TUGAS AKHIR – SS141501

ANALISIS LIKUIDITAS SAHAM SEKTOR PERBANKAN DI BEI MENGGUNAKAN INTERVENSI DAN MODEL ERROR MULTIPLIKATIF – *AUTOREGRESSIVE CONDITIONAL DURATION* (MEM–ACD)

LUH PUTU SHINTYA HANDAYANI
NRP 1315 105 016

Dosen Pembimbing
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017

TUGAS AKHIR – SS141501

ANALISIS LIKUIDITAS SAHAM SEKTOR PERBANKAN DI BEI MENGGUNAKAN INTERVENSI DAN MODEL ERROR MULTIPLIKATIF – *AUTOREGRESSIVE CONDITIONAL DURATION* (MEM–ACD)

LUH PUTU SHINTYA HANDAYANI
NRP 1315 105 016

Dosen Pembimbing
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017

FINAL PROJECT – SS141501

STOCK LIQUIDITY ANALYSIS OF BANKING SECTOR IN IDX USING INTERVENTION AND MULTIPLICATIVE ERROR MODEL – AUTOREGRESSIVE CONDITIONAL DURATION (MEM–ACD)

LUH PUTU SHINTYA HANDAYANI
NRP 1315 105 016

Supervisor
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2017

LEMBAR PENGESAHAN

ANALISIS LIKUIDITAS SAHAM SEKTOR PERBANKAN DI BEI MENGGUNAKAN INTERVENSI DAN MODEL ERROR MULTIPLIKATIF- *AUTOREGRESSIVE CONDITIONAL DURATION* (MEM-ACD)

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada
Program Studi Sarjana Departemen Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :
Luh Putu Shintya Handayani
NRP. 1315 105 016

Disetujui oleh Pembimbing:
Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si. ( )
NIP. 19831204 200812 1 002

Mengetahui,
Kepala Departemen

Dr. Suhartono
NIP. 19710929 199512 1 001

KEMENTERIAN RISET, TEKNOLOGI DAN PENDIDIKAN TINGGI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
DEPARTEMEN STATISTIKA

SURABAYA, JULI 2017

ANALISIS LIKUIDITAS SAHAM SEKTOR PERBANKAN DI BEI MENGGUNAKAN INTERVENSI DAN MODEL ERROR MULTIPLIKATIF - *AUTOREGRESSIVE CONDITIONAL DURATION* (MEM-ACD)

Nama	**:**	**Luh Putu Shintya Handayani**
NRP	**:**	**1315105016**
Departemen	**:**	**Statistika FMIPA ITS**
Dosen Pembimbing	**:**	**Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.**

Abstrak

Tax Amnesty (Pengampunan Pajak) merupakan Undang-Undang yang menjadi isu hangat 2016 dan berakhir pada Maret 2017. Kebijakan Tax Amnesty mengharuskan pihak bank menjadi pihak penerima dana repatriasi. Terkait hal itu, berdasarkan isu ekonomi finansial 2015 hingga 2016 terdapat saham bank yang selalu diburu oleh investor karena saham yang likuid. Saham perbankan yang paling dipertimbangkan untuk diperdagangkan yaitu Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), dan Bank Negara Indonesia (BBNI) karena masuk dalam kelompok saham LQ45. Tujuan penelitian ini adalah mengetahui gambaran data volume, mengetahui efek adanya efek intervensi akibat Tax Amnesty, dan mendapat kesimpulan mengenai likuiditas saham sebelum dan selama Tax Amnesty dari model ACD. Model ACD merupakan model alternatif lain di luar intervensi. Analisis intervensi yang dilakukan menunjukkan bahwa terdapat efek intervensi diberlakukannya Tax Amnesty pada volume saham perusahaan BMRI dan BBNI, namun tidak pada BBCA dan BBRI. Model intervensi yang terbentuk belum memenuhi distribusi normal. Model ACD menghasilkan bahwa volume transaksi lebih likuid dilihat dari durasi yang tinggi pada periode Tax Amnesty. Durasi *menunjukkan kejadian volume transaksi yang rendah, jadi bila nilai durasi tinggi maka volume transaksi rendah jarang terjadi. Hanya saja, pada saham BBRI tidak dapat dibandingkan sebelum Tax Amnesty dan setelah Tax Amnesty karena data tidak terdapat efek ACD dilihat dari parameter konstanta saja yang signifikan.*

Kata Kunci : Autoregressive Conditional Duration, Analisis Likuidias, Intervensi, Model Error Multiplikatif

STOCK LIQUDITY ANALYSIS OF BANKING SECTOR IN IDX USING INTERVENTION AND MULTIPLICATIVE ERROR MODEL - AUTOREGRESSIVE CONDITIONAL DURATION (MEM-ACD)

Student Name : Luh Putu Shintya Handayani
Student Number : 1315105016
Department : Statistics
Supervisor : Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si.

Abstract

Tax Amnesty is a law that is a hot issue in 2016 and ends in March 2017. The Tax Amnesty Policy requires the bank to be the recipient of the repatriation fund. Related to that, based on the issue of financial economy 2015 to 2016 there are some of banks stocks that are always hunted by investors because the stocks is liquid. The most widely considered banking stocks are Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), and Bank Negara Indonesia (BBNI) for being included in the LQ45 stock group. The purpose of this research is to know the description of volume data, to know the effect of intervention effect due to Tax Amnesty, and to get conclusion about stock liquidity before and during Tax Amnesty from ACD model. The ACD model is another alternative model outside the intervention. The result of interventions analysis shows that there is an effect of the intervention because of the Tax Amnesty on the volume of shares of BMRI and BBNI companies, but not on BBCA and BBRI. The intervention model has not met the normal distribution. The ACD model results in a more liquid volume of transactions viewed from the high duration of the Tax Amnesty period. Duration indicates a low transaction volume occurrence, so if the duration is high then low transaction volume is rare. However, BBRI shares can not be compared before Tax Amnesty *and after Tax Amnesty because there is no ACD effect seen from significant constants parameter only.*

Keyword : Autoregressive Conditional Duration, Intervention, Liquidity Analysis, Multiplicative Error Model

KATA PENGANTAR

Puji syukur kehadirat Tuhan Yang Maha Esa, atas limpahan rahmat yang tidak pernah berhenti sehingga penulis dapat menyelesaikan tugas akhir yang berjudul "**Analisis Likuiditas Saham Sektor Perbankan di BEI Menggunakan Intervensi dan Model *Error* Multiplikatif - *Autoregressive Conditional Duration* (MEM-ACD)**" dengan baik. Penulis menyadari bahwa dalam penyusunan tugas akhir ini tidak terlepas dari bantuan dan dukungan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Dr.rer.pol. Dedy Dwi Prastyo, S.Si., M.Si., selaku dosen pembimbing yang sabar membimbing dan memberi masukan kepada penulis dalam penyusunan tugas akhir.
2. Bapak Dr. Suhartono, selaku Ketua Departemen Statistika ITS yang telah memberikan fasilitas untuk kelancaran penyelesaian tugas akhir dan selaku dosen penguji yang telah memberikan saran untuk kebaikan tugas akhir.
3. Ibu Dr. Irhamah, S.Si., M.Si., selaku dosen penguji yang telah memberi masukan untuk kebaikan tugas akhir.
4. Bapak Dr. Sutikno, M.Si. selaku Ketua Program Studi S1 Departemen Statistika ITS yang telah memberikan fasilitas untuk kelancaran penyelesaian tugas akhir.
5. Bapak Prof. I Nyoman Budiantara, selaku dosen wali yang selalu memberikan arahan dan motivasi selama studi.
6. Bapak, Ibu, dan adik atas segala doa, kasih sayang, dukungan, dan masih banyak pemberian lain yang lebih daripada apa yang pantas penulis dapatkan.
7. Puspita Khanela, Giyanti Linda, Sinta Amalia, Vianty Rose, Fidyah Wijayanti, dan Ardhian Bayu yang selalu membantu dalam penyelesaian tugas akhir ditengah banyaknya tugas kuliah pada semester akhir.
8. Teman-teman Lintas Jalur Statistika 2015 yang berjuang menyelesaikan studi yang tidak dapat disebutkan satu per satu yang telah banyak membantu penulis.

9. Pihak-pihak lain yang telah mendukung dan membantu penyelesaian tugas akhir yang tidak bisa penulis sebutkan satu per satu.

Penulis berharap tugas akhir ini dapat memberikan manfaat untuk para pembaca. Penulis menyadari bahwa tugas akhir ini masih jauh dari kesempurnaan sehingga penulis menerima apabila ada saran dan kritik yang sifatnya membangun untuk penelitian-penelitian selanjutnya.

Surabaya, Juli 2017

Penulis

DAFTAR ISI

Halaman

HALAMAN JUDUL...i
LEMBAR PENGESAHAN..iii
ABSTRAK...v
ABSTRACT vii
KATA PENGANTAR ix
DAFTAR ISI xi
DAFTAR GAMBAR xiii
DAFTAR TABEL...xvii
DAFTAR LAMPIRAN xix

BAB I PENDAHULUAN
1.1 Latar Belakang 1
1.2 Rumusan Masalah 6
1.3 Tujuan 7
1.4 Manfaat 7
1.5 Batasan Masalah...8

BAB II TINJAUAN PUSTAKA
2.1 Volume Transaksi Saham.......................................9
2.2 Statistika Deskriptif..10
2.3 *Autoregressive Integrated Moving Average*.........12
2.4 Analisis Intervensi...16
2.5 *Generalized Autoregresive Conditional Heteroskedasticity* 17
2.6 Model *Error* Multiplikatif......................................21
2.7 Model *Autoregressive Conditional Duration*.......23
2.8 Estimasi *Autoregressive Conditional Duration* 28
2.9 Perumusan Model *Autoregressive Conditional Duration* 29
2.10 Kriteria Pemilihan Model.....................................32

BAB III METODOLOGI PENELIAN
3.1 Sumber Data dan Variabel Penelitian....................35
3.2 Langkah Analisis...37
3.3 Diagram Alir...39

BAB IV ANALISIS DAN PEMBAHASAN
4.1 Deskripsi Volume Transaksi Saham 41
4.2 Pemodelan Volume Transaksi Saham dengan Intervensi 46
4.3 Pemodelan Durasi dengan ACD...........................47

BAB V KESIMPULAN DAN SARAN
5.1 Kesimpulan..87
5.2 Saran..87

DAFTAR PUSTAKA 89
LAMPIRAN...93
BIODATA PENULIS 145

DAFTAR GAMBAR

Halaman

Gambar 3.1 Diagram Alir Analisis 40
Gambar 4.1 Boxplot Volume Transaksi Saham.......................41
Gambar 4.2 Histogram Volume Transaksi (a) BBCA, (b) BMRI (c) BBRI, dan (d) BBNI 43
Gambar 4.3 Boxplot Volume Transaksi (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*..................43
Gambar 4.4 *Time Series Plot* Volume Transaksi (a) BBCA, (b) BMRI, (c) BBRI, dan (d) BBNI...45
Gambar 4.5 *Time Series Plot* BBCA (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*...........46
Gambar 4.6 Box-cox *Plot* BBCA (a) Data Volume, (b) Data Transformasi 47
Gambar 4.7 ACF *Plot* BBCA (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing* 48
Gambar 4.8 PACF *Plot* BBCA 48
Gambar 4.9 Diagram Residual BBCA Terhadap T Intervensi 50
Gambar 4.10 *Time Series Plot* BMRI (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*...........52
Gambar 4.11 Box-cox *Plot* BMRI (a) Data Volume, (b) Data Transformasi 52
Gambar 4.12 ACF *Plot* BMRI (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing* 53
Gambar 4.13 PACF *Plot* BMRI..54
Gambar 4.14 Diagram Residual BMRI Terhadap T Intervensi 56
Gambar 4.15 *Time Series Plot* BBRI (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*...........58
Gambar 4.16 Box-cox *Plot* BBRI (a) Data Volume, (b) Data Transformasi 58
Gambar 4.17 ACF *Plot* BBRI (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing* 59

