . Hal ini dilakukan dengan menurunkan  $S(\phi, \mu)$  terhadap  $\mu$  dan  $\phi$  kemudian disamadengankan nol. Meminimumkan  $S(\phi, \mu)$  terhadap  $\mu$  menghasilkan

$$\frac{\partial S}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.10)$$

Dengan demikian akan diperoleh nilai taksiran parameter untuk  $\mu$  dari model AR(1) sebagai berikut.

$$\hat{\mu} = \frac{\sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1}}{(n-1)(1-\phi)} \quad (2.11)$$

untuk  $n$  besar dapat ditulis sebagai berikut.

$$\sum_{t=2}^n \frac{Y_t}{n-1} \approx \sum_{t=2}^n \frac{Y_{t-1}}{n-1} \approx \bar{Y} \quad (2.12)$$

Persamaan 2.12 dapat disederhanakan menjadi

$$\hat{\mu} = \frac{\bar{Y} - \phi \bar{Y}}{1 - \phi} = \frac{\bar{Y}(1 - \phi)}{1 - \phi} = \bar{Y} \quad (2.13)$$

Dengan cara yang sama operasi turunan terhadap  $\phi$  yaitu

$$\frac{\partial S}{\partial \phi} = - \sum_{t=2}^n 2[(Y_t - \bar{Y}) - \phi(Y_{t-1} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0 \quad (2.14)$$

sehingga diperoleh nilai taksiran sebagai berikut.

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (2.15)$$

Nilai-nilai persamaan (2.13) dan (2.15) merupakan taksiran parameter  $\mu$  dan  $\phi$  (Cryer, 1986).

## 2.6 Pengujian Signifikansi Parameter

Uji signifikansi parameter dilakukan untuk mengetahui signifikansi parameter model ARIMA sehingga dapat diketahui tiap variabel yang digunakan telah berpengaruh pada  $Y_t$ . Pengujian hipotesis dilakukan dengan menggunakan uji t. Misalkan yang diuji adalah parameter MA yaitu  $\theta$ , maka hipotesis yang diuji adalah sebagai berikut

$$H_0 : \theta_i = 0 \text{ untuk } i=1,2,\dots,q$$

$$H_1 : \theta_i \neq 0$$

$$\text{Statistik uji : } t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (2.16)$$

Tolak  $H_0$  jika  $|t_{hitung}| > t_{\alpha/2, df=n-p}$  dengan  $p$  adalah banyaknya parameter atau tolak  $H_0$  jika  $p-value < \alpha$  dengan  $\alpha$  adalah tingkat signifikansi (Bowerman dan O'Connell, 1993).

## 2.7 Uji Long Memory

### 2.7.1 Estimator GPH

Estimator GPH diperkenalkan oleh Geweke dan Porter-Hudak (1983) adalah salah satu yang paling populer dan banyak digunakan untuk menguji fraksi integrasi  $d$ . Hal ini didasarkan pada koordinat  $m$  periodogram pertama

$$I_j = \frac{1}{2\pi N} \left| \sum_{t=1}^N y_t \exp(i\lambda_j t) \right|^2 \quad (2.17)$$

Dimana

$\lambda_j = 2\pi j/N$  dan  $m$  adalah bilangan bulat positif lebih kecil dari  $N$ . Idenya adalah untuk memperkirakan *spectral density* dengan periodogram dan mengambil logaritma pada kedua sisi persamaan. Ini memberikan model regresi linier dalam parameter *Long Memory* yang dapat diperkirakan dengan metode kuadrat terkecil.

Estimator diberikan oleh  $-1/2$  kali estimator *Least Square* dari parameter slope dalam regresi  $\{\log I_j : j = 1, \dots, m\}$  pada konstanta dan variabel regressor

$$\tilde{X}_j = \log|1 - \exp(-i\lambda_j)| = (1/2)\log(2 - 2\cos\lambda_j) \quad (2.18)$$

Menurut definisi tersebut, estimator GPH adalah

$$\hat{d}_{GPH} = \frac{-0,5 \sum_{j=1}^m (\tilde{X}_j - \bar{\tilde{X}}) \log I_j}{\sum_{j=1}^m (\tilde{X}_j - \bar{\tilde{X}})^2} \quad (2.19)$$

dimana  $\bar{\tilde{X}} = (1/m) \sum_{j=1}^m \tilde{X}_j$ . Estimator ini dapat dimunculkan dengan menggunakan model:

$$\log I_j = \log c_f - 2d\tilde{X}_j + \log \xi_j \quad (2.20)$$

dimana  $\tilde{X}_j$  menunjukkan frekuensi ke- $j$  Fourier dan  $\xi_j$  adalah error yang berdistribusi dan identik dengan  $-E|\log \xi_j| = 0,577$ , yang dikenal sebagai konstanta Euler.

## 2.8 Proses Long Memory

*Long memory* merupakan sifat observasi yang memiliki korelasi kuat meskipun jarak waktu antar observasi jauh, diasumsikan  $Y_t, t = 1, 2, 3, \dots, T$  adalah suatu observasi dari proses waktu diskrit dengan nilai koefisien *autocorrelation* (ACF) sebesar  $\rho_k$  pada lag ke- $k$ . Kuswanto dan Sibertsen (2007) menjelaskan bahwa suatu proses stasioner yang memiliki sifat *long memory* ketika ACF pada  $k \rightarrow \infty$  sebagai berikut:

$$\lim_{k \rightarrow \infty} \frac{\rho_k}{c_p(k)^{2d-1}} = 1 \quad (2.21)$$

dimana  $c_p$  adalah konstanta dan  $d \in (0, 0.5)$  adalah parameter *long memory*. ACF proses *long memory* akan turun secara lambat membentuk pola hiperbolik. Untuk  $d \in (-0, 0.5)$  menunjukkan bahwa proses tersebut memiliki sifat *short memory*.

Identifikasi adanya sifat *long memory* dapat dilakukan dengan melakukan beberapa metode estimasi pada nilai  $d$ , diantaranya adalah *exact maximum likelihood* (EML), *modified profile likelihood* (MPL), *Geweke Porter Hudak estimator* (GPH estimator), dan *least square*. Jika  $0 < d < 0,5$  maka proses memiliki sifat *long memory*.

### 2.8.1 ARFIMA ( $p,d,q$ )

Wei (2006) menjelaskan  $Y_t$  yang mengikuti proses ARIMA  $(p,d,q)$  dengan nilai  $d$  integer menunjukkan bahwa  $Y_t$  merupakan proses yang tidak stasioner, tetapi setelah mengalami *differencing* sebanyak  $d$  kali, maka hasil *differencing* tersebut menjadi stasioner. Agar proses menjadi stasioner, nilai  $d$  harus kurang dari 1. Proses ARIMA  $(p,d,q)$  dijelaskan dengan persamaan (2.26).

$$\phi_p(B)(1-B)^d Y_t = \theta_q(B)a_t \quad (2.22)$$

Dimana  $\phi_p(B)\theta_q(B) \neq 0$  untuk  $|B| \leq 1$  dan  $a_t$  adalah proses *white noise* dengan mean nol dan varians  $\sigma_a^2$ , agar proses stasioner dan *invertible*. Agar proses ARIMA  $(p,d,q)$  menjadi suatu proses yang stasioner dengan  $d \neq 0$ , maka dijelaskan dengan persamaan sederhana (2.23).

$$(1-B)^d Y_t = a_t \quad (2.23)$$

Untuk proses (2.23) yang stasioner, dapat ditulis sebagai

$$Y_t = (1-B)^{-d} a_t = \sum_{k=0}^{\infty} \psi_j a_{t-j} \quad (2.24)$$

atau dengan kata lain

$$(1-B)^{-d} = \sum_{j=0}^{\infty} \psi_j B^j$$

Dengan menggunakan deret Taylor, maka diperoleh persamaan binomial

$$(1-B)^{-d} = \sum_{j=0}^{\infty} \binom{-d}{j} (-B)^j = \sum_{j=0}^{\infty} \psi_j B^j \quad (2.25)$$

Dengan

$$\psi_j = (-1)^j \binom{-d}{j} = (-1)^j \frac{(-d)(-d-1)\dots(-d-j+1)}{j!} = \frac{(j+d-1)(j+d-2)\dots(j+d-j)}{j!} = \frac{\Gamma(j+d)}{\Gamma(j+1)\Gamma(d)}$$

dengan  $\Gamma()$  adalah fungsi gamma. Dengan menggunakan formula Stirling

$$\Gamma(x) \approx \sqrt{2\pi e^{-x}} x^{\frac{x-1}{2}} \text{ ketika } x \rightarrow \infty$$

maka diperoleh

$$\psi_j = \frac{\Gamma(j+d)}{\Gamma(j+1)\Gamma(d)} \approx \frac{1}{\Gamma(d)} \frac{\sqrt{2\pi} e^{-j-d} (j+d)^{j+d-\frac{1}{2}}}{\sqrt{2\pi} e^{-j-1} (j+1)^{j+1-\frac{1}{2}}} \approx \frac{1}{\Gamma(d) j^{1-d}}$$

Diketahui bahwa  $(\Psi_j)$  dapat dijumlahkan secara kuadrat (*square summable*) jika dan hanya jika  $2(1-d) > 1$ , yaitu  $d < 0,5$ . Sama halnya dengan proses yang *invertible*, yaitu jika dan hanya jika  $-0,5 < d$ . Diperoleh proses pada (2.25) atau secara umum proses pada (2.23) adalah stasioner dan *invertible* jika dan hanya jika  $-0,5 < d < 0,5$ , dan proses tersebut sering disebut sebagai model ARFIMA  $(p,d,q)$ . Proses pada (2.24) dengan  $-0,5 < d < 0,5$  disebut *fractionally integrated* (atau *differenced*) noise.

Fungsi densitas spektral untuk ARFIMA  $(p,d,q)$  dimana  $d$  bukan suatu bilangan integer seperti yang dijelaskan oleh Souza (2008) adalah

$$f(\omega) = \frac{\sigma_a^2}{2\pi} \left| 1 - e^{-i\omega} \right|^{-2d} \left| \frac{\theta_q(e^{-i\omega})}{\phi_p(e^{-i\omega})} \right|^2 \quad (2.26)$$

dimana  $i^2 = -1$  dan  $\omega$  adalah frekuensi. Berdasarkan (2.26), merujuk dari persamaan (2.26), fungsi densitas spectral menjadi persamaan (2.27) (Wei, 2006).

$$f(\omega) = \frac{\sigma_a^2}{2\pi} \left| 1 - e^{-i\omega} \right|^{-2d} = \frac{\sigma_a^2}{2\pi} \left| \frac{2e^{-i\omega} \left( e^{\frac{i\omega}{2}} - e^{-\frac{i\omega}{2}} \right)}{2i} \right|^2$$

$$\frac{\sigma_a^2}{2\pi} = \left[ 2 \sin\left(\frac{\omega}{2}\right) \right]^{-2d}, -\pi \leq \omega \leq \pi \quad (2.27)$$

walaupun persamaan (2.27) akan divergen pada frekuensi nol, tetapi berdasarkan fungsi autokovarian

$$\begin{aligned}
 \gamma_k &= \int_{-\pi}^{\pi} e^{iak} f(\omega) d\omega = \frac{\sigma_a^2}{2\pi} \int_0^\pi 2 \cos(k\omega) \left[ 2 \sin\left(\frac{\omega}{2}\right) \right]^{-2d} d\omega \\
 &= \frac{(2)^{-2d} \sigma_a^2}{1} \frac{\cos\left(\frac{2k\pi}{2}\right) \Gamma(2-2d)(2)^{1+2d-1}}{(1-2d)\Gamma\left[\frac{1-2d+2k+1}{2}\right]\Gamma\left[\frac{1-2d-2k+1}{2}\right]} \\
 &= (-1)^k \sigma_a^2 \frac{\Gamma(1-2d)}{\Gamma(k-d+1)\Gamma(1-d-k)} \tag{2.28}
 \end{aligned}$$

dimana hasil dari integral adalah sebagai berikut.

$$\int_0^\pi \cos(k\omega) [\sin(\omega)]^{\alpha-1} d\omega = \frac{\pi \cos\left(\frac{k\pi}{2}\right) \Gamma(\alpha+1)(2)^{1-\alpha}}{\alpha \Gamma\left[\frac{\alpha+k+1}{2}\right]\Gamma\left[\frac{\alpha-k-1}{2}\right]}$$

Sehingga

$$\begin{aligned}
 \rho_k &= \frac{\gamma_k}{\gamma_0} = \frac{(-1)\Gamma(1-2d)}{\Gamma(k-d+1)\Gamma(1-d-k)} \frac{\Gamma(1-d)\Gamma(1-d)}{\Gamma(1-2d)} \\
 &= \frac{\Gamma(1-d)}{\Gamma(k-d+1)} \frac{(-1)^k (1-d-1)(1-d-2)...(1-d-k)\Gamma(1-d-k)}{\Gamma(1-d-k)} \\
 &= \frac{\Gamma(1-d)}{\Gamma(k-d+1)} (-1)^k (-1)^k (d)(d-1)...(d+k-1) \frac{\Gamma(1-d)\Gamma(k+d)}{\Gamma(k-d+1)\Gamma(d)} \tag{2.29}
 \end{aligned}$$

dengan menggunakan kembali formula Stirling, diperoleh

$$\begin{aligned}
 \rho_k &\propto \frac{\Gamma(1-d)}{\Gamma(d)} \frac{\sqrt{2\pi} e^{-k-d} (k+d)^{k+d-\frac{1}{2}}}{\sqrt{2\pi} e^{-k+d-1} (k-d+1)^{k-d+\frac{1}{2}}} \\
 &\propto \frac{\Gamma(1-d)}{\Gamma(d)} e^{-2d+1} (k)^{2d-1} \\
 &\propto c_p (k)^{2d-1} \tag{2.30}
 \end{aligned}$$

dimana  $c_p$  adalah sebuah konstanta.

Wei (2006) menjelaskan bahwa sebuah proses stasioner dikatakan *short memory* jika memiliki ACF yang terbatasi secara geometrik (*geometrically bounded*), yaitu jika

$$|\rho_k| \leq c_p(r)^k, k = 1, 2, \dots \quad (2.31)$$

dimana  $c$  adalah konstanta yang bernilai positif dan  $0 < r < 1$ . Dengan kata lain, proses stasioner dikatakan sebagai proses *long memory* jika memiliki ACF yang mengikuti sebuah bentuk *asymtotic hiperbolic*, yaitu jika

$$|\rho_k| \leq c_p(k)^\alpha, \text{ dimana } k \rightarrow \infty \quad (2.32)$$

dimana  $\alpha < 0$ . Sebuah proses *long memory* dengan ACF yang tidak dapat dijumlahkan secara mutlak, yaitu  $\sum_{k=-\infty}^{\infty} |\rho_k| = \infty$ .

Karena  $d$  diketahui kurang dari 0.5, berdasarkan (2.29) jelas bahwa ACF yang dijelaskan mengikuti bentuk *asymtotic hiperbolic*. Oleh sebab itu, proses *fractionally differenced noise* dan proses ARFIMA  $(p,d,q)$  adalah sebuah proses *long memory*. Lebih jauh, untuk ACF  $(\rho_k)$  berdasarkan (2.32),  $\sum_{k=-\infty}^{\infty} |\rho_k|$  hanya konvergen jika  $(2d-1) < -1$ , atau  $d < 0$ . Proses *fractionally differenced noise* dan proses ARFIMA  $(p,d,q)$  adalah benar merupakan proses *long memory* ketika  $0 < d < 0.5$ .

### 2.8.2 Proses ARFIMA

Sebuah proses ARFIMA memuat beberapa karakteristik, yaitu pada jumlah sampel terbatas akan sama dengan suatu proses nonstasioner. Contohnya, ACF pada model ARFIMA  $(p,d,q)$  akan turun secara lambat, suatu fenomena yang sama dengan dengan sampel *time series* nonstasioner. Serta, kesamaan antara kedua model antara ARFIMA dan model nonstasioner memiliki periodogram yang konvergen pada frekuensi nol. Contohnya, model stasioner ARFIMA sulit dibedakan dengan dengan model nonstasioner ARIMA. Ini menyebabkan *overdifferencing* memiliki dampak yang tidak diharapkan pada estimasi parameter dan peramalan.

Dalam peramalan terdapat syarat bahwa proses stasioner dan konvergen pada nilai rata-rata. Sehingga, peramalan proses *long memory*

seharusnya konvergen pada nilai rata-rata proses, walaupun akan konvergen secara lambat.

### 2.8.3 Estimasi Parameter ARFIMA ( $p,d,q$ )

Terdapat beberapa tahap dalam melakukan estimasi ARFIMA ( $p,d,q$ ) seperti yang dijelaskan oleh Reisen *et al.* (2001). Dalam tahap tersebut dilakukan inisialisasi awal untuk proses yang diamati sebagai  $\{Y_t\}$ , kemudian dilakukan inisialisasi pada proses ARMA ( $p,q$ ) sebagai  $\hat{U}_t = (1-B)^d$ , dan inisialisasi pada proses ARFIMA ( $0,d,0$ ) sebagai  $X_t = \frac{\phi(B)}{\theta(B)} Y_t$ .

Tahap estimasi parameter ARFIMA ( $p,d,q$ ) dilakukan secara iteratif untuk mendapatkan seluruh parameter yang konvergen. Tahap tersebut diawali dengan mengestimasi  $d$  pada model ARIMA ( $p,d,q$ ), dengan menotasikannya sebagai  $\hat{d}$ . Selanjutnya menghitung hasil differencing data dengan nilai *fractionally difference* yang diperoleh, yaitu  $\hat{U}_t = (1-B)^{\hat{d}} Y_t$ . Dengan menggunakan prosedur metode Box-Jenkins atau menggunakan prosedur minimisasi AIC selanjutnya menentukan order serta melakukan estimasi parameter  $\phi$  dan  $\theta$  pada proses ARMA ( $p,q$ ) yaitu  $\phi(B)\hat{U}_t = \theta(B) \in t$  dan menghitung  $\hat{X}_t = \frac{\hat{\phi}(B)}{\hat{\theta}(B)} Y_t$ . Langkah ini diulangi sampai diperoleh parameter yang konvergen.

Pada penelitian ini, untuk tahap melakukan estimasi  $\phi$  dan  $\theta$  akan digunakan teknik estimasi *maximum likelihood estimation* (MLE), karena metode estimasi ini memiliki beberapa keunggulan dibandingkan dengan teknik estimasi yang lainnya, yaitu semua informasi yang terdapat pada data digunakan, tidak hanya pada moment pertama atau kedua saja seperti pada metode moment, keuntungan ini juga dimiliki oleh metode *least squares*. Selain itu, metode ini mampu menghasilkan informasi dari sampel besar ke dalam kondisi yang umum. Kelemahan dari metode ini adalah perlu dilakukan pembentukan *probability density function* (pdf) gabungan pada pertama kali melakukan estimasi.

Pada metode MLE, fungsi likelihood disimbolkan  $L$  didefinisikan sebagai gabungan pdf dari data yang diamati. Namun,  $L$  dianggap sebagai fungsi

dari parameter yang tidak diketahui pada model. Untuk model ARIMA,  $L$  merupakan fungsi  $\phi, \theta, \mu$  dan  $\sigma_a^2$  dari observasi.

Asumsi yang harus dipenuhi untuk model ARIMA atau ARFIMA adalah residual *white noise* atau saling identik dan independen, serta berdistribusi normal dengan mean nol dan standart deviasi sebesar  $\sigma_a$ , maka pembentukan MLE misalnya untuk model AR(1) adalah diawali dengan membentuk pdf untuk setiap  $a_t$ , yaitu

$$(2\pi\sigma_a^2)^{-\frac{1}{2}} \exp\left(-\frac{a_t^2}{2\sigma_a^2}\right), \text{ untuk } -\infty < a_t < \infty$$

dan berdasarkan sifat independen, maka pdf gabungan untuk  $a_2, a_3, \dots, a_T$  adalah

$$(2\pi\sigma_a^2)^{\frac{(T-1)}{2}} \exp\left(-\frac{1}{2\sigma_a^2} \sum_{t=2}^T a_t^2\right) \quad (2.33)$$

untuk AR(1), maka

$$\begin{aligned} Y_2 - \mu &= \phi(Y_1 - \mu) + a_2 \\ Y_3 - \mu &= \phi(Y_2 - \mu) + a_3 \\ &\dots \\ Y_T - \mu &= \phi(Y_{T-1} - \mu) + a_T \end{aligned} \quad (2.34)$$

Jika kondisi pada  $Y_1 = Y_1$ , persamaan (2.34) menjelaskan sebuah transformasi antara  $a_2, a_3, \dots, a_T$  dan  $Y_2, Y_3, \dots, Y_T$  (dengan Jacobian yang sama dengan 1). Sehingga pdf gabungan dari  $Y_2, Y_3, \dots, Y_T$  dengan  $Y_1 = Y_1$  dapat diperoleh dengan menggunakan persamaan (2.34) untuk melakukan substitusi pada  $a$  ke dalam bentuk  $y$  pada persamaan (2.35).

$$f(Y_2, \dots, Y_T) = \left( 2\pi\sigma_a^2 \sum_{t=2}^T [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2 \right)^{-\frac{1}{2}} \quad (2.35)$$

Anggap bahwa distribusi marginal dari  $Y_1$  mengikuti proses representasi linier dari proses AR(1) dimana  $Y_1$  memiliki distribusi normal dengan mean  $\mu$  dan varian  $\sigma_a^2/(1-\phi^2)$ . Dengan mengalikan kondisional pdf pada persamaan (2.35) dengan pdf marginal dari  $Y_1$  menghasilkan  $Y_1, Y_2, \dots, Y_T$  dibutuhkan. Fungsi likelihood untuk model AR(1) adalah

$$L(\phi, \mu, \sigma_a^2) = (2\pi\sigma_a^2)^{-\frac{n}{2}}(1-\phi)^{\frac{1}{2}} \exp\left(-\frac{1}{2\sigma_a^2} S(\phi, \mu)\right) \quad (2.36)$$

Dimana

$$S(\phi, \mu) = \sum_{t=2}^T [(Y_t - \mu)]^2 + (1 - \phi^2)(Y_1 - \mu) \quad (2.37)$$

Fungsi  $S(\phi, \mu)$  disebut sebagai *unconditional sum-of-squares function*.

Secara umum, logaritma fungsi likelihood lebih mudah untuk bekerja daripada likelihood itu sendiri. Untuk kasus AR(1), fungsi likelihood dinotasikan  $l(\phi, \mu, \sigma_a^2)$ , yaitu

$$l(\phi, \mu, \sigma_a^2) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma_a^2) + \frac{1}{2} \log(1 - \phi^2) - \frac{1}{2\sigma_a^2} S(\phi, \mu) \quad (2.38)$$

Untuk memberikan nilai pada  $\phi$  dan  $\mu$ ,  $l(\phi, \mu, \sigma_a^2)$  dapat dimaksimalkan secara analitis pada  $\sigma_a^2$  sebelum parameter yang dicari dihitung, yaitu  $\phi$  dan  $\mu$ , sehingga diperoleh:

$$\sigma_a^2 = \frac{S(\hat{\phi}, \hat{\mu})}{n} \quad (2.39)$$

Pada konteks umum, biasanya pembagi parameter varians yang digunakan adalah  $n-2$  daripada  $n$  (dikurangi dua karena dilakukan estimasi pada dua parameter, yaitu  $\phi$  dan  $\mu$ ) untuk mendapatkan estimator dengan bias yang lebih kecil. Tetapi untuk kasus *time series* yang digunakan untuk sampel besar, penggunaan pembagi yang berbeda tidak akan menghasilkan perbedaan yang jauh.

## 2.9 Uji Nonlinieritas

### 2.9.1 Uji White

Uji neural networks dalam White dan Lee dkk. adalah suatu uji lain untuk linearitas yaitu :

$$y_t = \beta' w_t + \sum_{j=1}^q \theta_{0j} \left\{ \psi(y_j w_t) + \frac{1}{2} \right\} + u_t \quad (3.40)$$

Hipotesis nolnya adalah

$$H_0 : \theta_{01} = \theta_{02} = \dots = \theta_{0q} = 0$$

Permasalahan identifikasi di atas diselesaikan dengan menetapkan nilai-nilai dari  $\gamma_1, \dots, \gamma_q$  sehingga nilai-nilai dari  $\psi(\gamma_j w_i)$  dapat dihitung. Hal ini dilakukan melalui penentuan vektor-vektor itu secara acak dari suatu distribusi yang mungkin. Sebagai contoh, Lee *et al.* (1993) menggunakan suatu distribusi uniform. Karena variabel-variabel  $\psi(\gamma_j w_i)$  dimungkinkan sangat berkorelasi, Lee *et al.* (1993) menerapkan suatu transformasi komponen utama menjadi

$$\bar{\psi}_t = [\psi(\gamma'_j w_t), \dots, \psi(\gamma'_j w_t)] \quad (3.41)$$

dan menggunakan dua komponen utama yang ortonormal ke dalam bagian linear dari model pada regresi tambahan untuk uji linearitas.

### 2.8.2 Uji Terasvirta

Uji Terasvirta termasuk dalam kelompok uji Lagrange Multiplier (LM) dengan pendekatan ekspansi Taylor yang menggunakan statistik uji  $\chi^2$  dengan derajat bebas  $m$ . Prosedur uji Terasvirta dijelaskan sebagai berikut (Terasvirta dkk., 1993):

1. Meregresikan  $y_t$  pada  $1, Y_{t-1}, \dots, Y_{t-p}$  dan menghitung nilai  $\hat{u}_t = Y_t - \hat{Y}_t$
2. Meregresikan  $\hat{u}_t$  pada  $1, Y_{t-1}, \dots, Y_{t-p}$  dan  $m$  prediktor tambahan suku kuadratik dan kubik yang merupakan hasil dari pendekatan ekspansi Taylor.
3. Menghitung koefisien determinasi ( $R^2$ ) dari regresi pada langkah sebelumnya.
4. Menghitung statistik uji  $\chi^2 = nR^2$ , dengan  $n$  adalah jumlah pengamatan.

Hipotesis yang digunakan adalah sebagai berikut.

$H_0$  : Model Linier

$H_1$  : Model Nonlinier

Statistik uji  $\chi^2$  mengikuti distribusi  $\chi^2_v$ , keputusan tolak  $H_0$  jika  $p\text{-value}$  dari statistik uji  $\chi^2$  kurang dari taraf nyata 0,05.

Dibawah hipotesis linieritas,  $\chi^2$  mendekati distribusi  $\chi^2(m)$ , dengan  $m$  adalah banyaknya prediktor tambahan.

Sedangkan prosedur uji F uji linieritas tipe LM ini adalah sebagai berikut.

1. Meregresikan  $y_t$  pada  $1, Y_{t-1}, \dots, Y_{t-p}$  dan menghitung nilai  $\hat{u}_t = Y_t - \hat{Y}_t$  dan hitung jumlah kuadrat residual  $SSR_0 = \sum \hat{u}_t^2$
2. Meregresikan  $\hat{u}_t$  pada  $1, Y_{t-1}, \dots, Y_{t-p}$  dan m prediktor tambahan dan kemudian hitung residual  $\hat{v}_t = \hat{u}_t - \hat{\hat{u}}_t$  dan jumlah kuadrat residual  $SSR_1 = \sum \hat{v}_t^2$ . (m dan prediktor-prediktor yang terlibat bervariasi untuk suatu uji dengan uji yang lain).
3. Hitung
$$F = \frac{(SSR_0 - SSR_1)/m}{SSR_1/(T - p - 1 - m)}$$

Dengan  $n$  adalah banyaknya pengamatan yang digunakan.

Dibawah hipotesis linieritas,  $F$  mendekati distribusi  $F$  dengan derajat bebas  $m$  dan  $(T - p - 1 - m)$ . Penggunaan dari uji F menggantikan uji  $\chi^2$  ini didasarkan oleh rekomendasi dari teori asimtotis dalam sampel kecil, yaitu karena uji ini mempunyai sifat kuasa dan ukuran yang baik.

## 2.10 Nonlinier Time Series

Zivot dan Wang (2006) menjelaskan bahwa sejak sistem ekonomi dan finansial diketahui dapat mengalami perubahan struktur dan perilaku, dapat diasumsikan bahwa model *time series* yang berbeda diperlukan untuk menjelaskan kondisi data pada selang waktu yang berbeda. Model *time series* linier yang diterapkan pada data finansial ekonomi biasanya meninggalkan beberapa aspek data yang tidak dapat dijelaskan jika data memiliki struktur dan perilaku tidak linier. Oleh sebab itu, untuk mengatasi masalah ini dikembangkan metode *nonlinier time series*. Pemodelan perilaku *time series* data finansial ekonomi, memungkinkan adanya perbedaan dinamika dalam setiap *state* dan *regime* yang berbeda. Pada penelitian ini, akan digunakan dua model *nonlinier time series*, yang berfokus pada model yang mengasumsikan proses *autoregressive*, AR( $p$ ).

Kuswanto dan Sibbertsen (2008), melakukan perbandingan plot spektrum dan periodogram antara proses *long memory* dan proses dari model

nonlinier, yaitu proses Markov-switching dan proses *threshold*. Hasilnya menunjukkan bahwa bentuk plot spektrum dan periodogram ketiga proses tersebut cukup sulit dibedakan karena bentuknya identik. Hal ini menjadikan model nonlinier *timeseries* disebut sebagai *spurious long memory*.

### 2.10.1 Logistic Smooth Transition Autoregressive (LSTAR)

*Smooth Transition Autoregressive* (STAR) adalah model *regime switching* mirip dengan model SETAR namun memungkinkan untuk kelancaran transisi antara rezim. Telah dikenalkan secara rinci misalnya oleh Teräsvirta (1994). Umumnya, sebuah proses STAR order  $p$  didefinisikan oleh :

$$Y_t = X_t \phi^{(1)}(1 - G(Z_t)) + X_t \phi^{(2)}G(S_t; \gamma, c) + a_t \quad (2.42)$$

Dimana  $X_t = (1, y_{t-1}, y_{t-2}, \dots, y_{t-p})$ ;  $\phi^{(j)} = (\mu^{(j)}, \phi_{t-1}^{(j)}, \phi_{t-2}^{(j)}, \dots, \phi_{t-p}^{(j)})$ , yaitu parameter model AR, dimana  $j = 1, 2, \dots$  menunjukkan *regime*;  $a_t$  adalah *Gaussian white noise*,  $G(S_t; \gamma, c)$  adalah fungsi transisi yang mengatur pergerakan dari satu rezim ke rezim yang lain dan  $s_t$  adalah variabel transisi sehingga  $s_t = y_{t-l}$ .

Dua pilihan populer untuk fungsi *smooth transition* adalah fungsi logistik dan fungsi eksponensial. Kedua pilihan terdapat perbedaan dalam bentuk fungsi transisi penghalus yang digunakan. Fungsi *smooth transition* logistik, yang dijelaskan pada persamaan (2.43).

$$G(z_t; \gamma, c) = \frac{1}{1 + e^{-\gamma(z_t - c)}}, \gamma > 0 \quad (2.43)$$

dimana  $z_t = y_{t-1}$ , dengan parameter *delay*  $l$  yang merupakan bilangan integer positif  $l > 0$ . Model yang dihasilkan disebut sebagai model *logistic STAR* atau model LSTAR. Parameter  $c$  dapat diinterpretasikan sebagai *threshold*, dan  $\gamma$  menunjukkan derajat kecepatan dan kehalusan transisi.

Bentuk sederhana dari model LSTAR dapat dituliskan sebagai berikut.

$$y_t = \alpha_1 y_{t-1} \left\{ \frac{1}{1 + e^{-\gamma(z_t - c)}} \right\} + \alpha_2 y_{t-1} + \varepsilon_t \quad (2.44)$$

dimana  $y_t$  merupakan proses yang stasioner dengan  $\alpha_1, \alpha_2$  dan  $\gamma$  merupakan parameter yang tidak diketahui. Parameter  $\gamma$  menunjukkan derajat kecepatan dan

kehalusan transisi dan  $y_{t-l}$  merupakan fungsi transisi ketika lag  $l \geq 1$ . *delay*  $l$  yang merupakan bilangan integer positif  $l = 1$  sehingga  $y_{t-l} = y_{t-1}^2$

Model LSTAR dapat diestimasi dengan menggunakan *Nonlinier Least Squares* (NLS) sebagai berikut (Zivot dan Wang, 2006).

$$\hat{\Theta} = \arg \min_{\gamma, c} \sum_t \hat{a}_t^2 \quad (2.45)$$

Dengan

$$\hat{a}_t = y_t - \tilde{X}_t \hat{\phi}$$

$$\tilde{X}_t = \begin{bmatrix} X_t(1-G(S_t; \gamma, c)) \\ X_t G(S_t; \gamma, c) \end{bmatrix}$$

$$\hat{\phi} = \begin{bmatrix} \phi^{(1)} \\ \phi^{(2)} \end{bmatrix} = \left[ \sum_t (\tilde{X}_t' \tilde{X}_t) \right]^{-1} \left[ \sum_t (\tilde{X}_t' y_t) \right]$$

dengan catatan bahwa minimisasi fungsi objek NLS hanya ditampilkan untuk  $\gamma$  dan  $c$  karena  $\phi^{(1)}$  dan  $\phi^{(2)}$  dapat diestimasi dengan menggunakan *least squares* pada saat  $\gamma$  dan  $c$ . Di bawah asumsi residual berdistribusi normal, NLS akan ekuivalen dengan *maximum likelihood estimation* (MLE). Dengan kata lain, estimasi NLS dapat diinterpretasikan sebagai estimasi *quasi maximum likelihood*.

## 2.11 Kombinasi Peramalan

Kombinasi peramalan, atau disebut *forecast combination* dan *ensemble forecasting*, adalah teknik untuk meningkatkan akurasi dan mengurangi variabilitas hasil peramalan. Kombinasi peramalan dilakukan dengan menggabungkan hasil peramalan beberapa model *time series* yang saling berbeda, menjadi suatu peramalan gabungan, dengan harapan hasil gabungan ramalan tersebut lebih akurat daripada hasil peramalan model individu. Terdapat beberapa teknik untuk melakukan kombinasi peramalan, diantaranya yang digunakan dalam penelitian ini adalah model FISTAR (*Fractionally Integrated Smooth Transition Autoregressive*).

### 2.11.1 Fractionally Logistic Smooth Transition Autoregressive (FISTAR)

Model FI-STAR merupakan pengembangan dari model STAR standar yang memungkinkan untuk fraksional terintegrasi. Setelah Granger dan Joyeux (1980) dan Hosking (1981), proses time series univariat fraksional terintegrasi,  $y_t$ , dapat direpresentasikan sebagai

$$(1-B)^d(Y_t - \mu) = Z_t \quad (2.46)$$

dimana  $Z_t$  adalah proses *short memory*  $I(0)$  dan dengan operator differencing  $(1-B)^d$  didefinisikan sebagai

$$(1-B)^d = \sum_{k=0}^{\infty} \frac{\Gamma(k-d)}{\Gamma(k-d)\Gamma(k+1)} L^k \quad (2.47)$$

di mana  $\Gamma(\cdot)$  adalah fungsi gamma. Jika  $Z_t$  adalah proses ARMA  $(p, q)$ , maka  $y_t$  menjadi proses ARFIMA  $(p, d, q)$ .  $\phi(L)$  dan  $\theta(L)$  menunjukkan  $p$  dan  $q$  orde polinomial dengan semua akar di luar unit lingkaran, dan  $\varepsilon_t$  menunjukkan urutan perbedaan martingale, dengan  $E(\varepsilon_t^2) = \sigma^2$ .

Model STAR umum, yang dibuat secara operasional oleh Granger dan Terasvirta (1993) dan Terasvirta (1994), telah terbukti menjadi model *nonlinier* sangat berguna. Dua-rezim model STAR  $(p)$  dengan fungsi transisi  $G(S_t; \gamma, c)$  didefinisikan sebagai

$$y_t = \phi_{1,0} + \phi_{1,1}y_{t-1} + \dots + \phi_{1,p}y_{t-p} + (\phi_{2,0} + \phi_{2,1}y_{t-1} + \dots + \phi_{2,p}y_{t-p})G(S_t; \gamma, c) + \varepsilon_t \quad (2.48)$$

dimana  $\varepsilon_t$  adalah seperti di atas,  $c$  adalah ambang batas keseimbangan,  $\gamma$  mengontrol derajat kelengkungan  $G$ , dan  $S_t$  adalah variabel transisi yang mengatur perilaku *nonlinier* dari proses. Meskipun sejumlah pilihan yang masuk akal untuk  $G(S_t; \gamma, c)$ , dalam hal ini tetap fokus pada fungsi logistic.

$$G(z_t; \gamma, c) = \frac{1}{1 + e^{-\gamma(z_t - c)}} , \gamma > 0 \quad (2.49)$$

Jelas, bahwa  $\gamma \rightarrow 0$  fungsi runtuh untuk 0, sedangkan jika  $\gamma \rightarrow \infty$  fungsi kesatu yang konvergen. Dalam kedua kasus, model dalam persamaan (2.49) menjadi model linear AR  $(p)$ . Rezim korespondensi dalam sesuai dengan kasus di mana  $\gamma = 0$ , sedangkan rezim korespondensi luar sesuai dengan kasus di mana  $\gamma \rightarrow \infty$ .

FISTAR model, yang dikembangkan oleh van Dijk *et al.* (2002), tidak lebih dari kombinasi sederhana dari model *fractionally long memory* dan model STAR.  $x_t$  menjadi *fractionally difference* dari  $y_t$ ,  $x_t = (1-L)^d y_t$ . FI-LSTAR (p) Model ini kemudian didefinisikan sebagai

$$x_t = \phi_{1,0} + \phi_{1,1}y_{t-1} + \dots + \phi_{1,p}y_{t-p} + (\phi_{2,0} + \phi_{2,1}y_{t-1} + \dots + \phi_{2,p}y_{t-p}) \times \left( \frac{1}{1+e^{-\gamma(z_t-c)}} \right) + \varepsilon_t \quad (2.50)$$

dengan  $\varepsilon_t$  didefinisikan sebagai diatas. Model FI-LSTAR secara umum sebagian besar berasal dari model yang ada yang telah digunakan untuk mempelajari dinamika yang terkait dengan PPP. Jika  $d=0$ , model dalam persamaan (2.50) tereduksi menjadi model LSTAR standar tanpa *fractionally long memory*. Sebaliknya, jika  $\gamma=0$  atau jika  $\phi_{2,j}=0$  untuk  $j=0, \dots, p$ , hasilnya adalah model ARFIMA  $(p, d, q)$ . Tentu saja, tanpa nonlinier, proses ARFIMA  $(p, d, 0)$  menjadi proses stasioner AR  $(p)$  ketika  $d=0$  dan *unit root* ketika  $d=1$ . Dengan diketahui  $d$ , jika kita berasumsi bahwa semua akar ke  $1-\phi_{1,1}L-\dots-\phi_{1,p}L^p=0$  berada di luar lingkaran satuan, maka proses didefinisikan dalam persamaan (2.50) adalah stasioner dan ergodic bawah linearitas seperti di Terasvirta (1994). Di sini, untuk tes linearitas, perlu untuk menggunakan estimator konsisten  $d$ .

Untuk membangun tes untuk linearitas berdasarkan model FI-LSTAR, seseorang dapat memperpanjang prosedur pengujian digariskan oleh Tersvirta (1994) untuk model LSTAR. Hipotesis nol linearitas untuk model LSTAR standar, dengan  $d$  diasumsikan nol, dapat dibangun dalam lebih dari satu cara  $\gamma=0, \phi_{2,0}=\phi_{2,1}=\dots=\phi_{2,p}=0$ . Selanjutnya, parameter gangguan tidak dibatasi di bawah nol. Tes linearitas asli dikembangkan oleh Terasvirta untuk menghindari masalah ini. Secara khusus, seseorang dapat mengambil ekspansi deret Taylor sesuai fungsi transisi tentang  $\gamma=0$ . Berdasarkan hipotesis nol, tes dapat dilakukan melalui regresi OLS standar dengan pembatasan pada subset dari parameter. Ekstensi untuk model FI-LSTAR sangatlah mudah. Sebagaimana dibahas oleh Smallwood (2005), urutan pertama ekspansi Taylor tentang hasil  $\gamma=0$  dalam regresi tambahan berikut.

$$x_t = \beta_{1,0} + \sum_{j=1}^p \beta_{1,j} x_{t-j} + \sum_{j=1}^p \beta_{2,j} x_{t-j} S_t + \sum_{j=1}^p \beta_{3,j} x_{t-j} S_t^2 + U_t \quad (2.51)$$

Hipotesis null untuk linearitas kemudian diberikan oleh  $\beta_{2,j} = \beta_{3,j} = 0$ . Tes harus memperhitungkan perubahan dalam fungsi likelihood yang dihasilkan dari estimasi nilai  $d$ .  $\hat{\varepsilon}_t$  menunjukkan residual dari estimasi konsisten model ARFIMA  $(p,d,q)$ . Berdasarkan hipotesis linearitas, dan dengan asumsi Gaussian, gradien dari fungsi likelihood untuk observasi untuk model di atas sehubungan dengan  $d$  diberikan oleh

$$\frac{\partial l_t}{\partial d} = -\frac{\hat{\varepsilon}_t}{\sigma^2} \sum_{j=1}^{t-1} \frac{\hat{\varepsilon}_{t-j}}{j} \quad (2.52)$$

Kemudian, dapat diperoleh *Sum of Squared Error* (SSER) dan *Unrestricted Sum Of Squared Error* (SSEUR). Statistik uji  $\chi^2$  dan  $F$  yang diberikan oleh:

$$LM_{\chi^2} = \frac{T(SSE_R - SSE_{UR})}{SSE_R}, \quad LM_F = \frac{T(SSE_R - SSE_{UR}/2p)}{(SSE_{UR})/(T-3p-1)} \quad (2.53)$$

Statistik uji didistribusikan sebagai statistik uji  $\chi^2(2p)$  dan  $F(2p, T-3p-1)$  (lihat Teravirta, 1994; Van Dijk *et al.*, 2002; dan terutama Smallwood 2005 untuk rincian). Dalam merumuskan tes, penting untuk dicatat bahwa ada kemungkinan bahwa parameter integrasi,  $d$ , mungkin berbeda di bawah hipotesis nol dan alternatif seperti yang ditunjukkan oleh Baillie dan (Kapetanios, 2007). Sebagai contoh, van (Dijk *et al.*, 2002) cocok dengan model STAR fraksional terintegrasi dengan tingkat pengangguran AS dan menemukan bahwa tingkat persistensi yang diukur dengan parameter differencing nonlinieritas yang dianggap menurun sekali. Demikian pula, Taylor *et al.* (2001) menunjukkan, tanpa melaporkan perkiraan dari berbagai model, bahwa masih adanya nilai tukar riil diperkirakan turun setelah peneliti memperluas analisis mereka di luar model linier dan memungkinkan untuk nonlinieritas. Oleh karena itu, di bawah, diperkirakan keduanya di bawah hipotesis linearitas seperti di atas, dan di bawah hipotesis alternatif. Versi uji  $\chi^2$  dan p-value yang diminimumkan ditunjukkan dalam setiap contoh.

Sejumlah metode estimasi yang tersedia untuk model yang disajikan di sini. Untuk model FIESTAR, setelah Van Dijk *et al.* (2002), dipilih untuk

menggunakan modifikasi dari waktu estimator domain dari Beran (1995) untuk bersama-sama memperkirakan semua model parameters.<sup>4</sup> Berdasarkan asumsi bahwa pengamatan pra-sampel non-stokastik, estimator adalah asimtotik setara dengan MLE. Setelah Beran, ditetapkan  $y_0 = y_{-1} = \dots = \varepsilon_0 = \varepsilon_{-1} = \dots = 0$ . Perkiraan dari semua parameter model FI-LSTAR adalah seperangkat parameter yang memaksimalkan fungsi berikut.

$$AMLE(c, \gamma, \phi', d, \sigma^2) = -\frac{T}{2} \log(2\pi) - \frac{T}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{t=2}^T \varepsilon_t^2,$$

$$\varepsilon_t = x_t - \phi_{1,0} - \sum_{j=1}^p \phi_{1,j} x_{t-j} - \left( \phi_{2,0} + \sum_{j=1}^p \phi_{2,j} x_{t-j} \right) \left( \frac{1}{1+e^{-\gamma(z_t-c)}} \right) \quad (2.54)$$

dengan  $x_t = (1-L)^2 y_t$ . Untuk menaksir model ARFIMA  $(p,d,q)$ , yang diperlukan untuk pengujian linearitas di bawah nol, estimator Beran (1995) digunakan. Hal ini pada dasarnya dapat dicapai melalui maksimalisasi fungsi dalam persamaan (2.54) dengan diberlakukan  $c = \gamma = \phi_{2,j} = 0, j = 0, \dots, p$ .

## 2.12 Cek Diagnostik

Tahap selanjutnya yang dilakukan adalah cek diagnosa yaitu pengujian untuk mengetahui apakah residual telah memenuhi asumsi. Asumsi tersebut terdiri dari Residual *White Noise* dan berdistribusi Normal (Wei, 2006).

### 2.12.1 White Noise

Uji *white noise* residual digunakan untuk mengetahui apakah residual dari data yang diolah telah memenuhi asumsi atau tidak. Untuk menguji asumsi *white noise* tersebut dapat menggunakan uji uji Ljung-Box. Hipotesis yang digunakan dalam pengujian ini adalah sebagai berikut.

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

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

Statistik uji yang digunakan dalam pengujian ini adalah statistik uji Ljung-Box seperti pada persamaan berikut (Wei, 2006).