Gambar 4.18 PACF *Plot* BBRI 59
Gambar 4.19 Diagram Residual BBRI Terhadap
T Intervensi..61
Gambar 4.20 *Time Series Plot* BBNI (a) Sebelum
Tax Amnesty dan (b) Selama *Tax Amnesty*...........63
Gambar 4.21 Box-cox Plot BBNI (a) Data Volume,
(b) Data Transformasi 63
Gambar 4.22 ACF *Plot* BBNI (a) Data Volume,
(b) Data Transformasi, (c) Data *Differencing* 64
Gambar 4.23 PACF *Plot* BBNI..65
Gambar 4.24 Diagram Residual BBNI Terhadap
T Intervensi..66
Gambar 4.25 *Time Series Plot* Data *diff* Sebelum
Tax Amnesty (a) BBCA, (b) BMRI,
(c) BBRI, dan (d) BBNI 68
Gambar 4.26 *Time Series Plo*t Data *diff* Selama
Tax Amnesty (a) BBCA, (b) BMRI,
(c) BBRI, dan (d) BBNI 69
Gambar 4.27 ACF *Plot* Durasi BBCA (a) Sebelum dan
(b) Selama *Tax Amnesty*......................................72
Gambar 4.28 ACF dan PACF Plot Durasi Kuadrat BBCA
(a) Sebelum dan (b) Selama *Tax Amnesty*............73
Gambar 4.29 Durasi Taksiran Model ACD BBCA 75
Gambar 4.30 ACF *Plot* Durasi BMRI (a) Sebelum dan
(b) Selama *Tax Amnesty*......................................76
Gambar 4.31 ACF dan PACF *Plot* Durasi Kuadrat BMRI
(a) Sebelum dan (b) Selama *Tax Amnesty*............76
Gambar 4.32 Durasi Taksiran Model ACD BMRI 78
Gambar 4.33 ACF *Plot* Durasi BBRI (a) Sebelum dan
(b) Selama *Tax Amnesty*......................................79
Gambar 4.34 ACF dan PACF *Plot* Durasi Kuadrat BBRI
(a) Sebelum dan (b) Selama *Tax Amnesty*............80

Gambar 4.35 ACF *Plot* Durasi BBNI (a) Sebelum dan (b) Selama *Tax Amnesty*..82
Gambar 4.36 ACF dan PACF *Plot* Durasi Kuadrat BBNI (a) Sebelum dan (b) Selama *Tax Amnesty*............83
Gambar 4.37 Durasi Taksiran Model ACD BBNI......................85

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

Halaman

Tabel 2.1 Transformasi Box-Cox 13
Tabel 2.2 Karakteristik ACF dan PACF untuk Stasioneritas secara Teori 14
Tabel 3.1 Struktur Data Penelitian Sebelum *Tax Amnesty* 35
Tabel 3.2 Struktur Data Penelitian Sebelum *Tax Amnesty* (Lanjutan) 36
Tabel 3.3 Variabel Intervensi... 36
Tabel 4.1 Karakteristik Volume Transaksi Saham 42
Tabel 4.2 Karakteristik Volume Transaksi Sebelum dan Selama *Tax Amnesty* 44
Tabel 4.3 Estimasi dan Uji Signifikansi Parameter BBCA 49
Tabel 4.4 Uji Diagnosa Model ARIMA BBCA...................... 49
Tabel 4.5 Kriteria Kebaikan Model ARIMA BBCA 50
Tabel 4.6 Estimasi dan Uji Signifikansi Model Intervensi BBCA 51
Tabel 4.7 Uji Diagnosa Model Intervensi BBCA................... 51
Tabel 4.8 Estimasi dan Uji Signifikansi Parameter BMRI 54
Tabel 4.9 Uji Diagnosa Model ARIMA BMRI 55
Tabel 4.10 Kriteria Kebaikan Model ARIMA BMRI............... 55
Tabel 4.11 Estimasi dan Uji Signifikansi Model Intervensi BMRI... 56
Tabel 4.12 Uji Diagnosa Model Intervensi BMRI.................... 57
Tabel 4.13 Estimasi dan Uji Signifikansi Parameter BBRI...... 60
Tabel 4.14 Uji Diagnosa Model ARIMA BBRI 60
Tabel 4.15 Kriteria Kebaikan Model ARIMA BBRI................ 61
Tabel 4.16 Estimasi dan Uji Signifikansi Model Intervensi BBRI.. 62
Tabel 4.17 Uji Diagnosa Model Intervensi BBRI..................... 62
Tabel 4.18 Estimasi dan Uji Signifikansi Parameter BBNI...... 65
Tabel 4.19 Uji Diagnosa Model ARIMA BBNI....................... 66
Tabel 4.20 Kriteria Kebaikan Model ARIMA BBNI 66

Tabel 4.21 Estimasi dan Uji Signifikansi Model Intervensi BBNI..67
Tabel 4.22 Uji Diagnosa Model Intervensi BBRI.....................67
Tabel 4.23 Estimasi dan Uji Signifikansi Parameter ARIMA-GARCH Sebelum *Tax Amnesty* 70
Tabel 4.24 Estimasi dan Uji Signifikansi Parameter ARIMA-GARCH Selama *Tax Amnesty*..................71
Tabel 4.25 Estimasi dan Uji Signifikansi Parameter ACD BBCA..74
Tabel 4.26 Uji *White Noise* ACD BBCA..................................74
Tabel 4.27 Kriteria Kebaikan Model ACD BBCA 75
Tabel 4.28 Estimasi dan Uji Signifikansi Parameter ACD BMRI...77
Tabel 4.29 Uji *White Noise* ACD BMRI 78
Tabel 4.30 Kriteria Kebaikan Model ACD BMRI....................78
Tabel 4.31 Estimasi dan Uji Signifikansi Parameter ACD BBRI..80
Tabel 4.32 Uji *White Noise* ACD BBRI 81
Tabel 4.33 Kriteria Kebaikan Model ACD BBRI.....................82
Tabel 4.34 Estimasi dan Uji Signifikansi Parameter ACD BBNI 83
Tabel 4.35 Uji *White Noise* ACD BBNI...................................84
Tabel 4.36 Kriteria Kebaikan Model ACD BBNI 84

DAFTAR LAMPIRAN

Halaman

Lampiran 1 Data Volume Sebelum *Tax Amnesty* 93
Lampiran 2 Data Volume Selama Tax Amnesty 93
Lampiran 3 Statistika Deskriptif Volume Transaksi 94
Lampiran 4 *Time Series Plot* Semua Periode Data Volume 95
Lampiran 5 *Time Series Plot* Semua Periode Data Volume (Lanjutan).. 96
Lampiran 6 *Time Series Plot* Volume Sebelum *Tax Amnesty* 97
Lampiran 7 *Time Series Plot* Volume Sebelum *Tax Amnesty* (Lanjutan) 98
Lampiran 8 *Time Series Plot* Volume Selama Tax Amnesty 99
Lampiran 9 *Time Series Plot* Volume Selama *Tax Amnesty* (Lanjutan) 100
Lampiran 10 Syntax Model ARIMA BBCA 101
Lampiran 11 *Output* Model ARIMA BBCA 102
Lampiran 12 *Syntax* Model ARIMA BMRI 103
Lampiran 13 *Output* Model ARIMA BMRI............................ 104
Lampiran 14 *Syntax* Model ARIMA BBRI 105
Lampiran 15 *Output* Model ARIMA BBRI 106
Lampiran 16 *Syntax* Model ARIMA BBNI............................. 107
Lampiran 17 *Output* Model ARIMA BBNI 108
Lampiran 18 *Syntax* Model Intervensi BBCA......................... 109
Lampiran 19 *Syntax* Model Intervensi BMRI 110
Lampiran 20 *Syntax* Model Intervensi BBRI 111
Lampiran 21 *Syntax* Model Intervensi BBNI 112
Lampiran 22 *Time Series Plot* Data *Diff* Sebelum *Tax Amnesty* 113
Lampiran 23 *Time Series Plot* Data *Diff* Selama *Tax Amnesty* 114
Lampiran 24 *Syntax* Model ARIMA-GARCH dan ACD BBCA 115

Lampiran 25 *Syntax* Model ARIMA-GARCH dan ACD BBCA (Lanjutan)....................................116
Lampiran 26 *Syntax* Uji Distribusi Durasi BBCA Sebelum *Tax Amnesty* 117
Lampiran 27 *Syntax* Uji Distribusi Durasi BBCA Selama *Tax Amnesty*..118
Lampiran 28 *Output* Model ARIMA-GARCH BBCA Sebelum *Tax Amnesty* 119
Lampiran 29 *Output* Model ARIMA-GARCH BBCA Selama *Tax Amnesty*..120
Lampiran 30 *Output* Uji Distribusi Durasi BBCA 121
Lampiran 31 *Output* Model EACD BBCA Sebelum *Tax Amnesty* 122
Lampiran 32 *Output* Model EACD BBCA Selama *Tax Amnesty* 123
Lampiran 33 *Output* Model WACD BBCA Sebelum *Tax Amnesty* 124
Lampiran 34 *Output* Model WACD BBCA Selama *Tax Amnesty* 125
Lampiran 35 *Syntax* Model ARIMA-GARCH dan ACD BMRI 126
Lampiran 36 *Syntax* Model ARIMA GARCH dan ACD BMRI (Lanjutan) 127
Lampiran 37 *Syntax* Uji Distribusi Durasi BMRI Sebelum *Tax Amnesty* 128
Lampiran 38 *Syntax* Uji Distribusi Durasi BMRI Selama *Tax Amnesty*..129
Lampiran 39 *Syntax* Model ARIMA GARCH dan ACD BBRI 130
Lampiran 40 *Syntax* Model ARIMA GARCH dan ACD BBRI (Lanjutan) 131
Lampiran 41 *Syntax* Uji Distribusi Durasi BBRI Sebelum *Tax Amnesty* 132
Lampiran 42 *Syntax* Uji Distribusi Durasi BBRI Selama *Tax Amnesty*..133

Lampiran 43 *Syntax* Model ARIMA GARCH dan ACD BBNI..134
Lampiran 44 *Syntax* Model ARIMA GARCH dan ACD BBNI (Lanjutan)......................................135
Lampiran 45 *Syntax* Uji Distribusi Durasi BBNI Sebelum *Tax Amnesty* 136
Lampiran 46 *Syntax* Uji Distribusi Durasi BBNI Selama *Tax Amnesty* 137
Lampiran 47 *Syntax* Uji Asumsi *White Noise* 138
Lampiran 48 *Syntax* Uji Asumsi *White Noise* (Lanjutan)........139
Lampiran 49 *Output* Uji Asumsi *White Noise*.........................140
Lampiran 50 *Output* Uji Asumsi *White Noise* (Lanjutan).......141
Lampiran 51 Surat Pernyataan..143

(Halaman ini sengaja dikosongkan)

BAB I
PENDAHULUAN

1.1 Latar Belakang

Undang-undang Pengampunan Pajak (*Tax Amnesty*) yang merupakan salah satu isu hangat di perkembangan ekonomi Indonesia diyakini memberikan dampak positif bagi perekonomian. Diterapkannya *Tax Amnesty* akan memberikan dampak pada penerimaan pajak dan arus modal masuk atau *capital inflows*. Semakin banyak dana yang masuk maka akan mampu meningkatkan pertumbuhan ekonomi yang nantinya melonggarkan likuiditas pada saham perbankan. Likuiditas sangat menunjang tinggi renahnya profit yang diperoleh oleh pihak investor.

Pengampunan Pajak (*Tax Amnesty*) dimulai sejak Juli 2016 dan telah berakhir pada 31 Maret 2017. Berdasarkan Surat Penyertaan Harta dalam data statistik *Tax Amnesty* total harta yang dilaporkan mencapai Rp4.855 triliun, yang terdiri dari deklarasi harta dalam negeri dan deklarasi harta luar negeri. Dana repatriasi (komitmen penarikan dana dari luar negeri) mencapai Rp147 trliun (Chandra, 2017).

Didasarkan oleh isu ekonomi finansial di tahun 2015 hingga 2016 terdapat beberapa saham bank yang selalu diburu oleh investor ataupun trader. Pertimbangan pihak investor atau trader memilih saham perbankan adalah saham likuid artinya transaksi jual beli saham yang secara kontinyu dilakukan oleh investor dan trader dengan kata lain demand dan *supply* selalu tinggi. Selain itu kinerja perbankan yang baik juga memengaruhi harga per lembar saham di beberapa saham bank tersebut. Bedasarkan data yang diolah infobank saham-saham perbankan yang menduduki peringkat lima besar emiten adalah Bank Central Asia (BBCA), Bank Mandiri (BMRI) dan Bank Rakyat Indonesia (BBRI) (Apriyani, 2016).

Pada 2016 sektor pasar modal memang mengalami penurunan di tahun sebelumnya, termasuk saham sektor perbankan. Penurunan tidak lain disebabkan oleh perlambatan ekonomi secara global. Secara nasional terdapat tiga saham-saham perbankan yang masih dipertimbangkan, yakni Bank Central Asia (BBCA), Bank Mandiri (BMRI) dan Bank Rakyat Indonesia (BBRI). Saham BBCA perlu dipertimbangkan karena ditengah kondisi ekonomi yang sedang melambat, perseroan masih mampu mencatatkan laba bersih sebesar Rp13,37 triliun. Saham BBRI pada kuartal III 2015 berhasil membukukan pertumbuhan laba bersih sebesar 11,5% menjadi Rp6,42 triliun. Selain itu, saham BMRI juga bisa jadi pertimbangan di tahun depan karena per kuartal III-2015, kredit perseroan tumbuh mencapai 10,7%, serta memiliki target sebagai perbankan kelas atas di ASEAN tahun 2020 (Yoga, 2015).