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.56)$$

$n$  adalah banyak pengamatan,  $\hat{\rho}_k$  menunjukkan ACF residual pada lag ke  $k$  dan  $K$  adalah maksimum lag.  $H_0$  ditolak dapat dilihat berdasarkan nilai *p-value*, jika *p-value*  $> \alpha$  maka residual memenuhi asumsi white noise.

### 2.12.2 Distribusi Normal

Pengujian berikutnya yang dilakukan yaitu menguji apakah residual berdistribusi normal. Cara pengujian kenormalan data dengan menggunakan uji “*Kolmogorov Smirnov*” dengan menggunakan hipotesis sebagai berikut.

$$H_0: F(x) = F_0(x) \text{ (Data Berdistribusi Normal)}$$

$$H_1: F(x) \neq F_0(x) \text{ (Data tidak Berdistribusi Normal)}$$

Statistik uji

$$D = \text{Sup} |S(x) - F_0(x)| \quad (2.57)$$

$S(x)$  = fungsi peluang kumulatif yang dihitung dari data sampel

$F_0(x)$  = fungsi peluang kumulatif dari distribusi normal

$\text{Sup}$  = Nilai supremum untuk semua  $x$  dari  $|S(x) - F_0(x)|$

Hipotesis nol ditolak jika  $D > D_{(1-\alpha),n}$  dengan  $n$  adalah ukuran sampel (Daniel, 1989).

## 2.13 Pemilihan Model Terbaik dan Evaluasi Hasil Peramalan

Berdasarkan hasil pemodelan beberapa model yang telah dibentuk, terdapat banyak kemungkinan model untuk menggambarkan proses yang terjadi dalam data. Oleh sebab itu, selanjutnya dilakukan pemilihan model terbaik dari kemungkinan-kemungkinan model yang telah terbentuk. Terdapat banyak metode untuk menentukan model terbaik. Berdasarkan residual data *in sample*, dalam menentukan model terbaik salah satu di antaranya dapat menggunakan nilai minimum dari AIC (*Akaike's Information Criterion*) yang dijelaskan sebagai berikut (Wei, 2006).

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \quad (2.58)$$

dimana  $M$  adalah jumlah parameter di dalam model dan  $n$  adalah jumlah data *in sample*. Kelemahan AIC adalah kurang efektif untuk jumlah parameter yang

banyak, sehingga untuk  $n$  kecil tetapi  $M$  besar, lebih disarankan untuk menggunakan AICc (*Corrected AIC*), dengan fungsi sebagai berikut (Burnham dan Anderson, 2002).

$$AICc = AIC + \frac{2M(M+1)}{n-M-1} \quad (2.59)$$

Jika AIC dan AICc digunakan untuk menentukan model terbaik berdasarkan residual data *in sample*, maka untuk mengetahui kriteria kebaikan model dari data *out of sample* atau merupakan cara untuk mengevaluasi hasil peramalan, yang dapat menggunakan MSE (*Mean Square Error*) dan MAPE (*Mean Absolute Percentage Error*) yang dijelaskan sebagai berikut (Wei, 2006).

$$MSE = \frac{1}{L} \sum_{i=1}^L e_i^2 \quad (2.60)$$

$$RMSE = \sqrt{\frac{1}{L} \sum_{i=1}^L e_i^2} \quad (2.61)$$

dimana  $L$  adalah banyaknya ramalan yang dihasilkan. MSE dapat diartikan sebagai rata-rata kuadrat dari residual hasil ramalan. RMSE dapat diartikan sebagai akar rata-rata kuadrat dari residual hasil ramalan.

## 2.14 Macam-Macam Outlier

*Outlier* pada data *time series* merupakan gangguan kejadian yang mengakibatkan pengamatan tidak tepat pada suatu data. Dampak dari *outlier* pada data yaitu dapat mendatangkan suatu masalah dalam analisis data, membuat keputusan dan kesimpulan menjadi tidak *reliable* dan tidak valid. Sehingga prosedur yang dilakukan adalah mendeteksi dan menghilangkan pengaruh dari *outlier* tersebut.

Jenis *outlier* adalah *Additive outlier* (AO), *innovational outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC). Penanganan untuk kasus *outlier* adalah dengan menyisipkan variabel *dummy* ( $I$ ) kedalam model. Variabel *dummy* ditentukan berdasarkan pada jenis *outlier* yang ada. *Additive outlier* (AO) memberikan pengaruhnya pada pengamatan ke- $T$ , sedangkan *innovation-*

*outlier* (IO) berpengaruh pada pengamatan ke  $T$ ,  $T+1$ , dan seterusnya. Model *outlier* umum dengan  $k$  *outlier* yang beragam dapat dituliskan sebagai berikut

$$Y_t = \sum_{j=1}^k \beta_j V_j(B) I_t^{T_j} + X_t \quad (2.62)$$

dengan  $X_t$  merupakan model *time series* yang bebas dari *outlier*

$$X_t = \frac{\theta(B)}{\phi(B)} a_t$$

$$V_j(B) = \begin{cases} 1, & \text{untuk AO} \\ \frac{\theta(B)}{\phi(B)}, & \text{untuk IO} \end{cases}$$

$I_t^{(T)}$ : variabel *outlier* pada waktu ke- $T_j$  dan dinotasikan sebagai berikut

$$I_t^{T_j} = \begin{cases} 1, & t = T_j \\ 0, & t \neq T_j \end{cases} \quad (2.63)$$

*Level Shift* (LS) adalah kejadian yang mempengaruhi deret pada satu waktu tertentu yang memberikan perubahan tiba-tiba dan permanen. Model *outlier* LS dinyatakan sebagai

$$Y_t = X_t + \frac{1}{(1-B)} \beta I_t^{(T)} \quad (2.64)$$

*Temporary Changes* (TC) adalah suatu kejadian dimana *outlier* menghasilkan efek awal sebesar dilakukan  $\beta$  pada waktu  $t$ , kemudian secara perlahan sesuai dengan besarnya  $\delta$ . Model dapat disajikan sebagai berikut

$$Y_t = X_t + \frac{1}{(1-\delta B)} \beta I_t^{(T)} \quad (2.65)$$

Pada saat  $\delta=0$  maka TC akan menjadi kasus *additive outlier* sedangkan pada saat  $\delta=1$  maka TC akan menjadi kasus *level shift* (LS).

## 2.15 Saham LQ 45

Indeks LQ 45 hanya terdiri dari 45 saham yang telah terpilih melalui berbagai kriteria pemilihan, sehingga akan terdiri dari saham-saham dengan likuiditas dan kapitalisasi pasar yang tinggi. Saham-saham pada indeks LQ 45 harus memenuhi kriteria dan melewati seleksi utama sebagai berikut :

1. Masuk dalam ranking 60 besar dari total transaksi saham di pasar reguler (rata-rata nilai transaksi selama 12 bulan terakhir).
2. Ranking berdasar kapitalisasi pasar (rata-rata kapitalisasi pasar selama 12 bulan terakhir).
3. Telah tercatat di BEJ minimum 3 bulan.
4. Keadaan keuangan perusahaan dan prospek pertumbuhannya, frekuensi dan jumlah hari perdagangan transaksi pasar reguler.

Saham-saham yang termasuk didalam LQ 45 terus dipantau dan setiap enam bulan akan diadakan review (awal Februari, dan Agustus). Apabila ada saham yang sudah tidak masuk kriteria maka akan diganti dengan saham lain yang memenuhi syarat. Pemilihan saham - saham LQ 45 harus wajar, oleh karena itu BEJ mempunyai komite penasehat yang terdiri dari para ahli di BAPEPAM, Universitas, dan Profesional di bidang pasar modal.

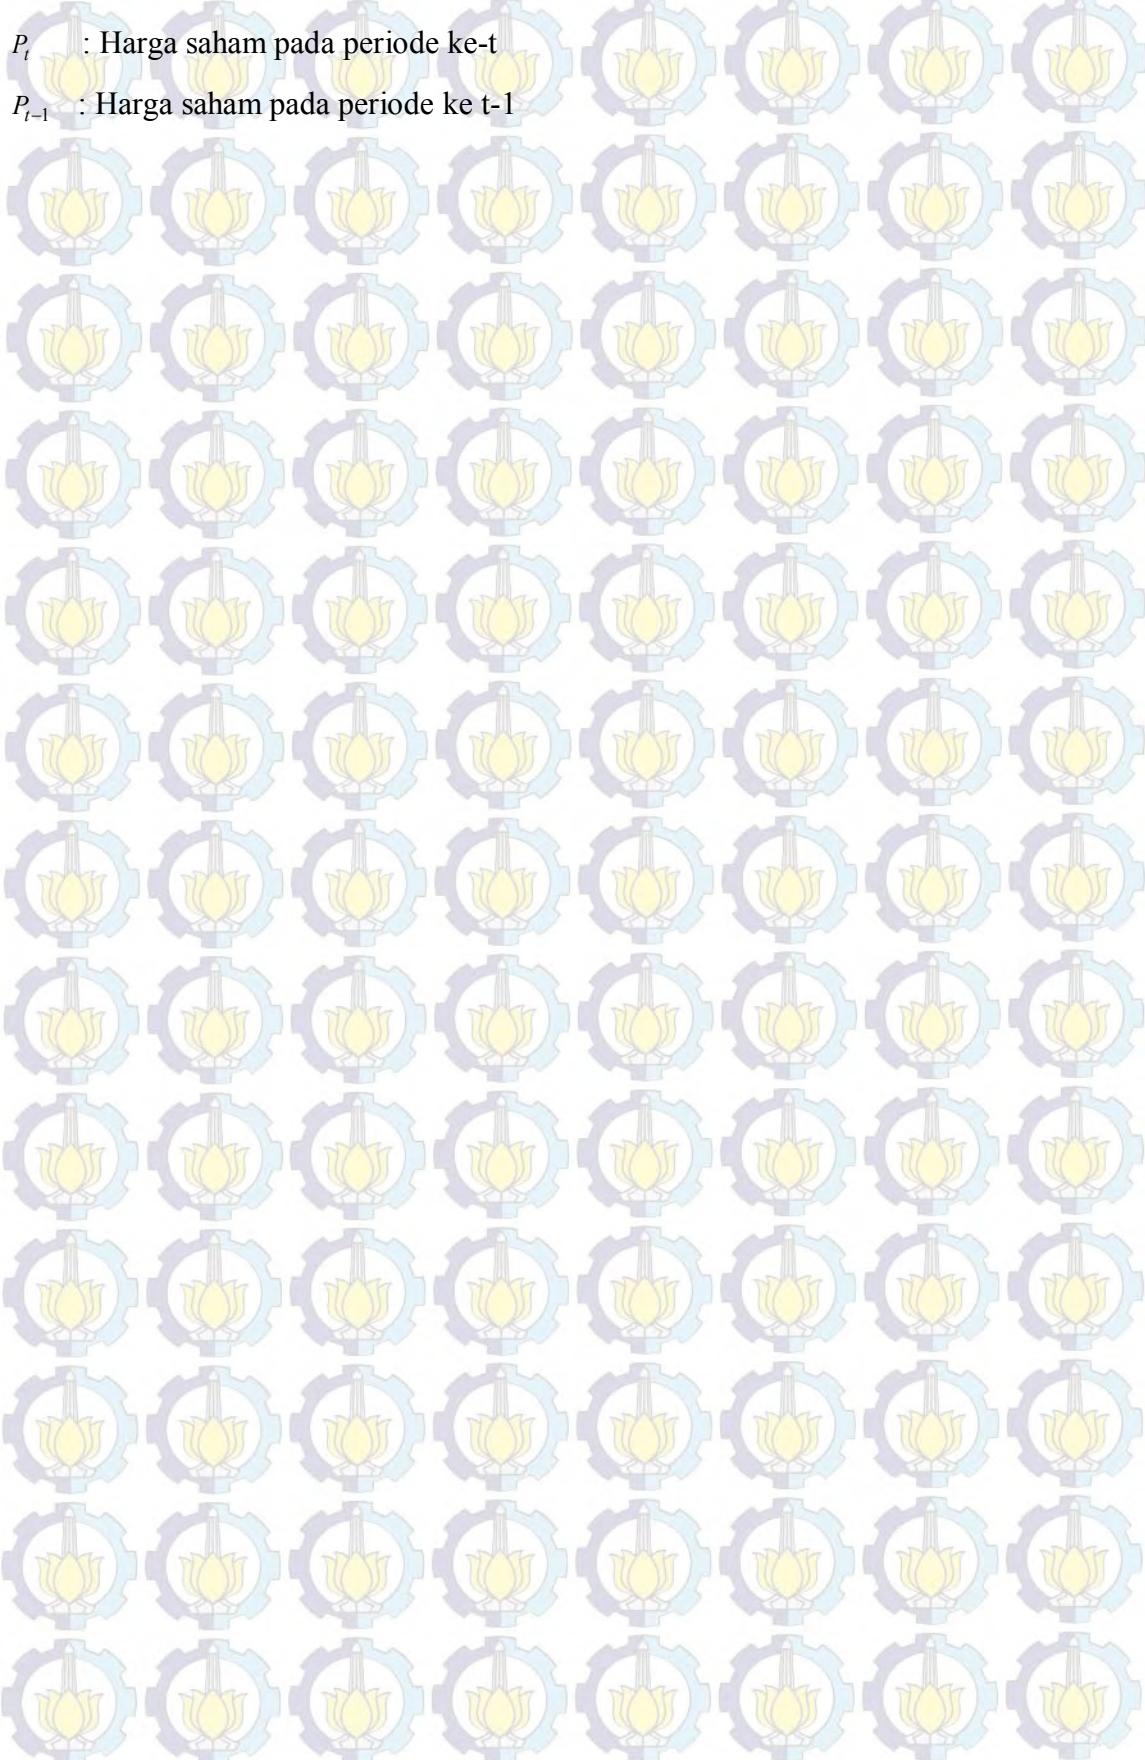
### **2.15 *Return* Saham**

Konsep *return* atau kembalian adalah tingkat keuntungan yang dinikmati oleh pemodal atas suatu investasi yang dilakukannya. *Return* saham merupakan income yang diperoleh oleh pemegang saham sebagai hasil dari investasinya di perusahaan tertentu. *Return* saham dapat dibedakan menjadi dua jenis (Jogiyanto 2000), yaitu *return* realisasi (*realized return*) dan *return* ekspektasi (*expected return*). *Return* realisasi merupakan *return* yang sudah terjadi dan dihitung berdasarkan data historis. *Return* realisasi dapat digunakan sebagai salah satu pengukuran kinerja perusahaan dan dapat digunakan sebagai dasar penentu *return* ekspektasi dan risiko di masa yang akan datang, sedangkan *return* ekspektasi merupakan *return* yang diharapkan terjadi di masa mendatang dan masih bersifat tidak pasti. Untuk menghitung *return* saham digunakan rumus sebagai berikut.

$$ret_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (2.66)$$

dimana,

$ret_t$  : *Return* saham pada periode ke t



$P_t$  : Harga saham pada periode ke-t

$P_{t-1}$  : Harga saham pada periode ke t-1

## BAB 3

# METODOLOGI PENELITIAN

Pada bab ini akan dibahas informasi mengenai sumber data, struktur data dan tahapan penelitian yang akan digunakan dalam penelitian ini.

### 3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder laporan saham harian dari salah satu bank besar yang masuk dalam saham LQ 45 yaitu PT Bank Negara Indonesia yang diperoleh dari YAHOO FINANCE. Periode data saham dari PT Bank Negara Indonesia yang akan diteliti adalah dari tanggal 8 Juni 2004 hingga 28 November 2014, sehingga terdapat sebanyak 2592 data saham harian untuk PT Bank Negara Indonesia. Data dibagi menjadi dua bagian yaitu data *in sample* dan data *out sample*, untuk PT. Bank Negara Indonesia data *in sample* sebanyak 2549 data mulai dari tanggal 8 Juni 2004 sampai tanggal 30 September 2014, sedangkan data *out sample* mulai dari tanggal 1 Oktober 2014 sampai 28 November 2014 yaitu sebanyak 42 data. Data saham harian tersebut kemudian dihitung nilai *return* sahamnya, sehingga terdapat sebanyak 2548 data *in sample* dan 42 data *out sample*.

### 3.2 Struktur Data Penelitian

Berikut struktur data penelitian yang akan digunakan.

Struktur data untuk *return* saham PT. Bank Negara Indonesia

Tabel 3.1 Struktur Data Penelitian PT. Bank Negara Indonesia

$t$	$y_t$
1	$y_1$
2	$y_2$
$\vdots$	$\vdots$
T	$y_T$

dengan  $t = 1, 2, \dots, T$  menunjukkan urutan data dan  $y_t$  adalah nilai return saham PT. Bank Negara Indonesia pada periode ke- $t$ .

### 3.3 Langkah Penelitian

Langkah analisis yang dilakukan untuk mencapai tujuan dari penelitian ini dibagi menjadi 2 bagian. Bagian pertama adalah langkah analisis untuk data bangkitan untuk keperluan simulasi dan bagian kedua adalah untuk analisis data *return* saham.

#### A. Bagian Pertama (Analisis Data Simulasi)

1. Membangkitkan data simulasi yang mengikuti proses *Linear Short Memory* (ARIMA), *NonLinear Short Memory* (LSTAR), *Linear Long Memory* (ARFIMA) dan *NonLinear Long Memory* (FILSTAR) sebanyak  $n = 200$  (sampel kecil) dan  $1000$  (sampel besar). Semua proses yang dibangkitkan tersebut dibatasi untuk model AR (1) dengan *setting* parameter sebagai berikut.
  - a. Data Bangkitan dengan mengikuti proses *Linear Short Memory* (ARIMA)

Pemilihan parameter di atas didasarkan pada derajat persistensi dari data bangkitan.

- Model ARIMA tanpa Outlier untuk  $n=200$  dan  $n=1000$

Bentuk umum model ARIMA :

$$Y_t = \phi Y_{t-1} + a_t$$

Skenario Simulasi :

Tabel 3.2 Skenario Simulasi Model ARIMA tanpa Outlier

Skenario ke-	$\phi_1$
1	0,2
2	0,5
3	0,8
4	-0,2
5	-0,5
6	-0,8

Keterangan: Semakin tinggi nilai  $\phi'_1$  maka data semakin pesisten. Perbedaan tanda positif dan negatif menunjukkan perbedaan arah pola pergerakan.

b. Data Bangkitan *NonLinear Short Memory* (LSTAR)

Pemilihan parameter untuk data bangkitan yang mengikuti proses LSTAR adalah sebagai berikut.

- Model LSTAR tanpa Outlier untuk n= 200 dan n=1000.

Bentuk umum model LSTAR :

$$Y_t = \phi' Y_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(Y_{t-1} - c)}} \right) - \theta' Y_{t-1} + a_t$$

Skenario simulasi :

Tabel 3.3 Skenario Simulasi Model LSTAR tanpa Outlier

Data Bangkitan ke-	$\gamma$	c	$\phi'$	$\theta'$
1	0,5	0	0,2	-0,2
2	0,5	0	0,5	-0,5
3	0,5	0	0,8	-0,8
4	5	0	0,2	-0,2
5	5	0	0,5	-0,5
6	5	0	0,8	-0,8
7	10	0	0,2	-0,2
8	10	0	0,5	-0,5
9	10	0	0,8	-0,8

Keterangan :

- Nilai  $\phi'$  dan  $\theta'$  menunjukkan persistensi dari pergerakan data.  
0,2 dan -0,2 mendekati nol menunjukkan data cenderung *mean referting*  
0,5 dan -0,5 menunjukkan data rata-rata persisten  
0,8 dan -0,8 mendekati satu menunjukkan data memiliki persistensi tinggi
- Nilai  $\gamma$  menunjukkan kehalusan fungsi transisi dari regime 1 ke regime 2.  
0,5 mendekati nol menunjukkan perpindahan dari regime 1 ke regime 2 secara *abropt* (kurang halus).  
5 menunjukkan perpindahan dari regime 1 ke regime 2 halus.  
10 menunjukkan perpindahan dari regime 1 ke regime 2 semakin halus.  
Semakin besar nilai  $\gamma$  maka perpindahan regime akan semakin halus.

c. Data Bangkitan *Linear Long Memory* (ARFIMA)

Pemilihan parameter untuk data bangkitan yang mengikuti proses ARFIMA adalah sebagai berikut.

- Model ARFIMA tanpa Outlier dengan n=200 dan n=1000

Bentuk umum model ARFIMA :

$$(1 - \phi_1 B)(1 - B)^d Y_t = a_t$$

Skenario simulasi :

Tabel 3.4 Skenario Simulasi Model ARFIMA tanpa Outlier

Skenario ke-	$\phi_1$	$d$
1	0,2	0,2
2	0,2	0,3
3	0,2	0,4
4	0,5	0,2
5	0,5	0,3
6	0,5	0,4
7	0,8	0,2
8	0,8	0,3
9	0,8	0,4
10	-0,2	0,2
11	-0,2	0,3
12	-0,2	0,4
13	-0,5	0,2
14	-0,5	0,3
15	-0,5	0,4
16	-0,8	0,2
17	-0,8	0,3
18	-0,8	0,4

Keterangan:

Semakin tinggi nilai  $\phi_1$  maka data semakin persisten. Perbedaan tanda positif dan negatif menunjukkan perbedaan arah pola pergerakan.

0,2 mendekati nilai nol menunjukkan data cenderung *mean reverting*

0,5 menunjukkan data memiliki rata-rata persistensi

0,8 menunjukkan data memiliki persistensi tinggi

Semakin tinggi nilai  $d$  (mendekati nilai satu) maka data semakin tidak stasioner.

d. Data Bangkitan *NonLinear Long Memory* (FILSTAR)

Pemilihan parameter untuk data bangkitan yang mengikuti proses FILSTAR adalah sebagai berikut.

- Model FILSTAR tanpa Outlier dengan n=200 dan n=1000

Bentuk umum model FILSTAR :

$$\dot{Y}_t = \phi \dot{Y}_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(\dot{Y}_{t-1} - c)}} \right) - \theta \dot{Y}_{t-1} + a_t$$

Keterangan :

$$\dot{Y}_t = (1 - B)^d Y_t$$

$$\dot{Y}_{t-1} = (1 - B)^d Y_{t-1}$$

Skenario simulasi :

Tabel 3.5 Skenario Simulasi Model FILSTAR tanpa Outlier

Skenario ke-	$d$	$\gamma$	$c$	$\phi'$	$\theta'$
1	0,2	0,5	0	0,2	-0,2
2	0,2	0,5	0	0,5	-0,5
3	0,2	0,5	0	0,8	-0,8
4	0,2	5	0	0,2	-0,2
5	0,2	5	0	0,5	-0,5
6	0,2	5	0	0,8	-0,8
7	0,2	10	0	0,2	-0,2
8	0,2	10	0	0,5	-0,5
9	0,2	10	0	0,8	-0,8
10	0,3	0,5	0	0,2	-0,2
11	0,3	0,5	0	0,5	-0,5
12	0,3	0,5	0	0,8	-0,8
13	0,3	5	0	0,2	-0,2
14	0,3	5	0	0,5	-0,5
15	0,3	5	0	0,8	-0,8
16	0,3	10	0	0,2	-0,2
17	0,3	10	0	0,5	-0,5
18	0,3	10	0	0,8	-0,8
19	0,4	0,5	0	0,2	-0,2
20	0,4	0,5	0	0,5	-0,5
21	0,4	0,5	0	0,8	-0,8
22	0,4	5	0	0,2	-0,2
23	0,4	5	0	0,5	-0,5
24	0,4	5	0	0,8	-0,8
25	0,4	10	0	0,2	-0,2
26	0,4	10	0	0,5	-0,5
27	0,4	10	0	0,8	-0,8

Keterangan :

- Nilai  $\phi'$  dan  $\theta'$  menunjukkan persistensi dari pergerakan data.

0,2 dan -0,2 mendekati nol menunjukkan data cenderung *mean reverting*  
 0,5 dan -0,5 menunjukkan data rata-rata persisten  
 0,8 dan -0,8 mendekati satu menunjukkan data memiliki persistensi tinggi  
 - Nilai  $\gamma$  menunjukkan kehalusan fungsi transisi dari regime 1 ke regime 2.  
 0,5 mendekati nol menunjukkan perpindahan dari regime 1 ke regime 2 secara *abrupt* (kurang halus).  
 5 menunjukkan perpindahan dari regime 1 ke regime 2 halus.  
 10 menunjukkan perpindahan dari regime 1 ke regime 2 semakin halus.  
 Semakin besar nilai  $\gamma$  maka perpindahan regime akan semakin halus.  
 - Semakin tinggi nilai  $d$  (mendekati nilai satu) maka data semakin tidak stasioner.

- e. Melakukan pengujian *long memory* pada data bangkitan dengan menggunakan uji GPH Estimator (*Geweke Poter Hudak*) dengan bandwith optimum sebesar 0.8.
- f. Melakukan pengujian *nonlineearitas* pada data bangkitan dengan menggunakan Uji Terasvirta dan Uji White.
- g. Melakukan pengulangan langkah a, b, c, d dan e sebanyak 1000 kali sehingga terdapat 1000 kali hasil pengujian.
- h. Menghitung power dari masing-masing tes pada masing-masing pengujian *long memory* dan *nonliniear*.
- i. Melakukan langkah a hingga langkah h dengan menambahkan efek outlier tipe *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC) pada langkah a, b dan c.
  - Data Bangkitan mengikuti proses *Linear Short Memory* (ARIMA) dengan menambahkan efek outlier tipe *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC).

#### ➤ Model ARIMA dengan *Additive Outlier*

*Additive Outlier* yang digunakan pada penelitian ini terletak pada pengamatan ke  $T_1=50$ ,  $T_2=100$ ,  $T_3=130$  dan  $T_4=170$  pada sampel kecil ( $n=200$ ), sedangkan pada sampel besar ( $n=1000$ ) *Additive Outlier* terletak pada pengamatan ke  $T_1=250$ ,  $T_2=500$ ,  $T_3=650$  dan  $T_4=750$ . Nilai parameter  $\phi_1$  yang digunakan sama seperti nilai  $\phi_1$  pada Tabel 3.2.

Bentuk umum model ARIMA dengan penambahan *Additive Outlier* :

$$Y_t = \frac{1}{1-\phi_1 B} a_t + \omega_1 I_t^{(T_1)} + \omega_2 I_t^{(T_2)} + \omega_3 I_t^{(T_3)} + \omega_4 I_t^{(T_4)}$$

dengan

$\omega_1 = 10$ ,  $\omega_2 = 13$ ,  $\omega_3 = 15$  dan  $\omega_4 = 17$  untuk semua parameter  $\phi_1$  pada  $n = 200$  dan  $n = 1000$ .

➤ Model ARIMA dengan Outlier *Level Shift*

Pada penelitian ini terdapat empat efek outlier *Level Shift*. Pada sampel kecil ( $n=200$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=51$ , untuk efek outlier *Level Shift* yang kedua terletak pada pengamatan ke  $T_2=76$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=126$ , untuk efek outlier *Level Shift* yang keempat terletak pada pengamatan ke  $T_4=151$  dengan  $\omega$  sebesar 20. Sedangkan pada sampel besar ( $n=1000$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=201$ , untuk efek outlier *Level Shift* yang kedua terletak pada pengamatan ke  $T_2=251$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=501$ , untuk efek outlier *Level Shift* yang keempat terletak pada pengamatan ke  $T_4=601$  dengan  $\omega$  sebesar 20. Saat efek outlier *Level Shift* yang kedua dan keempat efek tersebut kembali pada nilai semula. Nilai parameter  $\phi_1$  yang digunakan sama seperti nilai  $\phi_1$  pada Tabel 3.2.

Bentuk umum model ARIMA dengan penambahan Outlier *Level Shift* :

$$Y_t = \frac{1}{(1-\phi_1 B)} a_t + \frac{1}{(1-B)} (\omega I_t^{(T_1)} - \omega I_t^{(T_2)} + \omega I_t^{(T_3)} - \omega I_t^{(T_4)})$$

➤ Model ARIMA dengan Outlier *Temporary Change*

Terdapat satu efek *Temporary Change* yang digunakan pada penelitian ini. Efek outlier tersebut terletak pengamatan ke  $T_1 = 76$  dengan menggunakan  $\omega = 20$  dan  $\delta = 0,5$  pada sampel kecil ( $n=200$ ). Sedangkan pada sampel besar ( $n=1000$ ), efek outlier *Temporary Change* terletak pada pengamatan ke  $T_1 = 201$  dengan menggunakan  $\omega = 20$  dan  $\delta = 0,5$ . Nilai parameter  $\phi_1$  yang digunakan sama seperti nilai  $\phi_1$  pada Tabel 3.2.

Bentuk umum model ARIMA dengan penambahan Outlier *Temporary Change* :

$$Y_t = \frac{1}{(1-\phi_1 B)} a_t + \frac{1}{(1-\delta B)} (\omega I_t^{(T_1)})$$

#### ➤ Model ARIMA dengan *Innovational Outlier*

*Innovational Outlier* diletakkan pada *error* dari data bangkitan yang mengikuti proses ARIMA. Pada sampel kecil ( $n=200$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1 = 76$  dengan menggunakan  $\omega = 20$ . Sedangkan pada sampel besar ( $n=1000$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1 = 501$  dengan menggunakan  $\omega = 20$ . Nilai parameter  $\phi_1$  yang digunakan sama seperti nilai  $\phi_1$  pada Tabel 3.2.

Bentuk umum model ARIMA dengan penambahan *Innovational Outlier* :

$$Y_t = \frac{1}{(1-\phi_1 B)} (a_t + \omega I_t^{(T_1)})$$

- Data Bangkitan mengikuti proses *NonLinear Short Memory* (LSTAR) dengan menambahkan efek outlier tipe *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC).

#### ➤ Model LSTAR dengan *Additive Outlier*

*Additive Outlier* yang digunakan pada penelitian ini terletak pada pengamatan ke  $T_1 = 50$ ,  $T_2 = 100$ ,  $T_3 = 130$  dan  $T_4 = 170$  pada

sampel kecil ( $n=200$ ), sedangkan pada sampel besar ( $n=1000$ ) *Additivel Outlier* terletak pada pengamatan ke  $T_1=250$ ,  $T_2=500$ ,

$T_3=650$  dan  $T_4=750$ . Nilai parameter  $\gamma$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.3.

Bentuk umum model LSTAR dengan penambahan *Additive Outlier* :

$$Y_t = \phi' Y_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(Y_{t-1}-c)}} \right) + \theta' Y_{t-1} + \omega_1 I_t^{(T_1)} + \omega_2 I_t^{(T_2)} + \omega_3 I_t^{(T_3)} + \omega_4 I_t^{(T_4)} + a_t$$

dengan

$\omega_1 = 10$ ,  $\omega_2 = 13$ ,  $\omega_3 = 15$  dan  $\omega_4 = 17$  untuk semua parameter  $\gamma$ ,  $c$ ,  $\phi'$ ,  $\theta'$  pada  $n = 200$  dan  $n = 1000$ .

#### ➤ Model LSTAR dengan Outlier *Level Shift*

Pada penelitian ini terdapat empat efek outlier *Level Shift*. Pada sampel kecil ( $n=200$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=51$ , untuk efek outlier *Level Shift* yang kedua terletak pada pengamatan ke  $T_2=76$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=126$ , untuk efek outlier *Level Shift* yang keempat terletak pada pengamatan ke  $T_4=151$  dengan  $\omega$  sebesar 20. Sedangkan pada sampel besar ( $n=1000$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=201$ , untuk efek outlier *Level Shift* yang kedua terletak pada pengamatan ke  $T_1=251$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=501$ , untuk efek outlier *Level Shift* yang keempat terletak pada pengamatan ke  $T_4=601$  dengan  $\omega$  sebesar 20. Saat efek outlier *Level Shift* yang kedua dan keempat efek tersebut kembali pada nilai semula. Nilai parameter  $\gamma$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.3.

Bentuk umum model LSTAR dengan penambahan Outlier *Level Shift* :

$$Y_t = \phi' Y_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(Y_{t-1} - c)}} \right) + \theta' Y_{t-1} + a_t + \frac{1}{(1-B)} (\omega I_t^{(T_1)} - \omega I_t^{(T_2)} + \omega I_t^{(T_3)} - \omega I_t^{(T_4)})$$

➤ Model LSTAR dengan Outlier *Temporary Change*

Terdapat satu efek *Temporary Change* yang digunakan pada penelitian ini. Efek outlier tersebut terletak pada pengamatan ke  $T_1=76$  dengan menggunakan  $\omega=20$  dan  $\delta=0,5$  pada sampel kecil ( $n=200$ ). Sedangkan pada sampel besar ( $n=1000$ ), efek outlier *Temporary Change* terletak pada pengamatan ke  $T_1=201$  dengan menggunakan  $\omega=20$  dan  $\delta=0,5$  pada sampel kecil ( $n=200$ ). Nilai parameter  $\gamma$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.3.

Bentuk umum model LSTAR dengan penambahan Outlier *Temporary Change* :

$$Y_t = \phi' Y_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(Y_{t-1} - c)}} \right) + \theta' Y_{t-1} + a_t + \frac{1}{(1-\delta B)} (\omega I_t^{(T_1)})$$

➤ Model LSTAR dengan *Innovational Outlier*

*Innovational Outlier* diletakkan pada *error* dari data bangkitan yang mengikuti proses LSTAR. Pada sampel kecil ( $n=200$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1=76$ . Sedangkan pada sampel besar ( $n=1000$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1=501$ . Nilai parameter  $\gamma$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.3.

Bentuk umum model LSTAR dengan penambahan *Innovational Outlier* :

$$Y_t = \left[ \phi' Y_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(Y_{t-1} - c)}} \right) + \theta' Y_{t-1} \right] (a_t + \omega I_t^{(T_1)})$$

- Data Bangkitan mengikuti proses *Linear Long Memory* (ARFIMA) dengan menambahkan efek outlier tipe *Additive*

*Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC).

➤ Model ARFIMA dengan *Additive Outlier*

*Additive Outlier* yang digunakan pada data bangkitan yang mengikuti proses ARFIMA terletak pada pengamatan ke  $T_1=50$ ,  $T_2=100$ ,  $T_3=130$  dan  $T_4=170$  pada sampel kecil ( $n=200$ ), sedangkan pada sampel besar ( $n=1000$ ) *Additive Outlier* terletak pada pengamatan ke  $T_1=250$ ,  $T_2=500$ ,  $T_3=650$  dan  $T_4=750$ . Nilai parameter  $\phi$  dan  $d$  yang digunakan sama seperti yang disajikan pada Tabel 3.4.

Bentuk umum model ARFIMA dengan penambahan *Additive Outlier* :

$$Y_t = \frac{1}{(1-\phi_1 B)(1-B)^d} a_t + \omega_1 I_t^{(T_1)} + \omega_2 I_t^{(T_2)} + \omega_3 I_t^{(T_3)} + \omega_4 I_t^{(T_4)} + a_t$$

dengan

$\omega_1 = 10$ ,  $\omega_2 = 13$ ,  $\omega_3 = 15$  dan  $\omega_4 = 17$  untuk semua parameter  $\phi_1$  dan  $d$  pada  $n = 200$  dan  $n = 1000$ .

➤ Model ARFIMA dengan *Outlier Level Shift*

Pada penelitian data bangkitan yang mengikuti proses ARFIMA diberikan empat efek outlier *Level Shift*. Pada sampel kecil ( $n=200$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=51$ , untuk efek outlier *Level Shift* yang kedua terletak pada  $T_2=76$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=126$ , untuk efek outlier *Level Shift* yang kedua terletak pada  $T_4=151$  dengan  $\omega$  sebesar 20. Sedangkan pada sampel besar ( $n=1000$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=201$ , untuk efek outlier *Level Shift* yang kedua terletak pada  $T_2=250$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=501$ , untuk efek outlier *Level Shift* yang keempat terletak pada

$T_{100}=601$  dengan  $\omega$  sebesar 20. Saat efek outlier *Level Shift* yang kedua dan keempat efek tersebut kembali pada nilai semula. Nilai parameter  $\phi$  dan  $d$  yang digunakan sama seperti yang disajikan pada Tabel 3.4.

Bentuk umum model ARFIMA dengan penambahan Outlier *Level Shift* :

$$Y_t = \frac{1}{(1-\phi_1 B)(1-B)^d} a_t + \frac{1}{(1-B)} (\omega I_t^{(T_1)} - \omega I_t^{(T_2)} + \omega I_t^{(T_3)} - \omega I_t^{(T_4)})$$

#### ➤ Model ARFIMA dengan *Outlier Temporary Change*

Terdapat satu efek *Temporary Change* yang digunakan pada penelitian ini. Efek outlier tersebut terletak pada pengamatan ke  $T_1=76$  dengan menggunakan  $\omega=20$  dan  $\delta=0,5$  pada sampel kecil ( $n=200$ ). Sedangkan pada sampel besar ( $n=1000$ ), efek outlier *Temporary Change* terletak pada pengamatan ke  $T_1=201$  dengan menggunakan  $\omega=20$  dan  $\delta=0,5$  pada sampel kecil ( $n=200$ ). Nilai parameter  $\phi$  dan  $d$  yang digunakan sama seperti yang disajikan pada Tabel 3.4.

Bentuk umum model ARFIMA dengan penambahan Outlier *Temporary Change* :

$$Y_t = \frac{1}{(1-\phi_1 B)(1-B)^d} a_t + \frac{1}{(1-\delta B)} (\omega I_t^{(T_1)})$$

#### ➤ Model ARFIMA dengan *Innovational Outlier*

*Innovational Outlier* diletakkan pada error dari data bangkitan yang mengikuti proses ARFIMA. Pada sampel kecil ( $n=200$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1=76$ . Sedangkan pada sampel besar ( $n=1000$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1=501$ . Nilai parameter  $\phi$  dan  $d$  yang digunakan sama seperti yang disajikan pada Tabel 3.4.

Bentuk umum model ARFIMA dengan penambahan *Innovational Outlier* :

$$Y_t = \frac{1}{(1-\phi' B)(1-B)^d} (a_t + \omega I_t^{(T_1)})$$

- Data Bangkitan mengikuti proses NonLinear Long Memory (FILSTAR) dengan menambahkan efek outlier tipe *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC).

➤ Model FILSTAR dengan *Additive Outlier*

*Additive Outlier* yang digunakan pada penelitian ini terletak pada pengamatan ke  $T_1=50$ ,  $T_2=100$ ,  $T_3=130$  dan  $T_4=170$  pada sampel kecil ( $n=200$ ), sedangkan pada sampel besar ( $n=1000$ ) *Additive Outlier* terletak pada pengamatan ke  $T_1=250$ ,  $T_2=500$ ,  $T_3=650$  dan  $T_4=750$ . Nilai parameter  $\gamma$ ,  $d$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.5.

Bentuk umum model FILSTAR dengan penambahan *Additive Outlier* :

$$\dot{Y}_t = \phi' \dot{Y}_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(\dot{Y}_{t-1} - c)}} \right) + \theta' \dot{Y}_{t-1} + \omega_1 I_t^{(T_1)} + \omega_2 I_t^{(T_2)} + \omega_3 I_t^{(T_3)} + \omega_4 I_t^{(T_4)} + a_t$$

$$\dot{Y}_t = (1-B)^d Y_t$$

$$\dot{Y}_{t-1} = (1-B)^d Y_{t-1}$$

dengan

$\omega_1 = 10$ ,  $\omega_2 = 13$ ,  $\omega_3 = 15$  dan  $\omega_4 = 17$  untuk semua parameter  $\gamma$ ,  $d$ ,  $c$ ,  $\phi'$ ,  $\theta'$  pada  $n = 200$  dan  $n = 1000$ .

➤ Model FILSTAR dengan Outlier *Level Shift*

Pada penelitian data bangkitan yang mengikuti proses FILSTAR diberikan empat efek outlier *Level Shift*. Pada sampel kecil ( $n=200$ ) efek outlier *Level Shift* yang pertama terletak pengamatan ke  $T_1=51$ , efek outlier *Level Shift* yang kedua terletak pada pengamatan ke  $T_2=75$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_1=126$ , efek outlier *Level Shift* yang keempat terletak pada pengamatan ke

$T_4=150$  dengan  $\omega$  sebesar 20. Sedangkan pada sampel besar ( $n=1000$ ) efek outlier *Level Shift* yang pertama terletak pada pengamatan ke  $T_1=201$ , efek outlier *Level Shift* yang kedua terletak pada pengamatan ke  $T_2=251$ , untuk efek outlier *Level Shift* yang ketiga terletak pada pengamatan ke  $T_3=501$ , efek outlier *Level Shift* yang keempat terletak pada pengamatan  $T_4=601$  dengan  $\omega$  sebesar 20. Saat efek outlier *Level Shift* yang kedua dan keempat efek tersebut kembali pada nilai semula. Nilai parameter  $\gamma$ ,  $d$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.5.

Bentuk umum model FILSTAR dengan penambahan Outlier *Level Shift* :

- Menggunakan  $n=200$

$$\begin{aligned}\dot{Y}_t &= \phi' \dot{Y}_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(\dot{Y}_{t-1} - c)}} \right) + \theta' \dot{Y}_{t-1} + \frac{1}{(1-B)} (\omega I_t^{(T_1)} - \omega I_t^{(T_2)} + \omega I_t^{(T_3)} - \omega I_t^{(T_4)}) \\ \dot{Y}_t &= (1-B)^d Y_t \\ \dot{Y}_{t-1} &= (1-B)^d Y_{t-1}\end{aligned}$$

#### ➤ Model FILSTAR dengan Outlier *Temporary Change*

Terdapat satu efek *Temporary Change* yang digunakan pada penelitian ini. Efek outlier tersebut terletak pada pengamatan ke  $T_1=51$  dengan menggunakan  $\omega=20$  dan  $\delta=0,5$  pada sampel kecil ( $n=200$ ). Sedangkan pada sampel besar ( $n=1000$ ), efek outlier *Temporary Change* terletak pada pengamatan ke  $T_1=201$  hingga  $T_1=251$  dengan menggunakan  $\omega=20$  dan  $\delta=0,5$  pada sampel besar ( $n=1000$ ). Nilai parameter  $\gamma$ ,  $d$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.5.

Bentuk umum model FILSTAR dengan penambahan Outlier *Temporary Change* :

$$\dot{Y}_t = \phi' \dot{Y}_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(Y_{t-1} - c)}} \right) + \theta' \dot{Y}_{t-1} + a_t + \frac{1}{(1-\delta B)} (\omega I_t^{(T_1)})$$

$$\dot{Y}_t = (1 - B)^d Y_t$$

$$\dot{Y}_{t-1} = (1 - B)^d Y_{t-1}$$

➤ Model FILSTAR dengan *Innovational Outlier*

*Innovational Outlier* diletakkan pada error dari data bangkitan yang mengikuti proses FILSTAR. Pada sampel kecil ( $n=200$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1=76$ . Sedangkan pada sampel besar ( $n=1000$ ), outlier tersebut diletakkan pada pengamatan ke  $T_1=501$ . Berikut model dari data bangkitan yang akan digunakan. Nilai parameter  $\gamma$ ,  $d$ ,  $c$ ,  $\phi'$ ,  $\theta'$  yang digunakan sama seperti yang disajikan pada Tabel 3.5.

Bentuk umum model LSTAR dengan penambahan *Innovational Outlier* :

$$\dot{Y}_t = \left[ \phi' \dot{Y}_{t-1} \left( 1 - \frac{1}{1 + e^{-\gamma(\dot{Y}_{t-1} - c)}} \right) + \theta' \dot{Y}_{t-1} \right] (a_t + \omega I_t^{(T_1)}) \dot{Y}_t = (1 - B)^d Y_t$$

$$\dot{Y}_{t-1} = (1 - B)^d Y_{t-1}$$

2. Membandingkan hasil dari perhitungan power dari masing masing pengujian antara data bangkitan tanpa adanya efek outlier dengan data bangkitan yang telah ditambahkan dengan adanya efek outlier untuk melihat kerobustan dari uji Terasvirta, uji White dan uji GPH estimator.

#### B. Bagian Kedua (Analisis Data *Return* Saham)

1. Melakukan pengambilan data saham harian dari salah satu saham liquid dan *volatile* yang termasuk indeks LQ 45 yaitu saham PT. Bank Negara Indonesia dari periode 8 Juni 2004 hingga 28 November 2014.
2. Melakukan uji Long Memory pada data *return* saham PT. Bank Negara Indonesia dengan menggunakan uji GPH Estimator. Data *return* saham dibuat plot ACF dan PACF sebagai pendugaan secara visual indikasi proses *Long Memory*.

3. Melakukan uji *Lineearitas* pada data *return* saham PT. Bank Negara Indonesia dengan menggunakan Uji Terasvirta (Uji Lagrange Multiplier) dan Uji White.
  4. Melakukan pemodelan Long Memory untuk data *return* saham dengan ARFIMA.
- Membentuk dan memperoleh hasil peramalan model ARFIMA  $(p,d,q)$  dengan langkah sebagai berikut.
- 1) Mengestimasi  $d$  pada model ARIMA  $(p,d,q)$ , dengan menotasikannya sebagai  $\hat{d}$  berdasarkan bandwith 0,8.
  - 2) Menghitung nilai  $\hat{U}_t = (1-B)^{\hat{d}} Y_t$ .
  - 3) Menggunakan nilai  $\hat{U}_t$  sebagai data baru yang akan diolah.
  - 4) Membuat plot ACF dan PACF dari data baru  $\hat{U}_t$ .
  - 5) Menentukan dugaan orde AR atau MA yang sesuai dengan plot ACF dan PACF yang terbentuk. Sehingga didapatkan model ARFIMA  $(p,d,q)$ .
  - 6) Melakukan estimasi dan pengujian terhadap parameter yang dihasilkan, jika signifikan, maka model digunakan.
  - 7) Melakukan cek diagnosa yaitu mengecek asumsi *white noise* dan distribusi normal terhadap model yang terbentuk.
  - 8) Melakukan peramalan terhadap data dengan menggunakan model ARFIMA  $(p,d,q)$  yang terbaik.
5. Melakukan pemodelan non*Lineear* untuk setiap data *return* saham dengan model LSTAR.
    - a. Melakukan pemodelan dan peramalan untuk setiap data *return* saham dengan menggunakan model STAR. Model STAR yang digunakan yaitu model LSTAR
      - 1) Melakukan estimasi parameter dan pengujian signifikansi untuk parameter model LSTAR yang terbentuk.
      - 2) Memilih model yang memiliki nilai AIC terkecil dari semua model yang terbentuk.
      - 3) Melakukan pemodelan LSTAR dengan persaaan umum

$$y_t = \phi' x_t [1 - G(s_t; \gamma, c)] + \theta' x_t G(s_t; \gamma, c) + a_t$$

dengan fungsi transisi  $G(s_t; \gamma, c) = 1 - \frac{1}{1 + e^{-\gamma(z_t - c)}}$

4) Melakukan peramalan dari model LSTAR yang telah terbentuk.

#### 6. Melakukan pemodelan dengan FILSTAR

Langkah pemodelan dengan FISTAR adalah sebagai berikut.

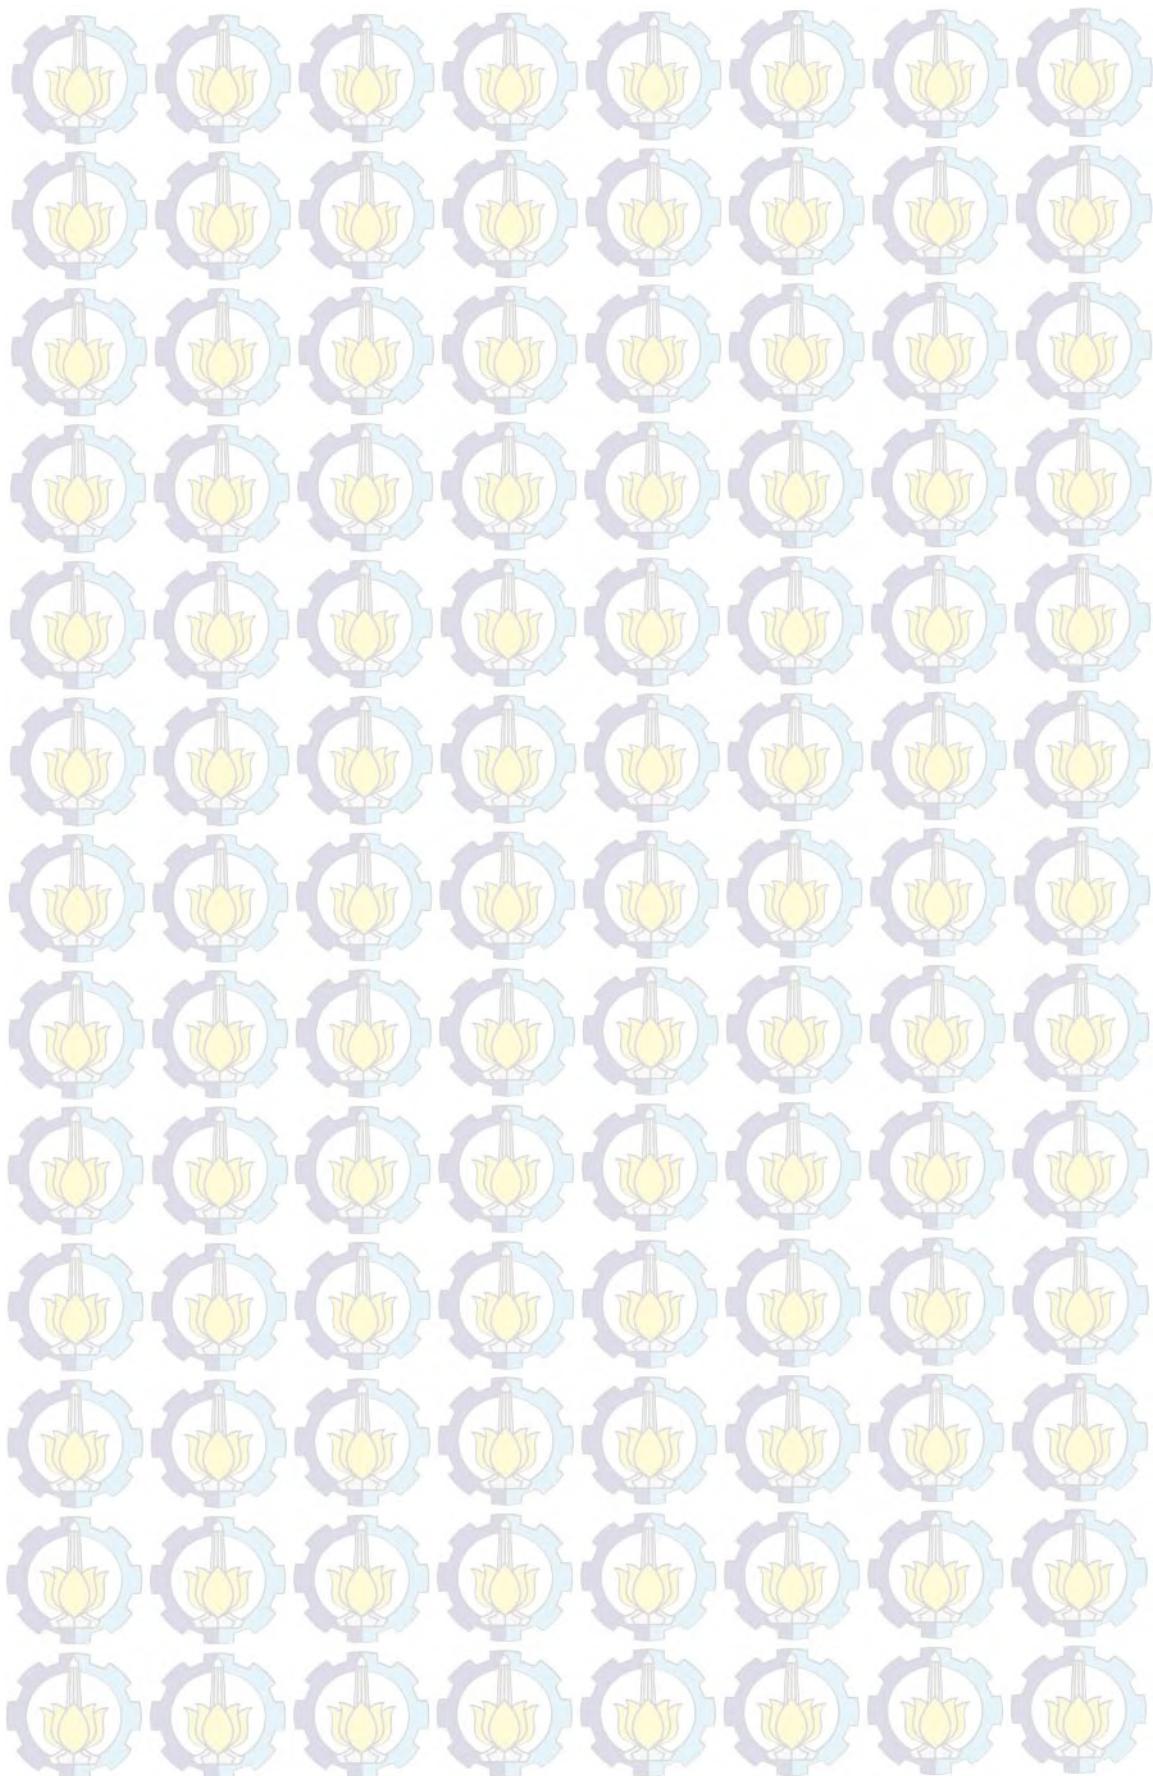
- Mengestimasi nilai parameter  $d$  dari data *return* saham PT. Bank Negara Indonesia dengan estimator GPH menggunakan *bandwidth* optimum 0,8.
- Setelah didapatkan nilai differencing dari estimator GPH, dilakukan pengolahan kembali menggunakan *datadiff series* untuk mendapatkan data baru yang telah didifferencing.. Kemudian mengolah data yang telah stasioner tersebut menggunakan model STAR, dalam hal ini model STAR yang digunakan adalah model LSTAR.
- Melakukan estimasi dan pengujian signifikansi parameter dari model yang terbentuk. Persamaan sederhana model ISTAR :

$$y_t = \phi' x_t [1 - G(s_t; \gamma, c)] + \theta' x_t G(s_t; \gamma, c) + a_t$$

dengan  $\dot{y}_t = (1 - B)^d y_t$  dan fungsi transisi

$$G(s_t; \gamma, c) = 1 - \frac{1}{1 + e^{-\gamma(z_t - c)}}$$

- Melakukan peramalan dari model FILSTAR yang telah terbentuk.
- Menentukan metode peramalan terbaik antara model ARFIMA, model LSTAR dan model FILSTAR dengan cara membandingkan hasil peramalan berdasarkan MSE dan RMSE data hasil peramalan.



## BAB 4

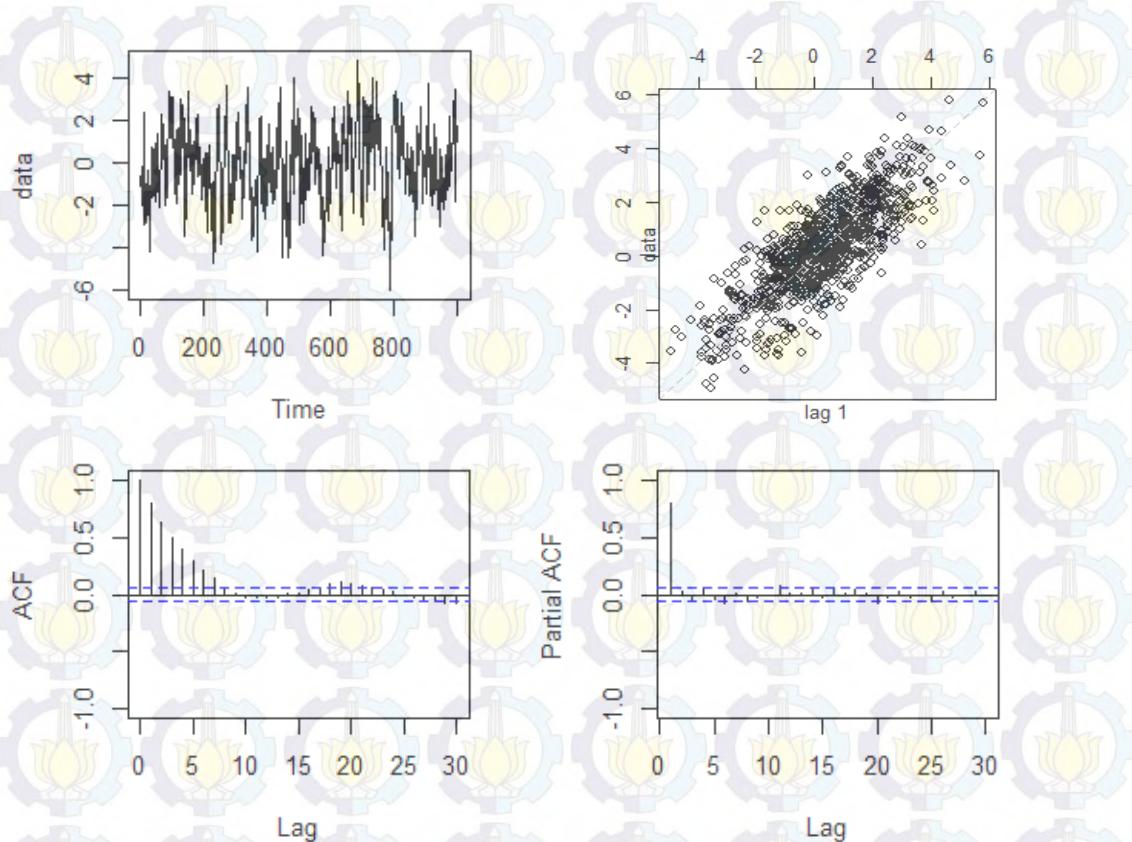
### HASIL DAN PEMBAHASAN

#### 4.1 Simulasi Data *Time Series*

Dalam penelitian ini dilakukan simulasi menurut sifat datanya yaitu short memory dan long memory, dimana untuk kedua data tersebut dibangkitkan pola linier dan nonlinier. Bangkitan data linier *short memory* menggunakan model ARIMA (*Autoregressive Integrated Moving Average*), bangkitan data nonlinier *short memory* menggunakan model LSTAR (*Logistic Smoothing Trasition Autoregressive*), bangkitan data linier long memory menggunakan model ARFIMA (*Autoregressive Fractionally Integrated Moving Average*), sedangkan bangkitan data nonlinier long memory menggunakan model FILSTAR (*Fractional Integrated Logistic Smoothing Trasition Autoregressive*). Data bangkitan tersebut kemudian ditambahkan efek outlier *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC). Pada penelitian ini akan dilakukan simulasi untuk mengetahui power dari uji Terasvirta, uji White dan uji GPH Estimator terhadap beberapa setting data bangkitan tersebut dengan dan tanpa penambahan efek outlier.

##### 4.1.1 Simulasi Data Bangkitan ARIMA (1,0,0)

Pada dasarnya ARIMA (*Autoregressive Integrated Moving Average*) merupakan suatu model dengan data yang memiliki sifat linier short memory. Berikut ini ditampilkan hasil simulasi dengan menggunakan data bangkitan ARIMA (1,0,0) dengan beberapa beberapa setting parameter  $\phi$  yaitu 0,2, 0,5, 0,8, -0,2, -0,5, -0,8 menggunakan jumlah sampel kecil n=200 dan sampel besar n=1000. Hasil simulasi yang ditampilkan merupakan hasil simulasi dari data bangkitan dengan dan tanpa penambahan outlier pada datanya. Efek dengan dan tanpa penambahan outlier dilihat berdasarkan power dari uji Terasvirta, uji White dan uji GPH Estimator. Berikut time series plot dari model ARIMA (1,0,0).



Gambar 4.1 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA Tanpa Tambahan Outlier

Berdasarkan Tabel 4.1 dapat diketahui bahwa pada saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 dengan sampel kecil ( $n=200$ ) power dari uji Terasvirta dan uji White berkisar antara 4,5% hingga 5,8%, hal ini menunjukkan bahwa data terdeteksi memiliki pola linier, sehingga uji Terasvirta dan uji White robust untuk mendeteksi kelinieran suatu data yang mengikuti proses ARIMA. Begitu pula halnya dengan sampel besar ( $n=1000$ ), pada saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 uji Terasvirta dan White robust untuk mendeteksi kelinieran suatu data yang mengikuti proses ARIMA, ini ditunjukkan oleh power dari kedua uji tersebut yang berkisar antara 3,6% hingga 5%. Di sisi lain, power dari uji GPH yang dihasilkan saat  $\phi$  bernilai 0,2, 0,5 dan 0,8 berkisar antara 88,3% hingga 100% untuk sampel kecil dan 93% hingga 100% untuk sampel besar, hal ini berarti bahwa saat  $\phi$  bernilai 0,2, 0,5 dan 0,8 data terdeteksi memiliki pola long memory. Akan tetapi power dari uji GPH yang dihasilkan saat  $\phi$  bernilai -0,2, -0,5 dan -0,8 berkisar antara 1% hingga 20,5% untuk sampel kecil dan 3,7%

hingga 19,4% untuk sampel besar, hal ini berarti bahwa saat  $\phi$  bernilai -0,2, -0,5 dan -0,8 data terdeteksi memiliki pola short memory. Hal ini cukup wajar karena proses ARIMA dengan  $\phi$  tinggi memiliki sifat persistensi yang tinggi, sehingga ketika data memiliki persistensi tinggi kemungkinan terdapat kesalahan identifikasi apakah terdeteksi short memory ataukah long memory. Dalam hal ini, saat  $\phi$  tinggi data yang mengikuti proses ARIMA (linier short memory) terdeteksi sebagai data yang berpolanya linier long memory. Sehingga uji GPH estimator tidak cukup bagus untuk mendeteksi sifat long memory atau short memory dengan deraja persistensi tinggi. Hal ini konsisten dengan hasil simulasi yang dilakukan oleh Kuswanto dan Sibertsen (2007).

Tabel 4.1 Hasil Simulasi Power dari Uji-uji pada Data ARIMA (1,0,0) Tanpa Penambahan Outlier pada n=200 dan n=1000

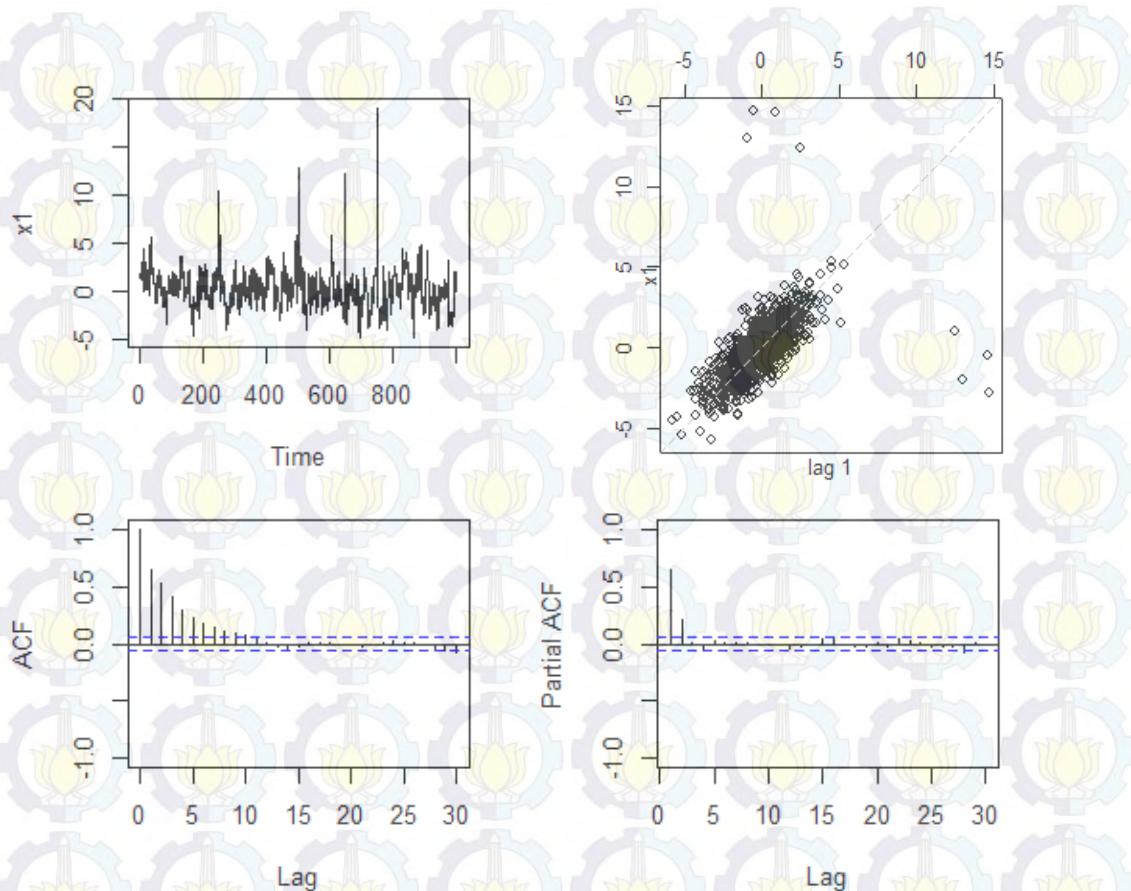
$\phi$	n = 200				n = 1000			
	Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,051	0,057	0,883	0,111	0,050	0,049	0,930	0,066
0,5	0,045	0,049	1,000	0,338	0,043	0,043	1,000	0,238
0,8	0,052	0,050	1,000	0,674	0,044	0,047	1,000	0,563
-0,2	0,049	0,053	0,205	-0,076	0,038	0,050	0,194	-0,039
-0,5	0,056	0,058	0,042	-0,152	0,047	0,052	0,048	-0,069
-0,8	0,050	0,056	0,010	-0,185	0,036	0,037	0,038	-0,079

#### 4.1.2 Simulasi Data Bangkitan ARIMA (1,0,0) dengan Penambahan Efek Outlier

Penambahan efek outlier *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC) diduga dapat mempengaruhi power dari uji Terasvirta, uji White dan uji GPH Estimator. Hal ini dapat dilihat dari hasil simulasi pada tabel 4.2, tabel 4.3, tabel 4.4 dan tabel 4.5.

- Data Mengikuti Proses ARIMA dengan Penambahan Outlier *Additive*

Berikut plot *time series* dari data bangkitan yang mengikuti proses ARIMA dengan penambahan efek outlier *additive*.



Gambar 4.2 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan Outlier *Additive*

Tabel 4.2 Hasil Simulasi Power dari Uji-uji pada Data ARIMA(1,0,0) dengan Penambahan Outlier *Additive* pada n=200 dan n=1000

$\phi$	n = 200				n = 1000			
	Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,095	0,143	0,507	-0,003	0,798	0,785	0,812	0,037
0,5	0,775	0,819	0,859	0,083	1,000	0,999	1,000	0,166
0,8	0,999	1,000	0,998	0,292	1,000	0,999	1,000	0,451
-0,2	0,090	0,123	0,210	-0,050	0,801	0,774	0,254	-0,026
-0,5	0,681	0,768	0,118	-0,068	1,000	0,998	0,200	-0,034
-0,8	1,000	1,000	0,105	-0,069	1,000	1,000	0,166	-0,034

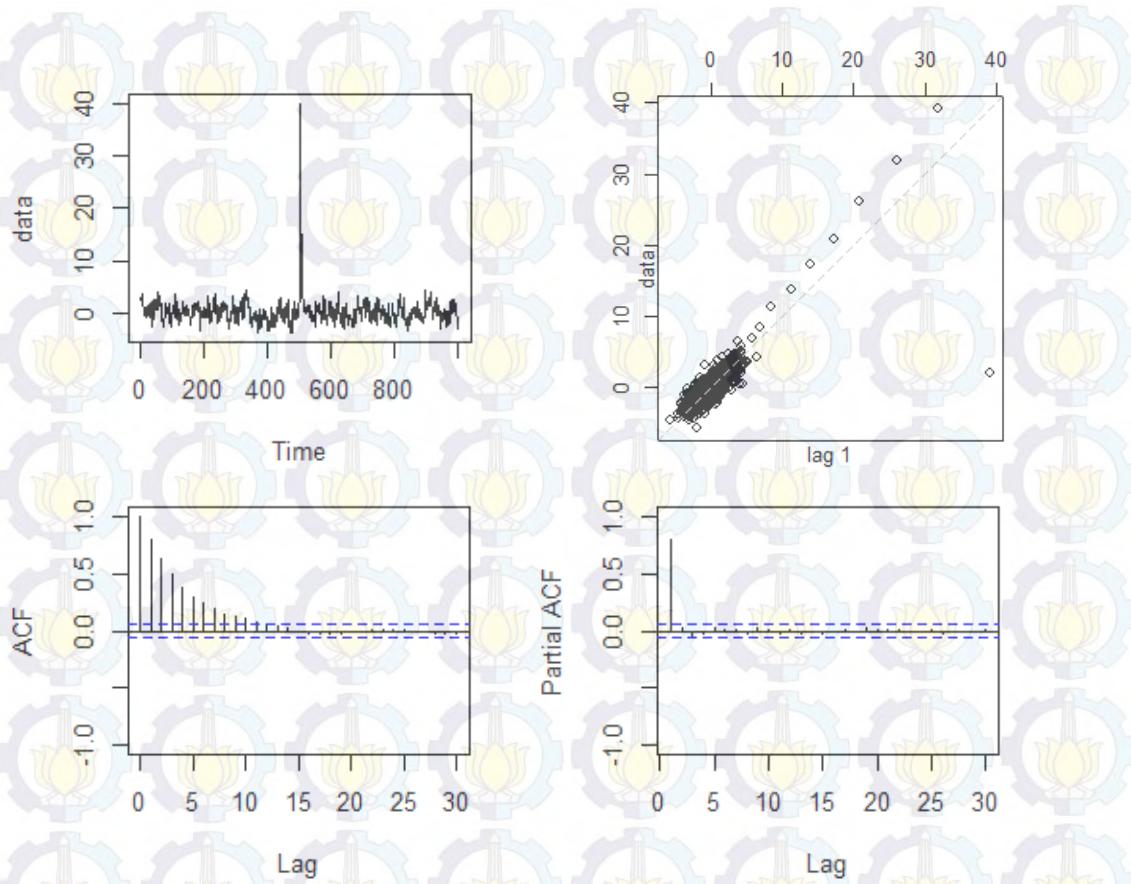
Berdasarkan Tabel 4.2 dapat diketahui bahwa dengan adanya penambahan outlier *additive* pada proses ARIMA dapat mempengaruhi perubahan power pada ketiga uji tersebut. Pada saat  $\phi$  bernilai 0,2 dan -0,2 untuk sampel kecil (n=200), uji Terasvirta dan uji White masih robust terhadap penambahan outlier *additive* karena power dari kedua uji tersebut mengalami kenaikan yang

tidak signifikan sehingga tidak mempengaruhi kesimpulan dari deteksi sebelumnya. Akan tetapi pada saat  $\phi$  bernilai 0,2 dan -0,2 untuk sampel besar ( $n=1000$ ) dan juga  $\phi$  bernilai 0,5, -0,5, 0,8 dan -0,8 baik untuk sampel kecil maupun sampel besar uji Terasvirta dan uji White tidak lagi robust karena kenaikan powernya yang sangat signifikan sehingga dapat mempengaruhi kesimpulan dari deteksi sebelumnya yang harusnya data memiliki pola linier menjadi nonlinier. Sehingga dalam hal ini adanya outlier *additive* sangat berpengaruh ketika ditambahkan pada data bangkitan yang mengikuti proses ARIMA dengan  $\phi$  bernilai -0,2 dan 0,2 untuk sampel besar dan juga  $\phi$  bernilai -0,5, -0,8, 0,5 dan 0,8 baik untuk sampel kecil maupun sampel besar.

Pada uji GPH estimator saat  $\phi$  bernilai 0,2, 0,5 dan 0,8 baik sampel besar maupun sampel kecil mengalami penurunan power yang tidak signifikan sehingga data terdeteksi mengikuti proses long memory. Akan tetapi saat uji GPH estimator saat  $\phi$  bernilai 0,2 untuk sampel kecil mengalami penurunan power yang signifikan sehingga data berubah pola menjadi short memory. Saat  $\phi$  bernilai 0,2 pada sampel besar mengalami penurunan power yang tidak signifikan dan tidak mempengaruhi kesimpulan dari deteksi sebelumnya, begitu pula untuk  $\phi$  bernilai 0,5, 0,8, -0,2, -0,5 dan -0,8 power uji GPH mengalami kenaikan dan penurunan yang tidak signifikan sehingga tidak mempengaruhi kesimpulan dari deteksi sebelumnya. Keberadaan outlier *additive* pada proses ARIMA tidak terlalu berpengaruh terhadap uji GPH estimator karena uji GPH masih cukup robust pada saat terdapat penambahan outlier *additive*. Secara keseluruhan, adanya penambahan outlier *additive* sangat berpengaruh terhadap kelinieran dari proses ARIMA untuk  $\phi$  bernilai 0,2, 0,5, 0,8, -0,5 dan -0,8, akantetapi tidak berpengaruh saat  $\phi$  bernilai -0,2 karena sifat datanya tetap, akan tetapi tidak terlalu berpengaruh terhadap uji GPH estimator.

- Data Mengikuti Proses ARIMA dengan Penambahan *Innovational Outlier*.

Selain mengikuti proses ARIMA dengan adanya efek outlier *additive*, terkadang data juga mengikuti proses ARIMA dengan adanya efek *Innovational Outlier*. Berikut plot *time series* dari data bangkitan yang mengikuti proses ARIMA dengan penambahan efek *Innovational Outlier*.



Gambar 4.3 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan *Innovational Outlier*

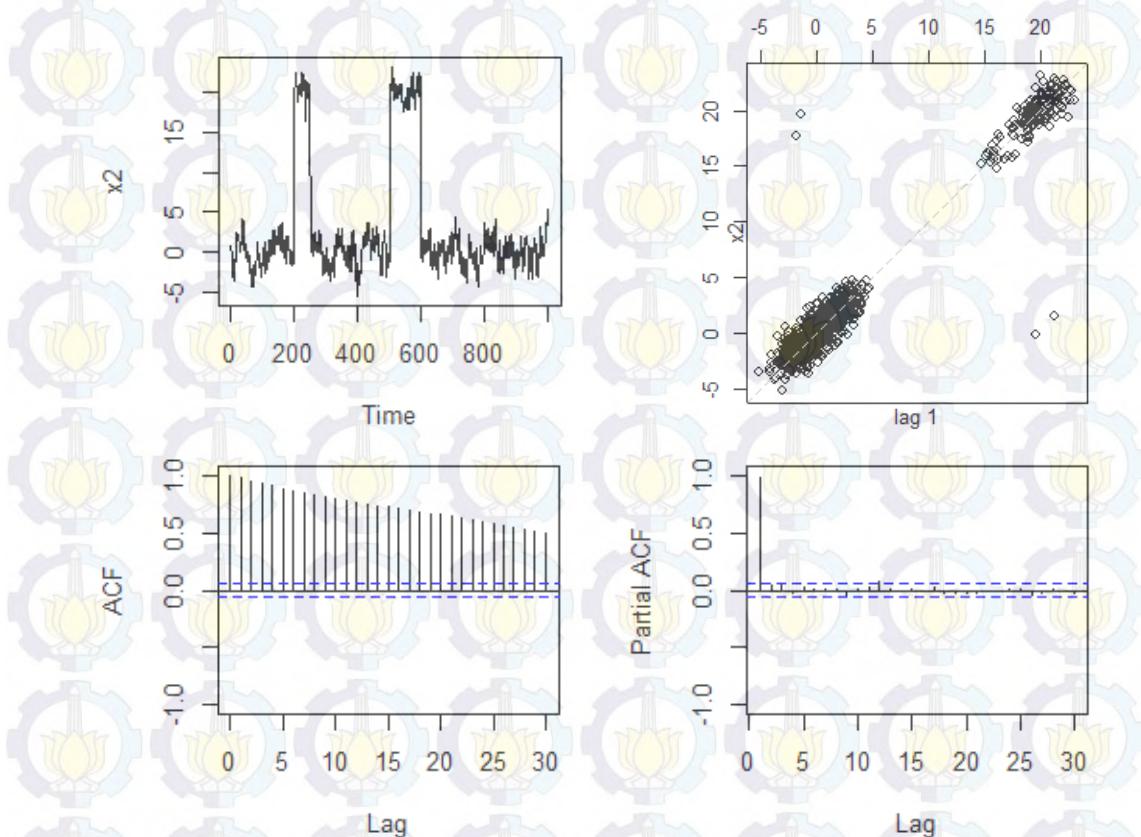
Tabel 4.3 Hasil Simulasi Power dari Uji-uji pada Data ARIMA(1,0,0) dengan Penambahan *Innovational Outlier* pada n=200 dan n=1000

$\phi$	n = 200				n = 1000			
	Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,049	0,060	0,925	0,092	0,017	0,022	0,992	0,087
0,5	0,023	0,061	1,000	0,367	0,003	0,018	1,000	0,231
0,8	0,036	0,062	1,000	0,668	0,005	0,016	1,000	0,547
-0,2	0,040	0,050	0,081	-0,078	0,030	0,031	0,193	-0,035
-0,5	0,005	0,019	0,000	-0,184	0,001	0,021	0,038	-0,066
-0,8	0,000	0,008	0,001	-0,180	0,000	0,013	0,000	-0,095

Pada Tabel 4.3 dapat dilihat bahwa adanya penambahan *Innovational Outlier* pada proses ARIMA tidak mempengaruhi kesimpulan dari deteksi pola data pada ARIMA tanpa penambahan outlier baik untuk sampel besar (n=1000) maupun sampel kecil (n=200). Hal ini karena power uji Terasvirta, uji White dan uji GPH estimator mengalami penurunan yang tidak signifikan sehingga tidak mempengaruhi perubahan deteksi awal. Pada  $\phi$  bernilai 0,2, 0,5 dan 0,8 pola data

masih mengikuti pola linier dengan power uji Terasvirta dan uji White untuk sampel besar dan sampel kecil berkisar antara 0,3% hingga 6,2%, sedangkan pada  $\phi$  bernilai -0,2, -0,5 dan -0,8 pola data masih mengikuti pola dengan power uji Terasvirta dan uji White untuk sampel besar dan sampel kecil berkisar antara 0% hingga 19,3%. Sehingga dalam hal ini, uji Terasvirta dan uji White masih robust digunakan ketika terdapat *Innovational Outlier* pada data bangkitan yang mengikuti proses ARIMA. Untuk uji GPH estimator power pada  $\phi$  bernilai 0,2, 0,5 dan 0,8 berkisar antara 92,5% hingga 100%, sedangkan pada  $\phi$  bernilai -0,2, -0,5 dan -0,8 berkisar antara 0% hingga 19,3%. Sehingga dapat disimpulkan bahwa adanya *Innovational Outlier* tidak akan mempengaruhi perubahan kesimpulan deteksi awal pada data bangkitan yang mengikuti proses ARIMA, sehingga uji GPH estimator robust dengan adanya penambahan *Innovational Outlier* ketika  $\phi$  bernilai -0,2, -0,5 dan -0,8.

- Data Mengikuti Proses ARIMA dengan Penambahan *Outlier Level Shift*.



Gambar 4.4 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan *Outlier Level Shift*

Tabel 4.4 Hasil Simulasi Power dari Uji-uji pada Data ARIMA(1,0,0) dengan Penambahan *Outlier Level Shift* pada n=200 dan n=1000

$\phi$	n = 200				n = 1000			
	Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,909	0,916	1,000	0,809	1,000	1,000	1,000	0,878
0,5	0,578	0,593	1,000	0,864	1,000	1,000	1,000	0,889
0,8	0,238	0,230	0,868	0,945	1,000	1,000	0,997	0,926
-0,2	1,000	1,000	1,000	0,769	1,000	1,000	1,000	0,890
-0,5	1,000	1,000	1,000	0,759	1,000	1,000	1,000	0,906
-0,8	1,000	1,000	1,000	0,762	1,000	1,000	1,000	0,922

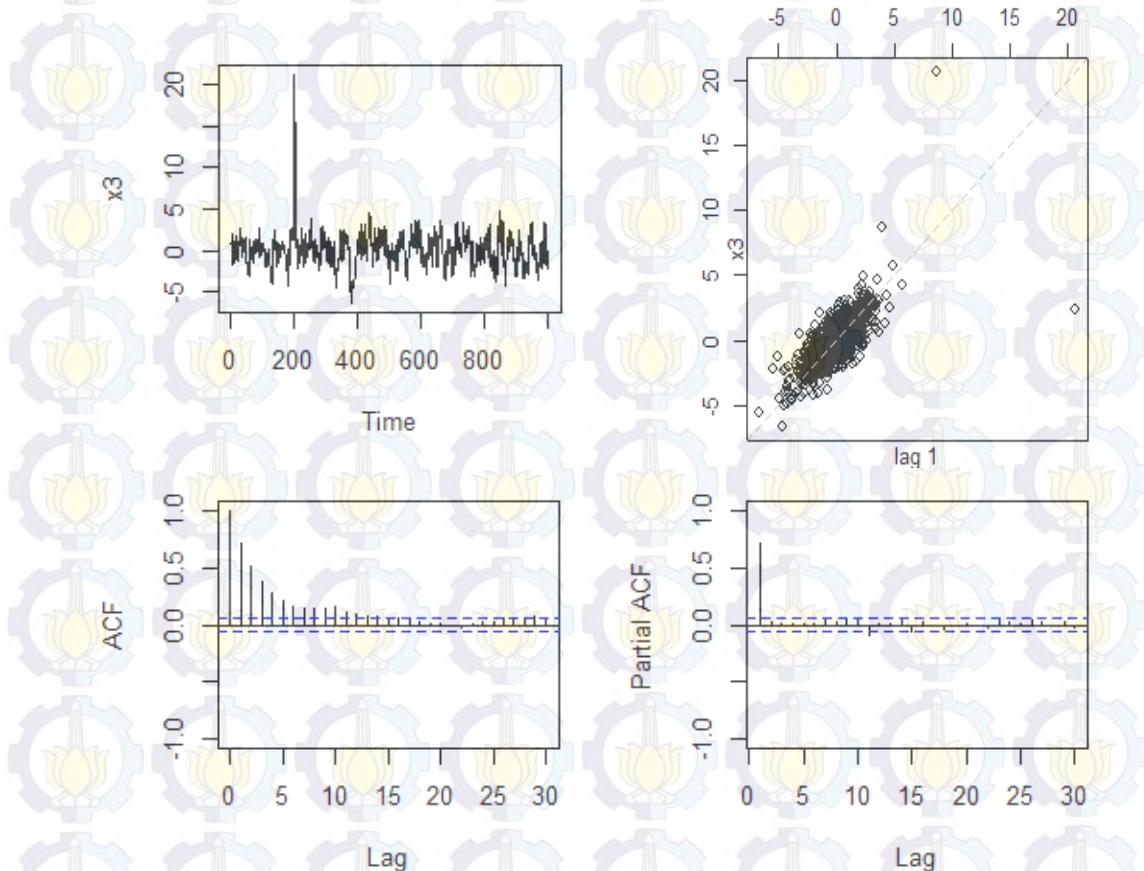
Tabel 4.4 menunjukkan dengan adanya penambahan *Outlier Level Shift* pada data bangkitan yang mengikuti proses ARIMA dapat mempengaruhi perubahan power pada uji Terasvirta, uji White dan uji GPH estimator. Pada saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 untuk sampel besar (n=1000), uji Terasvirta dan uji White tidak robust terhadap penambahan *Outlier Level Shift* karena power dari kedua uji tersebut mengalami kenaikan yang sangat signifikan sehingga power kedua uji tersebut mencapai 100%, hal ini sangat mempengaruhi kesimpulan dari deteksi sebelumnya yang semula linier menjadi nonlinier. Pada saat  $\phi$  bernilai 0,2, 0,5, -0,2, -0,5 dan -0,8 untuk sampel kecil (n=200) uji Terasvirta dan uji White tidak robust juga karena powernya mengalami kenaikan yang signifikan hingga power tersebut mencapai 57,8% hingga 100% sehingga dapat mempengaruhi kesimpulan dari deteksi sebelumnya yang harusnya data memiliki pola linier menjadi nonlinier. Akan tetapi, untuk sampel kecil saat  $\phi$  bernilai 0,8 uji Terasvirta dan uji White mengalami kenaikan yang tidak signifikan sehingga sifat data tetap linier. Sehingga adanya *Outlier Level Shift* akan sangat berpengaruh terhadap data bangkitan yang mengikuti proses ARIMA saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 baik untuk sampel besar maupun sampel kecil sehingga uji Terasvirta dan uji White tidak robust untuk kasus ini, tetapi *Outlier Level Shift* tidak berpengaruh saat  $\phi$  bernilai 0,8 untuk sampel kecil karena tidak merubah pola data.

Uji GPH estimator pada saat  $\phi$  bernilai 0,2, 0,5 dan 0,8 untuk sampel besar maupun sampel kecil mengalami penurunan power yang tidak signifikan

sehingga data tetap berpola long memory. Saat uji GPH estimator pada  $\phi$  bernilai -0,2, -0,5, -0,8 untuk sampel kecil maupun besar mengalami kenaikan power yang signifikan sehingga data berubah pola dari short memory menjadi long memory. Sehingga uji GPH estimator tidak robust lagi digunakan pada data bangkitan yang mengikuti proses ARIMA dengan penambahan *Outlier Level Shift*.

- Data Mengikuti Proses ARIMA dengan Penambahan Outlier *Temporary Change*.

Berikut gambar dari data yang mengikuti prises ARIMA dengan adanya outlier *Temporary Change*.



Gambar 4.5 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARIMA dengan Tambahan Outlier *Temporary Change*

Tabel 4.5 menunjukkan bahwa penambahan outlier *Temporary Change* dapat mengubah kesimpulan dari deteksi pada data bangkitan dengan proses ARIMA. Saat  $\phi$  bernilai 0,8, -0,2, -0,5 dan -0,8 untuk sampel kecil maupun sampel besar uji Terasvirta dan uji White tidak robust lagi untuk menguji

kelinieritasan dari data, hal ini karena saat adanya penambahan outlier *Temporary Change*, power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan sehingga data terdeteksi mengikuti proses nonlinier. Hal ini juga terjadi pada saat  $\phi$  bernilai 0,2 data yang berubah mengikuti proses nonlinier yang semula mengikuti proses linier, sehingga menyebabkan uji Terasvirta dan uji White tidak robust. Saat  $\phi$  bernilai 0,2 dan 0,5 untuk sampel kecil serta  $\phi$  bernilai 0,5 untuk sampel besar uji Terasvirta dan uji White masih robust karena power dari kedua uji tersebut mengalami penurunan atau peningkata yang tidak signifikan sehingga tidak mengubah kesimpulan deteksi awal yaitu berpola linier. Sehingga dapat ditarik kesimpulan bahwa adanya outlier *Temporary Change* memiliki pengaruh yang besar pada data bangkitan dengan mengikuti proses ARIMA. Ini karena dengan adanya outlier tersebut data yang semula linier menjadi nonlinier.

Tabel 4.5 Hasil Simulasi Power dari Uji-uji pada Data ARIMA(1,0,0) dengan Penambahan Outlier *Temporary Change* pada n=200 dan n=1000

$\phi$	n = 200				n = 1000			
	Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,310	0,354	1,000	0,322	0,987	0,950	1,000	0,149
0,5	0,020	0,047	1,000	0,334	0,032	0,048	1,000	0,235
0,8	0,597	0,638	1,000	0,451	0,999	0,943	1,000	0,497
-0,2	0,999	0,996	1,000	0,311	1,000	0,996	1,000	0,136
-0,5	1,000	1,000	1,000	0,314	1,000	1,000	1,000	0,161
-0,8	1,000	1,000	1,000	0,318	1,000	1,000	1,000	0,186

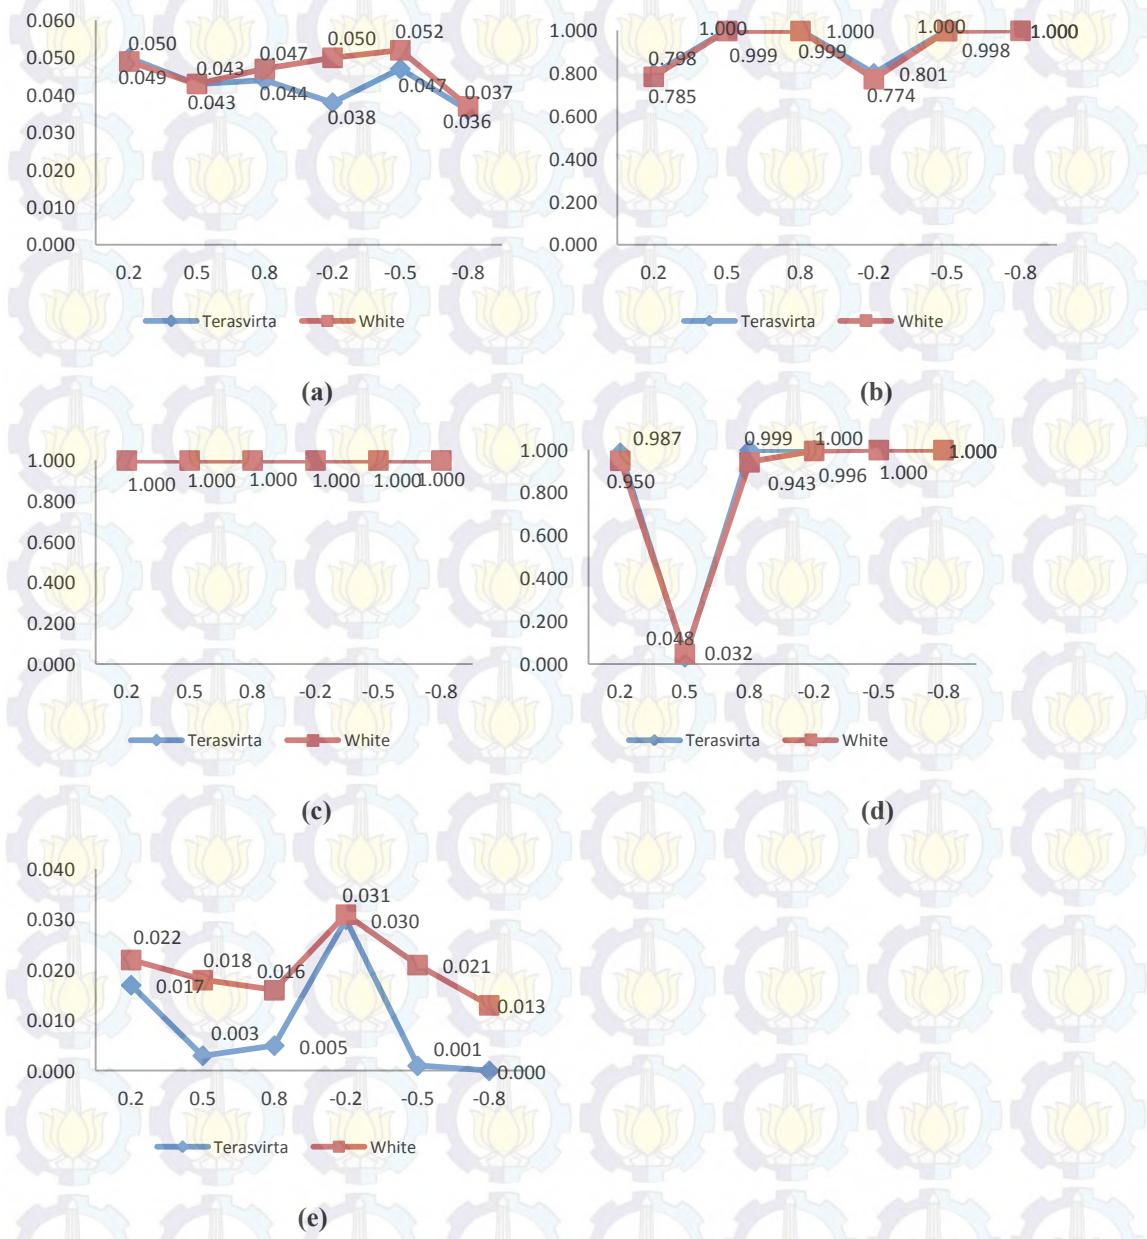
Pada uji GPH estimator, untuk  $\phi$  bernilai 0,2, 0,5 dan 0,8 baik sampel besar maupun sampel kecil pada data terdapat penurunan power yang tidak signifikan karena adanya efek outlier *Temporary Change* sehingga pola data tetap long memory. Saat  $\phi$  bernilai -0,2, -0,5 dan -0,8, adanya outlier *Temporary Change* sangat berpengaruh karena membuat kenaikan yang signifikan pada power uji GPH estimator sehingga mempengaruhi kesimpulan dari deteksi sebelumnya yang semula short memory berubah menjadi long memory. Sehingga dapat disimpulkan bahwa dengan adanya outlier *Temporary Change* pada data yang mengikuti proses ARIMA menyebabkan uji GPH estimator tidak robust untuk digunakan.