Seperti yang telah dijelaskan sebelumnya likuiditas saham suatu bank baik bila kinerja bank juga baik. Karakteristik pengelompokan bank menurut BUKU di OJK tidak hanya atas besarnya permodalan tetapi juga dilihat faktor kegiatan usaha bank, laporan laba/rugi bank, rekening administratif bank, kinerja bank mulai dari persentase rasio pemenuhan kecukupan modal minimum sampai persentase rasio aset likuid, perkembangan aset antar kelompok BUKU. Bank Umum berdasarkan Kegiatan Usaha yang selanjutnya disebut BUKU adalah pengelompokan Bank berdasarkan Kegiatan Usaha yang disesuaikan dengan modal inti yang dimiliki. Berdasarkan modal inti yang dimiliki, Bank dikelompokkan menjadi 4 (empat) BUKU, yaitu BUKU 1 dengan modal inti sampai dengan kurang dari Rp1.000.000.000.000,00 (satu triliun Rupiah); BUKU 2 dengan modal inti paling sedikit sebesar Rp1.000.000.000.000,00 (satu triliun Rupiah) sampai kurang dari Rp5.000.000.000.000,00 (lima triliun Rupiah); BUKU 3 modal inti paling sedikit sebesar Rp5.000.000.000.000,00 (lima triliun Rupiah) sampai kurang dari Rp30.000.000.000.000,00 (tiga puluh triliun Rupiah) dan BUKU 4 modal inti paling sedikit sebesar Rp30.000.000.000.000,00 (tiga puluh triliun Rupiah) (Otoritas Jasa Keuangan, 2016). Bank yang termasuk dalam kategori BUKU 4 adalah Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia serta ditambah satu bank lagi yaitu Bank CIMB Niaga per September 2016 (Nisaputra, 2016).

Empat saham perbankan yang diduga paling dipertimbangkan untuk diperdagangkan juga merupakan bank yang ditunjuk untuk menerima dana repatriasi dari kebijakan *Tax Amnesty*. Oleh karena itu, dalam penelitian ini ingin dianalisis volume saham di Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), dan Bank Negara Indonesia (BBNI) sebelum dan selama *Tax Amnesty*. Likuiditas berdasarkan durasi volume rendah dianalisis menggunakan Model Error Multiplikatif dengan pendekatan *ACD* (*Autoregressive Conditional Duration*). Model *Error* Multiplikatif digunakan untuk memodelkan data time series yang bernilai positif, dimana nilai mean error adalah 1 bila data berdistribusi eksponensial dan nilai error yang selalu bernilai positif (Engle, 2002). Pendekatan yang digunakan adalah *ACD* (*Autoregressive Conditional Duration*) untuk memodelkan mean dan nilai error dari data durasi volume transaksi saham (Engle & Russell, 1998). Selain menggunakan metode ACD, alternatif analisis lain adalah intervesi untuk melihat apakah terdapat efek intervensi akibat diberlakukannya kebijakan *Tax Amnesty*.

Penelitian terkait metode yang digunakan antara lain berjudul *Estimation of High-Frequency Volatility: An Autoregressive Conditional Duration Models Approach* diperoleh kesimpulan bahwa diusulkan metode untuk mengestimasi volatilitas *intraday* dengan mengintegrasikan varians bersyarat per satuan waktu yang diperoleh dari model *ACD*, dipertimbangkan estimasi model *ACD* dengan menggunakan metode SP (semiparametrik) (Tse & Yang, 2010). Hasil verifikasi Monte Carlo menunjukkan bahwa metode SP lebih efisien daripada QMLE (*Quasi Maximum Likelihood Estimates*) dan baik bila dibandingkan dengan MLE. Estimasi harian metode *ACD*-ICV dibandingkan dengan beberapa model volatilitas lainnya. Hasil Monte Carlo menunjukkan bahwa estimasi *ACD*-ICV menghasilkan RMSE terkecil, sedangkan kernel RV menghasilkan model estimasi terbaik hasil terbaik RV (*real*-

ized volatility). Hasil ini menggunakan 30 saham NYSE yang menunjukkan bahwa estimasi *ACD*-ICV dapat menangkap volatilitas data. Sehingga, keuntungan metode ini adalah dapat digunakan untuk memperkirakan volatilitas intraday selama interval seperti 15 menit atau satu jam.

Penelitian berjudul *Autoregressive Conditional Duration Models: An Application in the Brazilian Stock Market* memberikan gambaran bahwa selama beberapa dekade studi keuangan menggunakan data harian daimana yang biasa menjadi fokusan adalah harga penutupan per hari dan mengabaikan peristiwa *intraday* (Oliveira, Bueno, Kotsubo, & Bergmann, 2016). Namun, karena semakin berkembang pesat industri keuangan dan evolusi yang cepat pada optimasi computer sehingga data *intraday* dapat direkam dengan mudah pada setiap transaksi seperti harga dan volume transaksi. Adanya *cluster volatility* pada data *intraday* mendorong pengembangan area baru dalam analisis industri keuangan. Hasil penelitian menunjukkan bahwa model Burr-*ACD* berisi E*ACD* dan W*ACD* model sebagai kasus khusus. Meskipun dalam model Burr-*ACD* mungkin upaya yang lebih besar diperlukan untuk melaksanakan dan mengevaluasi dari daripada di *ACD* standar, keuntungan adalah bahwa kepadatan bersyarat dan Burr-*ACD* fungsi survival durasi transaksi. Model kurang membatasi dan bisa mengambil bentuk yang lebih realistis.

Penelitian selanjutnya menyajikan kerangka umum untuk mengevaluasi model *ACD* menggunakan uji Lagrange multiplier. Evaluasi didasarkan pada bentuk fungsional dari *mean* bersyarat dari model *ACD*. Alternatif dipertimbangkan adalah parametrik karena dalam kasus penolakan hipotesis disarankan untuk memperluas model. Pengujian yang dilakukan mudah digunakan, karena model hanya harus diperkirakan di bawah hipotesis nol, dan perhitungan salah satu uji statistik hanya membutuhkan satu atau dua tambahan regresi linear biasa. Versi uji statistik yang kuat untuk penyimpangan dari asumsi distribusi selain yang secara eksplisit diuji juga disajikan tapi tampaknya tes *robustifying* tidak sepenting dalam praktek seperti di beberapa aplikasi *time series* lainnya. Semua tes ditemukan memiliki sifat baik ukuran. Hasil dari aplikasi untuk perdagangan dan data *quotes* jelas menunjukkan kebutuhan untuk model *ACD* nonlinear. Masalah ini akan diambil dalam pekerjaan di masa depan. Penyesuaian durasi tampaknya topik layak pertimbangan lain lebih lanjut (Meitz & Terasvirta, 2004).

Penelitian tentang data transaksi saham Intel Corporation menunjukkan bahwa model yang terbaik adalah *EACD*(2,2) karena distribusi yang paling sesuai adalah eksponansial. Dimana yang digunkan dalam penelitian ini adalah data *intraday*. Model yang dibentuk juga telah memenuhi asumsi white noise berdasarkan uji Ljung Box. Dari model *EACD*(2,2) diketahui prediksi akan terjadi transaksi pada 15,01 detik setelah transaksi terakhir terjadi. Karena transaksi terakhir terjadi pada detik 57646 maka transaksi berikutnya diprediksi akan terjadi pada detik ke 57661,01 (Fitriyah, 2009).

Sebagai pertimbangan lain digunakan pula metode intervensi dimana penelitian tentang intervensi sudah banyak dilakukan. Salah satunya berjudul Peramalan Nilai Tukar Dolar Amerika Serikat terhadap Rupiah Menggunakan Intervensi dan ANFIS. Penelitian menyimpulkan bahwa pada metode intervensi, nilai tukar dollar Amerika Serikat terhadap rupiah dipengaruhi oleh kejadian Pemilihan Umum (Pemilu) Presiden dan pengumuman *People Bank of China* (PBoC) melakukan devaluasi yuan. Dari kedua metode yang digunakan diketahui bahwa model ANFIS menjadi model terbaik karena memiliki MAPE dan RMSE lebih kecil (Islami, 2016).

Penelitian sebelumnya yang berkaitan dengan volume saham adalah mengenai Pengaruh Return Saham, Volume Perdagangan dan Volatilitas Harga Saham Terhadap *Bid-Ask Spread* pada Perusahaan yang Melakukan Stock Split di Bursa Efek Indonesia menghasilkan bahwa return saham, volume perdagangan dan volatilitas harga saham secara serempak berpengaruh signifikan terhadap bid-ask spread pada perusahaan yang melakukan stock split di Bursa Efek (Napitupulu & Syahsunan, 2012). Pada penelitian lainnya diperoleh bahwa terdapat pengaruh yang signifikan antara harga saham, return saham, dan volume perdagangan terhadap likuiditas saham sesudah stock split (Mubarokah, 2011). Dari kedua penelitian tersebut dapat diketahui bahwa volume transaksi dapat digunakan sebagai salah satu acuan dalam menentukan likuiditas saham.

Berdasarkan penelitian sebelumnya, pada penelitian ini data *intraday* tidak tersedia oleh pihak BEI sehingga pemodelan data *intraday* tidak dapat dilakukan. Untuk menetukan durasi diperlukan pembatas terjadi dan tidak terjadinya kejadian dalam durasi sehingga didekati dengan ARMA-GARCH. Hasil penelitian diharapkan dapat menunjukkan perubahan likuiditas saham saham sektor perbankan yaitu Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), dan Bank Negara Indonesia (BBNI) dari masa sebelum *Tax Amnesty* dengan periode selama *Tax Amnesty* berlangsung. Model pembanding dari ACD adalah analisis intervensi yang menggunakan data volume transaksi harian sehingga diketahui adanya efek intervensi pada sebelum dengan periode selama *Tax Amnesty*.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, didapat rumusan masalah yang akan dibahas pada penelitian ini adalah menggambarkan likuiditas saham perbankan yaitu Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), dan Bank Negara Indonesia (BBNI) periode sebelum *Tax Amnesty* dan selama periode *Tax Amnesty* berlangsung. Metode penelitian ini adalah Intervensi untuk memodelkan data volume sehingga diketahui efek dari *Tax Amnesty*, serta Model Error Multiplikatif - *Autoregressive Conditional Duration* (MEM-ACD) untuk data durasi. Model ACD diharapkan mampu menangkap klaster volatilitas dari data volume transaksi saham dan menerangkan likuiditas saham sebelum dan selama *Tax Amnesty*. Volume transaksi saham yang dianalisis mampu menggambarkan likuiditas saham perbankan dilihat dari nilai durasi taksiran yang secara tidak langsung berhubungan dengan profit yang diperoleh investor.

1.3 Tujuan

Tujuan dari penelitian pada tugas akhir sesuai dengan latar belakang dan rumusan masalah adalah sebagai berikut.

1. Mendeskripsikan data volume transaksi saham perusahaan sektor perbankan di BEI selama periode sebelum *Tax Amnesty*, selama periode *Tax Amnesty* berlangsung, dan bila kedua periode tersebut digabungkan.
2. Menentukan model terbaik masing-masing volume transaksi saham dengan intervensi dan mengetahui efek *Tax Amnesty* terhadap volume transaksi.
3. Memperoleh kesimpulan mengenai likuiditas saham perbankan sebelum dan selama *Tax Amnesty* berlangsung dari model ACD terbaik. Model ACD mampu menjelaskan perbandingan likuiditas saham perbankan akibat adanya *Tax Amnesty*. Pemodelan ACD menggunakan data durasi dari volume transaksi saham.

1.4 Manfaat

Memberikan masukan bagi masing-masing perusahaan perbankan yang diberikan kewenangan menerima pembayaran Pengampunan Pajak (*Tax Amnesty*) dalam mengembangkan dana repatriasi yang diperoleh karena sangat bepengaruh pada profit saham dilihat dari volume transaksi dengan memberi kredit kepada UMKM untuk meningkatkan perekonomian. Hal ini karena semakin banyak modal yang dimiliki oleh pihak bank sehingga dapat membantu pertumbuhan ekonomi di Indonesia. Selain itu, karena isu Pengampunan Pajak (*Tax Amnesty*) saham pihak perbankan dengan nilai dan lembar saham terbanyak menjadi semakin likuid disebakan oleh banyaknya transansi jual beli saham oleh investor ataupun trader yang mengharapkan profit. Analisis ini juga dapat memberikan masukan kepada pihak Bursa Efek Indonesia dalam mendorong saham perbankan semakin diminati sebagai imstrumen investasi, jika pasar semakin diminati maka semakin banyak biaya transaksi yang masuk ke kas Bursa Efek Indonesia.

1.5 Batasan Masalah

Saham perbankan yang akan dianalisis hanya saham dari empat bank yang dinilai memiliki likuiditas terbaik yaitu Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), dan Bank Negara Indonesia (BBNI). Hal ini dapat diketahui dari saham-saham yang masuk dalam 45 saham yang paling likuid (LQ45) periode Februari 2016 sampai Juli 2016. Dimana keempat saham tersebut secara stabil selalu masuk dalam indeks LQ45. LQ45 adalah Indeks Likuiditas Bursa Efek Jakarta (Indonesia Stock Exchange, 2016). Periode data saham yang digunakan yaitu 4 Januari 2010 sampai 31 Maret 2017 dan dalam satu minggu hanya menggunakan lima hari kerja dimana saham aktif ditransaksikan sehingga tidak ada volume saham yang bernilai 0. Bila dalam pertengahan hari kerja terdapat hari libur maka volume transaksi saham mengikuti volume di satu periode sebelumnya.

BAB II
TINJAUAN PUSTAKA

2.1 Volume Transaksi Saham

Transaksi jual beli saham dipantau oleh pasar modal. Pasar modal adalah tempat kegiatan yang bersangkutan dengan penawaran umum dan perdagangan efek, perusahaan publik yang berkaitan dengan efek yang diterbitkannya, serta lembaga dan profesi yang berkaitan dengan efek (Presiden Republik Indonesia, 1995).

Volume transaksi saham mencerminkan kekuatan antara permintaan dan penawaran yang merupakan manivestasi dari tingkah laku investor maupun trader (Iin & Mulyani, 2011). Volume perdagangan merupakan bagian yang diterima dalam analisis teknikal. Kegiatan perdagangan dalam volume yang sangat tinggi di suatu bursa akan ditafsirkan sebagai tanda pasar akan membaik (*bullish*).

Semakin banyak volume saham yang ditransaksikan maka semakin likuid saham tersebut. Likuiditas saham adalah kemudahan untuk membeli dan menjual saham. Suatu aset dapat dikatakan likuid apabila aset tersebut dapat ditransaksikan dalam jumlah besar dengan waktu yang singkat dan biaya yang rendah (Mubarokah, 2011).

Data volume saham cenderung stasioner dalam rata-rata namun memiliki variasi yang besar sehingga tidak stasioner dalam variasi sehingga pada penelitian ini pemodelan dilakukan dengan Model Error Multiplikatif. Data durasi volume saham yang ditransaksikan pasti bernilai positif sehingga pendekatan yang digunakan *ACD* (*Autoregressive Conditional Duration*) dimana distribusi *error* bernilai positif yaitu distribusi eksponensial atau distribusi weibull. Sebelum dilakukan analisis pemodelan volume saham perbankan, data terlebih dahulu dieksplorasi agar mengetahui gambaran umun dari data. Eksplorasi dilakukan dengan metode statistika deskriptif. Untuk mengetahui ada tidaknya efek *tax amnesty* digunakan intervensi.

2.2 Statistika Deskriptif

Statistika Deskriptif dapat di definisikan sebagai metode-metode yang berkaitan dengan penyajian data sehingga memberikan informasi yang berguna. Statistika deskriptif hanya memberikan informasi mengenai data yang dimiliki dan tidak menarik suatu kesimpulan apapun tentang data tersebut. Penggunaan statistika deskriptif mengakibatkan kumpulan data akan tersaji dengan ringkas dan rapi serta dapat memberikan informasi inti dari kumpulan data yang ada (Walpole, 1995).

a. *Mean*

Mean atau rata-rata adalah perhitungan dengan cara membagi jumlah nilai data dengan banyaknya data (Walpole, 1995). Perhitungan menggunakan persamaan (2.1) berikut.

$$\overline{x} = \frac{1}{n}\sum_{i=1}^{n} x_i \tag{2.1}$$

dimana $\overline{x}$ adalah rata-rata, x_i adalah nilai data ke-i, dan n adalah banyaknya data.

b. Median

Median merupakan data yang harus dikelompokkan terlebih dahulu dari yang terkecil sampai terbesar dan diambil nilai tengahnya (Walpole, 1995). Persamaan median dapat dilihat pada persamaan (2.2).

$$Me = x_{(n+1/2)}, \text{ untuk jumlah data } (n) \text{ data ganjil}$$
$$Me = \frac{1}{2}\left(x_{n/2} + x_{(n/2)+1}\right), \text{ untuk jumlah data } (n) \text{ data genap} \tag{2.2}$$

dimana *Me* adalah median, *n* adalah banyaknya data, dan *x* adalah nilai data.

c. Minimum dan Maksimum

Minimum merupakan nilai terkecil dari dari suatu data dan maksimum merupakan nilai terbesar dari suatu data (Walpole, 1995). Volume transaksi saham harian bila terdapat nilai maksimum yang jauh dari nilai rata-rata maka kemungkinan terjadi reaksi pasar yang berlebihan akibat informasi yang terjadi sebelumnya.

d. Variansi

Variansi adalah rata-rata kuadrat selisih dari semua nilai data terhadap rata-rata hitung. Persamaan dapat ditulis seperti persamaan (2.3) (Walpole, 1995). Bila dalam transaksi saham volume transaksi harian suatu saham dari perusahaan emiten memiliki variasi tinggi maka resiko dari suatu saham tersebut tinggi, walaupun bila resiko tinggi biasanya mengghasilkan return yang tinggi.

$$s^2 = \frac{\sum_{i=1}^{n}\left(x_i - \bar{x}\right)^2}{n-1} \tag{2.3}$$

e. Koefisien Variansi

Koefisien variaansi merupakan suatu ukuran variansi yang dapat digunakan untuk membandingkan suatu distribusi data yang mempunyai satuan yang berbeda. Koefisien variasi adalah suatu perbandingan antara simpangan baku dengan nilai rata-rata dan dinyatakan dengan persentase sesuai persamaan (2.4) (Walpole, 1995). Bila volume transaksi harian suatu saham dari perusahaan emiten memiliki koefisien variasi tinggi maka tranksaksi saham tersebut cenderung tidak stabil, sehingga mungkin memberikan resiko yang lebih tinggi.

$$KV = \frac{s}{\bar{x}} \times 100\% \tag{2.4}$$

f. *Box-plot*

Box-plot adalah gambaran secara grafis, berdasarkan kuartil yang membantu menggambarkan sekumpulan data. Di dalam *box-plot* terdapat unsur lima statistik yaitu nilai minimum, Q_1 (kuartil pertama), median, Q_3 (kuartil ketiga), nilai maksimum (Douglas, William, & Samuel, 2007). Setelah data dieksplorasi secara deskrptif data kemulian dimodelkan dengan intervensi dan Model Error Multiplikatif -*Autoregressive Conditional Duration* (MEM-ACD).

2.3 *Autoregressive Integrated Moving Average*

Model *Autoregressive Integrated Moving Average* (ARIMA) Box-Jenkins merupakan penggabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) serta proses *differencing* orde d terhadap data *time series*. Bentuk umum model ARIMA (p, d, q) non musiman adalah sebagai berikut (Wei, 2006).

$$\phi_p(B)(1-B)^d V_t = \theta_0 + \theta_q(B) a_t \tag{2.5}$$

dengan,

V_t : volume transaksi harian perusahaan emiten

ϕ_p : koefisien komponen AR non musiman dengan orde p

θ_q : koefisien komponen MA non musiman dengan orde q

$\phi_p(B)$: $1-\phi_1 B - \ldots - \phi_p B^p$

$\theta_q(B)$: $1-\theta_1 B - \ldots - \theta_q B^q$

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

a_t : nilai residual pada saat t

Pembentukan model ARIMA biasanya dilakukan dengan menggunakan prosedur yang diungkapkan oleh Box-Jenkins. Prosedur tersebut terdiri dari identifikasi model, estimasi parameter, *diagnostic checking*, pemilihan model terbaik, dan peramalan. Untuk menggambarkan identifikasi model, model umum ARIMA (p, d, q) sebagai berikut.

$$(1-\phi_1 B - \ldots - \phi_p B^p)(1-B)^d V_t = \theta_0 + (1-\theta_1 B - \ldots - \theta_q B^q) a_t \tag{2.6}$$

Model identifikasi digunakan untuk mengidentifikasi data apakah sudah stasioner dalam varians dan *mean* sehingga memerlukan transformasi. Cara yang dapat dilakukan yaitu transformasi menstabilkan varian dengan transformasi *differencing*. Langkah-langkah untuk mengidentifikasi model dugaan adalah sebagai berikut.

1. Membuat plot untuk data *time series* dan pilih transformasi yang tepat. *Time series* adalah serangkaian pengamatan terhadap variabel yang akan diamati secara berurutan dari

waktu ke waktu dan antar pengamatan yang berdekatan saling berhubungan. Pengambilan data dilakukan pada interval waktu dan sumber yang sama (Wei, 2006). Analisis *time series* merupakan suatu metode peramalan untuk masa depan yang dilakukan berdasarkan nilai atau data masa lalu dari suatu variabel dan kesalahan (*error*) masa lalu. Tujuan dari metode peramalan *time series* ini adalah untuk menemukan pola data *time series* dan mengekstrapolasikan pola tersebut ke periode yang akan datang. Pada setiap *time series analysis*, langkah pertama adalah membuat plot dari data. Melalui pemeriksaan yang teliti pada plot data, biasanya didapatkan gambaran mengenai apakah deretan data mengandung tren atau *seasonal*, variabel yang tidak konstan, ketidaknormalan, dan fenomena ketidakstasioneran. Dalam analisis *time series* transformasi yang paling sering dilakukan adalah tranformasi menstabilkan varian dan *differencing*. Karena *differencing* dapat membuat beberapa nilai negatif, stabilisasi varian harus dilakukan terlebih dahulu sebelum melakukan *differences*. Tabel 2.1 menyajikan beberapa bentuk tranformasi *Box-Cox* berdasarkan nilai yang bersesuaian.

Tabel 2.1 Transformasi Box-Cox

Nilai Lambda	Jenis Transformasi
-1,0	$1/V_t$
-0.5	$1/\sqrt{V_t}$
0	$\ln V_t$
0.5	$\sqrt{V_t}$
1	V_t (tidak ada tranformasi)

2. Menghitung dan memeriksa ACF dan PACF contoh dari deret (*series*) data asli untuk membuktikan lebih jauh tingkat kepentingan dari *differencing*. Aturan umumnya adalah sebagai berikut.

a. Jika ACF mengalami penurunan dengan sangat lambat dan PACF *cuts off* setelah *lag* 1, diindikasikan bahwa diperlukan *differencing* $(1-B)V_t$.
b. Lebih umum, untuk menghilangkan ketidakstasioneran mungkin dibutuhkan untuk mempertimbangkan order *differencing* yang lebih tinggi $(1-B)^d V_t$ untuk $d > 1$. Kasus yang sering terjadi pada d adalah bernilai 0,1, atau 2.

Ketepatan transformasi dan *difference* dari deret (*series*) untuk mengidentifikasi orde p dan q (dimana diketahui bahwa p adalah orde dari *autoregressive polynomial* $(1-\phi_1 B-\ldots-\phi_p B^p)$ dan q adalah orde dari *moving average polynomial* $(1-\theta_1 B-\ldots-\theta_q B^q)$. Biasanya, orde p dan q kurang dari atau sama dengan 3.

Tabel 2.2 Karakteristik ACF dan PACF untuk Stasioneritas secara Teori

Proses	ACF	PACF
AR(p)	Turun cepat secara eksponensial (*dies down*)	Terputus setelah *lag* ke-p
MA (q)	Terputus setelah *lag* ke-p	Turun cepat secara eksponensial (*dies down*)
ARMA (p,q)	Turun cepat secara eksponensial menuju nol setelah lag (q-p)	Turun cepat secara eksponensial menuju nol setelah lag (p-q)

Autocorrelation Function (ACF) digunakan untuk melihat kestasioneran data terhadap mean dan juga digunakan untuk menunjukkan hubungan linier yang terjadi diantara pengamatan V_t dengan V_{t+k}. Korelasi antara V_t dengan V_{t+k} adalah sebagai berikut (Wei, 2006).

$$\hat{\rho}_k=\frac{\hat{\gamma}_k}{\hat{\gamma}_0}=\frac{\sum_{t=1}^{n-k}\left(V_t-\overline{V}\right)\left(V_{t+k}-\overline{V}\right)}{\sum_{i=1}^{n}\left(V_t-\overline{V}\right)^2},k=0,1,2,\ldots \qquad (2.7)$$

Partial Autocorrelation Function (PACF) digunakan untuk mengukur tingkat keeratan hubungan antara pengamatan V_t

dengan V_{t+k}. Secara umum rumus untuk perhitungan PACF sampai *lag* ke-*k* dijelaskan sebagai berikut (Wei, 2006).

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^{k} \hat{\phi}_{kj}\hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^{k} \hat{\phi}_{kj}\hat{\rho}_{j}} \tag{2.8}$$

dan $\hat{\phi}_{k+1,j} = \phi_{kj} - \hat{\phi}_{k+1,k+1}\hat{\phi}_{k,k+1-j}$, $j = 0,1,2,\ldots,k$.