Uji Terasvirta dan uji White saat digunakan pada data bangkitan dengan proses ARIMA memiliki nilai power yang berbeda. Hal ini dapat dilihat pada Gambar 4.6 sebagai berikut.



Gambar 4.6 Perbandingan Uji Terasvirta dan Uji White saat  $n=200$  pada Data Bangkitan ARIMA tanpa outlier (a), ARIMA dengan outlier *additive* (b), ARIMA dengan *Outlier Level Shift* (c), ARIMA dengan outlier *Temporary Change* (d) dan ARIMA dengan *Innovational Outlier* (e)

Berdasarkan Gambar 4.6 terlihat bahwa data bangkitan yang mengikuti proses ARIMA dengan dan tanpa adanya outlier saat  $n = 200$  lebih baik diuji dengan menggunakan uji White daripada uji Terasvirta untuk melihat kelinieritasan dari data. Hal ini karena power uji White lebih tinggi daripada uji Terasvirta.

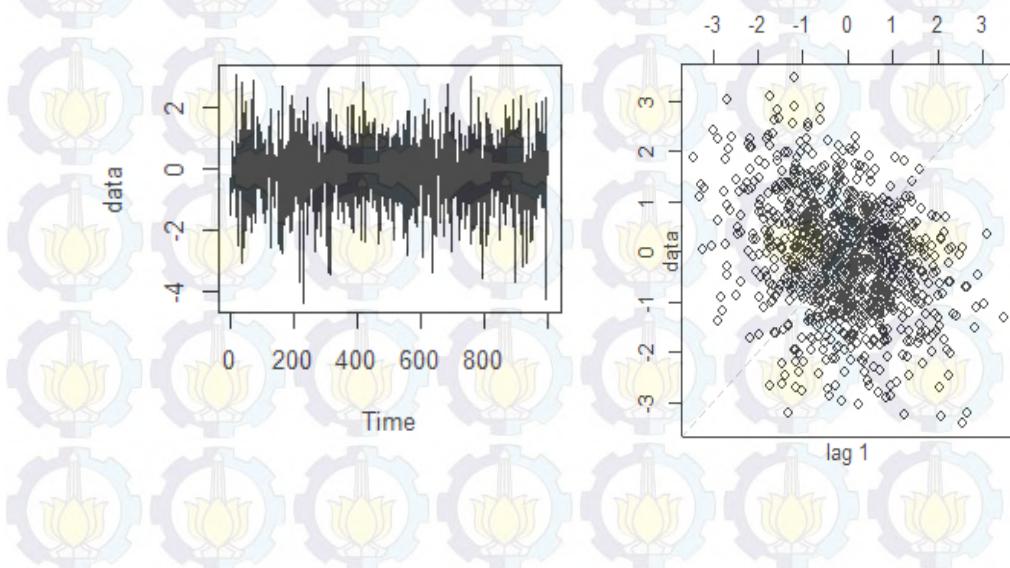


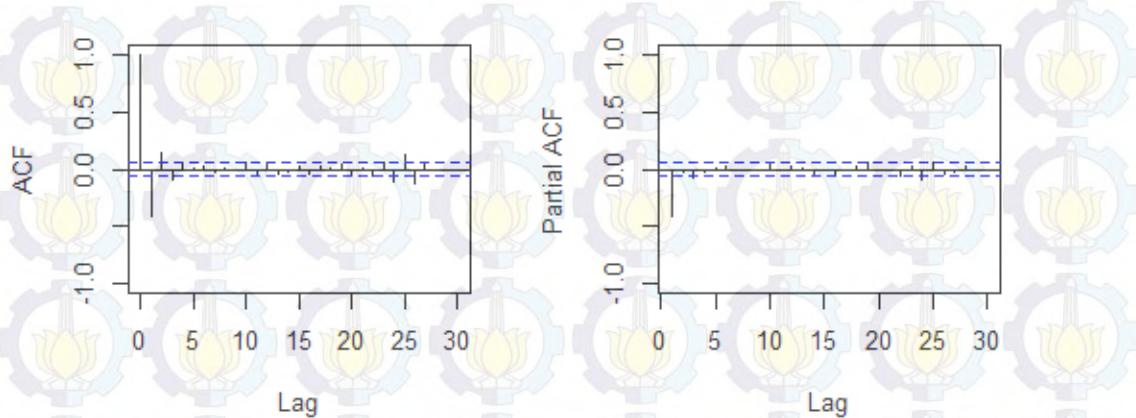
Gambar 4.7 Perbandingan Uji Terasvirta dan Uji White saat  $n=1000$  pada Data Bangkitan ARIMA tanpa outlier (a), ARIMA dengan outlier *additive* (b), ARIMA dengan *Outlier Level Shift* (c), ARIMA dengan outlier *Temporary Change* (d) dan ARIMA dengan *Innovational Outlier* (e)

Gambar 4.7 menunjukkan saat  $n=1000$  uji White memiliki power yang lebih tinggi daripada power dari uji Terasvirta baik untuk data bangkitan yang mengikuti proses ARIMA tanpa tambahan outlier maupun dengan tambahan outlier. Secara keseluruhan dapat disimpulkan bahwa untuk data bangkitan yang mengikuti proses ARIMA dengan dan tanpa tambahan outlier pada sampel besar dan sampel kecil lebih baik menggunakan uji White karena uji tersebut memiliki power yang lebih baik daripada uji Terasvirta.

#### 4.1.3 Simulasi Data Bangkitan LSTAR (*Logistic Smoothing Transition Autoregressive*)

LSTAR (*Logistic Smoothing Transition Autoregressive*) merupakan suatu model dengan data yang memiliki sifat nonlinier short memory. Dalam penelitian ini ditampilkan hasil simulasi dengan menggunakan data bangkitan yang mengikuti proses LSTAR dengan beberapa beberapa setting parameter yaitu  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5 serta 0,8 dan -0,8 menggunakan jumlah sampel kecil  $n=200$  dan sampel besar  $n=1000$ . Hasil simulasi yang ditampilkan merupakan hasil simulasi dari data bangkitan dengan dan tanpa penambahan outlier pada datanya. Efek dengan dan tanpa penambahan outlier dilihat berdasarkan power dari uji Terasvirta, uji White dan uji GPH Estimator. Berikut time series plot dari data yang mengikuti proses LSTAR.





Gambar 4.8 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR Tanpa Adanya Efek Outlier

Tabel 4.6 menunjukkan bahwa pada saat  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5, 0,8 dan -0,8 pada sampel besar ( $n=1000$ ) power dari uji Terasvirta dan uji White berkisar antara 64,6% hingga 100%, ini menunjukkan bahwa data terdeteksi memiliki pola nonlinier, sehingga uji Terasvirta dan uji White robust untuk mendeteksi kelinieran suatu data yang mengikuti proses LSTAR. Begitu pula halnya dengan sampel kecil ( $n=200$ ), pada saat  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8 uji Terasvirta dan White robust untuk mendeteksi kelinieran suatu data yang mengikuti proses LSTAR, ini ditunjukkan oleh power dari kedua uji tersebut yang berkisar antara 86,5% hingga 89,7%. Akan tetapi untuk sampel kecil ( $n=200$ ) saat  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5 serta 0,8 dan -0,8 uji Terasvirta tidak robust lagi untuk mendeteksi kelinieritasan dari data bangkitan yang mengikuti proses LSTAR, sama halnya saat  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5 serta 0,8 dan -0,8 uji Terasvirta dan uji White juga tidak robust mendeteksi kelinieran dari data. Uji Terasvirta dan uji White juga tidak robust digunakan saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 pada sampel besar ( $n=1000$ ), ini karena power dari kedua uji tersebut kurang dari 50%. Sehingga dapat disimpulkan bahwa uji Terasvirta dan uji White robust digunakan untuk mendeteksi kelinieran dari data bangkitan yang mengikuti proses LSTAR untuk sampel kecil ketika  $\gamma$ ,  $\alpha_1$  dan  $\alpha_2$  bernilai besar, sedangkan untuk

sampel besar masih robust digunakan ketika nilai  $\alpha_1$  dan  $\alpha_2$  berada pada 0,5 dan -0,5 ke atas.

Di sisi lain, power dari uji GPH robust digunakan untuk data bangkitan yang mengikuti proses LSTAR baik untuk sampel kecil maupun sampel besar saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5 serta 0,8 dan -0,8. Ini karena power dari uji GPH estimator memiliki nilai yang kurang dari 50% sehingga tepat terdeteksi sebagai data short memory.

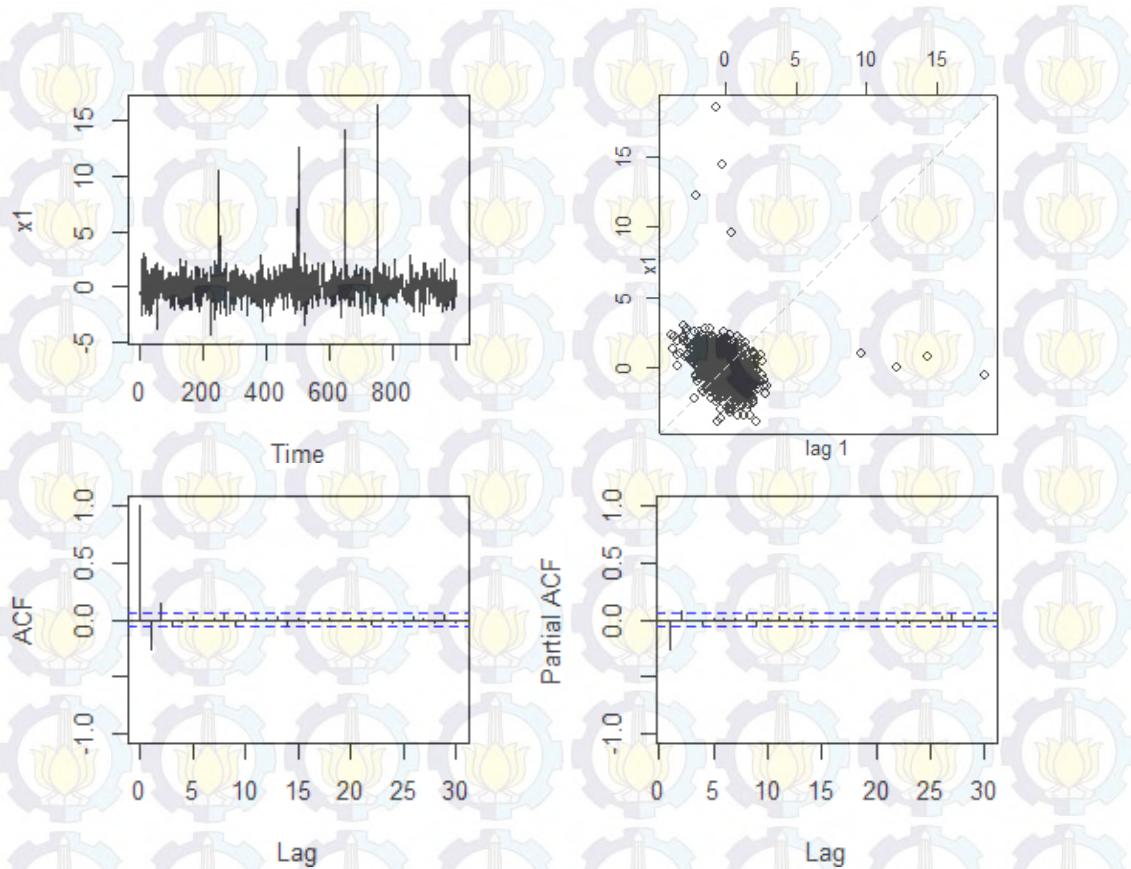
Tabel 4.6 Hasil Simulasi Power dari Uji-uji pada Data LSTAR Tanpa Penambahan Outlier pada n=200 dan n=1000

$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
			Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,5	0,2	-0,2	0,070	0,070	0,338	-0,042	0,126	0,129	0,293	-0,023
	0,5	-0,5	0,167	0,161	0,124	-0,099	0,670	0,646	0,119	-0,050
	0,8	-0,8	0,444	0,441	0,055	-0,141	0,989	0,987	0,065	-0,068
5	0,2	-0,2	0,106	0,127	0,326	-0,043	0,370	0,411	0,319	-0,021
	0,5	-0,5	0,475	0,512	0,156	-0,088	0,987	0,994	0,148	-0,045
	0,8	-0,8	0,886	0,897	0,062	-0,138	1,000	1,000	0,041	-0,071
10	0,2	-0,2	0,104	0,106	0,318	-0,043	0,349	0,397	0,326	-0,020
	0,5	-0,5	0,442	0,483	0,123	-0,094	0,985	0,991	0,127	-0,046
	0,8	-0,8	0,865	0,895	0,056	-0,140	1,000	1,000	0,045	-0,071

#### 4.1.4 Simulasi Data Bangkitan LSTAR (*Logistic Smoothing Transition Autoregressive*) dengan Penambahan Efek Outlier

Penambahan efek oulier *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC) diduga dapat mempengaruhi power dari uji Terasvirta, uji White dan uji GPH Estimator. Hal ini dapat dilihat dari hasil simulasi pada data bangkitan yang mengikuti proses LSTAR pada tabel 4.9, tabel 4.10, tabel 4.11 dan tabel 4.12.

- Data Mengikuti Proses LSTAR dengan Penambahan Outlier *Additive*.



Gambar 4.9 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek Outlier *Additive*

Tabel 4.7 menunjukkan bahwa adanya outlier *additive* berpengaruh terhadap perubahan pola data bangkitan yang mengikuti proses LSTAR. Untuk sampel kecil ( $n=200$ ) saat  $\gamma$  bernilai 5, 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8 dengan adanya outlier *additive* data bangkitan terdeteksi mengikuti proses linier yang semula nonlinier, sehingga uji Terasvirta dan uji White tidak lagi robust pada parameter tersebut. Hal ini karena power dari kedua uji tersebut mengalami penurunan yang signifikan hingga mencapai power 7%. Sedangkan saat  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 serta saat  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5 uji Terasvirta dan uji White juga tidak robust untuk mendeteksi kelinieran data yang mengikuti proses LSTAR dengan adanya penambahan outlier *additive* karena pola data tetap berpolai linier. Untuk sampel besar ( $n=1000$ ) uji Terasvirta dan uji White tidak robust lagi saat  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5 karena power dari kedua tes tersebut mengalami kenaikan yang

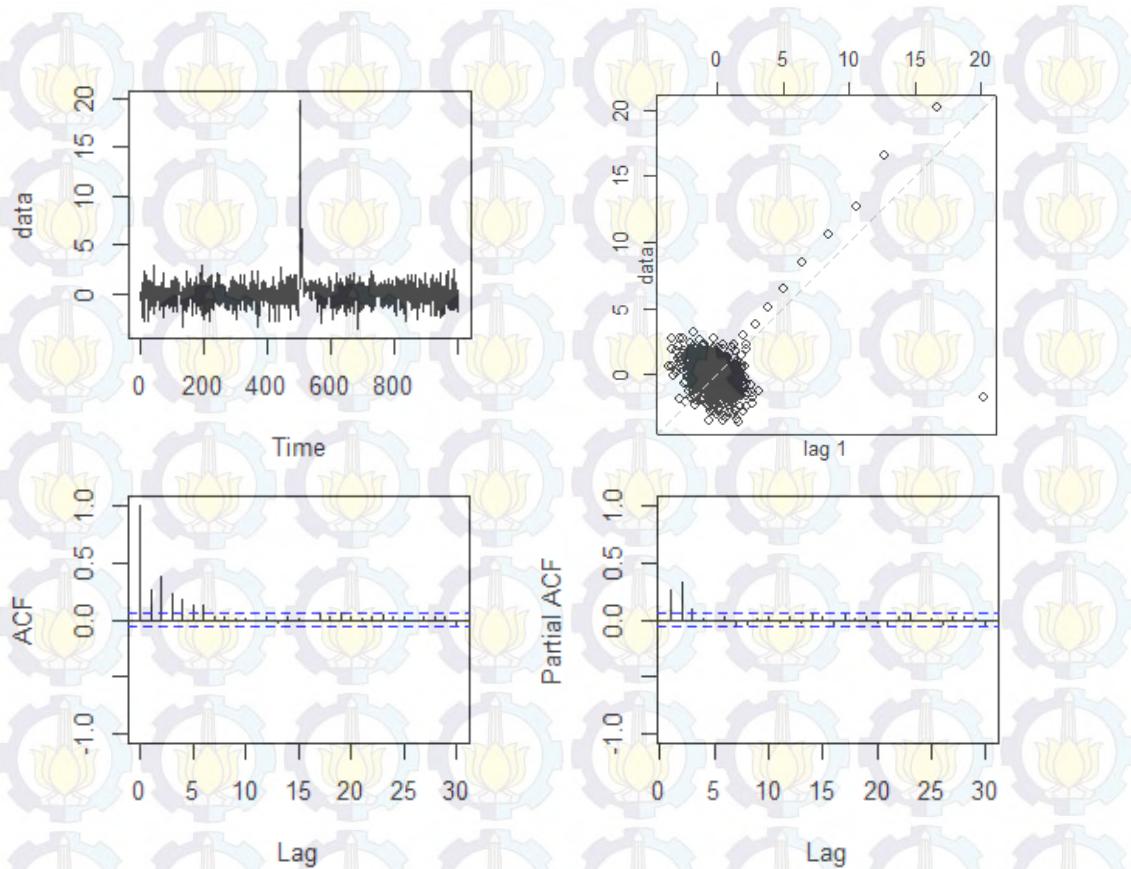
signifikan sehingga terdeteksi mengikuti proses linier. Sehingga pada parameter  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5,  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 uji White dan uji Terasvirta tidak robust digunakan untuk mendeteksi kelinieran. Saat  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8,  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5 serta 0,8 dan -0,8 uji Terasvirta dan uji White robust untuk digunakan pada data yang mengikuti proses LSTAR dengan adanya outlier *additive*.

Tabel 4.7 Hasil Simulasi Power dari Uji-uji pada Data LSTAR dengan Penambahan Outlier *Additive* pada n=200 dan n=1000

$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
			Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,5	0,2	-0,2	0,026	0,054	0,255	-0,044	0,159	0,261	0,333	-0,017
	0,5	-0,5	0,101	0,183	0,196	-0,051	0,913	0,963	0,227	-0,030
	0,8	-0,8	0,312	0,518	0,135	-0,063	1,000	0,998	0,183	-0,035
5	0,2	-0,2	0,029	0,051	0,268	-0,042	0,160	0,368	0,351	-0,016
	0,5	-0,5	0,079	0,206	0,209	-0,053	0,881	0,984	0,260	-0,028
	0,8	-0,8	0,171	0,523	0,157	-0,064	0,996	0,999	0,153	-0,039
10	0,2	-0,2	0,028	0,058	0,261	-0,044	0,181	0,378	0,367	-0,014
	0,5	-0,5	0,071	0,180	0,196	-0,056	0,884	0,982	0,259	-0,026
	0,8	-0,8	0,180	0,478	0,160	-0,063	0,997	0,999	0,132	-0,040

Uji GPH estimator masih robust digunakan meskipun terdapat penambahan outlier *additive* pada data bangkitan yang mengikuti proses LSTAR baik untuk sampel besar (n=1000) maupun sampel kecil (n=200). Ini karena power dari uji GPH mengalami kenaikan atau penurunan yang tidak signifikan sehingga tidak mempengaruhi kesimpulan dari deteksi sebelumnya yaitu data berpola short memory.

- Data Mengikuti Proses LSTAR dengan Penambahan *Innovational Outlier*. Berikut time series plot dari data bangkitan yang mengikuti proses LSTAR dengan tambahan *Innovational Outlier*.



Gambar 4.10 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek *Innovational Outlier*

Berdasarkan Tabel 4.8 dapat dilihat bahwa dengan adanya penambahan *Innovational Outlier*, uji Terasvirta dan uji White semakin robust ketika digunakan pada parameter-parameter tertentu. Saat  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5, 0,8 dan -0,8 untuk sampel kecil ( $n=200$ ) kedua uji tersebut mengalami kenaikan power yang signifikan sehingga data terdeteksi memiliki pola nonlinier. Begitu pula untuk sampel besar saat  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, adanya *Innovational Outlier* dapat terdeteksi mengikuti pola linier yang semula nonlinier karena power kedua uji tersebut mengalami kenaikan yang signifikan, sehingga uji Terasvirta dan uji White robust digunakan pada data bangkitan yang mengikuti proses LSTAR dengan penambahan *Innovational Outlier*. Sedangkan pada sampel kecil ketika  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 uji Terasvirta dan uji White tidak robust dengan adanya penambahan *Innovational Outlier* karena data berpolai linier.

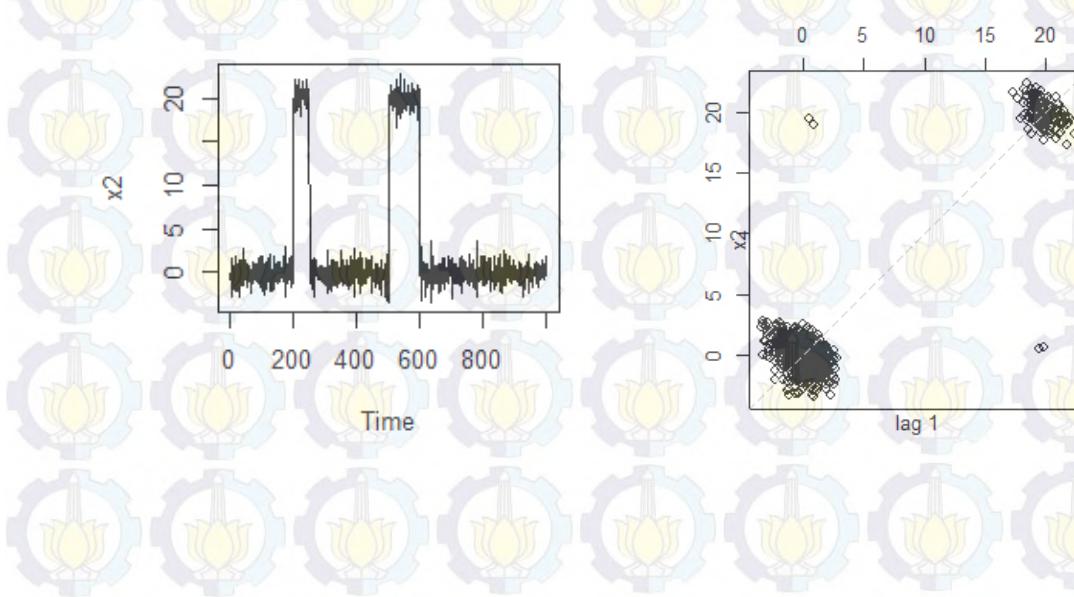
Penambahan *Innovational Outlier* pada data bangkitan yang mengikuti proses LSTAR juga mempengaruhi power dari uji GPH estimator. Uji GPH estimator tidak lagi robust digunakan pada  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8. Ini karena power dari uji GPH estimator mengalami kenaikan yang signifikan hingga power tersebut mencapai 100% sehingga mempengaruhi kesimpulan dari deteksi sebelumnya yang semula short memory menjadi long memory.

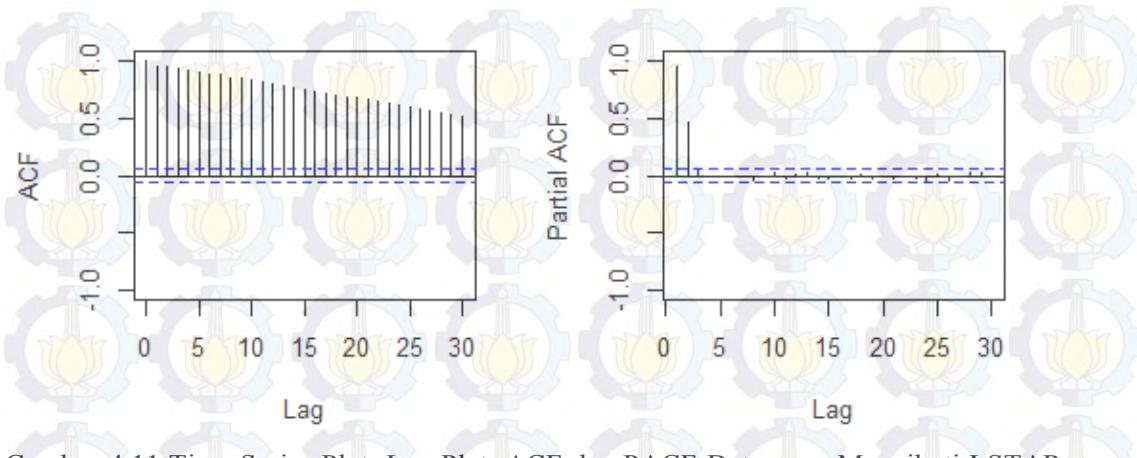
Tabel 4.8 Hasil Simulasi Power dari Uji-uji pada Data LSTAR dengan Penambahan *Innovational Outlier* pada n=200 dan n=1000

$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
			Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,5	0,2	-0,2	0,264	0,335	0,981	0,096	0,999	0,912	0,743	0,022
	0,5	-0,5	0,994	0,995	1,000	0,350	1,000	0,995	1,000	0,139
	0,8	-0,8	1,000	1,000	1,000	0,637	1,000	1,000	1,000	0,495
5	0,2	-0,2	0,286	0,376	0,994	0,114	0,999	0,898	0,763	0,026
	0,5	-0,5	0,931	0,960	1,000	0,312	1,000	0,997	1,000	0,180
	0,8	-0,8	1,000	1,000	1,000	0,677	1,000	1,000	1,000	0,452
10	0,2	-0,2	0,192	0,268	0,986	0,115	0,998	0,873	0,706	0,019
	0,5	-0,5	0,943	0,958	1,000	0,350	1,000	0,994	1,000	0,156
	0,8	-0,8	1,000	1,000	1,000	0,630	1,000	1,000	1,000	0,451

- Data Mengikuti Proses LSTAR dengan Penambahan *Outlier Level Shift*.

Berikut time series plot dari data bangkitan yang mengikuti proses LSTAR dengan tambahan *Outlier Level Shift*.





Gambar 4.11 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek *Outlier Level Shift*

Berdasarkan Tabel 4.9 dapat diketahui dengan adanya penambahan *Outlier Level Shift* pola data bangkitan yang mengikuti proses LSTAR pada parameter-parameter tertentu mengalami perubahan deteksi data yang tadinya linier menjadi nonlinier. Hal ini terjadi pada sampel kecil ( $n=200$ ) saat  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8,  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, sehingga uji Terasvirta dan uji White robust karena power dari kedua uji tersebut mengalami kenaikan signifikan hingga power menjadi 100%, ini yang menyebabkan perubahan pola data yang semula linier menjadi nonlinier. Sama halnya dengan sampel besar ( $n=1000$ ), ketika  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 uji Terasvirta dan uji White robust untuk mendekati kelinieran data karena dengan adanya penambahan *Outlier Level Shift* dari kedua uji tersebut mengalami kenaikan signifikan sehingga merubah pola data menjadi nonlinier. Sedangkan parameter yang lain tidak mengalami kenaikan atau penurunan yang signifikan sehingga tetap berpola nonlinier.

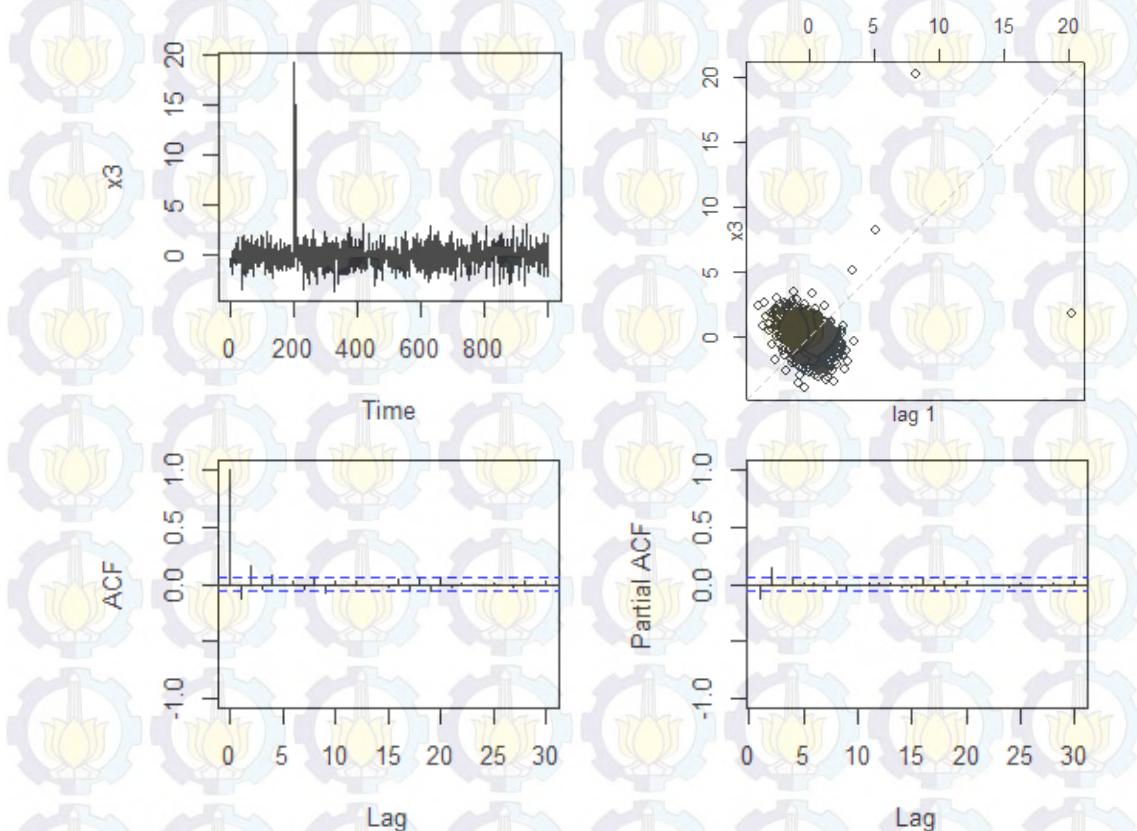
Uji GPH estimator pada  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 tidak robust lagi untuk digunakan dengan adanya penambahan *Outlier Level Shift* karena mengalami kenaikan power yang signifikan hingga powernya mencapai 100%. Secara keseluruhan *level shift* dapat merubah deteksi data bangkitan yang mengikuti proses LSTAR.

Tabel 4.9 Hasil Simulasi Power dari Uji-uji pada Data LSTAR dengan Penambahan Outlier *Shift* pada n=200 dan n=1000

$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
			Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,5	0,2	-0,2	0,999	0,997	1,000	0,777	1,000	1,000	1,000	0,885
	0,5	-0,5	0,999	0,999	1,000	0,766	1,000	1,000	1,000	0,892
	0,8	-0,8	1,000	1,000	1,000	0,757	1,000	1,000	1,000	0,898
5	0,2	-0,2	0,999	0,999	1,000	0,773	1,000	1,000	1,000	0,885
	0,5	-0,5	1,000	0,999	1,000	0,764	1,000	1,000	1,000	0,889
	0,8	-0,8	1,000	1,000	1,000	0,751	1,000	1,000	1,000	0,890
10	0,2	-0,2	0,998	0,998	1,000	0,776	1,000	1,000	1,000	0,884
	0,5	-0,5	1,000	1,000	1,000	0,765	1,000	1,000	1,000	0,889
	0,8	-0,8	1,000	1,000	1,000	0,752	1,000	1,000	1,000	0,889

- Data Mengikuti Proses LSTAR dengan Penambahan Outlier *Temporary Change*.

Berikut time series plot dari data bangkitan yang mengikuti proses LSTAR dengan tambahan outlier *Temporary Change*.



Gambar 4.12 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti LSTAR dengan Adanya Efek Outlier *Temporary Change*

Berdasarkan Tabel 4.10 dapat diketahui dengan adanya penambahan outlier *Temporary Change* pola data bangkitan yang mengikuti proses LSTAR pada parameter-parameter tertentu mengalami perubahan deteksi pola data yang tadinya linier menjadi nonlinier. Hal ini terjadi pada sampel kecil ( $n=200$ ) saat  $\gamma$  bernilai 0,5 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8,  $\gamma$  bernilai 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, sehingga uji Terasvirta dan uji White robust karena power dari kedua uji tersebut mengalami kenaikan signifikan hingga power menjadi 100%, ini yang menyebabkan perubahan deteksi data yang semula linier menjadi nonlinier. Sama halnya dengan sampel besar ( $n=1000$ ), ketika  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 uji Terasvirta dan uji White robust untuk mendeteksi kelinieran data karena dengan adanya penambahan outlier *Temporary Change* dari kedua uji tersebut mengalami kenaikan signifikan sehingga data mengikuti pola nonlinier. Sedangkan parameter yang lain tidak mengalami kenaikan atau penurunan yang signifikan sehingga pola data tetap nonlinier.

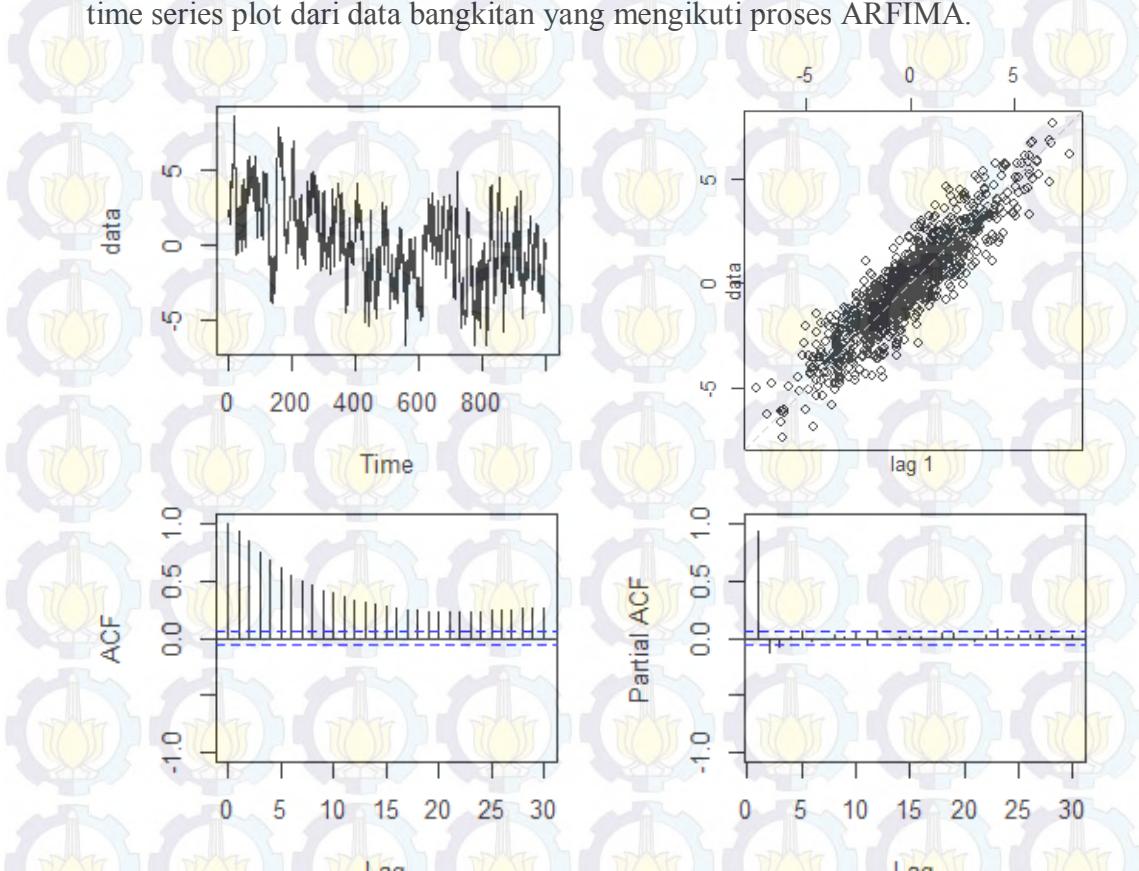
Tabel 4.10 Hasil Simulasi Power dari Uji-uji pada Data LSTAR dengan Penambahan Outlier *Temporary Change* pada  $n=200$  dan  $n=1000$

$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
			Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,5	0,2	-0,2	0,961	0,961	1,000	0,317	1,000	0,996	0,999	0,134
	0,5	-0,5	0,998	0,998	1,000	0,312	1,000	0,998	1,000	0,141
	0,8	-0,8	1,000	1,000	1,000	0,309	1,000	0,999	1,000	0,147
5	0,2	-0,2	0,956	0,960	1,000	0,312	1,000	0,996	0,999	0,133
	0,5	-0,5	0,987	0,991	1,000	0,312	1,000	0,996	1,000	0,135
	0,8	-0,8	0,999	0,999	1,000	0,305	1,000	1,000	1,000	0,137
10	0,2	-0,2	0,956	0,946	1,000	0,309	1,000	0,996	1,000	0,133
	0,5	-0,5	0,996	0,996	1,000	0,309	1,000	0,996	1,000	0,135
	0,8	-0,8	1,000	1,000	1,000	0,304	1,000	0,999	1,000	0,135

Selain itu, uji GPH estimator pun tidak robust untuk mendeteksi pola data. Uji GPH estimator pada  $\gamma$  bernilai 0,5, 5 dan 10 dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 tidak robust lagi untuk digunakan dengan adanya penambahan outlier *Temporary Change* karena mengalami kenaikan power yang signifikan hingga powernya mencapai 100%.

#### 4.1.5 Simulasi Data Bangkitan ARFIMA (*Autoregressive Fractionally Integrated Moving Average*)

Model ARFIMA (*Autoregressive Fractional Integrated Moving Average*) merupakan suatu model dengan data yang memiliki pola linier long memory. Berikut ini ditampilkan hasil simulasi dengan menggunakan data bangkitan ARFIMA dengan beberapa setting parameter  $\phi$  bernilai -0,2, -0,5, -0,8, 0,2, 0,5 dan 0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 menggunakan jumlah sampel kecil  $n=200$  dan sampel besar  $n=1000$ . Hasil simulasi yang ditampilkan merupakan hasil simulasi dari data bangkitan dengan dan tanpa penambahan outlier pada datanya. Efek dengan dan tanpa penambahan outlier dilihat berdasarkan power dari uji Terasvirta, uji White dan uji GPH Estimator. Berikut time series plot dari data bangkitan yang mengikuti proses ARFIMA.



Gambar 4.13 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA Tanpa Adanya Efek Outlier

Tabel 4.11 menunjukkan bahwa pada saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 baik untuk sampel besar ( $n=1000$ ) maupun sampel kecil ( $n=200$ ) power dari uji Terasvirta dan uji White berada di bawah 50%, ini menunjukkan bahwa data terdeteksi memiliki pola linier, sehingga uji Terasvirta dan uji White robust untuk mendeteksi kelinieran suatu data yang mengikuti proses ARFIMA. Selain itu, power dari uji GPH juga robust digunakan untuk data bangkitan yang mengikuti proses ARFIMA baik untuk sampel kecil maupun sampel besar saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 serta 0,8 dan -0,8. Ini karena power dari uji GPH estimator memiliki nilai yang lebih dari 50% bahkan mencapai 100% sehingga tepat terdeteksi sebagai data long memory.

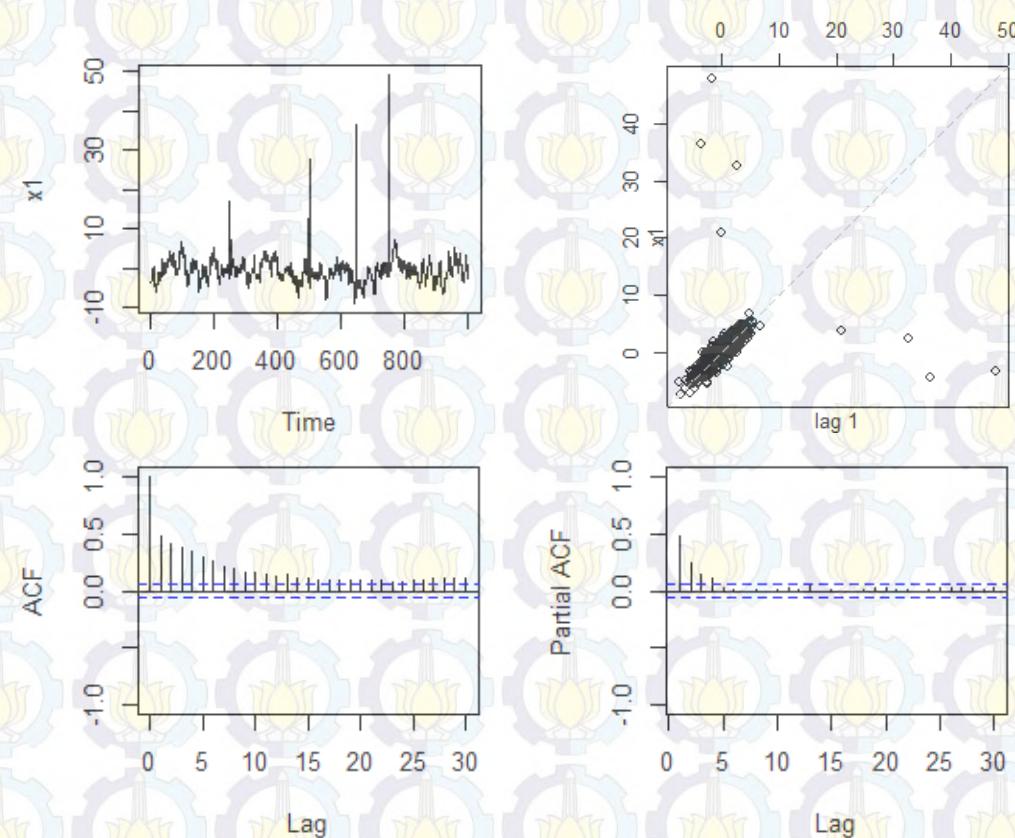
Tabel 4.11 Hasil Simulasi Power dari Uji-uji pada Data ARFIMA Tanpa Penambahan Outlier pada  $n=200$  dan  $n=1000$

$\phi$	$d$	n = 200				n = 1000			
		Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,2	0,056	0,053	0,999	0,312	0,067	0,065	1,000	0,265
0,2	0,3	0,054	0,062	1,000	0,413	0,095	0,097	1,000	0,369
0,2	0,4	0,077	0,087	1,000	0,514	0,143	0,146	1,000	0,471
0,5	0,2	0,042	0,045	1,000	0,539	0,055	0,058	1,000	0,439
0,5	0,3	0,037	0,048	1,000	0,643	0,061	0,067	1,000	0,540
0,5	0,4	0,055	0,055	1,000	0,741	0,059	0,065	1,000	0,642
0,8	0,2	0,032	0,034	0,919	0,876	0,029	0,034	1,000	0,762
0,8	0,3	0,025	0,020	0,616	0,972	0,016	0,015	0,997	0,861
0,8	0,4	0,015	0,015	0,256	1,057	0,006	0,007	0,816	0,961
-0,2	0,2	0,055	0,062	0,893	0,122	0,051	0,053	1,000	0,161
-0,2	0,3	0,071	0,059	0,988	0,225	0,068	0,078	1,000	0,262
-0,2	0,4	0,066	0,074	0,998	0,320	0,166	0,172	1,000	0,364
-0,5	0,2	0,042	0,052	0,712	0,048	0,048	0,050	1,000	0,131
-0,5	0,3	0,042	0,034	0,942	0,151	0,044	0,046	1,000	0,231
-0,5	0,4	0,059	0,062	0,994	0,247	0,106	0,098	1,000	0,334
-0,8	0,2	0,074	0,085	0,566	0,014	0,093	0,095	0,995	0,122
-0,8	0,3	0,071	0,066	0,908	0,116	0,082	0,078	1,000	0,222
-0,8	0,4	0,074	0,083	0,986	0,221	0,099	0,096	1,000	0,325

#### 4.1.6 Simulasi Data Bangkitan ARFIMA (*Autoregressive Fractional Integrated Moving Average*) dengan Penambahan Efek Outlier

Penambahan efek outlier *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC) diduga dapat mempengaruhi power dari uji Terasvirta, uji White dan uji GPH Estimator. Hal ini dapat dilihat dari hasil simulasi pada data bangkitan yang mengikuti proses ARFIMA pada tabel 4.14, tabel 4.15, tabel 4.16 dan tabel 4.17.