Pengujian signifikansi parameter dilakukan untuk mengetahui signifikansi parameter model ARIMA sehingga dapat diketahui bahwa tiap variabel atau parameter dalam model telah signifikan. Pengujian hipotesis dilakukan dengan menggunakan uji *t*. Pengujian parameter AR adalah sebagai berikut.

H_0 : $\phi_i = 0$ (parameter AR tidak signifikan)

H_1 : $\phi_i \neq 0$ (parameter AR signifikan) dimana $i = 1,2,\ldots,p$

Statistik uji yang digunakan adalah sebagai berikut.

$$t = \frac{\hat{\phi}_i}{SE\left(\hat{\phi}_i\right)} \tag{2.9}$$

H_0 ditolak apabila nilai $|t_{\text{hitung}}|$ lebih besar dari $t_{\alpha/2,n-n_p}$ dengan n_p adalah banyaknya parameter. Hal tersebut juga dapat dilihat dari besar P-*value*, jika P-*value* kurang dari α sebesar 0,05 keputusan yang diambil adalah tolak H_0 maka dapat dikatakan parameter tersebut signifikan.

Apabila yang diuji parameter MA yaitu θ, maka hipotesis menjadi sebagai berikut.

H_0 : $\theta_j = 0$ (parameter MA tidak signifikan)

H_1 : $\theta_j \neq 0$ (parameter MA signifikan) dimana $j = 1,2,\ldots,q$

Statistik uji yang digunakan adalah sebagai berikut.

$$t = \frac{\hat{\theta}_j}{SE\left(\hat{\theta}_j\right)} \tag{2.10}$$

H_0 ditolak apabila $|t_{\text{hitung}}|$ lebih besar dari $t_{\alpha/2, n-n_q}$ dengan n_q adalah banyaknya parameter. Hal tersebut juga dapat dilihat dari besar P-*value*, jika P-*value* kurang dari α sebesar 0,05 keputusan yang diambil adalah tolak H_0 maka dapat dikatakan parameter tersebut signifikan.

Setelah melakukan uji signifikansi model selanjutnya dilakukan *diagnostic checking* model sehingga asumsi *white noise* sesuai persamaan dan berdistribusi normal. Untuk mengetahui apakah residual data memenuhi asumsi distribusi normal, dilakukan pengujian menggunakan uji *Kolmogorov-Smirnov* sebagai berikut.

H_0 : residual data berdistribusi normal

H_1 : residual data tidak berdistribusi normal

Statistik uji yang digunakan adalah sebagai berikut.

$$D = Sup\left|F_n(a_t) - F_0(a_t)\right| \tag{2.11}$$

$F_n(a_t)$ merupakan fungsi peluang komulatif dari data sampel, fungsi $F_0(a_t)$ merupakan nilai peluang komulatif dari distribusi normal. Apabila nilai D lebih besar dari nilai tabel Kolmogorov-Smirnov $D_{(1-\alpha),n}$ maka H_0 di tolak yang berarti bahwa residual data tidak memenuhi asumsi distribusi normal.

2.4 Analisis Intervensi

Model intervensi merupakan suatu model yang dipergunakan pada saat kejadian khusus diluar perkiraan yang mempengaruhi variabel yang diramalkan. Pada analisis intervensi diasumsikan bahwa kejadian terjadi pada waktu T yang diketahui dari suatu *time series*. Tujuan utama dari analisis ini adalah mengukur besar dan lamanya efek intervensi pada suatu *time series*. Bentuk umum dari model intervensi *multiple intervention inputs* adalah sebagai berikut (Wei, 2006).

$$V_t = \sum_{j=1}^{k} \frac{\omega_j(B)B^{b_j}}{\delta_j(B)} I_{jt} + \frac{\theta(B)}{\phi(B)} a_t \tag{2.12}$$

dengan,

V_t : volume transaksi harian perusahaan emiten

I_{jt} : variabel intervensi (bisa *step* atau *pulse function*), $j = 1, 2, \ldots, k$

$\omega_j(B) : \omega_0 - \omega_1 B - \omega_2 B^2 - \ldots - \omega_s B^s$

$\delta_j(B) : 1 - \delta_1 B - \delta_2 B^2 - \ldots - \delta_r B^r$

$\dfrac{\theta(B)}{\phi(B)} a_t = N_t$: *noise series*

b : *delay* waktu dimana efek intervensi mulai terjadi

r : lamanya pengaruh intervensi

s : pola dari efek intervensi

Secara umum ada dua jenis variabel intervensi, yaitu fungsi step (*step function*) dan fungsi *pulse* (*pulse function*). Intervensi pada waktu *T* yaitu waktu mulainya terjadi intervensi dan berlanjut pada waktu berikutnya. Pada kondisi ini variabel intervensi merupakan *step function* secara matematis dapat dinotasikan sebagai berikut.

$$I_{jt} = S_t^{(T_j)} = \begin{cases} 1, & t \geq T_j \\ 0, & t < T_j \end{cases} \tag{2.13}$$

Sedangkan pulse function adalah intervensi pada waktu T yaitu waktu terjadinya intervensi dan terjadi saat itu saja (tidak berlanjutsampai waktu selanjutnya). Secara matematis bentuk intervensi fungli pulse dinotasikan sebagai berikut.

$$I_{jt} = T_t^{(T_j)} = \begin{cases} 1, & t = T_j \\ 0, & t \neq T_j \end{cases} \tag{2.14}$$

2.5 *Generalized Autoregresive Conditional Heteroskedasticity*

Asumsi dalam digunakan dalam regresi biasanya varian *error* konstan. Namun, dalam kehidupan nyata asumsi varian *error* kontan tidak dapat dipenuhi seperti pada kasus keuangan. Karakteristik dari volatilitas adalah adanya *cluster volatility*, volatilitas berubah-ubah berdasarkan waktu, volatiitas berubah di rentang waktu tertentu, dan volatilitas memberikan perubahan/reaksi terhadap perubahan harga sehingga muncul istilah *Leverage Effect*, yang artinya berita buruk memberikan efek yang lebih besar dibandingkan berita baik (Tsay, 2013).

Model GARCH adalah pengembangan dari model ARCH yang dikenalkan oleh Engle (1982) yang telah berhasil diaplikasikan pada data keuangan dengan adanya *volatility cluster*. Terbntuknya *cluster volatility* menyebabkan data terkelompok dalam beberapa bagian (*cluster*) sesuai dengan keindetikan varian yang dimiliki sehingga bersifat tidak stasioner dalam varian. Padahal pemodelan data *time series* dilakukan berdasarkan asumsi homoskedastisitas pada varian *error* sehingga pemodelan dengan time series ARIMA saja tidak cukup (Tsay, 2013). Pada kasus heteroskedastisitas, model regresi dapat dituliskan dengan persamaan (2.15) sebagai berikut.

$$V_t = \mu_t + \varepsilon_t \tag{2.15}$$

dimana $V_t = (V_1, V_2, V_3, \ldots, V_n)$ nilai ε_t merupakan residual yang memiliki variansi yang berubah ubah sepanjang waktu *t*. Sehingga pada kasus heteroskedastisitas nilai ε_t dimodelkan.

$$\varepsilon_t = \sigma_t Z_t \tag{2.16}$$

Nilai Z_t meruapakan variabel random yang *white noise* normal dengan *mean* 0 dan variansi 1, nilai ε_t dimodelkan dengan menggunakan model ARCH untuk menangkap heteroskedastisitas tersebut. Model ARCH(r) secara umum dinyatakan pada persamaan (2.17).

$$\sigma_t^2 = \omega + \tau_1 \varepsilon_{t-2}^2 + \cdots + \tau_r \varepsilon_{t-r}^2 \text{ dimana } t = r+1, \ldots, n$$

$$\sigma_t^2 = \omega + \sum_{j=1}^{r} \tau_j \varepsilon_{t-j}^2 \tag{2.17}$$

dimana *n* merupakan jumlah sampel, *r* menunjukkan orde dari model ARCH dan σ_t^2 merupakan varian bersyarat dari *error*. Pada model ARCH(r) nilai σ_t^2 hanya dipengaruhi oleh kuadrat residual periode sebelumnya.

Pada tahun 1986, Bollerslev dan Taylor kemudian mengembangkan model ARCH menjadi model GARCH (*Generalized Autoregressive Conditional Heteroscedasticity*). Model GARCH ini digunakan untuk menghindari orde yang besar pada model ARCH. Berikut ini merupakan persamaan secara umum dari model GARCH dengan order (r, s).

$$\begin{gathered}\sigma_t^2 = \omega + \tau_1 \varepsilon_{t-1}^2 + \ldots + \tau_r \varepsilon_{t-r}^2 + \beta_1 \sigma_{t-1}^2 + \ldots + \beta_s \sigma_{t-s}^2 \\ \sigma_t^2 = \omega + \sum_{i=1}^{r} \tau_i \varepsilon_{t-i}^2 + \sum_{j=1}^{s} \beta_j \sigma_{t-j}^2\end{gathered} \tag{2.18}$$

berdasarkan persamaan di atas, ditunjukkan bahwa pada model GARCH(r, s), *conditional variance* dari *error* σ_t^2 tidak hanya dipengaruhi oleh kuadrat residual periode sebelumnya tetapi juga dipengaruhi oleh varian *error* pada periode sebelumnya. Dimana nilai parameter $\omega > 0,\ \tau > 0,$ dan $\beta > 0$ (Cryer & Chan, 2008).

Estimasi parameter pada model GARCH dapat dilakukan dengan metode *Maximum Likelihood Estimasion* (MLE). Metode MLE yang digunakan untuk mengestimasi parameter model GARCH ini, memaksimumkan fungsi *conditional likelihood* yaitu fungsi distribusi normal dari residual, berikut ini adalah perhitungan estimasi parameter model GARCH tersebut.

$$L\left(\beta, \tau \middle| Y\right) = \prod_{t=1}^{n} \left(\frac{1}{2\pi\sigma_t^2} \right)^{1/2} \exp\left(-\frac{\varepsilon_t^2}{2\sigma_t^2} \right) \tag{2.19}$$

$$\ln L\left(\beta, \tau \middle| Y\right) = \ln\left(\prod_{t=1}^{n} \left(\left(\frac{1}{2\pi\left(\sum_{i=1}^{r} \tau_i \varepsilon_{t-i}^2 + \sum_{j=1}^{s} \beta_j \sigma_{t-j}^2 \right)} \right)^{1/2} \exp\left(-\frac{\varepsilon_t^2}{2\left(\sum_{i=1}^{r} \tau_i \varepsilon_{t-i}^2 + \sum_{j=1}^{s} \beta_j \sigma_{t-j}^2 \right)} \right) \right) \right) \tag{2.20}$$

$$\ln L\left(\beta,\tau \middle| Y\right)=\sum_{t=1}^{n}\frac{1}{2}\left(\begin{array}{l}\left(-\ln\left(2\pi\right)-\ln\left(\sum_{i=1}^{r}\tau_i\varepsilon_{t-i}^2+\sum_{j=1}^{s}\beta_j\sigma_{t-j}^2\right)\right)\\ -\dfrac{\varepsilon_t^2}{\left(\sum_{i=1}^{r}\tau_i\varepsilon_{t-i}^2+\sum_{j=1}^{s}\beta_j\sigma_{t-j}^2\right)}\end{array}\right) \quad (2.21)$$

Sesuai persamaan (2.19), nilai σ_t^2 dimasukkan fungsi *conditional variance* dari model GARCH sesuai pada persamaan (2.18), dan diperoleh penghitungan fungsi ln *likelihood* seperti yang ditunjukkan pada persamaan (2.20).

Selanjutnya diperoleh estimasi parameter model GARCH (r,s) sesuai persamaan (2.21), dimana $\beta=\left(\beta_1,\beta_2,\ldots,\beta_s\right)$ dan $\tau=\left(\tau_1,\tau_2,\ldots,\tau_r\right)$ (Wei, 2006). Model yang telah dibentuk kemudian dilakukan pengujian signifikansi terhadap parameter model GARCH(r,s). Dimana parameter β menunjukkan model GARCH serta parameter τ menunjukkan model ARCH. Berikut adalah pengujian signifikansi parameter model ARCH dengan hipotesis adalah:

H_0 : $\tau_i=0$ dimana $i=1,2,3,\ldots,r$

H_1 : $\tau_i\neq 0$

$$t_{hitung}=\frac{\hat{\tau}_i}{SE(\hat{\tau}_i)} \quad (2.22)$$

Hipotesis diatas diuji dengan statistik uji sesuai persamaan (2.11) dimana H_0 ditolak jika $\left|t_{hitung}\right|$ lebih besar dari $t_{\left(1-\alpha/2\right),(n_i)}$ yang menunjukkan bahwa parameter model ARCH(r) telah signifikan. Nilai n adalah jumlah observasi dan n_i adalah banyaknya parameter dalam model ARCH(r). Selanjutnya pengujian signifikan parameter pada model GARCH(r,s) sesuai persamaan (2.23).

H_0 : $\beta_j=0$ dimana $j=1,2,3,\ldots,s$

H_1 : $\beta_j\neq 0$

$$t_{hitung} = \frac{\hat{\beta}_j}{SE(\hat{\beta}_j)} \tag{2.23}$$

Hipotesis diatas diuji dengan statistik uji sesuai persamaan (2.12) dimana H_0 ditolak jika $|t_{hitung}|$ lebih besar dari $t_{\left(1-\alpha/2\right),\left(n_j\right)}$ yang menunjukkan bahwa parameter model GARCH(r,s) telah signifikan. Nilai *n* adalah jumlah observasi dan n_j adalah banyaknya parameter dalam model GARCH(r,s).

2.6 Model *Error* Multiplikatif

Terdapat series data $\{x_t\}, t = 1,\ldots,T$, dimana $x_t \geq 0$ untuk semua t. Probabilitas bersyarat dari series data dapat dimisalkan sesuai persamaan (2.24) berikut.

$$P(x_t < \xi | x_{t-1},\ldots,x_1) > 0 \tag{2.24}$$

untuk semua $\xi > 0$ dan untuk semua t, probabilitas diatas berada pada nilai nol atau disekitar nol dimana x lebih besar dari nol. Kondisional *mean* dan varians dapat didefinisikan sesuai persamaan (2.25) berikut.

$$\mu_t \equiv E(x_t | x_{t-1},\ldots,x_1), \qquad \sigma_t^2 \equiv V(x_t | x_{t-1},\ldots,x_1) \tag{2.25}$$

Sehingga model linier dapat ditulis sesuai persamaan (2.26) di bawah ini.

$$x_t = \mu_t + \varepsilon_t, \quad \varepsilon_t | \Im_{t-1} \sim D(0,\sigma_t^2) \tag{2.26}$$

Sesuai persamaan (2.26) diperlukam ketepatan dalam memilih ditribusi yang tepat. Bila nilai *mean* positif dan x adalah *non negative*, maka distribusi tidak boleh lebih negatif dari *mean* apalagi nilai *error* berbeda pada setiap pengamatan. Varians atau momen yang lebih tinggi tidak mungkin bernilai konstan. Pendekatan dengan maksimum likelihood akan sangat rumit, meskipun nilai kuadrat tetap konstan. Probabilitas di sekitar nol dapat ditulis sesuai persamaan (2.27).

$$P_{t-1}(x_t < \xi) = P_{t-1}(\varepsilon_t < \xi - \mu_t) \tag{2.27}$$

maka distribusi dari *error* harus berhenti pada $-\mu_t$ untuk memenuhi persamaan (2.27) (Engle, 2002).

Multiplikasi *error* model pertama kali dikembangkan oleh (Engle, 2002) dimana model tersebut digunakan untuk mengestimasi data yang bernilai positif. Ekspektasi dari data tidak lagi berdistribusi normal yaitu 0 karena distribusi normal terdapat nilai negatif sehingga distribusi *error* dari data haruslah positif yaitu 1 bila distribusi data eksponensial dan γ apabila berdistribusi weibull. Variansi data pada model ini adalah σ_t dimana di setiap *t* selang waktu tertentu memiliki variasi yang berbeda. Ide awal MEM diketahui dari teori ekonometrik finansial dan besarasal dari model ARCH (*Autoregressive Conditional Heteroscedasticity*). MEM yang dinamis dari waktu antar perdagangan disebut ACD (*Autoregressive Conditional Duration*) model (Hautsch, 2012). Model MEM dapat ditulis dalam persamaan (2.28) sebagai berikut (Engle, 2002).

$$x_t = \mu_t \varepsilon_t \left| \Im_{t-1} \sim D(1, \phi_t^2) \right. \tag{2.28}$$

dimana $\mathrm{E}\left[\varepsilon_i \left| \xi_{i-1} \right.\right] = 1$

Nilai *mean* dan *error* model sesuai dengan persamaan (2.25) serta besarnya *error* mulai dari nol sampai tak hingga seperti pada (2.24). Jika *error* identik dan independen, maka varians x akan sebanding dengan kuadrat dari rata-ratanya. Jika *error* tidak identik dan independen maka distribusi non negatif yang digunakan memiliki varians yang berbeda-beda pada setiap t. Residual dari x_t dapat dihitung dengan standar deviasi porposional dengan mengestimasi *mean* sebagai residual standar yaitu x_t / μ_t. Ini akan menjadi homokedastisitas walaupun residual x_t aditif dengan $x_t - \hat{\mu}_t = \hat{\mu}_t (\varepsilon_t - 1)$ (Engle, 2002).

Estimasi MEM biasanya dapat dilakukan dengan maksimum distribusi residual yang telah ditentukan. Biasanya distribusi yang digunakan adalah eksponensial karena memiliki sifat non-negatif. Asumsi bahwa residual berdistribusi eksponenial dengan *mean* satu disebut unit eksponensial dengan fungsi *univariat log* *likelihood* dapat ditulis seperti persamaan (2.29) berikut dimana θ merupakan vektor dari parameter yang akan diestimasi. Fungsi orde pertama dari persamaan (2.29) dapat ditulis pada persamaan (2.30) berikut (Engle, 2002).

$$L(\theta) = \sum_{t=1}^{T} \left[-\log(\mu_t(\theta)) - \frac{x_t}{\mu_t(\theta)} \right] \quad (2.29)$$

$$\frac{\partial L}{\partial \theta} = \sum_{t=1}^{T} \left[\frac{x_t - \mu_t}{\mu_t^2} \frac{\partial \mu_t}{\partial \theta} \right] \quad (2.30)$$

MEM diperoleh bila x_t adalah *squared (de-meaned) log return* maka digunkan pendekatan GARCH(r,s) seperti persamaan (2.18) (Engle, 2002). Namun bila x_t adalah durasi volume transaksi harian, *bid-ask spread*, dan durasi maka menggunakan pendekatan ACD(r,s) untuk *error* (Hautsch, 2012).

2.7 Model *Autoregressive Conditional Duration*

Setelah mengetahui model dasar yang digunakan dalam penelitian ini yaitu MEM maka selanjutnya pendekatan untuk *error* dilakukan dengan ACD. Model ACD muncul karena semakin berkembang pasar finansial seperti transaksi saham mengakibatkan semakin banyak data yang tercatat dalam frekuensi tinggi. Model ACD diperkenalkan pertama kali oleh Robert F. Engle dan Jeffrey R. Russell pada tahun 1998.

$t_0, t_1, t_2, \ldots, t_n$ menunjukkan saat terjadinya transaksi dan *n* adalah banyaknya transaksi, serta x_i merupakan durasi antara dua waktu dimana pada penelitian ini ditentukan dari *threshold* sehingga $x_i = t_i - t_{i-1}$. Model ACD ditentukan oleh kondisi dimana ψ_i merupakan ekspektasi bersyarat dari durasi ke-*i* dengan waktu durasi sebelumnya, yang dinyatakan pada persamaan (2.31) (Tsay, 2013).

$$\psi_i = E\left(x_i \middle| F_{i-1}\right) \quad (2.31)$$

dimana F_{i-1} adalah informasi yang ada pada *t-1* atau dalam penelitian ini adalah durasi ke *t-1* dituliskan x_{i-1}. Sesuai persamaan (2.31) model umum ACD dapat dituliskan seperti (2.32).

$$x_i = \psi_i \in_i \qquad (2.32)$$

Diasumsikan bahwa standardized durasi adalah $\{\in_i\} := x_i / \psi_i$ dimana proses bersifat identik dan independen dengan *positive support* dimana $\mathrm{E}(\in_i) = 1$. $\in_i$ mengikuti distribusi eksponensial standar atau distribusi weibull standar dan ψ_i dibentuk dari persamaan (2.33). Model ACD dapat dianggap sebagai model GARCH untuk data durasi (Tsay, 2013).

$$\psi_i = \omega + \sum_{j=1}^{r} \tau_j x_{i-j} + \sum_{j=1}^{s} \beta_j \psi_{i-j} \qquad (2.33)$$

Persamaan (2.33) menunjukan suatu ekspektasi bersyarat dari durasi ke-i yang bergantung pada *r* langkah dari durasi dan *s* langkah dari ekspektasi durasi. Oleh karena itulah model tersebut dinamakan model $\mathrm{ACD}(r,s)$. Sama seperti model GARCH $\eta_i = x_i - \psi_i$ adalah perbedaan urutan martingale $E(\eta_i | F_{i-1}) = 0$ sehinga model $\mathrm{ACD}(r,s)$ dapat ditulis seperti persamaan (2.34) (Tsay, 2013).

$$x_i = \omega + \sum_{j=1}^{\max(r),s} (\tau_j + \beta_j) x_{i-j} + \sum_{j=1}^{s} \beta_j \eta_{i-j} + \eta_j \qquad (2.34)$$

dimana merupakan model ARMA dengan inovasi non-Gaussian dengan $\tau_j = 0$ untuk $j > r$ dan $\beta_j = 0$ untuk $j > s$. Model dapat digunakan bila memenuhi asumsi stasioneritas seperti persamaan (2.35)

$$E(x_i) = \frac{\omega}{1 - \sum_{j=1}^{\max(r,s)} (\tau_j + \beta_j)} \qquad (2.35)$$

Diasumsikan bahwa $\omega > 0$ dan $1 > \sum_{j=1}^{\max(r,s)} \left(\tau_j + \beta_j\right)$ karena ekspektasi dari durasi adalah positif. Apabila *error* dalam persamaan diatas berdistribusi eksponensial maka model di atas disebut model *Exponential Autoregressive Conditional Duration* (EACD(r,s)). Serta apabila *error* dalam persamaan (2.36) berdistribusi weibull maka model di atas disebut model *Weibull Autoregressive Conditional Duration* (WACD(r,s)).

$EACD(1,1)$ dapat ditulis sesuai persamaan (2.36) berikut.

$$x_i = \psi_i \in_i \qquad \psi_i = \omega + \tau_1 x_{i-1} + \beta_1 \psi_{i-1} \tag{2.36}$$

dimana $\in_i$ mengikuti distribusi eksponensial standar. Mengukuti distribusi eksponensial standar dengan parameter $\lambda > 0$ seperti persamaan (2.37).

$$f\left(\in \middle| \lambda\right) = \begin{cases} \dfrac{1}{\lambda} e^{-\in/\lambda} \\ 0, \text{ untuk yang lain} \end{cases} \tag{2.37}$$

$\in \sim \exp(\lambda)$ sehingga $E(\in) = \lambda$ dan $Var(\in) = \lambda^2$ maka diperoleh CDF dari $\in$ sebagai berikut.

$$F\left(\in \middle| \lambda\right) = \begin{cases} 0, \text{ jika } \in < 0 \\ 1 - e^{-\in/\lambda}, \text{ jika } \in \geq 0 \end{cases}$$

Jika $\lambda = 1$ maka $\in$ berdistribusi eksponensial standar. Berdasarkan jabaran mengenai distribusi eksponensial standar maka $E(\in_i) = 1$, $Var(\in_i) = 1$ serta $E(\in_i^2) = Var(x_i) + \left[E(x_i)\right]^2 = 2$. Diasumsikan x_i stasioner maka dapat dicari varian dari x_i dari persamaan ekspektasi sesuai persamaan (2.38) berikut.

$$\begin{aligned} E(x_i) &= E\left[E(\psi_i \in_i \middle| F_{i-1})\right] = E(\psi_i) \\ E(\psi_i) &= \omega + \tau_1 E(x_{i-1}) + \beta_1 E(\psi_{i-1}) \end{aligned} \tag{2.38}$$

Asumsi stasioner maka $E(\psi_i) = E(\psi_{i-1})$ sehingga diperoleh persamaan (2.39).

$$\mu_x \equiv E(x_i) = E(\psi_i) = \frac{\omega}{1-\tau_1-\beta_1} \qquad (2.39)$$

Karena $E(\in_i^2)=2$ maka $E(x_i^2)=E\left[E(\psi_i^2 \in_i^2 \left| F_{i-1})\right.\right]=2E(\psi_i^2)$. Akar dari ψ_i pada persamaan (2.36) beserta ekspektasinya serta ψ_i dan x_i stasioner persamaan dapat dibentuk seperti (2.40).

$$E(\psi_i^2) = \mu_x^2 \times \frac{1-(\tau_1-\beta_1)^2}{1-2\tau_1^2-\beta_1^2-2\tau_1\beta_1} \qquad (2.40)$$

dengan menggunakan $Var(x_i)=E(x_i^2)+\left[E(x_i)\right]^2$ dan $E(x_i^2)=2E(\psi_i^2)$ maka diperoleh persamaan (2.41).

$$Var(x_i) = 2E(\psi_i^2)-\mu_x^2 = \mu_x^2 \times \frac{1-\beta_1^2-2\tau_1\beta_1^2}{1-\beta_1^2-2\tau_1\beta_1-2\tau_1^2} \qquad (2.41)$$

dimana μ_x sesuai persamaan (2.39). Hasil persamaan diatas menunjukkan bahwa untuk membentuk *uncondisional time-univariant varians* yaitu EACD$(1,1)$ sesuai model (2.36) maka $1>\beta_1^2-2\alpha_1\beta_1-2\beta_1^2$ harus dipenuhi.