- Data Mengikuti Proses ARFIMA dengan Penambahan Outlier *Additive*.



Gambar 4.14 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek Outlier *Additive*

Tabel 4.12 menunjukkan bahwa saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan menjadi 60% hingga 100% baik untuk sampel besar ( $n=1000$ ) maupun sampel kecil ( $n=200$ ), ini mempengaruhi kesimpulan dari deteksi sebelumnya yang awalnya data terdeteksi menjadi

nonlinier sehingga kedua uji tersebut tidak lagi robust untuk mendeteksi kelinieran dari data yang mengikuti proses ARFIMA jika terdapat outlier *additive*.

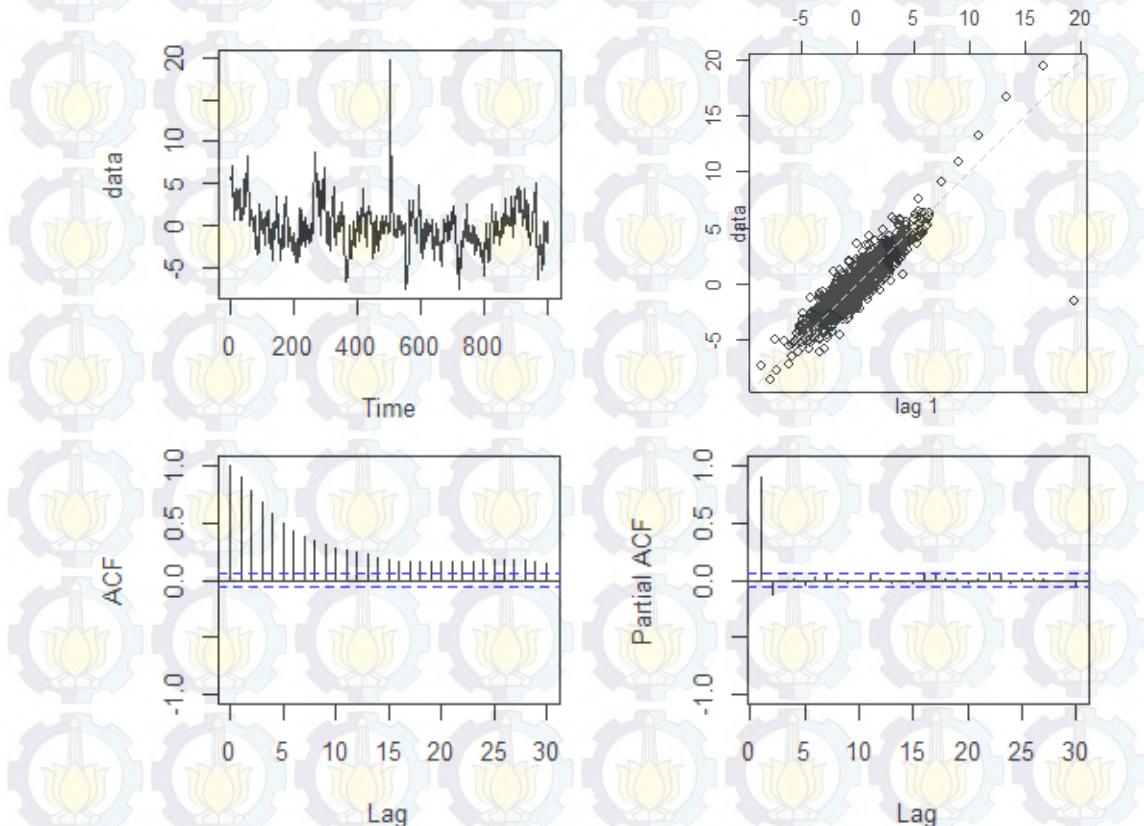
Tabel 4.12 Hasil Simulasi Power dari Uji-uji pada Data ARFIMA dengan Penambahan Outlier *Additive* pada n=200 dan n=1000

$\phi$	$d$	n = 200				n = 1000			
		Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,2	0,601	0,653	0,849	0,083	1,000	0,997	1,000	0,195
0,2	0,3	0,871	0,907	0,955	0,144	1,000	1,000	1,000	0,281
0,2	0,4	0,974	0,992	0,983	0,199	1,000	0,999	1,000	0,373
0,5	0,2	0,988	0,993	0,986	0,201	1,000	1,000	1,000	0,347
0,5	0,3	0,999	1,000	0,996	0,275	1,000	0,999	1,000	0,437
0,5	0,4	1,000	1,000	0,998	0,344	1,000	1,000	1,000	0,534
0,8	0,2	1,000	1,000	1,000	0,446	1,000	1,000	1,000	0,643
0,8	0,3	1,000	1,000	1,000	0,526	1,000	1,000	1,000	0,737
0,8	0,4	1,000	1,000	1,000	0,609	0,995	0,994	1,000	0,837
-0,2	0,2	0,011	0,040	0,584	0,010	0,037	0,052	0,987	0,100
-0,2	0,3	0,063	0,108	0,762	0,052	0,676	0,683	1,000	0,181
-0,2	0,4	0,359	0,432	0,898	0,104	0,999	0,995	1,000	0,266
-0,5	0,2	0,285	0,376	0,446	-0,016	1,000	0,994	0,949	0,069
-0,5	0,3	0,098	0,136	0,645	0,023	0,701	0,694	1,000	0,143
-0,5	0,4	0,023	0,054	0,826	0,069	0,084	0,113	1,000	0,220
-0,8	0,2	0,996	0,998	0,373	-0,025	1,000	1,000	0,909	0,055
-0,8	0,3	0,980	0,987	0,558	0,005	1,000	1,000	0,996	0,121
-0,8	0,4	0,902	0,918	0,721	0,041	1,000	0,999	1,000	0,193

Pada sampel kecil saat  $\phi$  bernilai -0,2 dan -0,5 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 uji Terasvirta dan uji White masih robust terhadap data dengan outlier *additive* karena power kedua uji tersebut mengalami kenaikan dan penurunan yang tidak signifikan sehingga tidak merubah kesimpulan pada deteksi sebelumnya. Hal yang serupa juga terjadi pada sampel besar saat  $\phi$  bernilai -0,2 dengan  $d$  bernilai 0,2 dan  $\phi$  bernilai -0,5 dengan  $d$  bernilai 0,4, power kedua uji tersebut mengalami penurunan yang tidak signifikan sehingga tidak mempengaruhi deteksi pola data pada deteksi sebelumnya. Akan tetapi untuk sampel besar saat  $\phi$  bernilai -0,2 dengan  $d$  bernilai 0,3 dan  $\phi$  bernilai 0,4 serta  $\phi$  bernilai -0,5 dengan  $d$  bernilai 0,2 dan  $\phi$  bernilai 0,3 uji Terasvirta dan uji White tidak lagi robust untuk mendeteksi kelinieran data ARFIMA dengan adanya outlier sebab power dari kedua uji tersebut mengalami

kenaikan yang sangat signifikan sehingga data terdeteksi mengikuti pola nonlinier. Power dari uji GPH juga robust digunakan untuk data bangkitan yang mengikuti proses ARFIMA baik untuk sampel kecil maupun sampel besar saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4. Ini karena power dari uji GPH estimator memiliki nilai yang lebih dari 50% bahkan mencapai 100% sehingga tepat terdeteksi sebagai data long memory. Uji GPH estimator tidak robust lagi digunakan pada sampel kecil saat saat  $\phi$  bernilai -0,5 dengan  $d$  bernilai 0,2 karena power uji GPH mengalami penurunan signifikan sehingga data terdeteksi menjadi short memory.

- Data Mengikuti Proses ARFIMA dengan Penambahan *Innovational Outlier*.



Gambar 4.15 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek *Innovational Outlier*

Tabel 4.13 menunjukkan bahwa dengan adanya *Innovational Outlier* pada data bangkitan yang mengikuti proses ARFIMA akan mempengaruhi power dari uji Terasvirta dan uji White pada parameter-parameter tertentu. Pada sampel

kecil saat  $\phi$  bernilai 0,2 dengan  $d$  bernilai 0,3 dan 0,4,  $\phi$  bernilai 0,5 dengan  $d$  bernilai 0,4 serta  $\phi$  bernilai -0,2 dan -0,5 dengan  $d$  bernilai 0,4 power dari kedua uji tersebut mengalami kenaikan yang signifikan disebabkan dengan adanya *Innovational Outlier* sehingga kedua tes tersebut tidak lagi robust untuk pengujian kelinieritasan dari data karena outlier telah menjadikan data terdeteksi menjadi nonlinier.

Tabel 4.13 Hasil Simulasi Power dari Uji-ujji pada Data ARFIMA dengan Penambahan *Innovational Outlier* pada n=200 dan n=1000

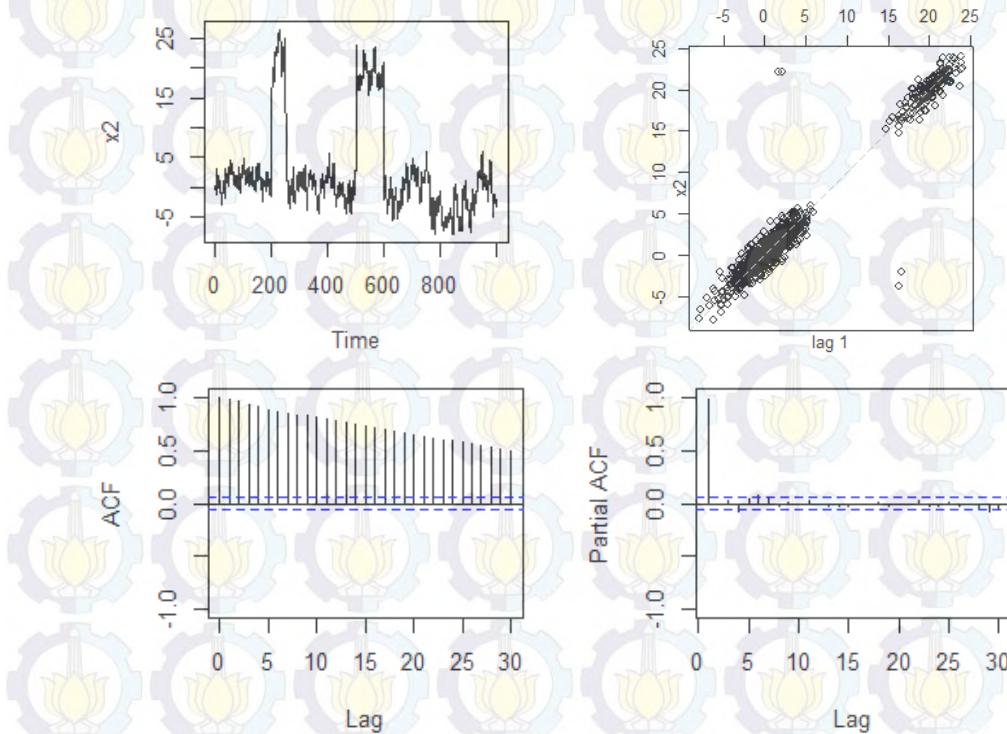
$\phi$	$d$	n = 200				n = 1000			
		Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,2	0,150	0,183	0,964	0,133	0,985	0,812	1,000	0,217
0,2	0,3	0,616	0,611	0,994	0,190	1,000	0,929	1,000	0,315
0,2	0,4	0,769	0,787	1,000	0,275	1,000	0,977	1,000	0,401
0,5	0,2	0,063	0,151	1,000	0,384	0,917	0,761	1,000	0,398
0,5	0,3	0,363	0,443	1,000	0,405	1,000	0,953	1,000	0,490
0,5	0,4	0,636	0,706	1,000	0,494	1,000	0,974	1,000	0,571
0,8	0,2	0,053	0,125	1,000	0,713	0,202	0,328	1,000	0,717
0,8	0,3	0,152	0,254	0,990	0,794	0,863	0,620	1,000	0,810
0,8	0,4	0,446	0,436	0,960	0,822	0,810	0,486	0,980	0,896
-0,2	0,2	0,178	0,189	0,238	-0,048	0,942	0,794	0,999	0,122
-0,2	0,3	0,373	0,390	0,551	0,004	1,000	0,917	1,000	0,206
-0,2	0,4	0,826	0,822	0,851	0,073	1,000	0,985	1,000	0,298
-0,5	0,2	0,048	0,069	0,033	-0,129	0,559	0,614	0,972	0,082
-0,5	0,3	0,134	0,234	0,288	-0,043	0,999	0,941	1,000	0,182
-0,5	0,4	0,721	0,809	0,485	-0,004	1,000	0,985	1,000	0,261
-0,8	0,2	0,000	0,004	0,041	-0,112	0,001	0,097	0,945	0,067
-0,8	0,3	0,002	0,080	0,066	-0,109	0,964	0,871	1,000	0,169
-0,8	0,4	0,432	0,532	0,309	-0,044	0,998	0,989	1,000	0,264

Untuk sampel besar ketika  $\phi$  bernilai 0,2, 0,5, -0,2, -0,5 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 uji Terasvirta dan uji White juga tidak robust digunakan karena power kedua uji tersebut mengalami kenaikan yang sangat signifikan hingga powernya mencapai 100%, sehingga data terdeteksi menjadi nonlinier. Hal tersebut juga terjadi pada saat  $\phi$  bernilai 0,8 dan -0,8 dengan  $d$  bernilai 0,3 dan 0,4, pada sampel besar dan sampel kecil data bangkitan yang mengikuti proses ARFIMA terdeteksi menjadi nonlinier. Lain halnya saat  $\phi$  bernilai 0,8 dan -0,8 dengan  $d$  bernilai 0,2, untuk sampel besar dan kecil uji Terasvirta dan uji White

robust digunakan karena tidak merubah deteksi data meskipun di dalam data terdapat *Innovational Outlier*.

Pada tabel 4.13 juga menunjukkan adanya *Innovational Outlier* juga dapat mempengaruhi perubahan power dari uji GPH estimator, pada sampel kecil ketika  $\phi$  bernilai 0,5, -0,8, -0,5 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 power dari uji GPH estimator mengalami penurunan yang signifikan sehingga mempengaruhi terdeteksi mengikuti pola short memory. Dengan demikian, uji GPH estimator tidak robust pada parameter tersebut. Untuk parameter  $\phi$  bernilai 0,2, 0,5, 0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 pada sampel kecil, uji GPH masih robust digunakan karena hanya mengalami penurunan yang tidak signifikan sehingga deteksi pola data tetap. Sedangkan pada sampel besar untuk parameter  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 power dari uji GPH estimator juga mengalami penurunan yang tidak signifikan sehingga memiliki data tetap terdeteksi sebagai long memory.

- Data Mengikuti Proses ARFIMA dengan Penambahan *Outlier Level Shift*.



Gambar 4.16 Time Series Plot, ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek *Outlier Level Shift*

Tabel 4.14 Hasil Simulasi Power dari Uji-ujji pada Data ARFIMA dengan Penambahan *Outlier Level Shift* pada n=200 dan n=1000

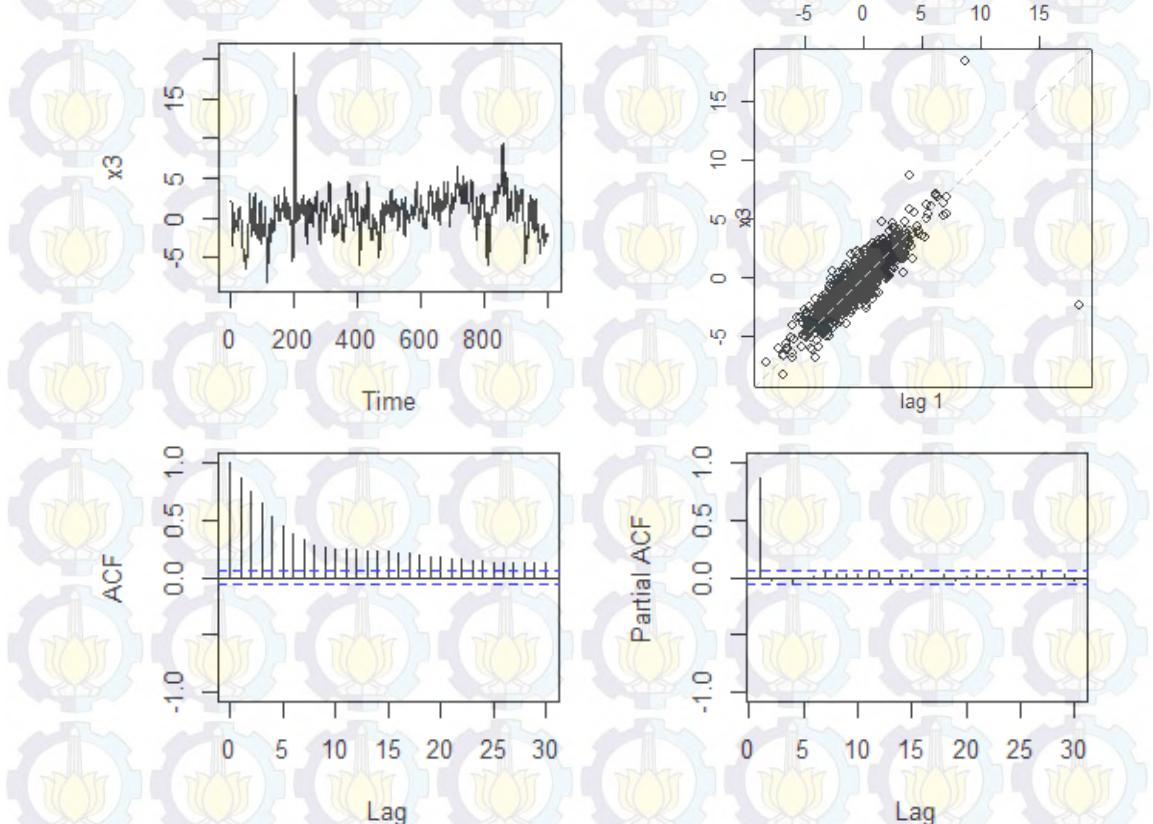
$\phi$	$d$	n = 200				n = 1000			
		Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,2	0,695	0,711	0,999	0,850	1,000	1,000	1,000	0,889
0,2	0,3	0,493	0,507	0,995	0,872	1,000	1,000	1,000	0,896
0,2	0,4	0,379	0,383	0,990	0,890	1,000	1,000	1,000	0,902
0,5	0,2	0,350	0,349	0,968	0,906	1,000	1,000	1,000	0,900
0,5	0,3	0,250	0,255	0,931	0,926	1,000	1,000	1,000	0,913
0,5	0,4	0,169	0,159	0,848	0,951	0,994	0,986	0,995	0,920
0,8	0,2	0,122	0,121	0,587	0,987	0,844	0,839	0,956	0,953
0,8	0,3	0,105	0,092	0,418	1,011	0,365	0,332	0,821	0,970
0,8	0,4	0,086	0,072	0,278	1,033	0,138	0,087	0,584	0,994
-0,2	0,2	0,988	0,990	1,000	0,808	1,000	1,000	1,000	0,901
-0,2	0,3	0,951	0,954	0,999	0,828	1,000	1,000	1,000	0,904
-0,2	0,4	0,829	0,840	0,998	0,851	1,000	1,000	1,000	0,911
-0,5	0,2	1,000	1,000	1,000	0,798	1,000	1,000	1,000	0,916
-0,5	0,3	0,998	0,998	1,000	0,818	1,000	1,000	1,000	0,920
-0,5	0,4	0,999	0,998	1,000	0,839	1,000	1,000	1,000	0,925
-0,8	0,2	1,000	1,000	1,000	0,803	1,000	1,000	1,000	0,931
-0,8	0,3	1,000	1,000	1,000	0,820	1,000	1,000	1,000	0,934
-0,8	0,4	1,000	1,000	1,000	0,845	1,000	1,000	0,999	0,939

Berdasarkan hasil pada Tabel 4.14 dapat diketahui bahwa saat  $\phi$  bernilai -0,2, -0,5, -0,8, dengan  $d$  bernilai 0,2, 0,3 dan 0,4 pada sampel kecil dan sampel besar, power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan dengan power mencapai 58,4% hingga 100%. Hal ini menyebabkan uji Terasvirta dan uji White tidak robust digunakan pada parameter tersebut karena dengan adanya *Outlier Level Shift* data terdeteksi berpola nonlinier. Untuk sampel kecil saat  $\phi$  bernilai 0,2 dengan  $d$  bernilai 0,2 *Outlier Level Shift* juga mempengaruhi deteksi data menjadi nonlinier karena power dari kedua uji tersebut mengalami peningkatan yang signifikan. Hal yang serupa juga terjadi pada sampel besar dengan  $\phi$  bernilai 0,2, 0,5 dengan  $d$  bernilai 0,2, 0,3, 0,4 serta  $\phi$  bernilai 0,8 dengan  $d$  bernilai 0,2, power dari uji Terasvirta dan uji White juga mengalami kenaikan signifikan sehingga data terdeteksi berpola nonlinier. Berbeda halnya pada sampel besar saat  $\phi$  bernilai 0,8 dengan  $d$  bernilai 0,3, 0,4, data tetap terdeteksi linier karena power kedua uji mengalami kenaikan yang tidak

begitu signifikan. Pada sampel kecil saat  $\phi$  bernilai 0,2 dengan  $d$  bernilai 4,  $\phi$  bernilai 0,5 dengan  $d$  bernilai 0,2, 0,3, 0,4,  $\phi$  bernilai 0,8 dengan  $d$  bernilai 0,2, 0,3, 0,4 tidak mengalami perubahan deteksi data sehingga pada parameter ini uji Terasvirta dan uji White robust untuk digunakan.

Pada uji GPH estimator untuk sampel kecil maupun sampel besar saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5, -0,5, -0,8 dengan  $d$  bernilai 0,2, 0,3, 0,4 power dari uji GPH tidak mengalami kenaikan yang signifikan sehingga data tetap terdeteksi long memory, akan tetapi saat  $\phi$  bernilai 0,8 dengan  $d$  bernilai 0,3 dan 0,4 power dari uji GPH estimator mengalami penurunan yang sangat signifikan karena ada penambahan *Outlier Level Shift* pada datanya, sehingga data terdeteksi menjadi short memory yang semula long memory.

- Data Mengikuti Proses ARFIMA dengan Penambahan Outlier *Temporary Change*.



Gambar 4.17 Time Series Plot, Lag Plot ACF dan PACF Data yang Mengikuti ARFIMA dengan Adanya Efek Outlier *Temporary Change*

Tabel 4.15 Hasil Simulasi Power dari Uji-uji pada Data ARFIMA dengan Penambahan Outlier *Temporary Change* pada n=200 dan n=1000

$\phi$	d	n = 200				n = 1000			
		Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,2	0,036	0,049	1,000	0,339	0,093	0,107	1,000	0,262
0,2	0,3	0,012	0,044	1,000	0,359	0,139	0,159	1,000	0,339
0,2	0,4	0,144	0,200	1,000	0,394	0,857	0,805	1,000	0,426
0,5	0,2	0,160	0,221	1,000	0,390	0,845	0,768	1,000	0,395
0,5	0,3	0,510	0,556	1,000	0,442	0,997	0,946	1,000	0,484
0,5	0,4	0,808	0,837	1,000	0,496	1,000	0,963	1,000	0,578
0,8	0,2	0,976	0,969	1,000	0,580	1,000	0,964	1,000	0,684
0,8	0,3	0,999	0,985	1,000	0,652	0,999	0,912	1,000	0,783
0,8	0,4	0,998	0,961	1,000	0,730	0,955	0,784	1,000	0,875
-0,2	0,2	0,818	0,843	1,000	0,318	1,000	0,993	1,000	0,203
-0,2	0,3	0,456	0,504	1,000	0,328	0,986	0,938	1,000	0,262
-0,2	0,4	0,151	0,172	1,000	0,347	0,406	0,403	1,000	0,334
-0,5	0,2	1,000	1,000	1,000	0,321	1,000	0,996	1,000	0,199
-0,5	0,3	0,996	0,999	1,000	0,326	1,000	0,996	1,000	0,246
-0,5	0,4	0,892	0,910	1,000	0,333	1,000	0,984	1,000	0,304
-0,8	0,2	1,000	1,000	1,000	0,328	1,000	1,000	1,000	0,209
-0,8	0,3	1,000	1,000	1,000	0,328	1,000	1,000	1,000	0,244
-0,8	0,4	1,000	1,000	1,000	0,335	1,000	0,996	1,000	0,293

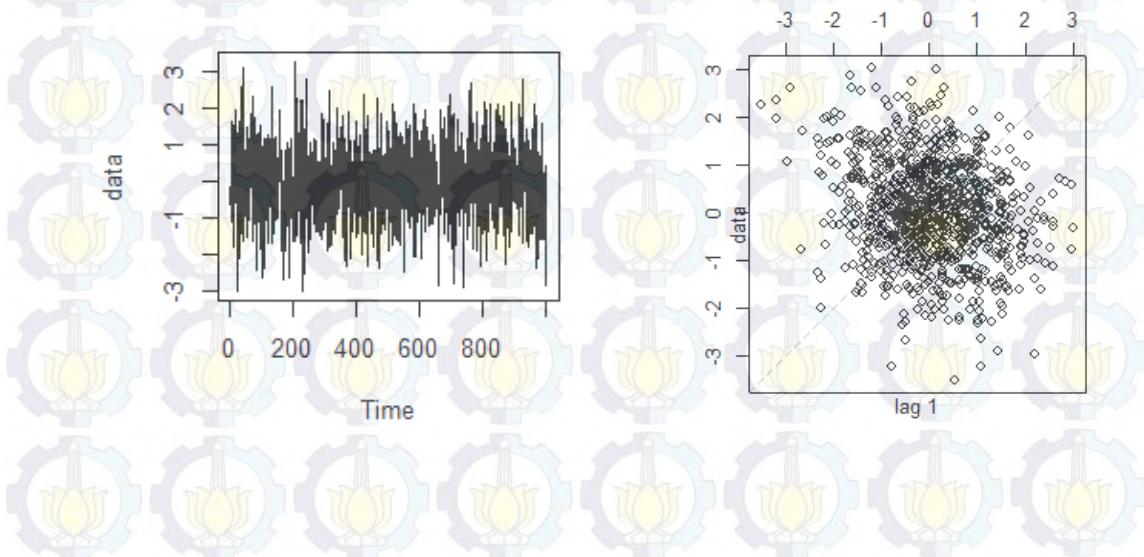
Berdasarkan Tabel 4.15 dapat dilihat bahwa pada sampel besar (n=1000) maupun sampel kecil (n=200) saat  $\phi$  bernilai -0,5, -0,8 dengan  $d$  bernilai 0,2, 0,3, 0,4 power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan sehingga power dari kedua uji tersebut robust sehingga mempengaruhi kesimpulan dari pendeksi sebelumnya yang semula linier menjadi nonlinier. Hal ini sama halnya ketika  $\phi$  bernilai 0,5 dengan  $d$  bernilai 0,3, 0,4,  $\phi$  bernilai 0,8 dengan  $d$  bernilai 0,2, 0,3, 0,4,  $\phi$  bernilai -0,2 dengan  $d$  bernilai 0,2, 0,3 untuk sampel kecil (n=200) uji Terasvirta dan uji White tidak robust lagi karena power dari kedua uji tersebut mengalami kenaikan yang signifikan sehingga merubah deteksi data yang sebelumnya linier menjadi nonlinier. Begitu pula yang terjadi pada sampel besar (n=1000) saat  $\phi$  bernilai 0,2 dengan  $d$  bernilai 0,4,  $\phi$  bernilai 0,5, 0,8 dengan  $d$  bernilai 0,2, 0,3, 0,4,  $\phi$  bernilai -0,2 dengan  $d$  bernilai 0,2, 0,3, power uji Terasvirta dan uji White mengalami kenaikan yang signifikan sehingga merubah deteksi data menjadi nonlinier. Untuk parameter selain itu baik sampel

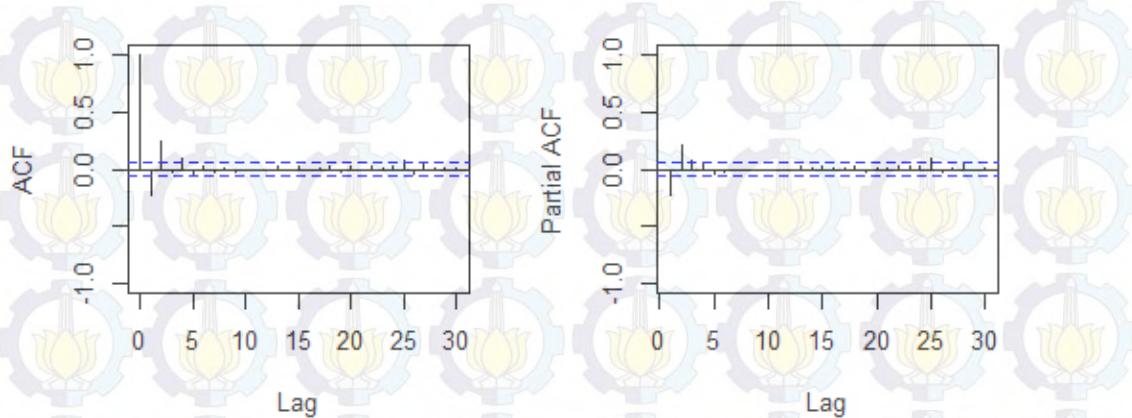
besar maupun sampel kecil mengalami penurunan atau kenaikan yang tidak signifikan sehingga data tetap terdeteksi memiliki pola linier.

Uji GPH estimator untuk sampel kecil maupun sampel besar saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5, -0,5, -0,8 dengan  $d$  bernilai 0,2, 0,3, 0,4 power dari uji GPH tidak mengalami kenaikan atau penurunan yang signifikan sehingga data tetap terdeteksi memiliki pola long memory sehingga uji GPH estimator masih robust digunakan saat terdapat penambahan outlier *Temporary Change* pada data bangkitan yang mengikuti proses ARFIMA.

#### 4.1.7 Simulasi Data Bangkitan FILSTAR (*Fractional Integrated Logistic Smoothing Autoregressive*)

Model FILSTAR merupakan suatu model dengan data yang memiliki pola nonlinier long memory. Berikut ini ditampilkan hasil simulasi dengan menggunakan data bangkitan FILSTAR dengan beberapa setting parameter  $d$  bernilai 0,2, 0,3 dan 0,4,  $\gamma$  bernilai 0,5, 5 dan 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 menggunakan jumlah sampel kecil  $n=200$  dan sampel besar  $n=1000$ . Hasil simulasi yang ditampilkan merupakan hasil simulasi dari data bangkitan dengan dan tanpa penambahan outlier pada datanya. Efek dengan dan tanpa penambahan outlier dilihat berdasarkan power dari uji Terasvirta, uji White dan uji GPH Estimator. Berikut time series plot dari data bangkitan yang mengikuti proses FILSTAR.





Gambar 4.18 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR tanpa Adanya Efek Outlier

Tabel 4.16 menunjukkan bahwa pada saat  $\gamma$  bernilai 0,5,5 dan 10 dengan  $d$  bernilai 0,2, 0,3 dan 0,4,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5, 0,8 dan -0,8 untuk sampel besar ( $n=1000$ ) power dari uji Terasvirta dan uji White berada di atas 50%, ini menunjukkan bahwa data terdeteksi memiliki pola nonlinier, sehingga uji Terasvirta dan uji White robust untuk mendeteksi kelinieran suatu data yang mengikuti proses FILSTAR pada parameter-parameter tersebut karena ketepatan deteksinya tersebut. Saat sampel kecil, uji Terasvirta dan uji White dapat mendeteksi dengan tepat data yang mengikuti proses FILSTAR (nonlinier long memory) saat  $d$  bernilai 0,2, 0,3 dan 0,4 dengan  $\gamma$  bernilai 5, 10, dengan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8. Sehingga saat sampel besar uji Terasvirta dan uji White tepat mendeteksi data yang mengikuti pola FILSTAR (nonlinier long memory) saat  $\alpha_1$  dan  $\alpha_2$  bernilai besar, sedangkan pada sampel kecil uji Terasvirta dan uji White tepat mendeteksi data yang mengikuti pola FILSTAR (nonlinier long memory) saat  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8 ke atas dengan  $\gamma$  bernilai 5 ke atas.

Selain itu, power dari uji GPH juga robust digunakan untuk data bangkitan yang mengikuti proses FILSTAR baik untuk sampel kecil maupun sampel besar saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5 dan -0,8 dengan  $d$  bernilai 0,2, 0,3 dan 0,4 serta 0,8 dan -0,8,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8. Ini karena power dari uji GPH estimator memiliki nilai yang lebih dari 50% bahkan mencapai 100% sehingga tepat terdeteksi sebagai data long memory.

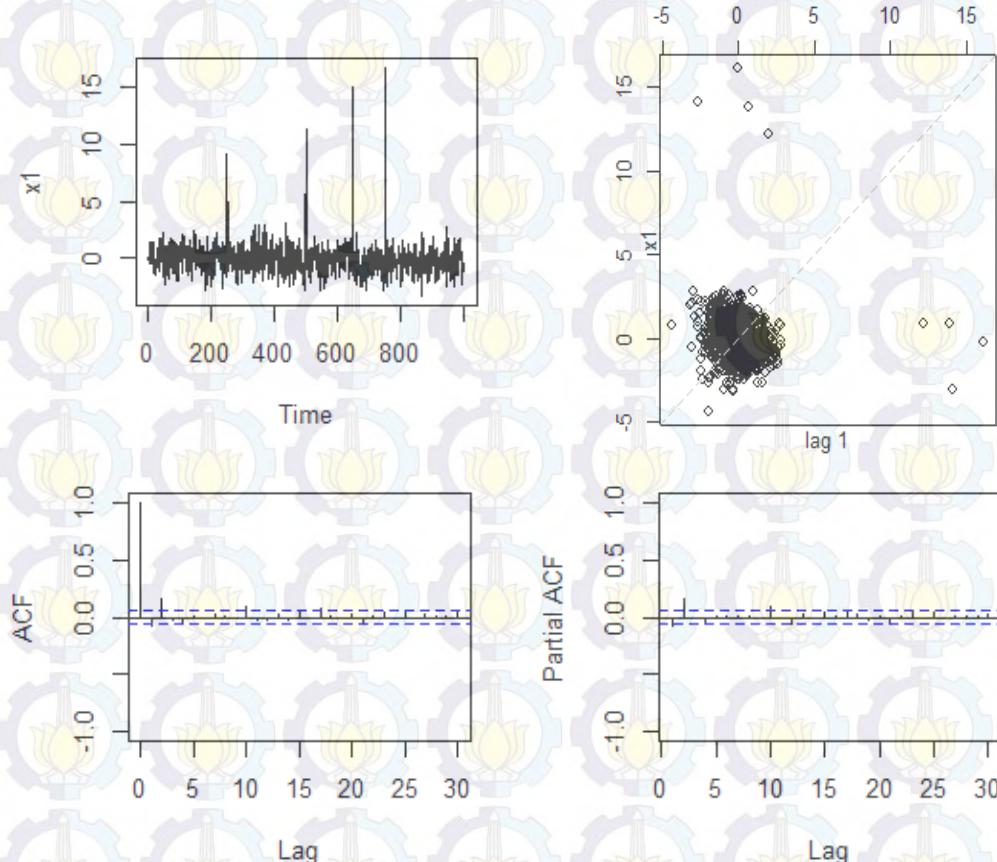
Tabel 4.16 Hasil Simulasi Power dari Uji-uji pada Data FILSTAR tanpa Penambahan Outlier pada n=200 dan n=1000

d	$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
				Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,5	0,2	-0,2	0,074	0,079	0,963	0,162	0,166	0,159	1,000	0,182
		0,5	-0,5	0,143	0,151	0,895	0,107	0,608	0,587	1,000	0,154
		0,8	-0,8	0,335	0,325	0,775	0,065	0,956	0,947	1,000	0,134
	5	0,2	-0,2	0,107	0,112	0,952	0,162	0,408	0,443	1,000	0,181
		0,5	-0,5	0,422	0,461	0,879	0,116	0,987	0,993	0,998	0,157
		0,8	-0,8	0,819	0,851	0,783	0,073	1,000	1,000	0,995	0,128
	10	0,2	-0,2	0,130	0,137	0,962	0,167	0,365	0,404	1,000	0,182
		0,5	-0,5	0,382	0,413	0,887	0,116	0,982	0,989	1,000	0,156
		0,8	-0,8	0,804	0,834	0,798	0,074	1,000	1,000	0,999	0,134
0,3	0,5	0,2	-0,2	0,102	0,092	0,995	0,262	0,190	0,181	1,000	0,281
		0,5	-0,5	0,157	0,159	0,991	0,216	0,684	0,663	1,000	0,257
		0,8	-0,8	0,279	0,292	0,959	0,172	0,954	0,943	1,000	0,239
	5	0,2	-0,2	0,125	0,140	0,993	0,264	0,417	0,458	1,000	0,283
		0,5	-0,5	0,442	0,481	0,983	0,216	0,988	0,993	1,000	0,261
		0,8	-0,8	0,812	0,846	0,955	0,176	1,000	1,000	1,000	0,238
	10	0,2	-0,2	0,115	0,120	0,998	0,272	0,412	0,431	1,000	0,284
		0,5	-0,5	0,433	0,471	0,981	0,223	0,989	0,993	1,000	0,260
		0,8	-0,8	0,779	0,802	0,966	0,181	1,000	1,000	1,000	0,237
0,4	0,5	0,2	-0,2	0,111	0,112	0,999	0,368	0,271	0,271	1,000	0,385
		0,5	-0,5	0,188	0,201	1,000	0,319	0,742	0,737	1,000	0,362
		0,8	-0,8	0,361	0,352	1,000	0,284	0,963	0,953	1,000	0,343
	5	0,2	-0,2	0,132	0,147	1,000	0,370	0,447	0,471	1,000	0,385
		0,5	-0,5	0,459	0,491	0,998	0,330	0,958	0,965	1,000	0,365
		0,8	-0,8	0,752	0,768	0,992	0,292	1,000	0,998	1,000	0,346
	10	0,2	-0,2	0,126	0,135	1,000	0,376	0,410	0,442	1,000	0,385
		0,5	-0,5	0,460	0,480	0,999	0,327	0,968	0,966	1,000	0,364
		0,8	-0,8	0,751	0,781	0,995	0,290	0,996	0,993	1,000	0,348

#### 4.1.8 Simulasi Data Bangkitan FILSTAR (*Fractional Integrated Logistic Smoothing Autoregressive*) dengan Penambahan Efek Outlier

Penambahan efek outlier *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift* (LS), dan *Temporary Change* (TC) diduga dapat mempengaruhi power dari uji Terasvirta, uji White dan uji GPH Estimator. Hal ini dapat dilihat dari hasil simulasi pada data bangkitan yang mengikuti proses FILSTAR pada tabel 4.19, tabel 4.20, tabel 4.21 dan tabel 4.22.

- Data Mengikuti Proses FILSTAR dengan Penambahan Outlier Additive.



Gambar 4.19 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek Outlier *Additive*

Tabel 4.17 menunjukkan bahwa saat saat  $\gamma$  bernilai 0,5,5 dan 10 dengan  $d$  bernilai 0,2, 0,3 dan 0,4,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5, 0,8 dan -0,8 power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan menjadi 60% hingga 100% untuk sampel besar ( $n=1000$ ), ini menunjukkan bahwa dengan adanya outlier *additive* kedua uji tersebut semakin robust untuk mendeteksi kelinieran dari data yang mengikuti proses FILSTAR. Pada sampel kecil saat  $\gamma$  bernilai 0,5,5 dan 10 dengan  $d$  bernilai 0,2, 0,3 dan 0,4,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8 uji Terasvirta dan uji White tidak robust terhadap data dengan outlier *additive* karena power kedua uji tersebut mengalami penurunan yang signifikan sehingga merubah deteksi pola data yang semula nonlinier menjadi linier. Hal yang serupa juga terjadi pada sampel kecil saat  $\gamma$  bernilai 5

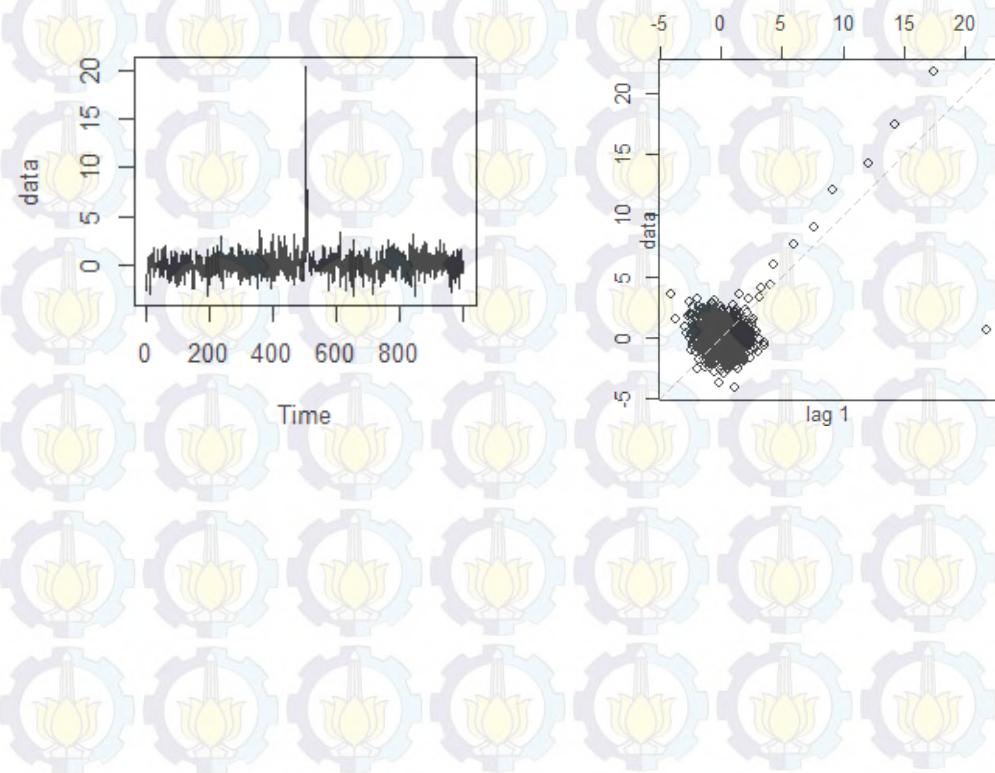
dan 10 dengan  $d$  bernilai 0,4 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, power kedua uji tersebut mengalami kenaikan yang signifikan sehingga mempengaruhi deteksi pola data pada deteksi sebelumnya. Akan tetapi untuk sampel besar  $\gamma$  bernilai 0,5 dengan  $d$  bernilai 0,2 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5 uji Terasvirta dan uji White tidak lagi robust untuk mendeteksi kelinieran data yang mengikuti proses FILSTAR dengan adanya outlier *additive* sebab power dari kedua uji tersebut mengalami penurunan yang signifikan sehingga bisa merubah pendekstrian pola.