Hasil yang sama dapat diperoleh untuk model WACD(r,s). Untuk WACD$(1,1)$ dilakukan dengan cara yang sama hanya menggunakan distribusi weibull standar (Tsay, 2013). $\in_i$ berdistribusi weibull dengan parameter bentuk $\gamma>0$ dan parameter skala $\lambda>0$ memiliki fungsi kepadatan probabilitas (pdf) dan fungsi distribusi komulatif (CDF) masing-masing sesuai persamaan berikut.

$$f\left(\in \middle| \gamma,\lambda\right) = \begin{cases} \dfrac{\gamma}{\lambda^\gamma} \in^{\gamma-1} e^{-(\in/\lambda)^\gamma}, \text{ jika } \in \geq 0 \\ 0, \text{ untuk yang lainnya} \end{cases}$$

$$F\left(\in \middle| \gamma,\lambda\right) = \begin{cases} 0, \text{ jika } \in < 0 \\ 1-e^{-(\in/\lambda)^\gamma}, \text{ jika } \in \geq 0 \end{cases}$$

Error Eksponensial-ACD dapat dilihat pada persamaan (2.42). Weibull-ACD dapat dilihat pada persamaan (2.43) (Engle & Russell, 1998).

$$\varepsilon_t \sim Exp(1), \theta_{\mathrm{E}} = (\omega, \tau, \beta)^{\mathrm{T}}, \tau = (\tau_1, ..., \tau_p), \beta = (\beta_1, ..., \beta_q) \qquad (2.42)$$

$$\varepsilon_t \sim W(\gamma, 1), \theta_w = (\omega, \tau, \beta, \gamma)^{\mathrm{T}} \qquad (2.43)$$

Forecasting model EACD dapat diperoleh dengan menggunakan prosedur yang sama dengan model GARCH. Model EACD$(1,1)$ dengan *forecast origin* adalah $i = h$. Untuk *forecast* langkah kedepan model dinyatakan $x_{h+i} = \psi_{h+1} \in_{h+1}$ dengan $\psi_{h+1} = \omega + \tau_1 x_h + \beta_1 \psi_h$. Perhitungan $x_h(1)$ *foresast* satu langkah kedepan dengan origin *h* sesuai persamaan (Tsay, 2013) (2.44).

$$x_h(1) = E(x_{h+1} | F_h) = E(\psi_{h+1} \in_{h+1}) = \psi_{h+1} \qquad (2.44)$$

diketahui bahwa $i = h$. *Forecast error* adalah $e_h(1) = x_{h+1} - x_h(1) = \psi_{h+1}(\in_{h+1} - 1)$. Kondisional varians dari *forecast error* adalah ψ_{h+1}^2. Untuk *forecast* multi langkah kedepan digunakan $x_{h+j} = \psi_{h+j} \in_{h+j}$ sehingga untuk *j=2* dapat ditulis sesuai (2.45)

$$\begin{aligned} \psi_{h+2} &= \omega + \tau_1 x_{h+1} + \beta_1 \psi_{h+1} \\ \psi_{h+2} &= \omega + (\tau_1 + \beta_1) x_{h+1} + \beta_1 \psi_{h+1} (\in_{h+1} - 1) \end{aligned} \qquad (2.45)$$

Sehingga *forecast* 2 langkah kedepan daapat ditulis seperti persamaan (2.46) dan *forecast error* sesuai (2.47).

$$\begin{aligned} x_h(2) &= E(\psi_{h+2} \in_{h+2}) \\ x_h(2) &= \omega + (\tau_1 + \beta_1) \psi_{h+1} = \omega + (\tau_1 + \beta_1) x_h(1) \end{aligned} \qquad (2.46)$$

$$\begin{aligned} e_h(2) &= \omega(\in_{h+2} - 1) + \tau_1 \psi_{h+1} \\ &(\in_{h+2} \in_{h+1} - 1) + \beta_1 \psi_{h+1} (\in_{h+2} - 1) \end{aligned} \qquad (2.47)$$

Secara umum *forecast* dapat ditulis sesuai persamaan (2.48).

$$x_h(m) = \omega + (\tau_1 + \beta_1) x_h(m-1), \ m > 1 \qquad (2.48)$$

Bila ditulis dalam subtitusi berulang rumus *forecasting* dapat ditulis sebagai (2.49) berikut. Jika $\tau_1 + \beta_1 < 1$ maka ditulis sesuai persamaan (2.50)

$$x_h(m) = \frac{\omega\left[1-(\tau_1+\beta_1)^{m-1}\right]}{1-\tau_1-\beta_1} + (\tau_1+\beta_1)^{m-1} x_h(1) \quad (2.49)$$

$$x_h(m) = \frac{\omega}{1-\tau_1-\beta_1}, \text{ dimana } m = \infty \quad (2.50)$$

$\eta_j = x_j - \psi_j$ maka $E(\eta_j) = 0$ dan $E(\eta_j \eta_t) = 0$ untuk $t \neq j$. η_j merupakan variabel yang tidak identik. Melalui perhitungan $\psi_j = x_j - \eta_j$ dapat diperoleh model EACD(r,s) sesuai (2.51).

$$x_i = \omega + \sum_{j=1}^{g} (\tau_j - \beta_j) x_{i-j} + \eta_i - \sum_{j=1}^{s} \beta_i \eta_{i-j} \quad (2.51)$$

dimana $g = \max\{r,s\}$ sehingga dapat diketahui bahwa $\tau_j = 0$ untuk $j > r$ dan $\gamma_j = 0$ untuk $j > s$.

2.8 Estimasi *Autoregressive Conditional Duration*

Untuk model ACD(r,s) maka $i_0 = \max(r,s)$ dan $x_t = (x_1, \ldots, x_t)'$. Fungsi likelihood pada durasi $x_1, \ldots, x_T$ seperti pada persamaan (2.52) di bawah.

$$f\left(x_T \mid \boldsymbol{\theta}\right) = \left[\prod_{i=i_0+1}^{T} f\left(x_i \mid F_{i-1}, \boldsymbol{\theta}\right)\right] \times f\left(x_{i_0} \mid \boldsymbol{\theta}\right) \quad (2.52)$$

dimana $\boldsymbol{\theta}$ merupakan vektor parameter model dan T adalah ukuran sampel. Fungsi kepadatan peluang marjinal (pdf) $f\left(x_{i_0} \mid \boldsymbol{\theta}\right)$ pada persamaan (2.52) sedikit rumit untuk model umum ACD. Karena akibat dari fungsi likelihood ukuran sampel T meningkat, maka fungsi kepadatan peluang ini sering diabaikan, sehingga menggunakan metode likelihood bersyarat. Untuk model WACD digunakan pdf seperti (2.53) diperoleh fungsi log likelihood bersyarat.

$$\ell\left(x\middle|\boldsymbol{\theta},x_{i_0}\right)=\sum_{i=i_0+1}^{T}\boldsymbol{\gamma}\ln\left[\Gamma\left(1+\frac{1}{\boldsymbol{\gamma}}\right)\right]+\ln\left(\frac{\boldsymbol{\gamma}}{x_i}\right)$$

$$+\gamma\ln\left(\frac{x_i}{\psi_i}\right)-\left(\frac{\Gamma\left(1+\frac{1}{\gamma}\right)x_i}{\psi_i}\right)^{\alpha} \tag{2.53}$$

dimana $\psi_i=\omega+\sum_{j=1}^{r}\tau_j x_{i-j}+\sum_{j=1}^{s}\beta_j\psi_{i-j}$, $\boldsymbol{\theta}=(\omega,\tau_1,\ldots,\tau_r,\beta_1,\ldots\beta_s,\gamma)'$ dan $x=(x_{i_0},\ldots,x_T)'$. Bila, $\gamma=1$ turunan fungsi log likelihood bersyarat menjadi model EACD(r,s) (Tsay, 2013). Fungsi gamma (x) dapat ditulis sebagai berikut.

$$\Gamma(x)=\int_0^{\infty}\beta^{x-1}\exp^{-\beta}\,dx$$

konvergen untuk $x>0$

2.9 Perumusan Model *Autoregressive Conditional Duration*

Sebelum masuk ke tahapan perumusan model ACD untuk menentukan durasi data terlebih dahulu dihitung nilai residual ARMA-GARCH. Nilai residual yang lebih kecil dari nol diberi nilai 1 dan yang lebih besar dari nol diberi nilai 0. Hal ini diambil dari konsep pengelolaan risiko dimana efek negatif lebih memiliki andil dibanding efek positif (Tsay, 2013). Artinya berita buruk pada perusahaam emiten memiliki efek lebih tinggi dibanding berita baik. Maka model ACD dibentuk melalui tahapan yakni :

a. Menghitung durasi

Tahap awal dalam pengujian model ACD adalah dengan menghitung durasi atau interval antara dua waktu kejadian yaitu $X_i=t_i-t_{i-1}$, dengan X_i adalah durasi ke-i, t_i adalah saat kejadian ke-i yang nilai residual yang lebih kecil dari nol, dan t_{i-1} adalah kejadian yang terjadinya sebelumnya (Christoffersen & Pelletier, 2003).

b. Pemeriksaan adanya efek ACD

Pemeriksaan adanya efek ACD dengan menggunakan *correlogram* atau ACF dan Uji Ljung Box. Jika tidak ada efek ACD maka ACF dan PACF seharusnya adalah nol pada semua *lag* atau secara statistik tidak signifikan. Uji Ljung Box mengikuti distribusi khi-kuadrat dengan derajat kebebasan (db) sebesar m (lag maksimum). Jika nilai Ljung Box lebih kecil dari nilai kritis statistik dari tabel distribusi khi-kuadrat maka tidak ada efek ACD dalam data. Sebaliknya jika nilai Ljung Box lebih besar dari nilai kritis statistik dari tabel distribusi khi-kuadrat maka data mengandung efek ACD. Persamaan uji Ljung Box pada langkah ini sesuai (2.58).

c. Pengujian distribusi durasi

Pengujian distribusi data durasi yaitu Eksponensial dan Weibull mensyaratkan bahwa durasi harus memiliki sifat *memory less* dan rata-rata adalah $1/p$. Distribusi yang memiliki sifat *memory less* adalah eksponensial dengan hipotesis:

H_0 : data durasi bersifat memory less (berdistribusi eksponensial) sehingga $\lambda = 1$

H_1 : data durasi tidak bersifat memory less (berdistribusi weibull sehingga $\lambda \neq 1$

Berdasarkan hipotesis nol didapat distribusi durasi yang digunakan adalah:

$$f_{\exp} = (x, \lambda) = \lambda \exp(-\lambda x) \qquad (2.54)$$

dimana eksponensial memiliki *hazard function* sesuai persamaan:

$$\lambda_{\exp}(x) = \frac{f_{\exp}(x)}{1 - F_{\exp}(x)} = \lambda \qquad (2.55)$$

Menguji independensi secara statistik harus membuat alternatif yang dapat menunjukkan dependensi durasi dengan mengikuti distribusi weibull yang dapat dituliskan seperti persamaan (2.58)

$$f_w = (x, \gamma, \lambda) = \gamma^{\lambda} \lambda x^{\lambda - 1} \exp(-(\gamma x)^{\lambda}) \qquad (2.58)$$

dimana weibull memiliki keuntungn bahwa *hazard function* memiliki bentuk *closed form* pada persamaan (2.56).

$$\lambda_{\exp}(x) = \frac{f_{\exp}(x)}{1 - F_{\exp}(x)} = \lambda \tag{2.56}$$

Dimana distribusi eksponensial muncul sebagai kasus khusus dengan error yang sama, ketika $\lambda = 1$. Distribusi weibull dapat mengurangi hazard function ketika $\lambda < 1$, yang sesuai dengan jumlah yang berlebihan dari durasi yang singkat dan jumlah yang berlebihan dari durasi yang panjang.

d. Estimasi parameter model EACD dan WACD
e. Pemeriksaaan Diagnostik Model (Pengujian Asumsi Residual Model)

Pemeriksaan diagnostik dilakukan untuk mengetahui apakah data *time series* tersebut masih mengandung autokorelasi atau tidak. Hal tersebut dapat dilakukan dengan menggunakan analisis residual yaitu dengan menggunakan uji independensi residual. Uji independensi residual dari autokorelasi sekumpulan residual yang telah diperoleh digunakan untuk mendeteksi ada tidaknya korelasi residual antar *lag*. Suatu proses τ_t dikatakan *white noise* jika τ_t bersifat identik dan independen terhadap fungsi distribusi yang lain dengan $E(\tau_t) = 0$ dan $\text{var}(\tau_t) = \sigma^2$ (Wei, 2006). Secara matematis, α_t yang *white noise* akan mengikuti fungsi ACF dan PACF yang ditunjukkan sesuai persamaan (2.57) berikut.

$$\rho_k = \begin{cases} 1, k = 0 \\ 0, k \neq 0 \end{cases} \text{ dan } \phi_{kk} = \begin{cases} 1, k = 0 \\ 0, k \neq 0 \end{cases} \tag{2.57}$$

Pengujian asumsi *white noise* dilakukan dengan menggunakan uji Ljung Box yang didasarkan pada nilai ACF dengan hipotesis sebagai berikut.