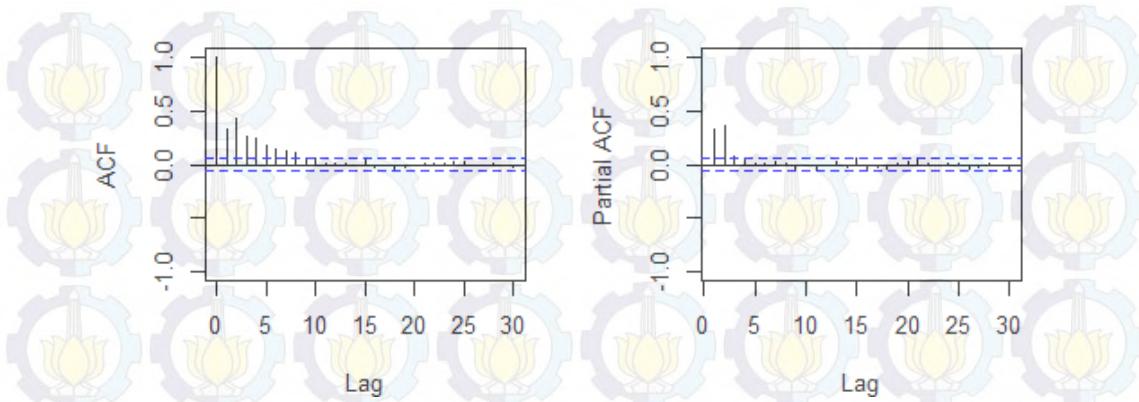
Tabel 4.17 Hasil Simulasi Power dari Uji-uji pada Data FILSTAR dengan Penambahan Outlier *Additive* pada n=200 dan n=1000

$d$	$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
				Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,5	0,2	-0,2	0,051	0,094	0,660	0,026	0,588	0,574	0,996	0,120
		0,5	-0,5	0,019	0,036	0,564	0,008	0,120	0,317	0,986	0,095
		0,8	-0,8	0,063	0,148	0,490	-0,006	0,744	0,936	0,961	0,079
	5	0,2	-0,2	0,045	0,077	0,651	0,023	0,676	0,704	0,998	0,121
		0,5	-0,5	0,012	0,076	0,586	0,007	0,532	0,896	0,988	0,098
		0,8	-0,8	0,026	0,202	0,493	-0,004	0,881	0,998	0,958	0,078
	10	0,2	-0,2	0,042	0,087	0,651	0,023	0,652	0,677	0,998	0,119
		0,5	-0,5	0,014	0,054	0,523	0,001	0,507	0,863	0,996	0,099
		0,8	-0,8	0,032	0,191	0,484	-0,004	0,859	0,993	0,969	0,080
0,3	0,5	0,2	-0,2	0,247	0,308	0,838	0,074	0,995	0,985	1,000	0,202
		0,5	-0,5	0,060	0,101	0,758	0,050	0,730	0,765	1,000	0,177
		0,8	-0,8	0,019	0,071	0,713	0,034	0,500	0,807	1,000	0,154
	5	0,2	-0,2	0,286	0,343	0,840	0,074	0,995	0,993	1,000	0,202
		0,5	-0,5	0,110	0,174	0,753	0,051	0,927	0,983	1,000	0,178
		0,8	-0,8	0,061	0,250	0,723	0,041	0,934	0,998	0,998	0,157
	10	0,2	-0,2	0,260	0,322	0,831	0,070	0,997	0,990	1,000	0,201
		0,5	-0,5	0,096	0,177	0,754	0,053	0,938	0,984	1,000	0,179
		0,8	-0,8	0,048	0,211	0,698	0,034	0,929	0,999	0,999	0,159
0,4	0,5	0,2	-0,2	0,624	0,658	0,944	0,127	1,000	0,999	1,000	0,288
		0,5	-0,5	0,306	0,363	0,901	0,099	0,988	0,985	1,000	0,263
		0,8	-0,8	0,124	0,187	0,862	0,085	0,870	0,949	1,000	0,239
	5	0,2	-0,2	0,637	0,683	0,931	0,122	1,000	0,999	1,000	0,289
		0,5	-0,5	0,395	0,466	0,879	0,105	0,983	0,988	1,000	0,268
		0,8	-0,8	0,278	0,442	0,865	0,090	0,990	0,997	1,000	0,246
	10	0,2	-0,2	0,636	0,681	0,929	0,124	1,000	0,998	1,000	0,287
		0,5	-0,5	0,394	0,467	0,907	0,108	0,986	0,988	1,000	0,265
		0,8	-0,8	0,256	0,425	0,861	0,089	0,977	1,000	1,000	0,243

Uji GPH juga robust digunakan untuk data bangkitan yang mengikuti proses FILSTAR baik untuk sampel besar saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $d$  bernilai 0,2, 0,3, 0,4 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8. Ini karena power dari uji GPH estimator memiliki nilai yang lebih dari 50% bahkan mencapai 100% sehingga tepat terdeteksi sebagai data long memory. Uji GPH estimator tidak robust lagi digunakan pada sampel kecil saat  $\gamma$  bernilai 0,5 dengan  $d$  bernilai 0,2 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8 karena power uji GPH mengalami penurunan signifikan sehingga pola data terdeteksi menjadi short memory. Akan tetapi untuk parameter lain pada sampel kecil ( $n=200$ ), uji GPH estimator masih robust digunakan karena hanya mengalami kenaikan ataupun penuruan power yang tidak signifikan. Sehingga secara keseluruhan, untuk sampel kecil pada data bangkitan yang mengikuti proses FILSTAR, uji Terasvirta tidak robust digunakan ketika terdapat outlier *additive*. Sedangkan pada sampel besar, uji Terasvirta dan uji White robust untuk data yang mengikuti proses FILSTAR dengan adanya outlier *additive*. Untuk uji GPH estimator, pada parameter-parameter tertentu masih robust digunakan.

- Data Mengikuti Proses FILSTAR dengan Penambahan *Innovational Outlier*.





Gambar 4.20 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek *Innovational Outlier*

Tabel 4.18 menunjukkan bahwa dengan adanya *Innovational Outlier* pada data bangkitan yang mengikuti proses FILSTAR akan mempengaruhi power dari uji Terasvirta dan uji White pada parameter-parameter tertentu. Pada sampel besar saat  $d$  bernilai 0,2 dan 0,3,  $\gamma$  bernilai 0,5, 5 dan 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5, 0,8 dan -0,8 dengan power dari kedua uji tersebut mengalami kenaikan yang signifikan disebabkan dengan adanya *Innovational Outlier* sehingga kedua tes tersebut robust untuk pengujian kelinieritasan dari data yang mengikuti proses FILSTAR karena outlier telah mengubah deteksi pola data yang semula linier menjadi nonlinier. Untuk sampel besar  $d$  bernilai 0,4,  $\gamma$  bernilai 0,5, 5 dan 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 uji Terasvirta dan uji White juga robust digunakan karena power kedua uji tersebut mengalami kenaikan yang sangat signifikan hingga powernya mencapai 100%, sehingga deteksi pola data berubah menjadi nonlinier. Hal tersebut juga terjadi pada saat sampel kecil dengan parameter  $d$  bernilai 0,2,  $\gamma$  bernilai 0,5, 5 dan 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5, 0,8 dan -0,8 data bangkitan yang mengikuti proses FILSTAR memiliki nonlinier. Sama halnya juga untuk sampel kecil saat  $d$  bernilai 0,3,  $\gamma$  bernilai 0,5,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5,  $d$  bernilai 0,3,  $\gamma$  bernilai 5,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,8 dan -0,8,  $d$  bernilai 0,3,  $\gamma$  bernilai 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8,  $d$  bernilai 0,4,  $\gamma$  bernilai 0,5, 5, 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,8 dan -0,8 uji Terasvirta dan uji White robust digunakan meskipun terdapat penambahan *Innovational Outlier* karena pola data berubah deteksi data dari linier menjadi nonlinier.

Tabel 4.18 Hasil Simulasi Power dari Uji-uji pada Data FILSTAR dengan Penambahan *Innovational Outlier* pada n=200 dan n=1000

d	$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
				Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,5	0,2	-0,2	0,057	0,059	0,963	0,117	0,113	0,122	1,000	0,146
		0,5	-0,5	0,705	0,777	1,000	0,306	1,000	0,984	1,000	0,209
		0,8	-0,8	1,000	1,000	1,000	0,654	1,000	1,000	1,000	0,478
	5	0,2	-0,2	0,053	0,069	0,990	0,142	0,213	0,269	1,000	0,143
		0,5	-0,5	0,537	0,686	1,000	0,325	1,000	0,994	1,000	0,182
		0,8	-0,8	1,000	1,000	1,000	0,689	1,000	1,000	1,000	0,437
	10	0,2	-0,2	0,050	0,052	0,951	0,101	0,190	0,242	1,000	0,148
		0,5	-0,5	0,568	0,692	1,000	0,329	1,000	0,994	1,000	0,196
		0,8	-0,8	0,999	1,000	1,000	0,646	1,000	1,000	1,000	0,429
0,3	0,5	0,2	-0,2	0,098	0,118	0,990	0,154	0,277	0,257	1,000	0,233
		0,5	-0,5	0,246	0,322	1,000	0,316	0,998	0,951	1,000	0,250
		0,8	-0,8	0,922	0,997	1,000	0,661	1,000	1,000	1,000	0,480
	5	0,2	-0,2	0,100	0,115	0,980	0,154	0,499	0,531	1,000	0,218
		0,5	-0,5	0,412	0,579	1,000	0,346	0,996	0,986	1,000	0,256
		0,8	-0,8	0,994	0,994	1,000	0,707	1,000	1,000	1,000	0,478
	10	0,2	-0,2	0,052	0,064	0,996	0,175	0,453	0,474	1,000	0,227
		0,5	-0,5	0,247	0,403	1,000	0,335	0,997	0,993	1,000	0,263
		0,8	-0,8	0,963	0,976	1,000	0,637	1,000	0,999	1,000	0,471
	0,5	0,2	-0,2	0,293	0,343	0,986	0,183	0,981	0,916	1,000	0,323
		0,5	-0,5	0,152	0,244	1,000	0,370	0,779	0,712	1,000	0,325
		0,8	-0,8	0,911	0,924	1,000	0,688	1,000	1,000	1,000	0,499
	5	0,2	-0,2	0,295	0,315	0,999	0,216	0,995	0,949	1,000	0,322
		0,5	-0,5	0,108	0,250	1,000	0,336	0,876	0,896	1,000	0,330
		0,8	-0,8	0,739	0,804	1,000	0,663	1,000	1,000	1,000	0,516
	10	0,2	-0,2	0,266	0,289	0,998	0,224	0,997	0,954	1,000	0,321
		0,5	-0,5	0,152	0,250	1,000	0,383	0,819	0,895	1,000	0,330
		0,8	-0,8	0,717	0,753	1,000	0,689	1,000	1,000	1,000	0,479

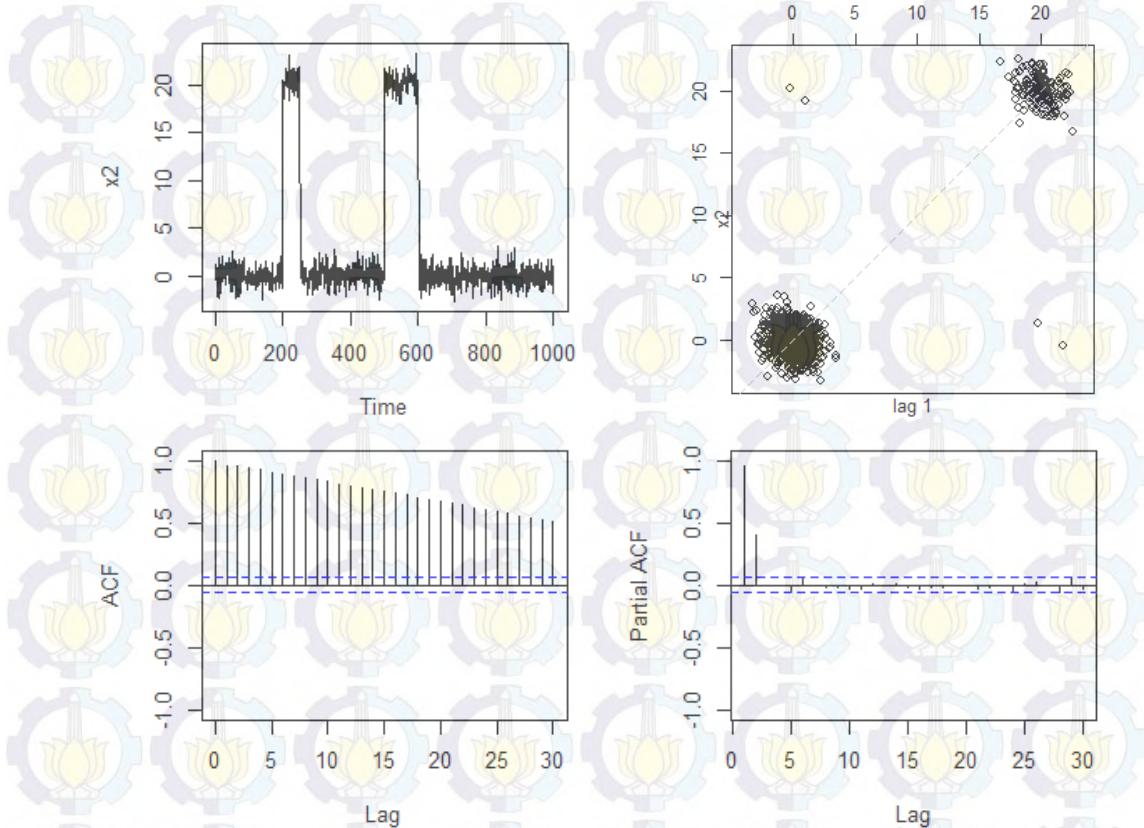
Pada sampel kecil untuk parameter  $d$  bernilai 0,2,  $\gamma$  bernilai 0,5, 5, 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2,  $d$  bernilai 0,3,  $\gamma$  bernilai 0,5,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2,  $d$  bernilai 0,3,  $\gamma$  bernilai 5,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5,  $d$  bernilai 0,3,  $\gamma$  bernilai 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5,  $d$  bernilai 0,4,  $\gamma$  bernilai 0,5, 5, 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5 uji Terasvirta dan uji White tidak robust digunakan karena dengan adanya *Innovational Outlier* tidak bisa lagi mendekripsi kelinieran dari data yang

mengikuti proses FILSTAR. Hal ini terjadi juga pada sampel besar dengan parameter  $d$  bernilai 0,2 dan 0,3,  $\gamma$  bernilai 0,5, 5, 10,  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, saat parameter tersebut uji Terasvirta dan uji White tidak robust digunakan untuk mendeteksi kelinieran dari data yang mengikuti proses FILSTAR dengan adanya *Innovational Outlier*.

Adanya *Innovational Outlier* membuat power dari uji GPH estimator mengalami kenaikan yang tidak signifikan baik untuk sampel kecil maupun sampel besar, hal ini membuat uji GPH estimator robust ketika digunakan pada data yang mengikuti proses FILSTAR dengan adanya *Innovational Outlier* karena masih bisa menangkap kelongmemoryan dari data meskipun terdapat penambahan *Innovational Outlier*.

- Data Mengikuti Proses FILSTAR dengan Penambahan *Outlier Level Shift*.

Berikut time series plot dari data bangkitan yang mengikuti proses FILSTAR dengan adanya efek *Outlier Level Shift*.



Gambar 4.21 Time Series Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek *Outlier Level Shift*

Tabel 4.19 Hasil Simulasi Power dari Uji-uji pada Data FILSTAR tanpa Penambahan Outlier *Shift* pada n=200 dan n=1000

d	$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
				Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,5	0,2	-0,2	0,957	0,958	1,000	0,815	1,000	1,000	1,000	0,895
		0,5	-0,5	0,994	0,995	1,000	0,808	1,000	1,000	1,000	0,901
		0,8	-0,8	1,000	1,000	1,000	0,798	1,000	1,000	1,000	0,908
	5	0,2	-0,2	0,965	0,964	1,000	0,819	1,000	1,000	1,000	0,893
		0,5	-0,5	0,988	0,987	1,000	0,807	1,000	1,000	1,000	0,899
		0,8	-0,8	0,999	0,999	1,000	0,795	1,000	1,000	1,000	0,900
	10	0,2	-0,2	0,953	0,952	1,000	0,820	1,000	1,000	1,000	0,894
		0,5	-0,5	0,989	0,989	1,000	0,805	1,000	1,000	1,000	0,898
		0,8	-0,8	1,000	1,000	1,000	0,794	1,000	1,000	1,000	0,899
0,3	0,5	0,2	-0,2	0,872	0,886	0,999	0,839	1,000	1,000	1,000	0,902
		0,5	-0,5	0,967	0,968	1,000	0,827	1,000	1,000	1,000	0,906
		0,8	-0,8	0,996	0,996	1,000	0,820	1,000	1,000	1,000	0,912
	5	0,2	-0,2	0,850	0,858	1,000	0,838	1,000	1,000	1,000	0,899
		0,5	-0,5	0,949	0,947	0,999	0,829	1,000	1,000	1,000	0,904
		0,8	-0,8	0,988	0,989	1,000	0,816	1,000	1,000	1,000	0,906
	10	0,2	-0,2	0,855	0,860	0,998	0,836	1,000	1,000	1,000	0,899
		0,5	-0,5	0,945	0,949	1,000	0,826	1,000	1,000	1,000	0,903
		0,8	-0,8	0,988	0,989	1,000	0,817	1,000	1,000	1,000	0,905
0,4	0,5	0,2	-0,2	0,675	0,686	1,000	0,855	1,000	1,000	1,000	0,906
		0,5	-0,5	0,831	0,838	0,997	0,849	1,000	1,000	1,000	0,912
		0,8	-0,8	0,948	0,946	1,000	0,839	1,000	1,000	1,000	0,918
	5	0,2	-0,2	0,680	0,689	1,000	0,857	1,000	1,000	1,000	0,905
		0,5	-0,5	0,818	0,826	0,999	0,848	1,000	1,000	1,000	0,909
		0,8	-0,8	0,904	0,908	0,999	0,840	1,000	1,000	1,000	0,912
	10	0,2	-0,2	0,677	0,685	0,998	0,859	1,000	1,000	1,000	0,906
		0,5	-0,5	0,836	0,840	1,000	0,851	1,000	1,000	1,000	0,911
		0,8	-0,8	0,929	0,931	0,999	0,840	1,000	1,000	1,000	0,912

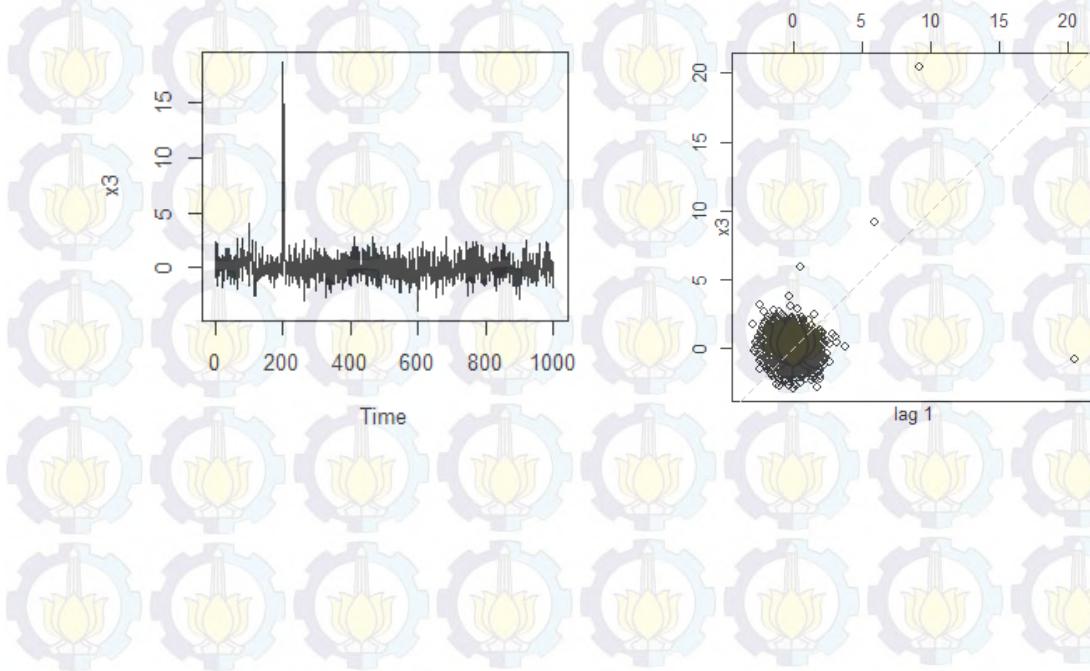
Berdasarkan hasil pada Tabel 4.19 dapat diketahui bahwa saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $d$  bernilai 0,2 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 pada sampel besar, power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan dengan power mencapai 100%. Hal ini menyebabkan uji Terasvirta dan uji White masih robust digunakan pada parameter tersebut karena dengan adanya *Outlier Level Shift* dapat merubah deteksi pola data yang semula linier menjadi

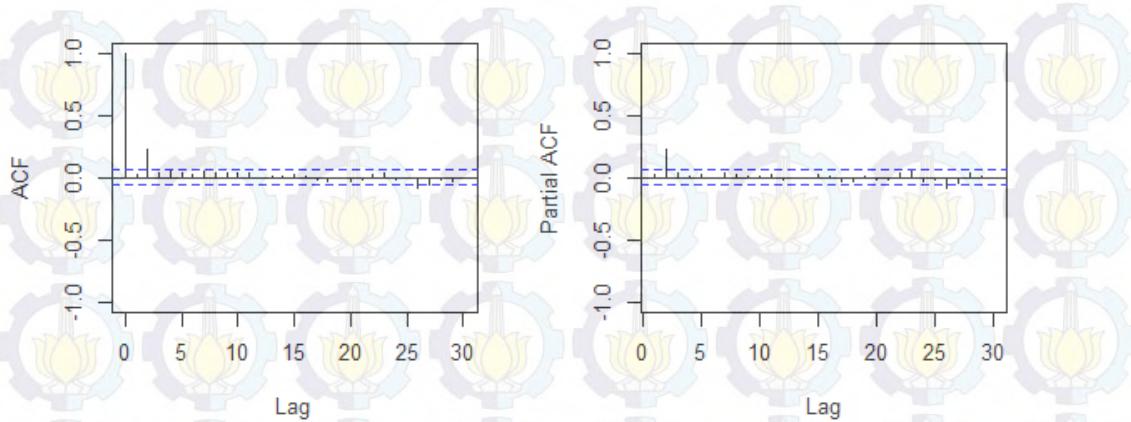
nonlinier sehingga mengikuti prinsi dari proses FILSTAR. Untuk sampel kecil saat  $\gamma$  bernilai 0,5 dengan  $d$  bernilai 0,2, 0,3, 0,4 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8,  $\gamma$  bernilai 5, 10 dengan  $d$  bernilai 0,2, 0,3, 0,4 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 *Outlier Level Shift* juga mempengaruhi perubahan deteksi data menjadi nonlinier karena power dari kedua uji tersebut mengalami peningkatan yang signifikan sehingga pada parameter ini uji Terasvirta dan uji White robust untuk digunakan. Untuk parameter yang lain, uji White dan uji Terasvirta tidak lagi robust untuk digunakan karena terdapat penambahan efek *Outlier Level Shift*.

Pada uji GPH estimator untuk sampel kecil maupun sampel besar saat  $\phi$  bernilai 0,2, 0,5, 0,8, -0,2, -0,5, -0,5, -0,8 dengan  $d$  bernilai 2,3,4 power dari uji GPH tidak mengalami kenaikan yang signifikan sehingga tidak merubah pola data yaitu data tetap terdeteksi berpola long memory. Dalam hal ini uji GPH estimator robust digunakan pada data bangkitan yang mengikuti proses FILSTAR meskipun terdapat penambahan *Outlier Level Shift*.

- Data Mengikuti Proses FILSTAR dengan Penambahan Outlier *Temporary Change*.

Berikut time series plot dari data bangkitan yang mengikuti proses FILSTAR dengan adanya efek outlier *Temporary Change*.





Gambar 4.22 Time Series Plot, Lag Plot, ACF dan PACF Data yang Mengikuti FILSTAR dengan Adanya Efek Outlier *Temporary Change*

Berdasarkan Tabel 4.20 dapat dilihat bahwa pada sampel besar ( $n=1000$ ) saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $d$  bernilai 0,2 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2 pada sampel besar, power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan dengan power mencapai 100%. Hal ini menyebabkan uji Terasvirta dan uji White robust digunakan pada parameter tersebut karena dengan adanya *Outlier Level Shift* dapat merubah deteksi pola data yang semula linier menjadi nonlinier. Sedangkan pada sampel kecil ( $n$  bernilai 200) saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $d$  bernilai 0,2, 0,3, 0,4 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,5 dan -0,5 power dari uji Terasvirta dan uji White mengalami kenaikan yang signifikan hingga menyebabkan perubahan deteksi pola data yang semula linier menjadi nonlinier. Sehingga dengan adanya outlier *Temporary Change* dapat merubah deteksi pola data yang semula linier menjadi nonlinier. Dengan demikian adanya outlier *Temporary Change* dapat membuat uji Terasvirta dan uji White semakin robust digunakan karena kedua uji tersebut dapat mendeteksi kelinieran dari data bangkitan yang mengikuti proses FILSTAR meskipun terdapat efek outlier *Temporary Change*.

Uji GPH estimator untuk sampel kecil maupun sampel besar saat saat  $\gamma$  bernilai 0,5, 5, 10 dengan  $d$  bernilai 0,2, 0,3, 0,4 dan  $\alpha_1$  dan  $\alpha_2$  bernilai 0,2 dan -0,2, 0,5 dan -0,5, 0,8 dan -0,8 power dari uji GPH tidak mengalami kenaikan atau penurunan yang signifikan sehingga tidak merubah pendekstrian pola data yaitu data tetap berpola long memory sehingga uji GPH estimator masih robust

digunakan saat terdapat penambahan outlier *Temporary Change* pada data bangkitan yang mengikuti proses FILSTAR.

Tabel 4.20 Hasil Simulasi Power dari Uji-uji pada Data FILSTAR tanpa Penambahan Outlier *Temporary Change* pada n=200 dan n=1000

d	$\gamma$	$\alpha_1$	$\alpha_2$	n = 200				n = 1000			
				Terasvirta	White	GPH	Mean GPH	Terasvirta	White	GPH	Mean GPH
0,2	0,5	0,2	-0,2	0,474	0,543	1,000	0,321	0,997	0,956	1,000	0,210
		0,5	-0,5	0,841	0,885	1,000	0,322	1,000	0,995	1,000	0,199
		0,8	-0,8	0,989	0,990	1,000	0,318	1,000	0,998	1,000	0,196
	5	0,2	-0,2	0,440	0,525	1,000	0,325	0,997	0,975	1,000	0,211
		0,5	-0,5	0,779	0,874	1,000	0,320	1,000	0,997	1,000	0,200
		0,8	-0,8	0,931	0,976	1,000	0,316	1,000	0,999	1,000	0,188
0,3	10	0,2	-0,2	0,449	0,540	1,000	0,326	0,997	0,969	1,000	0,211
		0,5	-0,5	0,779	0,869	1,000	0,317	1,000	0,994	1,000	0,200
		0,8	-0,8	0,923	0,959	1,000	0,317	1,000	0,999	1,000	0,190
	5	0,2	-0,2	0,184	0,241	1,000	0,332	0,695	0,696	1,000	0,274
		0,5	-0,5	0,493	0,620	1,000	0,332	0,996	0,966	1,000	0,258
		0,8	-0,8	0,874	0,912	1,000	0,327	1,000	0,993	1,000	0,247
0,4	10	0,2	-0,2	0,169	0,240	1,000	0,335	0,668	0,762	1,000	0,277
		0,5	-0,5	0,416	0,596	1,000	0,333	0,986	0,987	1,000	0,259
		0,8	-0,8	0,725	0,869	1,000	0,326	1,000	1,000	1,000	0,246
	5	0,2	-0,2	0,160	0,207	1,000	0,336	0,687	0,767	1,000	0,274
		0,5	-0,5	0,428	0,609	1,000	0,331	0,974	0,981	1,000	0,262
		0,8	-0,8	0,700	0,833	1,000	0,327	0,999	0,999	1,000	0,246
0,5	10	0,2	-0,2	0,041	0,066	1,000	0,357	0,158	0,234	1,000	0,351
		0,5	-0,5	0,202	0,295	1,000	0,349	0,681	0,787	1,000	0,331
		0,8	-0,8	0,540	0,679	1,000	0,341	0,948	0,976	1,000	0,317
	5	0,2	-0,2	0,046	0,090	1,000	0,357	0,234	0,402	1,000	0,355
		0,5	-0,5	0,187	0,330	0,999	0,349	0,796	0,908	1,000	0,336
		0,8	-0,8	0,453	0,670	0,999	0,344	0,962	0,981	1,000	0,319
0,6	10	0,2	-0,2	0,044	0,083	1,000	0,358	0,244	0,362	1,000	0,348
		0,5	-0,5	0,221	0,371	1,000	0,348	0,809	0,920	1,000	0,336
		0,8	-0,8	0,446	0,639	1,000	0,339	0,967	0,990	1,000	0,317

## 4.2 Aplikasi pada Saham LQ 45

Saham LQ 45 yang dijadikan bahan studi kasus dalam tugas akhir ini adalah saham bank yang masuk ke dalam saham LQ 45. Nilai *return* harga saham yang akan dianalisis pada penelitian ini, bukan harga saham secara langsung

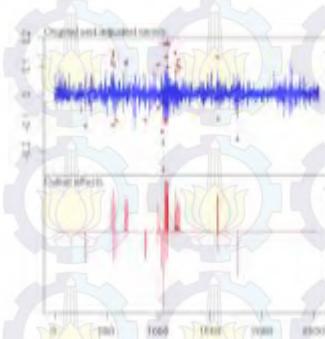
karena kenyataannya investor lebih tertarik mengetahui informasi pergerakan return saham daripada harga saham itu sendiri (Ding et al.(1993), Andersen et al.(2003), Sibbertsen (2006)). Dalam penelitian ini return saham yang dianalisis hanya return saham Bank Negara Indonesia. Hal ini karena diantara kelima bank yang masuk ke dalam LQ45, hanya return saham Bank Negara Indonesia yang memiliki fenomena nonlinier long memory.Hal ini didukung oleh hasil uji Terasvirta, uji White dan Uji GPH Estimator sebagai berikut.

Tabel 4.21 Pengujian Long Memory dan Nonlinieritas *Return Saham*

Bank	GPH Estimator	Terasvirta					White				
		Bandwith = 0,8	lag 1	lag 2	lag 3	lag 4	lag 5	lag 1	lag 2	lag 3	lag 4
BCA	-0,051	0,379	0,059	0,000	0,000	0,000	0,348	0,195	0,460	0,245	0,387
BNI	<b>0,043</b>	<b>0,066</b>	<b>0,002</b>	<b>0,000</b>	< 2,2e-16	< 2,2e-16	<b>0,056</b>	<b>0,026</b>	<b>0,000</b>	<b>0,005</b>	<b>0,014</b>
BRI	-0,018	0,002	0,000	0,000	< 2,2e-16	< 2,2e-16	0,009	0,109	0,015	0,470	0,096
Danamon	-0,044	0,091	0,141	0,000	0,000	< 2,2e-16	0,046	0,004	0,370	0,249	0,024
Mandiri	-0,040	0,001	0,000	0,000	0,000	< 2,2e-16	0,218	0,152	0,152	0,070	0,048

Berdasarkan Tabel 4.21 hasil uji long memory dan nonlinieritas menunjukkan bahwa hanya return saham Bank Negara Indonesia yang memiliki fenomena long memory dan nonlinieritas, hal ini karena hasil nilai d dari uji GPH Estimator dengan bandwith 0,8 menghasilkan nilai 0,043 yang berada diantara 0 hingga 1, sedangkan hasil uji Terasvirta dan uji White menunjukkan bahwa nilai p-value kurang dari nilai  $\alpha = 0,05$  yang berarti bahwa data mengikuti fenomena nonlinier. Adanya fenomena nonlinieritas pada data return saham Bank Negara Indonesia memiliki dua kemungkinan yaitu memang benar-benar mengikuti pergerakan return saham tersebut atau karena adanya outlier yang menyebabkan data return saham dapat teruji sebagai fenomena nonlinieritas. Dalam hal ini dilakukan pengujian outlier pada data return saham tersebut. Berikut hasil pengujian outlier pada data return saham Bank Negara Indonesia.

Berdasarkan tabel 4.24 dapat dilihat bahwa outlier yang mendominasi data return saham BNI adalah outlier AO (*Additive Outlier*). Akan tetapi ada pula outlier TC (*Temporary Change*) pada data tersebut. Outlier tersebut disebabkan adanya kejadian ekstrim yang terjadi di Indonesia yang menyebabkan kenaikan atau penurunan *return* saham yang sangat drastis.



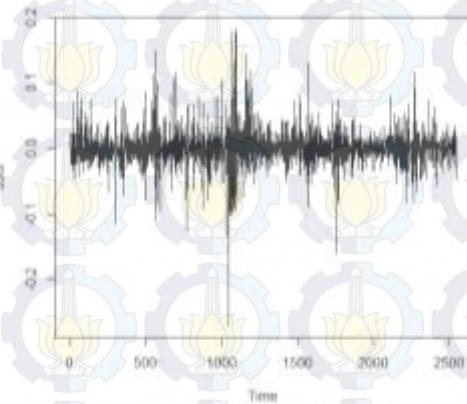
Gambar 4.23 Jenis Outlier pada Data Return Saham Bank Negara Indonesia

Tabel 4.22 Pengujian Outlier pada *Return* Saham Bank Negara Indonesia

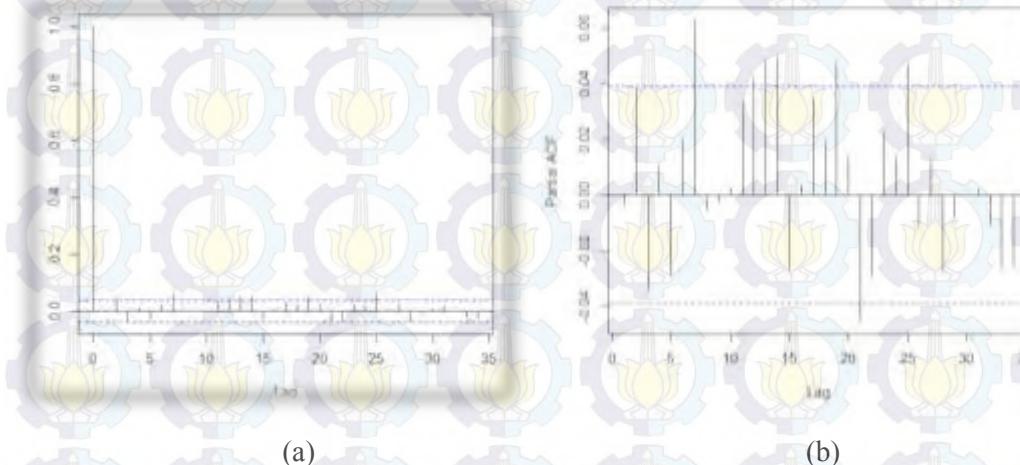
	type	ind	time	coefhat	tstat
1	AO	296	296	-0,115	-5,004
2	AO	551	551	0,113	4,925
3	AO	562	562	0,150	6,556
4	AO	563	563	0,133	5,791
5	AO	564	564	-0,111	-4,857
6	AO	575	575	0,103	4,506
7	AO	593	593	-0,095	-4,162
8	AO	687	687	0,107	4,674
9	AO	696	696	0,116	5,083
10	AO	874	874	-0,093	-4,059
11	TC	998	998	0,101	5,78
12	AO	1000	1000	-0,099	-4,076
13	AO	1034	1034	-0,132	-5,775
14	AO	1045	1045	-0,271	-11,818
15	AO	1047	1047	-0,172	-7,504
16	AO	1062	1062	0,179	7,818
17	AO	1070	1070	-0,101	-4,414
18	AO	1080	1080	0,132	5,771
19	AO	1082	1082	-0,094	-4,084
20	AO	1087	1087	0,095	4,162
21	AO	1091	1091	0,182	7,961
22	AO	1095	1095	0,177	7,726
23	AO	1161	1161	0,145	6,324
24	TC	1166	1166	0,075	4,555
25	TC	1177	1177	0,105	6,142
26	AO	1192	1192	0,120	5,219
27	AO	1204	1204	0,093	4,064
28	AO	1569	1569	0,131	5,711
29	TC	1570	1570	-0,072	-4,417
30	AO	1761	1761	-0,161	-7,013

Berdasarkan Tabel 4.22 dan Gambar 4.23 terlihat bahwa pada data return saham PT. Bank Negara Indonesia terdapat 30 outlier yang berjenis outlier *additive* dan outlier *Temporary Change*.

Pengambilan data saham Bank Negara Indonesia mulai 8 Juni 2004 hingga 28 November 2014. Data saham tersebut kemudian dihitung return sahamnya kemudian dilakukan pengolahan selanjutnya. Berikut adalah sajian deskripsi series data return saham dari masing-masing indeks saham.



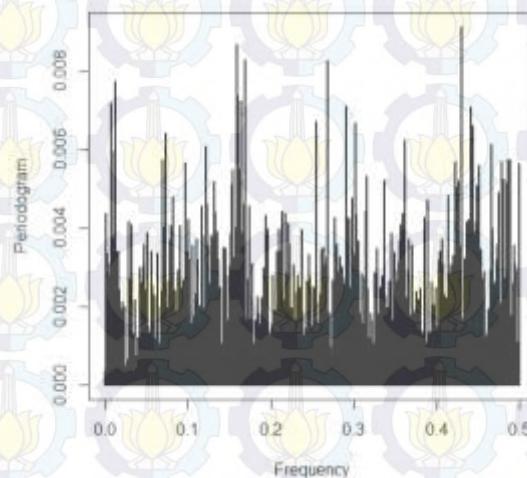
Gambar 4.24 Plot Time Series Return Saham Bank Negara Indonesia



Gambar 4.25 Plot ACF (a) dan PACF (b) Return Saham Bank Negara Indonesia

Berdasarkan Gambar 4.25 terlihat bahwa plot PACF terkesan tidak jelas apakah mengikuti pola long memory atau short memory. Hal tersebut memunculkan 2 kemungkinan, yaitu data series tersebut non stasioner atau data tersebut sebenarnya mengikuti fenomena Long Memory. Berikut adalah hasil pemeriksaan atau pengujian stasioneritas untuk data return saham tersebut baik stasioner dalam mean maupun variannya. Untuk stasioneritas dalam varians dalam

hal ini tidak perlu dilakukan lagi karena perhitungan return saham telah menggunakan fungsi  $\ln$ . Untuk mengetahui kelongmemoryan dari data digunakan periodogram sebagai berikut.



Gambar 4.26 Plot Periodogram *Return* Saham Bank Negara Indonesia

Hasil pengujian long memory dan nonlinieritas pada Tabel 4.21 menunjukkan bahwa data return saham Bank Negara Indonesia memiliki fenomena long memory dan nonlinier, akan tetapi pada pengujian outlier pada Tabel 4.32 menunjukkan bahwa terdapat efek outlier yang mempengaruhi data return saham tersebut sehingga kemungkinan besar fenomena nonlinieritas dari data return tersebut dipengaruhi oleh adanya outlier, bukan hasil asli dari pergerakan data return saham. Oleh karena itu, dalam pemodelan dicoba kemungkinan ketiga model yaitu model ARFIMA sebagai Long Memory, ESTAR sebagai Nonlinieritas dan FISTAR untuk fenomena long memory dan nonlinier. Ketiga model tersebut dibentuk, kemudian diramalkan untuk dibandingkan error terkecilnya.

#### 4.2.1 Pemodelan dan Peramalan Data Return Saham Bank Negara Indonesia dengan Menggunakan Model ARFIMA (p,d,q)

Tahap berikutnya setelah melakukan beberapa pengujian adalah melakukan pemodelan terhadap data return saham Bank Negara Indonesia. Pemodelan kali ini yaitu menggunakan model ARFIMA, langkah yang dilakukan

yaitu melakukan estimasi parameter dari model ARFIMA (p,d,q). Berikut hasil estimasi dari model ARFIMA (p,d,q)

Tabel 4.23 Estimasi Parameter Model ARFIMA

	Estimate	Std. Error	z value	Pr(> z )
d	0,098	0,019	5,223	0,000
AR (1)	0,549	0,023	23,510	< 2e-16
MA (1)	0,641	0,022	28,641	< 2e-16

Berdasarkan Tabel 4.23 dapat diketahui bahwa estimasi parameter untuk AR(1) sebesar 0,549 dan MA(1) sebesar 0,641 dengan nilai estimasi dari d sebesar 0,098. Nilai p-value dari ketiga parameter tersebut bernilai kurang dari  $\alpha = 0,05$  yang berarti bahwa koefisien dari parameter tersebut signifikan terhadap model. Sehingga model ARFIMA yang terbentuk adalah ARFIMA (1,0,098,1) dengan model sebagai berikut.

$$(1 - \phi_1 B)(1 - B)^d y_t = (1 - \theta_1 B)a_t$$

$$(1 - 0,549B)(1 - B)^d y_t = (1 - 0,641B)a_t$$

$$(y_t - 0,549y_{t-1})(1 - B)^{0,098} = a_t - 0,641a_{t-1}$$

Setelah melakukan estimasi parameter dan pembentukan model, selanjutnya dilakukan pengujian pada residual untuk mengetahui apakah residual telah memenuhi asumsi *White noise* (identik dan independen) dan berdistribusi normal ( $0, \sigma^2$ ). Hipotesis untuk menguji apakah residual *White noise* adalah sebagai berikut.

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (residual white noise)}$$

$$H_1 : \text{minimal terdapat satu } \rho_k \neq 0, \text{ dimana } k = 1, 2, \dots, K$$

$$\alpha = 5\% (0,05)$$

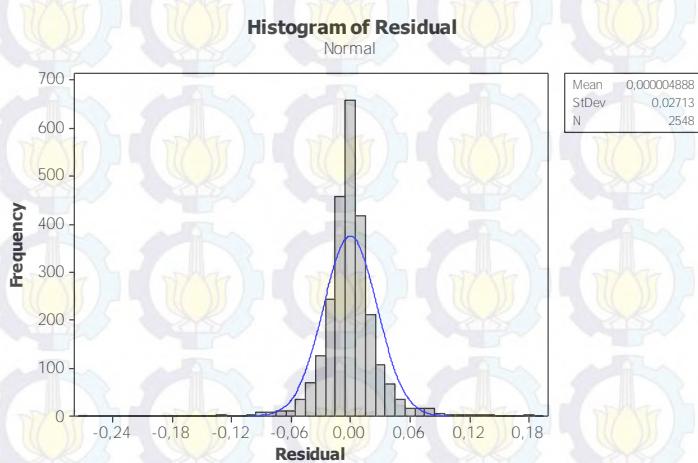
Hasil pengujian dengan menggunakan uji statistik L-Jung Box yang ditampilkan pada tabel berikut ini.

Tabel 4.24 Pengujian *White Noise* Residual Model ARFIMA (1,0,098,1)

X-Squared	df	P-Value
79,433	36	4,102e-05

Tabel 4.24 menunjukkan p-value statistik uji L-Jung Box kurang dari 5% yaitu sebesar 4,102e-05. Ini berarti bahwa  $H_0$  ditolak dan menunjukkan

bahwa residual model ARFIMA (1,0.098,1) tidak *White noise*. Untuk mengetahui residual berdistribusi normal atau tidak dapat dilakukan dengan cara membentuk histogram residual. Jika histogram membentuk pola distribusi normal, maka dapat dikatakan bahwa residual berdistribusi normal. Adapun histogram dari residual model ARFIMA (1,0.098,1) adalah sebagai berikut.



Gambar 4.27 Histogram Residual Model ARFIMA (1,0.098,1)

Gambar 4.27 menunjukkan bahwa pola residual yang terbentuk seperti distribusi normal standart, yaitu memiliki puncak di bagian tengah di titik nol. Pengujian menggunakan histogram sangat bergantung pada subyektivitas peneliti, sehingga untuk memastikan apakah distribusi residual benar-benar mengikuti distribusi normal dapat dilakukan pengujian dengan menggunakan statistik Kolmogorov-Smirnov. Pengujian tersebut menggunakan hipotesis sebagai berikut.

$$H_0: F(x) = F_0(x) \quad (x \text{ merupakan residual yang berdistribusi Normal } (0, \sigma^2))$$

$$H_1: F(x) \neq F_0(x) \quad (x \text{ merupakan residual yang tidak berdistribusi Normal } (0, \sigma^2))$$

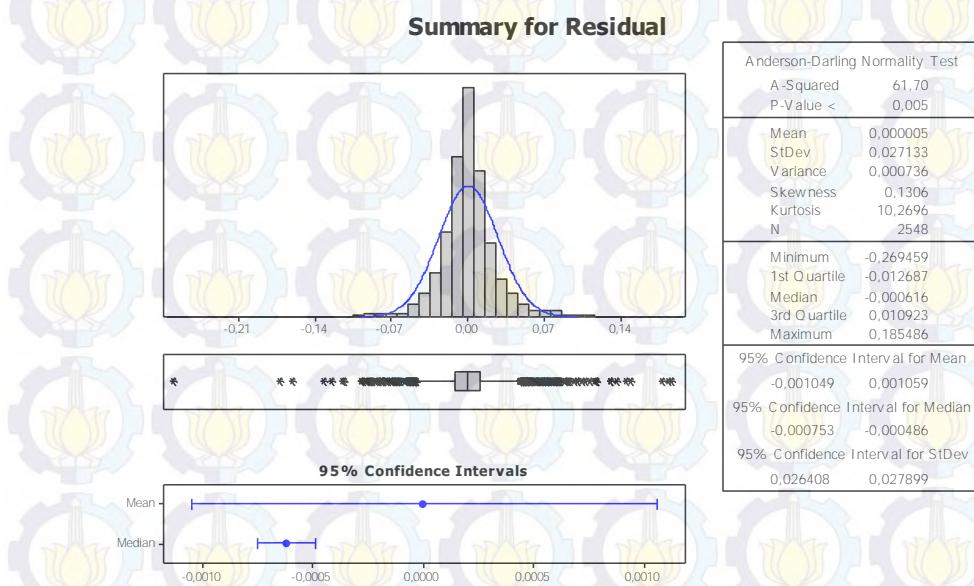
Hasil pengujian normalitas residual dilakukan dengan menggunakan pengujian Kolmogorov-Smirnov, dengan hasil sebagai berikut.

Tabel 4.25 Pengujian Normalitas dengan Statistik Uji Kolmogorov-Smirnov

D	P-Value
0,460	< 2,2e-16

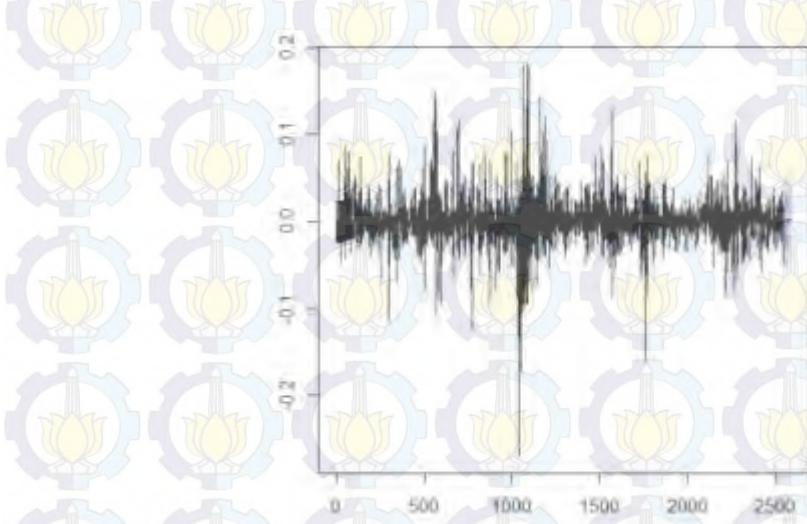
Berdasarkan Tabel 4.25 diketahui bahwa p-value yang dihasilkan dengan menggunakan statistik Kolmogorov-Smirnov bernilai kurang dari 5%. Hal ini berarti bahwa tolak  $H_0$  dan menunjukkan residual tidak berdistribusi Normal

$(0, \sigma^2)$ . Residual yang dihasilkan tidak berdistribusi normal karena memiliki nilai kurtosis yang sangat tinggi yaitu sebesar 10,269 yang disajikan pada Gambar 4.27 sebagai berikut.



Gambar 4.28 *Graphycal Summary* dari Residual Model ARFIMA (1,0.098,1)

Hasil dari cek diagnosa pada residual model ARFIMA (1,0.098,1) menunjukkan bahwa residual memenuhi asumsi White noise akan tetapi tidak berdistribusi normal karena memiliki nilai kurtosis yang sangat besar. Adapun hasil dari pemodelan ARFIMA (1,0.098,1) menghasilkan peramalan sebagai berikut.



Gambar 4.29 Hasil Ramalan Model ARFIMA (1,0.098,1)

Tabel 4.26 Hasil Ramalan Model ARFIMA (1,0,098,1)

Data ke-	Ramalan
2549	0,000981176
2550	0,000947986
2551	0,000761935
2552	0,000639992
...	...
2588	0,004246291
2589	0,020965128
2590	0,000000000
<b>MSE</b>	<b>0,04%</b>
<b>RMSE</b>	<b>2,01%</b>

Berdasarkan pada hasil ramalan di Tabel 4.26 terlihat bahwa hasil ramalan memiliki nilai kebaikan model untuk MSE sebesar 0,04% dan RMSE sebesar 2,01%.

#### 4.2.2 Pemodelan dan Peramalan Data *Return* Saham Bank Negara Indonesia dengan Menggunakan Model LSTAR

Berdasarkan perhitungan parameter *fractional difference* ( $d$ ) yang bernilai di antara 0 dan 0,5, serta bentuk plot ACF yang turun secara cepat, memungkinkan bahwa model memiliki sifat *spurious long memory*. Sehingga ada kemungkinan bahwa model lebih cocok untuk dimodelkan dengan menggunakan model nonlinier. Pada penelitian ini, dilakukan pembentukan model nonlinier yaitu LSTAR (*Logistic Smoothing Transition Autoregression*). Pada pemodelan LSTAR ini digunakan asumsi bahwa parameter delay = 1 dengan dua transisi. Hasil identifikasi dan estimasi parameter model LSTAR untuk data return saham Bank Negara Indonesia adalah sebagai berikut.

Tabel 4.27 Hasil Estimasi Parameter Model LSTAR

Parameter	t <sub>hitung</sub>	P-value	AIC
delay = 1			
$\phi_{1,1} = -0.076$	-0.9253	0.3548	
$\phi_{1,2} = 0.096$	1.1217	0.2620	
$\gamma = 39.077$	0.9107	0.3625	
$c = -0.064$	-1.5924	0.1113	-18372

Model yang terbentuk berdasarkan estimasi parameter tersebut adalah sebagai berikut.

$$y_t = -0,076 y_{t-1} \left( 1 - \frac{1}{1 + e^{-39,077(y_{t-1} - 0,064)}} \right) + 0,096 y_{t-1} \frac{1}{1 + e^{-39,077(y_{t-1} - 0,064)}} + a_t$$

Berdasarkan Tabel 4.27 diketahui bahwa parameter dari model LSTAR memiliki nilai p-value lebih dari  $\alpha = 5\%$ , hal ini berarti bahwa parameter dari model tersebut tidak signifikan terhadap model. Ini artinya fenomena kenonlinieritasan dari data return saham Bank Negara Indonesia tidak signifikan. Langkah selanjutnya yaitu melakukan cek diagnosa White noise dan distribusi normal. Hipotesis untuk menguji apakah residual *White noise* adalah sebagai berikut.

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (residual white noise)}$$

$$H_1 : \text{minimal terdapat satu } \rho_k \neq 0, \text{ dimana } k = 1, 2, \dots, K$$

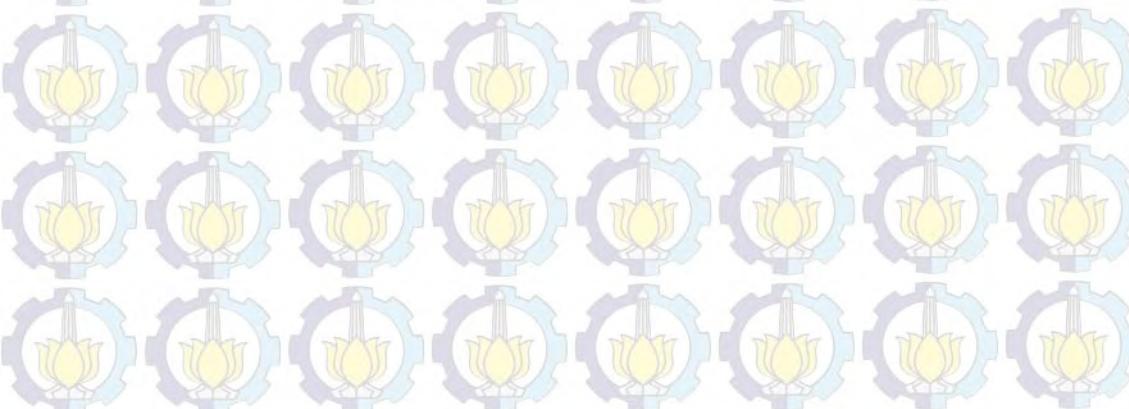
$$\alpha = 5\% (0,05)$$

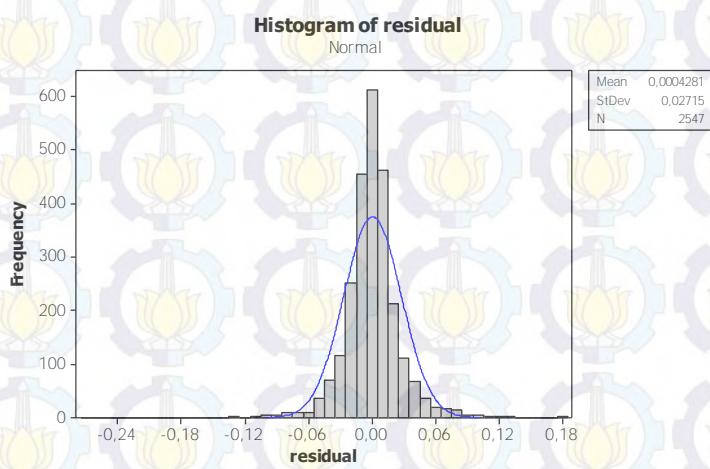
Hasil pengujian dengan menggunakan uji statistik L-Jung Box yang ditampilkan pada tabel berikut ini.

Tabel 4.28 Pengujian *White Noise* Residual Model LSTAR

	X-Squared	df	P-Value
	89,344	36	1,987e-06

Tabel 4.28 menunjukkan p-value statistik uji L-Jung Box lebih kecil dari 5% yaitu sebesar 1,987e-06. Ini berarti bahwa tolak  $H_0$  dan menunjukkan bahwa residual model LSTAR tidak *White noise*. Untuk mengetahui residual berdistribusi normal atau tidak dapat dilakukan dengan cara membentuk histogram residual. Jika histogram membentuk pola distribusi normal, maka dapat dikatakan bahwa residual berdistribusi normal. Adapun histogram dari residual model LSTAR adalah sebagai berikut.





Gambar 4.30 Histogram Residual Model LSTAR

Gambar 4.30 menunjukkan bahwa pola residual yang terbentuk seperti distribusi normal standart, yaitu memiliki puncak di bagian tengah di titik nol. Pengujian menggunakan histogram sangat bergantung pada subyektivitas peneliti, sehingga untuk memastikan apakah distribusi residual benar-benar mengikuti distribusi normal dapat dilakukan pengujian dengan menggunakan statistik Kolmogorov-Smirnov. Pengujian tersebut menggunakan hipotesis sebagai berikut.

$H_0: F(x) = F_0(x)$  ( $x$  merupakan residual yang berdistribusi Normal  $(0, \sigma^2)$ )

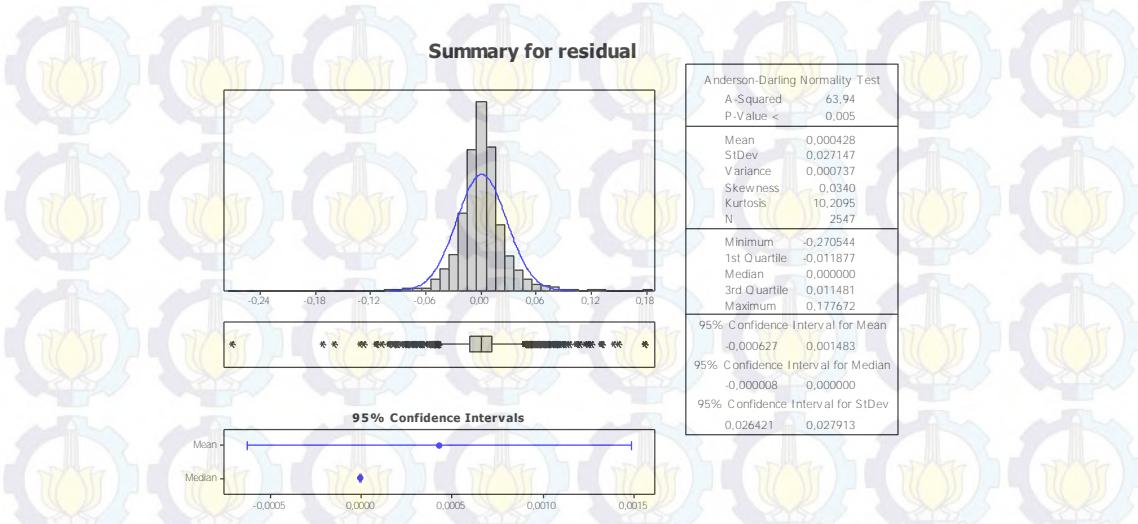
$H_1: F(x) \neq F_0(x)$  ( $x$  merupakan residual yang tidak berdistribusi Normal  $(0, \sigma^2)$ )

Hasil pengujian normalitas residual dilakukan dengan menggunakan pengujian Kolmogorov-Smirnov, dengan hasil sebagai berikut.

Tabel 4.29 Pengujian Normalitas Residual Model LSTAR dengan Statistik Uji Kolmogorov-Smirnov

D	P-Value
0,998	< 2,2e-16

Berdasarkan Tabel 4.29 diketahui bahwa p-value yang dihasilkan dengan menggunakan statistik Kolmogorov-Smirnov bernilai kurang dari 5%. Hal ini berarti bahwa tolak  $H_0$  dan menunjukkan residual tidak berdistribusi Normal  $(0, \sigma^2)$ . Residual yang dihasilkan tidak berdistribusi normal karena memiliki nilai kurtosis yang sangat tinggi yaitu sebesar 10,2095 yang disajikan pada Gambar 4.31 sebagai berikut.



Gambar 4.31 *Graphycal Summary* dari Residual Model LSTAR

Hasil dari cek diagnosa pada residual model LSTAR menunjukkan bahwa residual memenuhi asumsi White noise akan tetapi tidak berdistribusi normal karena memiliki nilai kurtosis yang sangat besar. Adapun hasil dari pemodelan LSTAR menghasilkan peramalan sebagai berikut.

Tabel 4.30 Hasil Ramalan Model LSTAR

Data ke-	Ramalan
2549	-1,11E-04
2550	-1,40E-06
2551	-1,77E-08
2552	-2,23E-10
...	...
2588	-9,97E-79
2589	-1,26E-80
2590	-1,59E-82
<b>MSE</b>	<b>0,04%</b>
<b>RMSE</b>	<b>2,01%</b>

Berdasarkan pada hasil ramalan di Tabel 4.30 terlihat bahwa hasil ramalan dari model LSTAR memiliki nilai kebaikan model untuk MSE sebesar 0,04% dan RMSE sebesar 2,01%.

### 4.2.3 Pemodelan dan Peramalan Data Return Saham Bank Negara Indonesia dengan Menggunakan Model FILSTAR

Berdasarkan pengujian pada awal pembahasan bahwa data return saham bergerak secara nonlinier long memory. Pada penelitian ini, dilakukan pembentukan dua model gabungan antara nonlinier dengan long memory yaitu model FISTAR (*Fractionally Integrated Smoothing Transition Autoregression*). Pada pemodelan FISTAR ini yang digunakan adalah model FILSTAR (*Fractionally Integrated Logistic Smoothing Transition Autoregression*) dengan asumsi bahwa parameter delay = 1 dengan dua transisi. Tahap pertama yang dilakukan yaitu mendifferencing terlebih dahulu data return saham dengan differencing fractional sebesar 0,04334821 sesuai dengan nilai  $d$  pada pengujian long memory dengan menggunakan uji GPH Estimator. Hasil dari pendifferencing data return saham adalah sebagai berikut.

Tabel 4.31 Differencing Fractional Data *Return* Saham BNI

Data ke-	Differencing (0,0433)
1	2,23E-02
2	-2,46E-02
3	-1,01E-04
4	-4,46E-04
5	-5,24E-04
...	...
2546	-4,93E-02
2547	1,94E-02
2548	-1,40E-02

Tabel 4.31 menunjukkan data return saham Bank Negara Indonesia yang sudah didifferencing fraksional dengan  $d= 0,04334821$ . Tahap selanjutnya yang dilakukan yaitu mengestimasi parameter LSTAR dengan menggunakan data yang sudah didifferencing tersebut. Hasil estimasinya adalah sebagai berikut.

Tabel 4.32 Estimasi Parameter Model FILSTAR

Parameter	t <sub>hitung</sub>	P-value	AIC
delay = 1			-18376
$\phi_{1,1} = -0.125$	-0.145	0.146	
$\phi_{1,2} = 0.098$	1.106	0.269	
$\gamma = 36.539$	1.039	0.299	
$c = -0.073$	-1.868	0.062	

Model yang terbentuk berdasarkan estimasi parameter tersebut adalah sebagai berikut.

$$\hat{y}_t = -0,125 \hat{y}_{t-1} \left( 1 - \frac{1}{1 + e^{-36,539(\hat{y}_{t-1} + 0,073)}} \right) + 0,098 \frac{1}{1 + e^{-36,539(\hat{y}_{t-1} + 0,073)}} + a_t$$

dengan  $\hat{y}_t = (1 - B)^d y_t$

Berdasarkan Tabel 4.32 diketahui bahwa parameter dari model FILSTAR memiliki nilai p-value lebih dari  $\alpha = 5\%$ , hal ini berarti bahwa parameter dari model tersebut tidak signifikan terhadap model. Ini artinya fenomena kenonlinieritasan dari data return saham Bank Negara Indonesia tidak signifikan. Langkah selanjutnya yaitu melakukan cek diagnosa White noise dan distribusi normal. Hipotesis untuk menguji apakah residual *White noise* adalah sebagai berikut.

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0 \text{ (residual white noise)}$$

$$H_1 : \text{minimal terdapat satu } \rho_k \neq 0, \text{ dimana } k = 1, 2, \dots, K$$

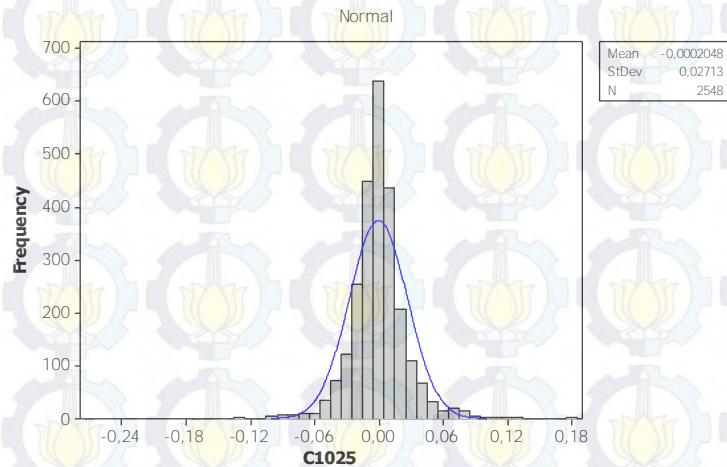
$$\alpha = 5\% (0,05)$$

Hasil pengujian dengan menggunakan uji statistik L-jung Box yang ditampilkan pada tabel berikut ini.

Tabel 4.33 Pengujian *White Noise* Residual Model FILSTAR

L-Jung Box	df	P-Value
84,723	36	8,371e-06

Tabel 4.33 menunjukkan p-value statistik uji L-jung Box lebih besar dari 5% yaitu sebesar 8,371e-06. Ini berarti bahwa tolak  $H_0$  dan menunjukkan bahwa residual model LSTAR tidak *White noise*. Untuk mengetahui residual berdistribusi normal atau tidak dapat dilakukan dengan cara membentuk histogram residual. Jika histogram membentuk pola distribusi normal, maka dapat dikatakan bahwa residual berdistribusi normal. Adapun histogram dari residual model FILSTAR adalah sebagai berikut.



Gambar 4.32 Histogram Residual Model FILSTAR

Gambar 4.32 menunjukkan bahwa pola residual yang terbentuk seperti distribusi normal standart, yaitu memiliki puncak di bagian tengah di titik nol. Pengujian menggunakan histogram sangat bergantung pada subyektivitas peneliti, sehingga untuk memastikan apakah distribusi residual benar-benar mengikuti distribusi normal dapat dilakukan pengujian dengan menggunakan statistik Kolmogorov-Smirnov. Pengujian tersebut menggunakan hipotesis sebagai berikut.

$$H_0: F(x) = F_0(x) \quad (x \text{ merupakan residual yang berdistribusi Normal } (0, \sigma^2))$$

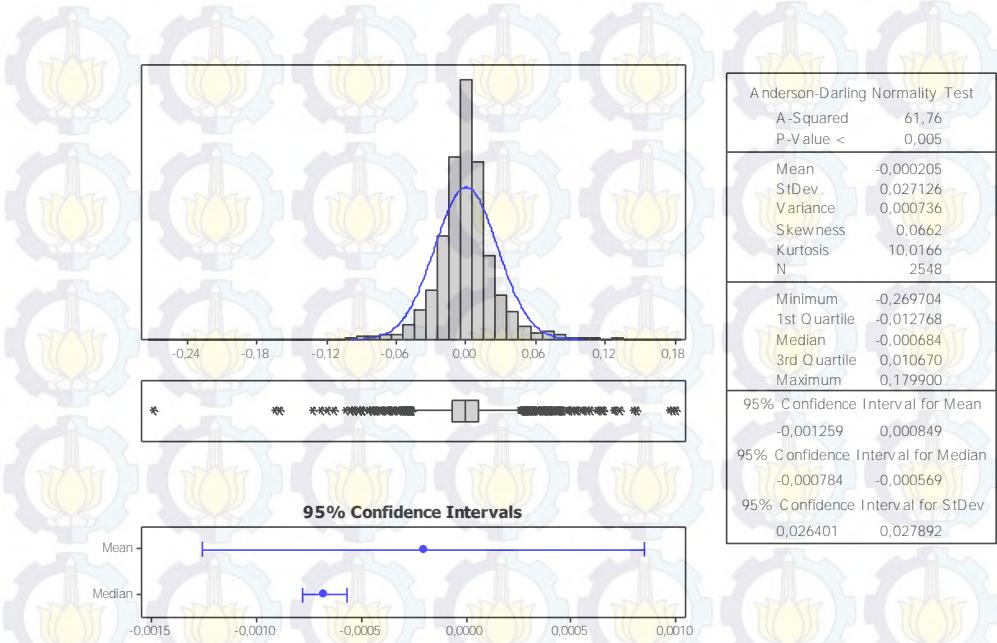
$$H_1: F(x) \neq F_0(x) \quad (x \text{ merupakan residual yang tidak berdistribusi Normal } (0, \sigma^2))$$

Hasil pengujian normalitas residual dilakukan dengan menggunakan pengujian Kolmogorov-Smirnov, dengan hasil sebagai berikut.

Tabel 4.34 Pengujian Normalitas Residual Model FILSTAR dengan Statistik Uji Kolmogorov-Smirnov

D	P-Value
0,460	< 2,2e-16

Berdasarkan Tabel 4.34 diketahui bahwa p-value yang dihasilkan dengan menggunakan statistik Kolmogorov-Smirnov bernilai kurang dari 5%. Hal ini berarti bahwa tolak  $H_0$  dan menunjukkan residual tidak berdistribusi Normal  $(0, \sigma^2)$ . Residual yang dihasilkan tidak berdistribusi normal karena memiliki nilai kurtosis yang sangat tinggi yaitu sebesar 10,2095 yang disajikan pada Gambar 4.33 sebagai berikut.



Gambar 4.33 *Graphycal Summary* dari Residual Model FILSTAR

Hasil dari cek diagnosa pada residual model FILSTAR menunjukkan bahwa residual memenuhi asumsi White noise akan tetapi tidak berdistribusi normal karena memiliki nilai kurtosis yang sangat besar. Adapun hasil dari pemodelan FILSTAR menghasilkan peramalan sebagai berikut.

Tabel 4.35 Hasil Ramalan Model FILSTAR

Data ke-	Ramalan
2549	5,10E-04
2550	-1,66E-05
2551	5,39E-07
2552	-1,76E-08
...	...
2588	-5,09E-62
2589	1,66E-63
2590	-5,40E-65
<b>MSE</b>	<b>0,04%</b>
<b>RMSE</b>	<b>2,01%</b>

Berdasarkan pada hasil ramalan di Tabel 4.35 terlihat bahwa hasil ramalan memiliki nilai kebaikan model untuk MSE sebesar 0,04% dan RMSE sebesar 2,01%.

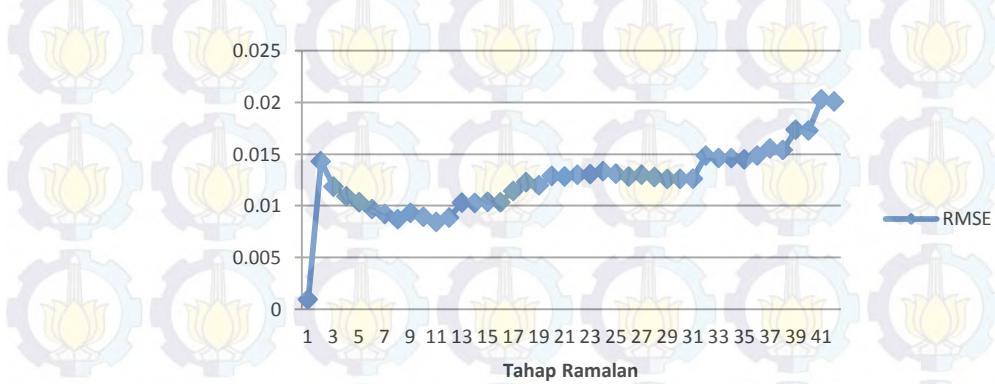
Berdasarkan hasil pembahasan tentang peramalan model ARFIMA (1,0,098,1), LSTAR dan FILSTAR didapatkan perbandingan sebagai berikut.

Tabel 4.36 Perbandingan Antara Model ARFIMA, LSTAR dan FILSTAR

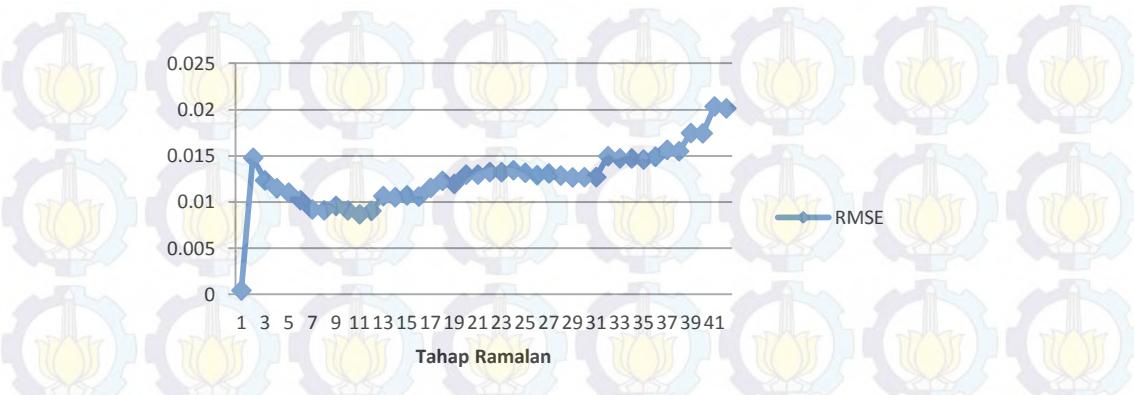
Model	Kriteria Kebaikan Model		Asumsi	
	MSE	RMSE		
ARFIMA (1,0.098,1)	0,04%	2,01%	Tidak White Noise	Tidak Berdistribusi Normal
LSTAR	0,04%	2,01%	Tidak White Noise	Tidak Berdistribusi Normal
FILSTAR	0,04%	2,01%	Tidak White Noise	Tidak Berdistribusi Normal

Berdasarkan Tabel 4.36 diketahui bahwa ketiga model tersebut memenuhi asumsi tidak White noise dan juga tidak memenuhi asumsi distribusi normal. Hal ini karena kurtosis dari ketiga model tersebut terlalu besar yaitu melebihi angka 10. Berdasarkan kriteria kebaikan model untuk ARFIMA memiliki MSE dan RMSE sebesar 0,0403620824296719% dan 2,00903166798515%, sedangkan untuk model LSTAR memiliki nilai MSE dan RMSE sebesar 0,0404979400928936% dan 2,01241000029551%, untuk model FILSTAR memiliki nilai MSE dan RMSE sebesar 0,040466898593286% dan 2,01163860057631%. Dari hasil tersebut, model terbaik yang digunakan untuk data return saham Bank Negara Indonesia adalah model ARFIMA (1,0.098,1) karena memiliki nilai MSE dan RMSE terkecil, selain itu parameter dari model ARFIMA (1,0.098,1) semuanya signifikan terhadap model.

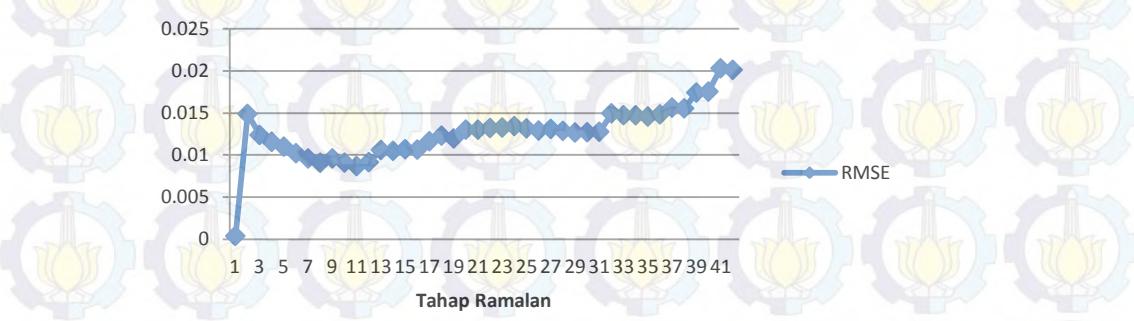
Berikut ditampilkan pula hasil RMSE per tahap mulai dari peramalan untuk satu periode ke depan hingga 42 periode ke depan.



Gambar 4.34 RMSE per Tahap pada Model ARFIMA



Gambar 4.35 RMSE per Tahap pada Model LSTAR

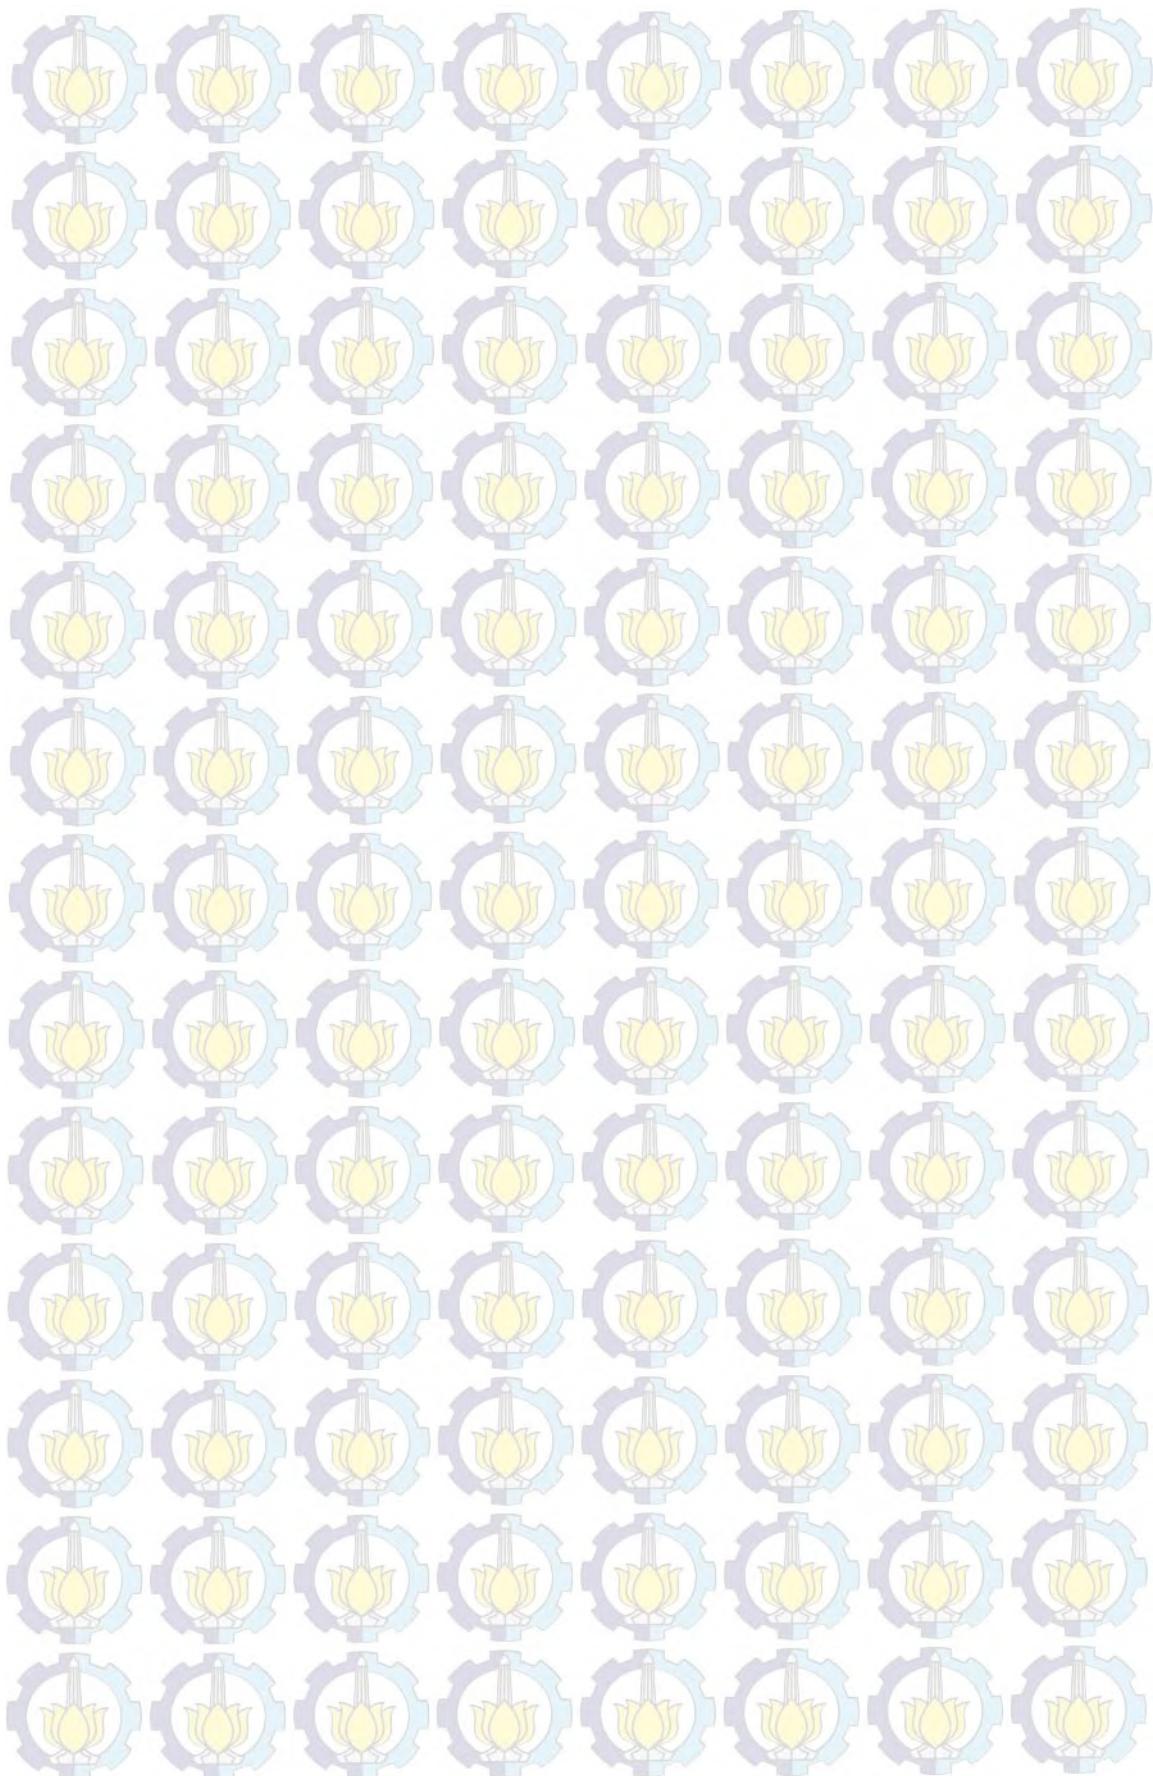


Gambar 4.36 RMSE per Tahap pada Model FILSTAR

Berdasarkan Gambar 4.34, Gambar 4.35 dan Gambar 4.36 terlihat bahwa semakin banyak periode yang diramalkan maka hasil RMSE akan semakin besar. Hasil ramalan pada data return saham Bank Negara Indonesia yang terbaik adalah ramalan pada satu periode ke depan, hal ini terlihat dari nilai RMSE pada model ARFIMA, LSTAR maupun FILSTAR yang mendekati nilai 0.

Hasil dari penerapan terhadap return saham Bank Negara Indonesia sesuai dengan hasil dari simulasi yang telah dibahas sebelumnya. Model terbaik yang didapatkan adalah model yang mengikuti proses long memory yaitu ARFIMA (1,0.098,1), padahal ketika dilakukan pengujian data tersebut memiliki fenomena nonlinier long memory. Dalam hal ini telah terjadi kesalahan deteksi pada pengujian awal karena terdapat 30 outlier pada data return saham Bank Negara Indonesia dan sebagian besar outlier tersebut merupakan outlier *additive*. Sehingga hal ini mendukung hasil simulasi sebelumnya yaitu jika data yang mengikuti proses linier long memory (ARFIMA) ditambahkan dengan outlier *additive*, uji Terasvirta da uji White tidak robust lagi digunakan untuk mendekripsi

kelinieran dari data bangkitan yang mengikuti proses ARFIMA karena dapat mempengaruhi kesimpulan dari deteksi sebelumnya yaitu linier long memory menjadi nonlinier long memory.



## BAB 5

### KESIMPULAN DAN SARAN

#### 5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, berikut beberapa kesimpulan yang diperoleh adalah sebagai berikut.

1. Hasil dari simulasi yang telah dilakukan pada data bangkitan yang mengikuti proses linier short memory (ARIMA), linier long memory (ARFIMA), nonlinier short memory (LSTAR) dan nonlinier long memory (FILSTAR) adalah sebagai berikut.
  - Uji terasvirta dan uji white mampu mendeteksi kelinieran data yang mengikuti proses ARIMA dan ARFIMA tanpa outlier pada semua parameter yang ditentukan baik untuk sampel kecil maupun sampel besar. Sedangkan untuk data yang mengikuti proses LSTAR dan FILSTAR tanpa adanya outlier, uji terasvirta dan uji white robust digunakan ketika parameter  $\gamma = 5$  dan  $10$  dengan  $\alpha_1$  dan  $\alpha_2 = 0,8$  dan  $-0,8$  untuk sampel kecil, sedangkan untuk sampel besar robust digunakan ketika  $\gamma = 0,5, 5$  dan  $10$  dengan  $\alpha_1$  dan  $\alpha_2 = 0,5$  dan  $-0,5, 0,8$  dan  $-0,8$ . Pada model FILSTAR hal itu berlaku untuk semua  $d$  yang ditentukan.
  - Adanya efek outlier dapat mempengaruhi power dari uji terasvirta dan uji white sehingga mempengaruhi kesimpulan dari deteksi saat data tanpa outlier. Data bangkitan yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR dapat berubah sifat yang semula linier menjadi nonlinier, yang semula nonlinier dapat berubah menjadi linier.
  - Uji GPH estimator mampu mendeteksi data yang mengikuti proses ARIMA tanpa outlier saat  $\phi = -0,2, -0,5$  dan  $-0,8$ , sedangkan pada data yang mengikuti proses ARFIMA, LSTAR dan FILSTAR tanpa outlier uji GPH estimator robust digunakan pada semua parameter yang ditentukan baik untuk sampel kecil maupun sampel besar.
  - Efek outlier dapat mempengaruhi power dari uji GPH estimator sehingga mempengaruhi kesimpulan dari deteksi saat data tanpa outlier. Data

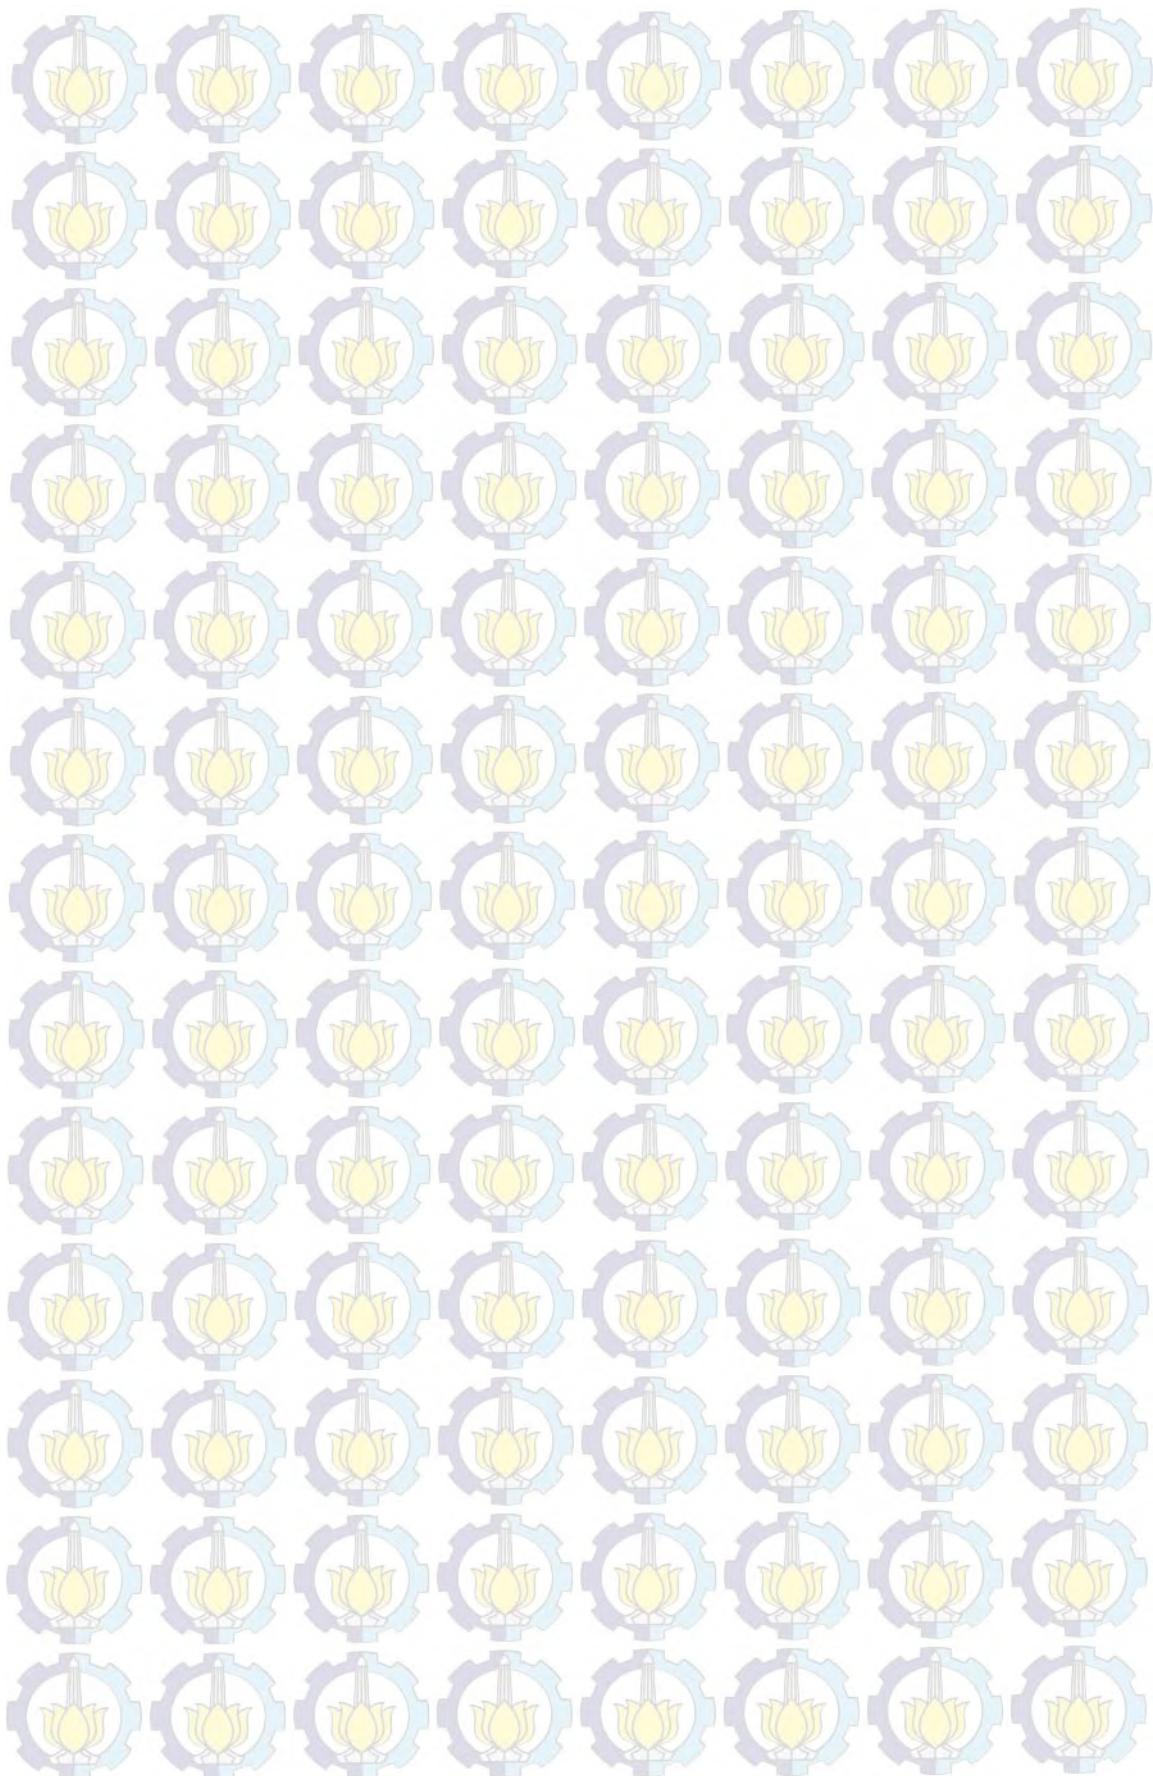
bangkitan yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR dapat berubah sifat yang semula short memory menjadi long memory, yang semula long memory dapat berubah menjadi short memory.

- Hasil simulasi menunjukkan bahwa untuk mendeteksi kelinieran data bangkitan yang mengikuti proses ARIMA, ARFIMA, LSTAR dan FILSTAR lebih robust menggunakan uji white daripada uji terasvirta. Hal ini terlihat dari power uji white yang lebih tinggi jika dibandingkan dengan power uji terasvirta pada semua parameter yang digunakan.
2. Pemodelan dari data *return* saham Bank Negara Indonesia didapatkan bahwa model ARFIMA lebih baik dalam *fitting model* daripada model LSTAR dan FILSTAR karena parameter dari model ARFIMA signifikan semua dalam model, sedangkan parameter pada model LSTAR dan FILSTAR tidak signifikan di dalam model. Begitu pula ketika dilakukan *forecasting* 42 tahap ke depan, hasilnya sama-sama menunjukkan bahwa model ARFIMA memberikan hasil *forecast* yang lebih baik dan akurat dari pada LSTAR dan FILSTAR dengan nilai MSE dan RMSE sebesar 2,01% dan 0,04%. Hasil dari penerapan terhadap return saham Bank Negara Indonesia sesuai dengan hasil dari simulasi yang telah dibahas sebelumnya yaitu jika data yang mengikuti proses linier long memory (ARFIMA) ditambahkan dengan outlier additive, uji terasvirta da uji white tidak robust lagi digunakan untuk mendeteksi kelinieran dari data bangkitan yang mengikuti proses ARFIMA karena dapat mempengaruhi kesimpulan dari deteksi sebelumnya yaitu linier long memory menjadi nonlinier long memory.

## 5.2 Saran

Berdasarkan kesimpulan yang diperoleh, dapat disarankan sebaiknya menggunakan uji white untuk mendeteksi kelinieran dari suatu data yang mengikuti proses *time series* karena sudah terbukti dari hasil simulasi bahwa uji white memiliki power yang lebih tinggi dari uji terasvirta. Pada penelitian selanjutnya disarankan agar menggunakan uji lain untuk menguji kelinieritasan dari data serta menggunakan uji selain uji GPH estimator untuk menguji proses

long memory. Selain itu, pada penelitian selanjutnya juga disarankan agar menggunakan contoh penerapan yang lebih banyak lagi.



## DAFTAR PUSTAKA

- Aranda, R., & Jaramillo, P. (2008). *Nonlinier Dynamic in The Chilean Stock Market: Evidence From Returns and Trading Volume*. Chile: Central Bank of Chile Working Papers.
- Barkoulas, J. T., Baum, C. F., & Travlos, N. (2000). Long Memory in The Greek Stock Market. *Applied Financial in Economics* 10(2), 177-184.
- Barnett, W., Gallant, A., Hinnich, M., Jungeilges, J., Aplan, D., & Jensen, M. (1997). A Single-Blind Controlled Competition Among Tests for nonlinierty and Chaos. *Journal of Econometrics* (82), 157-192.
- Benamar, A. (2009). A FI-STAR Approach to The Purchasing Power Parity in the North African Countries. *Journal of International Business Research*, Vol. 2, No. 3, 136-147.
- Boutahar, M., Mootamri, I., & Peguin-Feissolle, A. (2007). *An Exponential FISTAR Model Applied to The US Real Effective Exchange Rate*. Marseille: Groupement de Recherche en Economie.
- Box, G.E.P. and Jenkins, G.M. (1970). Time Series Analysis, Forecasting and Control, Holden-day, San Fransisco.
- Brock, W., Dechert, W., Scheinkman, J., & LeBaron, B. (1996). A Test for Independence Based on The Correlation Dimension. *Econometric Reviews* (15) , 197-235.
- Caporale, G. M., & Gil-Alana, L. A. (2010). Long Memory and Fractional Integration. *Discussion Papers of DIW Berlin are indexed in RePEc and SSRN* .
- Cheung, Y. and K. Lai, 1995, A Search for Long Memory in International Stock Market Returns, *Journal of International Money and Finance* 14, 597-615.
- Chu, P. K. K. (2001). Using BDS Statistics to Detect Nonlinearity in Time Series. Conference Paper, University of Macau. Online. ([http://umir.umac.mo/jspui/handle/123456789/13015?mode=full&submit\\_simple>Show+full+item+record](http://umir.umac.mo/jspui/handle/123456789/13015?mode=full&submit_simple>Show+full+item+record))

- [http://umir.umac.mo/jspui/handle/123456789/13015?mode=full&submit\\_si mple>Show+full+item+record](http://umir.umac.mo/jspui/handle/123456789/13015?mode=full&submit_si mple>Show+full+item+record), diakses Selasa, 30 Juli 2014, pukul 11:50 WIB).
- Cont, R. (2005). *Long Range Dependence in Financial Markets*. France: Centre de Math'ematiques appliqu'ees, Ecole Polytechnique.
- Crato, N., 1994, Some International Evidence Regarding The Stochastic Behavior of Stock Returns, *Applied Financial Economics* 4, 33-39.
- Crato, N. (1994). Some International Evidence Regarding The Stochastic Behavior. *Applied Financial Economics* 4, 33-39.
- Crato, N., & Ray, B. (2000). Memory in Returns and Volatilities of Futures' Contracts. *The Journal of Futures Market* 20(6), 525-543.
- Danilenko, S. (2009). Long-Term Memory Effect in Stock Prices Analysis. *Journal of Economics and Management*, 151-155.
- Diebold, F., & Inoue, C. (2001). Long Memory and Regime Switching. *Journal of Econometrics*, 105(1), 131-159.
- Ding, Z., Granger, W., & Engle, R. F. (1993). A Long Memory Property of Stock Market Returns and A New Model. *Journal of Empirical Finance* 1, 83-106.
- Eitelman, P. S., & Vitanza, J. T. (2008). *International Finance Discussion Papers No. 956*.
- Fama, E., & French, K. (1988). Permanent and Temporary Components of Stock Prices. *Journal of Political Economy* 96(2), 246-273.
- Geweke, J., & Hudak, S. P. (1983). The Estimation and Application of Long Memory Time Series Models. *Journal of Time series Analysis* 4, 221-237.
- Goodwin, P. (2009). New Evidence on the Value of Combining Forecasts. *Winter Issue 12*, 33-35.
- Gujarati, D. (2003). *Basic Econometric, 4th edition*. New York: McGraw Hill.
- Hinich, M. J., & Patterson, D. M. (1985). Evidence of Nonlinierty in Daily Stock Returns. *Journal of Business and Economic Statistics* No. 3, 69-77.
- Hosking, J. (1981). Fractional Differencing. *Biometrika* 68(1), 165-176.

- Isfan, M., Mendes, D. A., & Menezes, R. (2007). *Forecasting Financial Time Series By Using Artificial Neural Network*. Portugal: Department of Statistical Methodology, INE, Avenida António José de Almeida.
- Kapetanios, G., Labhard, V., & Price, S. (2005). Forecasting Using Bayesian and Information Theoretic Model Averaging: an Application to UK Inflation. *Working Paper No. 268. United Kingdom: Bank of England*.
- Kuswanto, H., & Sibbertsen, P. (2007). Can we distinguish between common nonlinear time series distinguish between common nonlinear time series. *Discussion Paper no. 178, Leibniz Hannover University, Germany* .
- Kuswanto, H., & Sibertsen, P. (2011). A New Test Against Spurious Long Memory Using Temporal Aggregation. *Journal of Statistical Computation and Simulation*, i-first Published on 17 January 2011, DOI:10.1080/00949655.2010.483231.
- Kuswanto, H., & Sibertsen, P. (2008). A Study on purious Long Memory in Nonlinier Time Series Models. *Applied Mathematical Science*, 2(55), 2713-2734.
- Lee, T.-H., White, H. and Granger, C.W.J. (1993). "Testing for Neglected Nonlinearity in Time Series Models: A Comparison of Neural Networks Methods and Alternative Test", *Journal of Econometrics*, 56, 269-290.
- Liu, M. (2000). Modelling long Memory in Stock Market Volatility. *Journal of Econometrics* 99, 139-171.
- Lo, A. (1991). Long-Term Memory in Stock Market Prices. *Journal of Econometrics* 59, 1279-1313.
- Makridakis, S. & M. Hibdon, (2000). "The M3-Competition : Result, Conclusion and Implication". *International Journal of Forecasting* 16(1) : 451–476.
- Schmidt-Mohr, U. (1996). *Volatility Forecasting with Nonlinear and Linear Time Series Models: A Comparison*. Bleichstr: LGT Asset Managemen.
- Sewell, M. (2011). *Characterization of Financial Time Series*. Ucl Department Of Science.

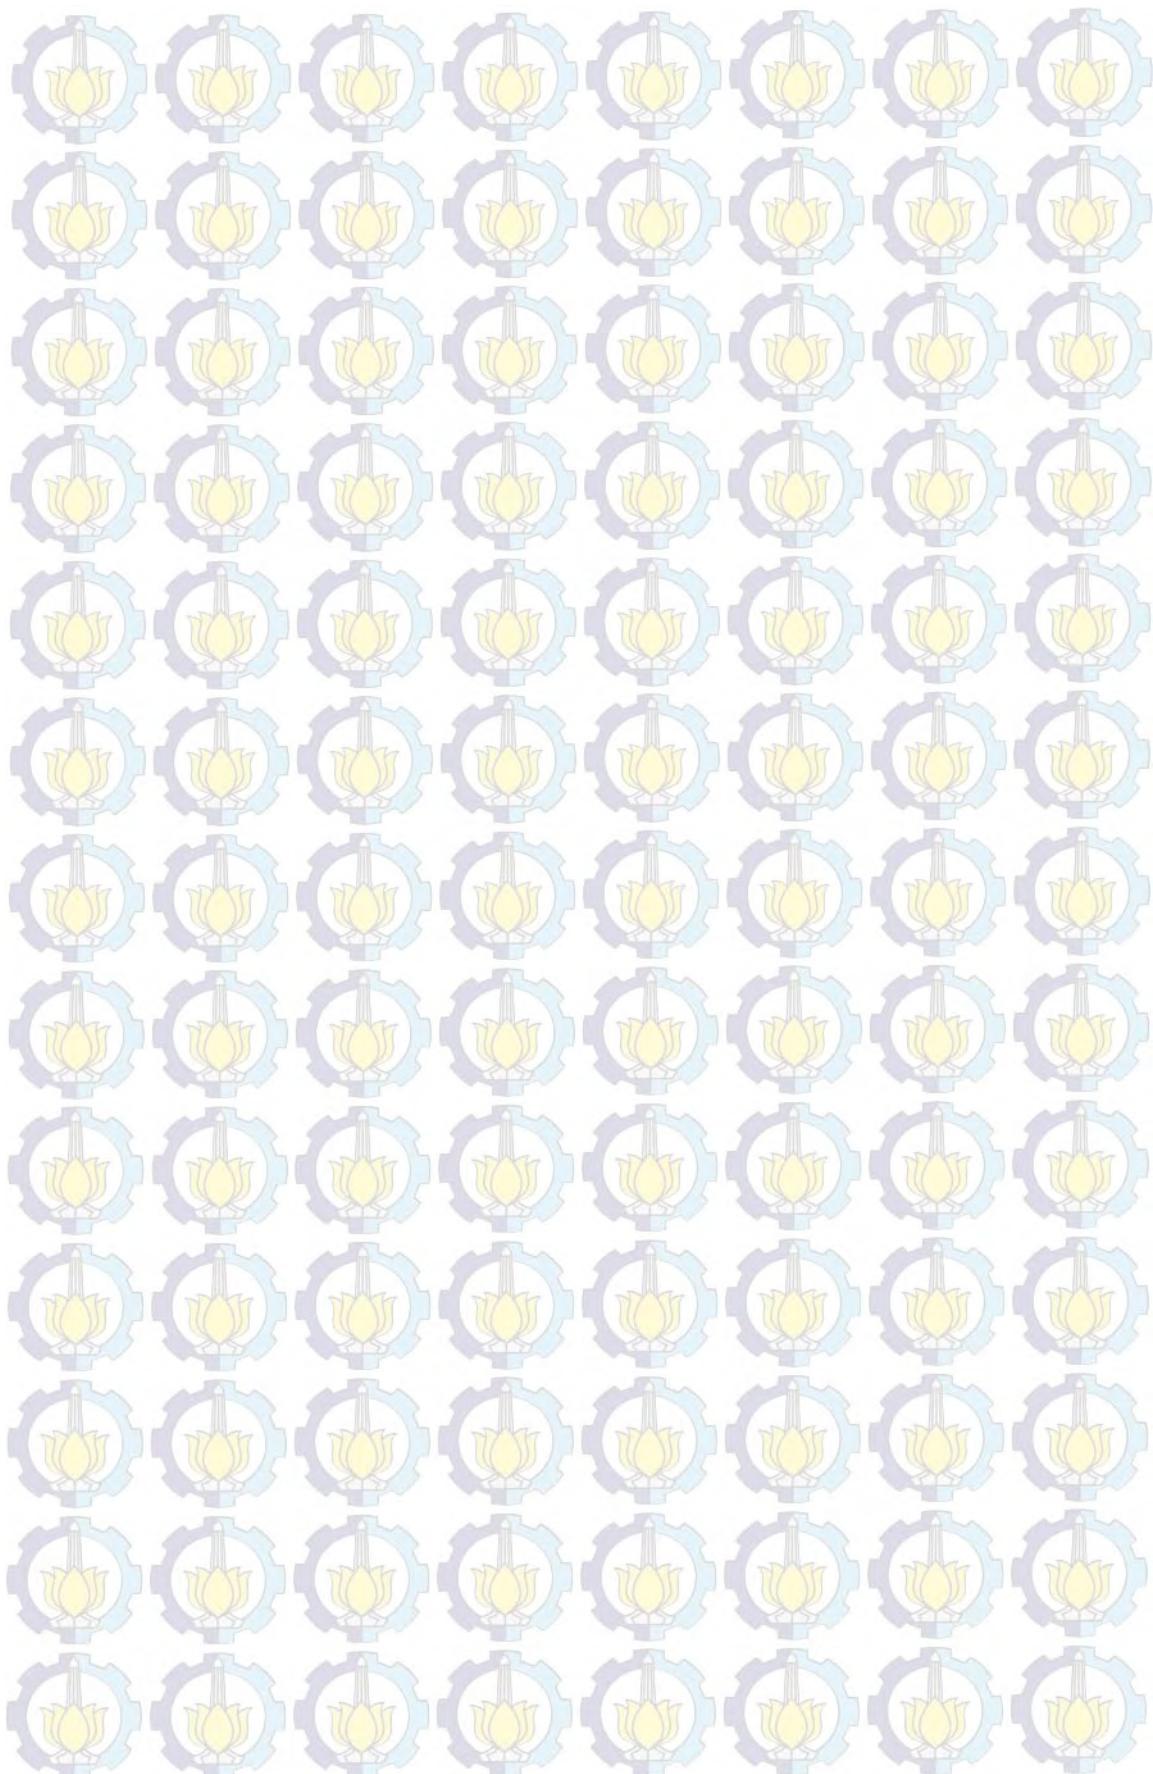
- Shittu, O. I., & Yaya, O. S. (2010). On fractionally integrated logistic smooth transitions in time series. *American Journal Of Scientific And Industrial Research* 1(3), 439-447.
- Smallwood, A. D. (2008). Measuring the persistence of deviations from purchasing power parity with a fractionally integrated STAR model. *Journal of International Money and Finance* 27, 1161-1176.
- Stensholt, B.K. and Tjostheim, D. (1987). "Multiple Bilinear Time Series Models", *Journal of Time Series Analysis*, 8, 221-233.
- Suhartono. (2008). New Procedures for Model Selection in Feedforward Neural Networks for Time Series Forecasting. *Jurnal Ilmu Dasar*, Vol. 9 No. 2, 104-113.
- Terasvirta, T., Lin, C.-F. dan Granger, C. W. J. (1993). Power of the Neural Networks Linearity Test,. *Journal of Time Series Analysis*, 14, 159-171.
- Tjostheim, D. (1986). "Some Doubly Stochastic Time Series Models", *Journal of Time Series Analysis*, 7, 51-72.
- Wei, W. W. S. (2006). *Time Series Analysis Second Edition: Univariate and Multivariate Methods* (2<sup>nd</sup> eds). New York, United States of America: Pearson Education.
- Wojtowicz, T., & Gurgul, H. (2009). *Long Memory of Volatility Measures in Time Series*. Poland: Department of Economics and Econometrics, Faculty of Management, University of Science and Technology.
- Zivot, E., & Wang, J. (2006). *Modelling Financial Time Series Models with S-plus*. New York: Springer.

## BIOGRAFI PENULIS



Puspita Kartikasari (penulis) yang akrab dipanggil Puspita lahir di kabupaten Jombang pada tanggal 21 Mei 1991, merupakan putri bungsu dari dua bersaudara pasangan Imam Subagjo dan Dwi Krisnaningati. Penulis telah menempuh pendidikan formal di TK Pertiwi I Jombang (1996-1997), SDN Jombatan III Jombang (1997-2003), SMPN 2 Jombang (2003-2006), SMAN 2 Jombang (2006-2009) dan S1 Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan

Alam Institut Teknologi Sepuluh Nopember (ITS) (2009-2013). Pada tahun ajaran 2013/2014 semester ganjil, penulis melanjutkan pendidikan S2 di Jurusan Statistika, FMIPA, ITS. Dengan penuh kerendahan hati, penulis mengharapkan saran dan kritik yang membangun dari para pembaca. Bagi pembaca yang memiliki saran, kritik atau ingin berdiskusi dengan penulis dapat disampaikan melalui *e-mail* [puspitakartikasari21@gmail.com](mailto:puspitakartikasari21@gmail.com).



## LAMPIRAN

### Lampiran 1 Sintaks Program R untuk Data Bangkitan ARIMA tanpa Outlier

```
arima <- function(alpha, N)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    ts.sim <- arima.sim(list(order = c(1,0,0), ar = 0.2), n = 1000)
    data <- as.ts(ts.sim)
    test1 <- terasvirta.test(data)
    pval1[i] <- test1$p.value
    test2 <- white.test(data)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[i] <- test3[1]
  }

  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)

  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(data)
  par(mfrow=c(1,2))
  acf(data, ylim=c(-1,1))
  pacf(data, ylim=c(-1,1))

  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH,
  mean_d=d_mean)
}
library(tseries)
library(fracdiff)
arima(0.05, 1000)
```

Lampiran 2 Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek  
*Additive Outlier*

```
arima <- function(alpha, N)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
#pval4 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    ts.sim <- arima.sim(list(order = c(1,0,0), ar = -0.8), n = 1000)
    x <- as.ts(ts.sim)
    x1 <- x
    x1[250] <- x[250] + 10
    x1[500] <- x[500] + 13
    x1[650] <- x[650] + 15
    x1[750] <- x[750] + 17
    x1 <- as.ts(x1)
    test1 <- terasvirta.test(x1)
    pval1[i] <- test1$p.value
    test2 <- white.test(x1)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(x1,0.8)
    pval3[i] <- test3[1]
  }

  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)

  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(x1)

  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH,
       mean_d=d_mean)
}
library(tseries)
library(fracdiff)
arima(0.05, 1000)
```

## Lampiran 3 Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek *Innovational Outlier*

```
arima <- function(alpha, N)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  n <- 1000
  phi <- 0.9
  x <- runif(n, -1, 1)
  e <- rnorm(n, sd=0.5)
  x[1] <- 0.0
  e[501] <- 40
  for(j in (2:n)) {
    x[j] <- phi*x[j-1] + e[j]
  }
  x4 <- x
  obs <- x[501:550]
  list(series=x4,obs=obs)
  for(i in 1:N)
  {
    obs1 <- obs
    ts.sim <- arima.sim(list(order = c(1,0,0), ar = 0.2), n = 1000)
    data <- as.ts(ts.sim)
    data[501:550] = obs1
    data = data
    test1 <- terasvirta.test(data)
    pval1[i] <- test1$p.value
    test2 <- white.test(data)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[i] <- test3[1]
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(data)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
library(tseries)
library(fracdiff)
arima(0.05, 1000)
```

Lampiran 4 Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek Outlier *Level Shift*

```
arima <- function(alpha, N)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    ts.sim <- arima.sim(list(order = c(1,0,0), ar = 0.8), n = 1000)
    x <- as.ts(ts.sim)
    omega <- 20
    delta <- 1
    t1 <- 201:250
    t2 <- 501:600
    efek1 <- omega*(delta^(t1-201))
    efek2 <- omega*(delta^(t2-501))
    x2 <- x
    x2[t1] <- x[t1] + efek1
    x2[t2] <- x[t2] + efek2
    x2 <- as.ts(x2)
    test1 <- terasvirta.test(x2)
    pval1[i] <- test1$p.value
    test2 <- white.test(x2)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(x2,0.8)
    pval3[i] <- test3[1]
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(x2)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH,
       d=d_mean)
}
library(tseries)
library(fracdiff)
arima(0.05, 1000)
```

Lampiran 5 Sintaks Program R untuk Data Bangkitan ARIMA dengan Efek Outlier *Temporary Change*

```
arima <- function(alpha, N)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    ts.sim <- arima.sim(list(order = c(1,0,0), ar = 0.8), n = 1000)
    x <- as.ts(ts.sim)
    omega <- 20
    delta <- 0.5
    t1 <- 201:250
    efek <- omega*(delta^(t1-201))
    x3 <- x
    x3[t1] <- x[t1] + efek
    x3 <- as.ts(x3)
    test1 <- terasvirta.test(x3)
    pval1[i] <- test1$p.value
    test2 <- white.test(x3)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(x3,0.8)
    pval3[i] <- test3[1]
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(x3)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH,
       mean_d=d_mean)
}
library(tseries)
library(fracdiff)
arima(0.05, 1000)
```

Lampiran 6 Sintaks Program R untuk Data Bangkitan ARFIMA tanpa Outlier

```
library(arfima)
library(ltsa)
library(parallel)
arfima <- function(alpha, N, dd)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    ts.sim <- arfima.sim(1000, model = list(phi = -0.2, dfrac = dd))
    data <- as.ts(ts.sim)
    test1 <- terasvirta.test(data)
    pval1[i] <- test1$p.value
    test2 <- white.test(data)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[i] <- test3[1]
  }
  pval1 = pval1
  pval2 = pval2
  pval3 = pval3

  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)

  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N

  list(pval1, pval2, pval3, d_mean, terasvirta=terasvirta, white=white, GPH=GPH,
       d=d_mean)
}
library(tseries)
library(fracdiff)
arfima(0.05, 1000, 0.2)
```

## Lampiran 7 Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek

### Additive Outlier

```
arfima <- function(alpha, N, dd)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    ts.sim <- arfima.sim(1000, model = list(phi = 0.2, dfrac = dd))
    x <- as.ts(ts.sim)
    x1 <- x
    x1[250] <- x[250] + 10
    x1[500] <- x[500] + 13
    x1[650] <- x[650] + 15
    x1[750] <- x[750] + 17
    x1 <- as.ts(x1)
    test1 <- terasvirta.test(x1)
    pval1[i] <- test1$p.value
    test2 <- white.test(x1)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(x1,0.8)
    pval3[i] <- test3[1]
  }
  pval1 = pval1
  pval2 = pval2
  pval3 = pval3
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(x1)
  list(terasvirta=terasvirta, white=white, GPH=GPH, d=d_mean)
}
library(tseries)
library(fracdiff)
arfima(0.05, 10, 0.2)
```

Lampiran 8 Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek  
*Innovational Outlier*

```

arfima <- function(alpha, N, dd)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  n <- 1000
  phi <- -0.8
  x <- runif(n, -1, 1)
  e <- rnorm(n, sd=0.5)
  x[1] <- 0.0
  e[501] <- 20
  for(j in (2:n)) {
    x[j] <- phi*x[j-1] + e[j]
  }
  x4 <- x
  obs <- x[501:550]
  list(series=x4,obs=obs)
  for(i in 1:N)
  {
    obs1 <- obs
    ts.sim <- arfima.sim(1000, model = list(phi = -0.8, dfrac = dd))
    data <- as.ts(ts.sim)
    data[501:550]= obs1
    data = data
    test1 <- terasvirta.test(data)
    pval1[i] <- test1$p.value
    test2 <- white.test(data)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[i] <- test3[1]
  }
  pval1 = pval1
  pval2 = pval2
  pval3 = pval3
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(data)
  list(pval1, pval2, pval3, d_mean, terasvirta=terasvirta, white=white, GPH=GPH, d=d_mean)
}
library(tseries)
library(fracdiff)
arfima(0.05, 1000, 0.2)

```

## Lampiran 9 Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek

### Outlier Level Shift

```
arfima <- function(alpha, N, dd)
{
  pval1 <- matrix(nrow=N, ncol=1)
  pval2 <- matrix(nrow=N, ncol=1)
  pval3 <- matrix(nrow=N, ncol=1)
  for(i in 1:N)
  {
    omega <- 20
    delta <- 1
    ts.sim <- arfima.sim(1000, model = list(phi = 0.2, dfrac = dd))
    x <- as.ts(ts.sim)
    t1 <- 201:250
    t2 <- 501:600
    efek1 <- omega*(delta^(t1-201))
    efek2 <- omega*(delta^(t2-501))
    x2 <- x
    x2[t1] <- x[t1] + efek1
    x2[t2] <- x[t2] + efek2
    x2 <- as.ts(x2)
    test1 <- terasvirta.test(x2)
    pval1[i] <- test1$p.value
    test2 <- white.test(x2)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(x2, 0.8)
    pval3[i] <- test3[1]
  }
  pval1 = pval1
  pval2 = pval2
  pval3 = pval3
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(x2)
  list( terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
arfima(0.05, 10, 0.2)
```

Lampiran 10 Sintaks Program R untuk Data Bangkitan ARFIMA dengan Efek Outlier *Temporary Change*

```

arfima <- function(alpha, N, dd)
{
  pval1 <- matrix(nrow=N,ncol=1)
  pval2 <- matrix(nrow=N,ncol=1)
  pval3 <- matrix(nrow=N,ncol=1)
  for(i in 1:N)
  {
    omega <- 20
    delta <- 0.5
    ts.sim <- arfima.sim(1000, model = list(phi = -0.8, dfrac = dd))
    x <- as.ts(ts.sim)
    t1 <- 201:250
    efek <- omega*(delta^(t1-201))
    x3 <- x
    x3[t1] <- x[t1] + efek
    x3 <- as.ts(x3)
    test1 <- terasvirta.test(x3)
    pval1[i] <- test1$p.value
    test2 <- white.test(x3)
    pval2[i] <- test2$p.value
    test3 <- fdGPH(x3,0.8)
    pval3[i] <- test3$d
  }
  pval10=na.omit(pval1)
  N1 = length(pval1)
  pval20=na.omit(pval2)
  N2 = length(pval2)
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  #power4 <- which(pval4 >= alpha)
  pval3 <- as.numeric(pval3)
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/N
  white <- length(power2)/N
  GPH <- (power3)/N
  ts.plot(x3)
  list(terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
arfima(0.05, 1000, 0.2)

```

Lampiran 11 Sintaks Program R untuk Data Bangkitan LSTAR tanpa Outlier

```

lstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- rnorm(N,0,1)
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data<- lstar.ser[201:N]
    data <- as.ts(data)
    test1 <- terasvirta.test(data)
    pval1[j] <- test1$p.value
    test2 <- white.test(data)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH,
       mean_d=d_mean)
}
library(tseries)
library(fracdiff)
lstar(0.05,25,-0.9,0.9,0,1200,100,1000,10)

```

## Lampiran 12 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek

### Additive Outlier

```
lstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- rnorm(N,0,1)
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta))))))+(alpha2*lstar.ser[n-1])+eps[n]
    }
    data <- lstar.ser[201:N]
    x <- as.ts(data)
    x1 <- x
    x1[250] <- x[250] + 10
    x1[500] <- x[500] + 13
    x1[650] <- x[650] + 15
    x1[750] <- x[750] + 17
    x1 <- as.ts(x1)
    test1 <- terasvirta.test(x1)
    pval1[j] <- test1$p.value
    test2 <- white.test(x1)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(x1,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(x1)
  list(terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
lstar(0.05,0.5,0.2,0.2,0,1200,100,1000,1000)
```

## Lampiran 13 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek

### *Innovational Outlier*

```

lstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  n <- 1000
  phi <- 0.8
  x <- runif(n, -1, 1)
  e <- rnorm(n, sd=0.5)
  x[1] <- 0.0
  e[501] <- 20
  for(j in (2:n)) {
    x[j] <- phi*x[j-1] + e[j]
  }
  x4 <- x
  obs <- x[501:550]
  list(series=x4,obs=obs)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    obs1 <- obs
    eps <- rnorm(N,0,1)
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data<- lstar.ser[201:N]
    data <- as.ts(data)
    data[501:550]= obs1
    data = data
    test1 <- terasvirta.test(data)
    pval1[j] <- test1$p.value
    test2 <- white.test(data)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(data)
  list(terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
lstar(0.05,0.5,0.8,-0.8,0,1200,100,1000,1000)

```

Lampiran 14 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek Outlier *Level Shift*

```

lstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- rnorm(N,0,1)
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n]
    }
    data <- lstar.ser[201:N]
    x <- as.ts(data)
    omega <- 20
    delta <- 1
    t1 <- 201:250
    t2 <- 501:600
    efek1 <- omega*(delta^(t1-201))
    efek2 <- omega*(delta^(t2-501))
    x2 <- x
    x2[t1] <- x[t1] + efek1
    x2[t2] <- x[t2] + efek2
    x2 <- as.ts(x2)
    test1 <- terasvirta.test(x2)
    pval1[j] <- test1$p.value
    test2 <- white.test(x2)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(x2,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(x2)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
library(tseries)
library(fracdiff)
lstar(0.05,0.5,0.2,-0.2,0,1200,100,1000,1000)

```

Lampiran 15 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek Outlier *Temporary Change*

```

lstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- rnorm(N,0,1)
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data <- lstar.ser[201:N]
    x <- as.ts(data)
    omega <- 20
    delta <- 0.5
    t1 <- 201:250
    efek <- omega*(delta^(t1-201))
    x3 <- x
    x3[t1] <- x[t1] + efek
    x3 <- as.ts(x3)
    test1 <- terasvirta.test(x3)
    pval1[j] <- test1$p.value
    test2 <- white.test(x3)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(x3,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(x3)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
library(tseries)
library(fracdiff)
lstar(0.05,0.5,0.2,-0.2,0,1200,100,1000,1000)

```

Lampiran 16 Sintaks Program R untuk Data Bangkitan FILSTAR tanpa Outlier

```

filstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k, dd)
{
  pval1 <- matrix(nrow=k, ncol=1)
  pval2 <- matrix(nrow=k, ncol=1)
  pval3 <- matrix(nrow=k, ncol=1)
  lstar <- matrix(nrow=N, ncol=m)
  lstar.ser <- matrix(nrow=N, ncol=1)
  for(j in 1:k)
  {
    eps <- arfima.sim(1200, model = list(phi = 0.01, dfrac = dd))
    lstar.ser[1] <- 0

    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta))))))+(alpha2*lstar.ser[n-1])+eps[n]
    }
    data<- lstar.ser[201:N]
    data <- as.ts(data)
    test1 <- terasvirta.test(data)
    pval1[j] <- test1$p.value
    test2 <- white.test(data)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH,
       mean_d=d_mean)
}
library(tseries)
library(fracdiff)
filstar(0.05,0.5,0.2,-0.2,0,1200,100,1000,1000,0.2)

```

Lampiran 17 Sintaks Program R untuk Data Bangkitan FILSTAR dengan Efek  
*Additive Outlier*

```

filstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k, dd)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- arfima.sim(1200, model = list(phi = 0.01, dfrac = dd))
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data <- lstar.ser[201:N]
    x <- as.ts(data)
    x1 <- x
    x1[250] <- x[250] + 10
    x1[500] <- x[500] + 13
    x1[650] <- x[650] + 15
    x1[750] <- x[750] + 17
    x1 <- as.ts(x1)
    test1 <- terasvirta.test(x1)
    pval1[j] <- test1$p.value
    test2 <- white.test(x1)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(x1,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(x1)
  list(terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
library(tseries)
library(fracdiff)
filstar(0.05,0.5,0.5,-0.5,0,1200,100,1000,1000,0.2)

```

Lampiran 18 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek  
*Innovational Outlier*

```

filstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k, dd)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  n <- 1000
  phi <- 0.2
  x <- runif(n, -1, 1)
  e <- rnorm(n, sd=0.5)
  x[1] <- 0.0
  e[501] <- 20
  for(j in (2:n)) {
    x[j] <- phi*x[j-1] + e[j]
  }
  x4 <- x
  obs <- x[501:550]
  list(series=x4,obs=obs)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    obs1 <- obs
    eps <- arfima.sim(1200, model = list(phi = 0.01, dfrac = dd))
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data<- lstar.ser[201:N]
    data <- as.ts(data)
    data[501:550]= obs1
    data = data
    test1 <- terasvirta.test(data)
    pval1[j] <- test1$p.value
    test2 <- white.test(data)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(data,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  list(terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
filstar(0.05,0.5,0.2,-0.2,0,1200,100,1000,1000,0.2)

```

## Lampiran 19 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek

### Outlier *Level Shift*

```

filstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k, dd)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- arfima.sim(1200, model = list(phi = 0.01, dfrac = dd))
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data <- lstar.ser[201:N]
    x <- as.ts(data)
    omega <- 20
    delta <- 1
    t1 <- 201:250
    t2 <- 501:600
    efek1 <- omega*(delta^(t1-201))
    efek2 <- omega*(delta^(t2-501))
    x2 <- x
    x2[t1] <- x[t1] + efek1
    x2[t2] <- x[t2] + efek2
    x2 <- as.ts(x2)
    test1 <- terasvirta.test(x2)
    pval1[j] <- test1$p.value
    test2 <- white.test(x2)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(x2,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(x2)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
library(tseries)
library(fracdiff)
filstar(0.05,0.5,0.2,-0.2,0,1200,100,1000,1000,0.2)

```

Lampiran 20 Sintaks Program R untuk Data Bangkitan LSTAR dengan Efek Outlier *Temporary Change*

```

filstar <- function(alpha, gamma, alpha1, alpha2, eta, N, m, series, k, dd)
{
  pval1 <- matrix(nrow=k,ncol=1)
  pval2 <- matrix(nrow=k,ncol=1)
  pval3 <- matrix(nrow=k,ncol=1)
  lstar <- matrix(nrow=N,ncol=m)
  lstar.ser <- matrix(nrow=N,ncol=1)
  for(j in 1:k)
  {
    eps <- arfima.sim(1200, model = list(phi = 0.01, dfrac = dd))
    lstar.ser[1] <- 0
    for(n in 2:N)
    {
      lstar.ser[n] <- (alpha1*lstar.ser[n-1]*(1-(1/(1+exp(-gamma*(lstar.ser[n-1]-eta)))))+(alpha2*lstar.ser[n-1])+eps[n])
    }
    data <- lstar.ser[201:N]
    x <- as.ts(data)
    omega <- 20
    delta <- 0.5
    t1 <- 201:250
    efek <- omega*(delta^(t1-201))
    x3 <- x
    x3[t1] <- x[t1] + efek
    x3 <- as.ts(x3)
    test1 <- terasvirta.test(x3)
    pval1[j] <- test1$p.value
    test2 <- white.test(x3)
    pval2[j] <- test2$p.value
    test3 <- fdGPH(x3,0.8)
    pval3[j] <- test3$d
  }
  power1 <- which(pval1 <= alpha)
  power2 <- which(pval2 <= alpha)
  power3a <- which(pval3 >= 0)
  power3b <- which(pval3 >= 1)
  power3 <- length(power3a)-length(power3b)
  pval3 <- pval3
  d_mean <- mean(pval3)
  terasvirta <- length(power1)/k
  white <- length(power2)/k
  GPH <- (power3)/k
  ts.plot(x3)
  list(pval1, pval2, pval3, terasvirta=terasvirta, white=white, GPH=GPH, mean_d=d_mean)
}
library(tseries)
library(fracdiff)
filstar(0.05,0.5,0.2,-0.2,0,1200,100,1000,1000,0.2)

```

Lampiran 21 Data *Return* Saham Bank Negara Indonesia

Tanggal	Saham BNI	Return Saham BNI
08/06/2004	1019,1	*
09/06/2004	1042,8	0,022989518
10/06/2004	1019,1	-0,022989518
11/06/2004	1019,1	0
14/06/2004	1019,1	0
15/06/2004	1019,1	0
16/06/2004	1019,1	0
17/06/2004	995,4	-0,023530497
18/06/2004	995,4	0
21/06/2004	995,4	0
...	...	...
...	...	...
...	...	...
14/11/2014	5875	0
18/11/2014	5800	-0,012848142
19/11/2014	5825	0,004301082
20/11/2014	5800	-0,004301082
21/11/2014	5775	-0,004319661
24/11/2014	5825	0,008620743
25/11/2014	5875	0,008547061
26/11/2014	5900	0,004246291
27/11/2014	6025	0,020965128
28/11/2014	6025	0

Lampiran 22 Pengujian Stasioneritas Data *Return* Saham Bank Negara Indonesia dengan Dickey Fuller Test dengan Software R versi 3.0.0

```
> data=read.table("D://BNI2.txt")
> y=data$V1[1:2505]
> library(tseries)
> adf.test(y)
    Augmented Dickey-Fuller Test
data: y
Dickey-Fuller = -11.1144, Lag order = 13, p-value = 0.01
alternative hypothesis: stationary

Warning message:
In adf.test(y) : p-value smaller than printed p-value
Lampiran 3 Jenis Outlier (R versi 3.0.0)
```

Lampiran 23 Pendekstrian Tipe Outlier Data Return Saham Bank Negara Indonesia dengan Dickey Fuller Test dengan Software R versi 3.0.0

```

Series: ts(data)
ARIMA(0,0,0) with zero mean
Coefficients:
AO296   AO551   AO562   AO563   AO564   AO575   AO593   AO687
AO696   -0.1146  0.1128  0.1502  0.1326 -0.1112  0.1032 -0.0953  0.1071
0.1164
s.e.    0.0229  0.0229  0.0229  0.0229  0.0229  0.0229  0.0229  0.0229
0.0229
AO874   TC998   AO1000  AO1034  AO1045  AO1047  AO1062
AO1070  -0.0930  0.1009 -0.0996 -0.1323 -0.2707 -0.1719  0.1790 -
0.1011
s.e.    0.0229  0.0175  0.0244  0.0229  0.0229  0.0229  0.0229
0.0229
AO1080  AO1082  AO1087  AO1091  AO1095  AO1161  TC1166  TC1177
AO1192  0.1322 -0.0935  0.0953  0.1823  0.1769  0.1448  0.0745  0.1005
0.1195
s.e.    0.0229  0.0229  0.0229  0.0229  0.0229  0.0229  0.0164  0.0164
0.0229
AO1204  AO1569  TC1570  AO1761
0.0931  0.1308 -0.0722 -0.1606
s.e.    0.0229  0.0229  0.0164  0.0229
sigma^2 estimated as 0.0005245: log likelihood=6007.13
AIC=-11952.27 AICc=-11951.48 BIC=-11771.13
Outliers:
  type  ind time  coefhat   tstat
1  AO   296  296 -0.11460 -5.004
2  AO   551  551  0.11280  4.925
3  AO   562  562  0.15015  6.556
4  AO   563  563  0.13263  5.791
5  AO   564  564 -0.11123 -4.857
6  AO   575  575  0.10319  4.506
7  AO   593  593 -0.09531 -4.162
8  AO   687  687  0.10705  4.674
9  AO   696  696  0.11641  5.083
10 AO   874  874 -0.09295 -4.059
11 TC   998  998  0.10092  5.780
12 AO  1000 1000 -0.09964 -4.076
13 AO  1034 1034 -0.13227 -5.775
14 AO  1045 1045 -0.27065 -11.818
15 AO  1047 1047 -0.17185 -7.504
16 AO  1062 1062  0.17905  7.818
17 AO  1070 1070 -0.10110 -4.414
18 AO  1080 1080  0.13217  5.771
19 AO  1082 1082 -0.09353 -4.084
20 AO  1087 1087  0.09531  4.162
21 AO  1091 1091  0.18232  7.961
22 AO  1095 1095  0.17693  7.726
23 AO  1161 1161  0.14483  6.324
24 TC  1166 1166  0.07452  4.555
25 TC  1177 1177  0.10047  6.142
26 AO  1192 1192  0.11953  5.219
27 AO  1204 1204  0.09308  4.064
28 AO  1569 1569  0.13079  5.711
29 TC  1570 1570 -0.07224 -4.417
30 AO  1761 1761 -0.16062 -7.013

```

#### Lampiran 24 Estimasi Model ARFIMA (R versi 3.0.0)

```
> data=read.table("D://BNI2.txt")
> a <- arfima(data$V1)
> summary(a)
Coefficients:
            Estimate Std. Error z value Pr(>|z|)
d      0.09777   0.01872  5.223 1.76e-07 ***
ar.arl 0.54883   0.02334 23.510 < 2e-16 ***
ma.mal 0.64145   0.02240 28.641 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
sigma[eps] = 0.02714428
[d.tol = 0.0001221, M = 100, h = 5.874e-05]
Log likelihood: 5574 ==> AIC = -11140.4 [4 deg.freedom]
```

#### Lampiran 25 Pengujian Residual Model ARFIMA (R versi 3.0.0):

- Pengujian *White Noise* dengan Statistik von Mises Residual Model ARFIMA (R versi 3.0.0):

```
> wn<-Box.test(resi, lag=36, type="Ljung-Box")
> wn
    Box-Ljung test
data: resi
X-squared = 79.4328, df = 36, p-value = 4.102e-05
```

- Pengujian Normalitas dengan Kolmogorov-Smirnov Residual Model ARFIMA (R versi 3.0.0):

```
> library(fBasics)
> ksnormTest(resi)
Title:
One-sample Kolmogorov-Smirnov test

Test Results:
STATISTIC:
D: 0.4601
P VALUE:
Alternative Two-Sided: < 2.2e-16
Alternative Less: < 2.2e-16
Alternative Greater: < 2.2e-16
Description:
Wed Jan 21 16:25:35 2015 by user: pusrita
```

#### Lampiran 26 Estimasi Parameter LSTAR (1) (R versi 3.0.0):

```
> library(mgcv)
> library(Matrix)
> library(lattice)
> library(snow)
> library(mnormt)
> library(foreach)
> library(iterators)
> library(codetools)
```

```

> library(MASS)
> library(nlme)
> library(tsDyn)
> library(tseries)
> data=read.table("D://BNI.txt")
> y=data$V1[1:2548]
> m=lstar(y,d=1,m=1,mL=1,mH=1,include="none")
> summary(m)

Non linear autoregressive model
LSTAR model
Coefficients:
Low regime:
  phiL.1
-0.07564369
High regime:
  phiH.1
0.09547743

Smoothing parameter: gamma = 39.08

Threshold
Variable: Z(t) = + (1) X(t)

Value: -0.06412

Residuals:
    Min      1Q  Median      3Q     Max 
-0.270544 -0.011876  0.000000  0.011474  0.177672 

Fit:
residuals variance = 0.0007365, AIC = -18372, MAPE = 99.92% 

Coefficient(s):
            Estimate Std. Error t value Pr(>|z|)    
phiL.1   -0.075644  0.081749 -0.9253  0.3548    
phiH.1    0.095477  0.085118  1.1217  0.2620    
gamma    39.076919 42.908624  0.9107  0.3625    
th      -0.064123  0.040268 -1.5924  0.1113    

Non-linearity test of full-order LSTAR model against full-order AR
model
F = 0.18691 ; p-value = 0.66553

Threshold
Variable: Z(t) = + (1) X(t)

```

### Lampiran 27 Pengujian Residual Model LSTAR:

- Pengujian *White Noise* dengan Statistik von Mises Residual Model LSTAR (R versi 3.0.0):

```

Box-Ljung test
data: resi
X-squared = 89.3438, df = 36, p-value = 1.987e-06

```

- Pengujian Normalitas dengan Kolmogorov-Smirnov Residual Model LSTAR (R versi 3.0.0):

```
> library(fBasics)
> ksnormTest(resi)
Title:
One-sample Kolmogorov-Smirnov test

Test Results:
STATISTIC:
D: 0.9984
P VALUE:
Alternative Two-Sided: < 2.2e-16
Alternative Less: < 2.2e-16
Alternative Greater: 1
```

Lampiran 28 Estimasi Parameter FILSTAR (1) (R versi 3.0.0):

```
> library(mgcv)
> library(Matrix)
> library(lattice)
> library(snow)
> library(mnrmmt)
> library(foreach)
> library(iterators)
> library(codetools)
> library(MASS)
> library(nlme)
> library(tsDyn)
> library(tseries)
> data=read.table("D://DatadiffBNI.txt")
> y=data$V1[1:2548]
> m=lstar(y,d=1,m=1,mL=1,mH=1,include="none")
> summary(m)

Non linear autoregressive model

LSTAR model
Coefficients:
Low regime:
phiL.1
-0.1244484

High regime:
phiH.1
0.09834139

Smoothing parameter: gamma = 36.54

Threshold
Variable: Z(t) = + (1) X(t)

Value: -0.07264

Residuals:
Min      1Q   Median      3Q      Max 
          
```

```

-0.2697041 -0.0127659 -0.0006854 0.0106664 0.1799002

Fit:
residuals variance = 0.0007356, AIC = -18376, MAPE = 134.5%

Coefficient(s):
            Estimate Std. Error t value Pr(>|z|)
phiL.1   -0.124448   0.085518 -1.4552 0.14561
phiH.1    0.098341   0.088910  1.1061 0.26869
gamma   36.538467  35.184696  1.0385 0.29905
th     -0.072638   0.038896 -1.8675 0.06183 .
---
Signif. codes:  0 `***' 0.001 `**' 0.01 `*' 0.05 `.' 0.1 ` ' 1

Non-linearity test of full-order LSTAR model against full-order AR
model
F = 0.38368 ; p-value = 0.5357

Threshold
Variable: Z(t) = + (1) X(t)

```

### Lampiran 29 Pengujian Residual Model FILSTAR:

- Pengujian *White Noise* dengan Statistik von Mises Residual Model FILSTAR (R versi 3.0.0):

```

> library(normwhn.test)
> wn<-Box.test(resi, lag=36, type="Ljung-Box")
> wn
      Box-Ljung test
data: resi
X-squared = 84.7229, df = 36, p-value = 8.371e-06

```

- Pengujian Normalitas dengan Kolmogorov-Smirnov Residual Model FILSTAR (R versi 3.0.0):

```

> library(fBasics)
> ksnormTest(data)
Title:
One-sample Kolmogorov-Smirnov test

Test Results:
STATISTIC:
D: 0.4601
P VALUE:
Alternative Two-Sided: < 2.2e-16
Alternative Less: < 2.2e-16
Alternative Greater: < 2.2e-16

```