H_0 : $\rho_1 = \rho_2 = \ldots = \rho_K = 0$ (residual *white noise*)

H_1 : minimal ada satu $\rho_k \neq 0$ dengan $k = 1, 2, 3, \ldots, K$ (residual tidak *white noise*)

Statistik uji yang digunakan pada pengujian ini ditulis sesuai persamaan (2.58) dengan *n* adalah banyaknya data, *k* adalah lag waktu, dan $\hat{\rho}_k^2$ adalah nilai autokorelasi lag ke-k dari deret waktu.

$$Q = n(n+2)\sum_{k=1}^{K}\frac{\hat{\rho}_k^2}{(n-k)} \quad (2.58)$$

Nilai Q dibandingkan dengan nilai tabel $\chi^2_{\alpha,db}$ (Wei, 2006). H_0 ditolak jika $Q > \chi^2_{\alpha,db}$ yang menunjukkan bahwa residual tidak memenuhi asumsi *white noise*.

2.10 Kriteria Pemilihan Model

Pendugaan model biasanya tidak tunggal sehingga diperlukan suatu kriteria tertentu untuk memilih model terbaik dari beberapa model yang diperolah. Terdapat dua kriteria yang digunakan sebagai alternatif memilih model yaitu *AIC* (*Akaike's Information Criterion*) dan *SBC* (*Schwarz's Bayesian Criterion*). Kriteria pemilihan model ini berdasarkan kemungkinan log. *AIC* ditulis pada persamaan (2.59) (Ruppert, 2004).

$$AIC = -2\log(L) + 2(p+q) \quad (2.59)$$

dengan p dan q adalah jumlah parameter dalam model dan L adalah kemungkinan yang telah dievaluasi pada MLE. Model *SBC* dapat ditulis sesuai persamaan (2.60).

$$SBC = -2\log(L) + \log(n)(p+q) \quad (2.60)$$

dengan n adalah jumlah periode waktu (jumlah data). Model terbaik adalah dengan nilai *AIC* dan *SC* terendah. Kedua kriteria di ats akan cenderung untuk memilih model yang memiliki nilai kemungkinan terbesar. Ini masuk akal karena nilai L yang besar berarti data yang di observasi kemungkinan besar menggunakan model tersebut (Ruppert, 2004).

Dari persamaan diketahui bahwa log(n) > 2 jika $n \geq 8$. Oleh karena kebanyakan series waktu lebih dari 8, SBC membebankan $p+q$ lebih banyak daripada yang dilakukan kriteria AIC. Oleh karena itu AIC akan cenderung memilih model yang memiliki banyak parameter daripada model yang dipilih menggunakan SBC. Pada AIC digunakan *trade off* yang lebih mendukung nilai L yang besar daripada nilai $p+q$ yang kecil (Ruppert, 2004).

Adanya perbedaan antara AIC dan SBC ini dikarenakan cara metode ini didesain. AIC didesain untuk memilih model yang akan memiliki prediksi terbaik dan tanpa banyak memperhatikan faktor lain dengan memiliki sangat banyak parameter. SBC didesain untuk menentukan nilai *p* dan *q* yang sebenarnya. Namun, dalam prakteknya model terbaik dari AIC biasanya mirip dengan model terbaik dari SBC dan sering juga merupakan model yang sama. Karena AIC dan SBC berdasar pada *log-likelihood*, penggunaan salah satu kriteria ini sangat mirip dengan *likelihood ratio test* (Ruppert, 2004).

(Halaman ini sengaja dikosongkan)

BAB III
METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari *finance.yahoo.com* dengan struktur data disajikan dalam tabel 3.1 dimana t menunjukkan periode waktu dan $V_{m,t}$ menunjukkan volume transaksi untuk satu bank.

Tabel 3.1 Struktur Data Penelitian Sebelum *Tax Amnesty*

Tahun	Bulan	Tanggal	t	$V_{m,t}$	Residual ARMA-GARCH	Dummy ($D_{m,t}$)	Durasi ($X_{m,i}$)
2010	Januari	4	1	$V_{m,1}$	…	1	$X_{m,0}$
		5	2	$V_{m,2}$	…	0	
		6	3	$V_{m,3}$	…	1	$X_{m,1}$ = 3-1 = 2
		⋮	⋮	⋮	⋮	⋮	⋮
		29	20	$V_{m,20}$	…	0	…
	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	Desember	1	499	$V_{m,499}$	…	…	…
		2	500	$V_{m,500}$	…	…	…
		3	501	$V_{m,501}$	…	…	…
		⋮	⋮	⋮	⋮	⋮	⋮
		30	520	$V_{m,520}$	…	…	…
…	…	…	…	…	…	…	…
…	…	…	…	…	…	…	…
…	…	…	…	…	…	…	…
2016	Januari	1	1565	$V_{m,1565}$	…	…	…
		2	1566	$V_{m,1566}$	…	…	…
		3	1567	$V_{m,1567}$	…	…	…
		⋮	⋮	⋮	⋮	⋮	⋮
		29	1585	$V_{m,1585}$	…	…	…

Tabel 3.2 Struktur Data Penelitian Sebelum *Tax Amnesty* (Lanjutan)

Tahun	Bulan	Tanggal	t	$V_{m,t}$	Residual ARMA-GARCH	Dummy ($D_{m,t}$)	Durasi ($X_{m,i}$)
2016	…	…	…	…	…	…	…
	…	…	…	…	…	…	…
	…	…	…	…	…	…	…
	Juni	1	1673	$V_{m,1673}$	…	…	…
		2	1674	$V_{m,1674}$	…	…	…
		3	1675	$V_{m,1675}$	…	…	…
		⋮	⋮	⋮	⋮	⋮	⋮
		30	1694	$V_{m,1694}$	…	1	…

dimana m = 1, 2, 3, 4 merupakan kode untuk masing-masing emiten serta *dummy* (D_t) merupakan nilai 0 dan 1 untuk menentukan durasi, dimana nilai 0 jika nilai residual model ARMA-GARCH lebih besar dari nol.

$$D_{m,t} = \begin{cases} 1, \text{ jika residual ARMA-GARCH} < 0 \\ 0, \text{ jika residual ARMA-GARCH} \geq 0 \end{cases}$$

X_{m,t^*} adalah data durasi yang dianalisis dengan syarat $X_{m,t} > 0$ dimana $t^* = 1, 2, \ldots, l$. Struktur data untuk periode selama *Tax Amnesty* berlangsung dihitung sama dengan tabel 3.1 hanya tahun dan bulan berbeda sesuai periode *Tax Amnesty* yaitu 1 Juli 2016 sampai 31 Maret 2017.

Variabel yang digunkan dalam analisis intervensi dalam penelitian ini adalah *dummy* bernilai 1 pada analisis intervensi dapat dijelaskan pada tabel 3.3 berikut.

Tabel 3.3 Variabel Intervensi

Kejadian Intervensi (T)	Waktu
Tax Amnesty	1 Juli 2016 – 31 Maret 2017

Di situs *finance.yahoo.com* didapatkan data volume transaksi saham perusahaan sektor perbankan yang memiliki kapital besar yaitu Bank Central Asia $V_{1,t}$ dengan kode emiten BBCA, Bank

Mandiri $V_{2,t}$ dengan kode emiten BMRI, Bank Rakyat Indonesia $V_{3,t}$ dengan kote emiten BBRI, dan Bank Negara Indonesia $V_{4,t}$ dengan kote emiten BBNI. Volume perdagangan merupakan suatu instrumen yang dapat digunakan untuk melihat reaksi pasar modal terhadap informasi melalui parameter volume saham yang diperdagangkan di pasar dimana diambil dari 4 Januari 2010 sampai dengan 31 Maret 2017. Pemilihan periode tersebut didasarkan pada krisis finansial global karena jatuhnya "Lehman Brother" yang merupakan bank investasi raksasa ke-4 di Amerika Serikat pada tanggal 15 September 2008 akibat dari *Suprime Mortage*. Jatuhnya perusahaan tersebut menyababkan turunnya perekonomian global dan kondisi ekonomi cenderung tidak stabil. Selain itu penggunaan periode sampai dengan Maret 2017 adalah karena kebijakan *Tax Amnesty* diakhiri pada Maret 2017.

3.2 Langkah Analisis

Metode analisis yang digunakan dalam penelitian ini adalah metode intervensi dan Model *Error* Multiplikatif secara univariat dengan pendekatan ACD. Analisis ACD dilakukan pada dua periode yakni periode 1 mulai 4 Januari 2010 sampai 30 Juni 2016 sebelum *Tax Amnesty* berlangsung dan periode 2 mulai 1 Juli 2016 sampai 31 Maret 2017 yaitu periode selama *Tax Amnesty* berlangsung. Masing-masing saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia akan dimodelkan seperti langkah berikut.

1. Data di *download* di situs *finance.yahoo.com* dengan memasukkan kode perusahaan emiten yang sahamnya akan dianalisis dan menentukan rentang waktu saham yang akan di *download*.
2. Analisis fokus pada volume transaksi harian saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia.
3. Melakukan analisis eksplorasi data volume transaksi saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia sehingga dapat mengetahui gambaran data secara visual.

4. Menggambarkan data volume transaksi saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia dengan *time series plot*.
5. Melakukan analisis intervensi untuk data volume transaksi saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia.
   a. Membagi data volume harian saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia menjadi dua yaitu sebelum intervensi dan selama intervensi
   b. Memodelkan volume transaksi saham harian dengan model ARIMA dari data sebelum intervensi
   c. Identifikasi pola dengan *time series plot* untuk melihat stasioneritas data volume transaksi harian masing-masing saham dalam *mean* dan varians
   d. Jika tidak stasioner dalam variansi maka dilakukan transformasi *Box-cox* dan jika tidak stasioner dalam mean maka dilakukan *differencing*
   e. Identifikasi dugaan model dengan ACF dan PACF dari data volume transaksi harian yang telah stasioner dalam *mean* dan varians
   f. Melakukan estimasi parameter model dan uji signifikansi parameter. Pada tahapan ini dipilih model yang semua parameternya signifikan dari masing-masing perusahaan
   g. Pemeriksaan asumsi residual *white noise* dan distribusi normal (Uji *Kolmogorov Smirnov*) pada masing-masing model yang terbentuk
   h. Pemilihan model ARIMA terbaik menggunakan kriteria AIC dan SBC dari saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia terendah
   i. Melakukan identifikasi orde model intervensi dan menentukan (*b,r,s*) dilihat dari plot residual yang signifikan
   j. Estimasi parameter dan uji signifikansi parameter model intervensi saham Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia

k. Pemeriksaan diagnosa dengan pengujian asumsi residual *white noise* dan distribusi normal (Uji *Kolmogorov Smirnov*) pada masing-masing model intervensi yang telah dibentuk

Setelah itu adalah tahapan analisis MEM-ACD sebagai model alternatif atau model lain di luar analisis intevensi.

6. Melakukan pemodelan ARMA-GARCH dan residualnya digunakan untuk menetukan durasi pada masing-masing perusahaan. Bila nilai residual kurang dari 0 diberi nilai 1, namun bila nilai residual lebih dari 1 diberi nilai 0.
7. Menghitung durasi saham masing-masing perusahaan dengan menghitung jarak antar kejadian yang bernilai 1 pada residual ARMA-GARCH
8. Melakukan pengujian distribusi eksponensial dan weibull dari data durasi masing-masing perusahaan
9. Memodelkan durasi dari saham dengan menggunakan model ACD baik Eksponensial ACD atau Weibull ACD dengan langkah-langkah sebagai berikut.
   a. Pemeriksaan efek ACD dari durasi volume transasksi saham harian Bank Central Asia, Bank Mandiri, Bank Rakyat Indonesia, dan Bank Negara Indonesia
   b. Identifikasi dugaan model dengan ACF dan PACF dari data durasi kuadrat
   c. Estimasi parameter model EACD dan WACD dari durasi volume transasksi saham harian masing-masing perusahaan.
   d. Pemeriksaaan diagnostik model EACD dan WACD.
   e. Pemilihan model EACD atau WACD terbaik menggunakan kriteria AIC dan SBC terendah.
10. Membandingan likuiditas saham pada periode sebelum *Tax Amnesty* dan selama *Tax Amnesty* berlangsung.

3.3 Diagram Alir

Langkah analisis yang telah disebutkan dalam poin 3.2 dapat ditulis secara ringkas dalam bentuk diagram alir sebagai berikut.

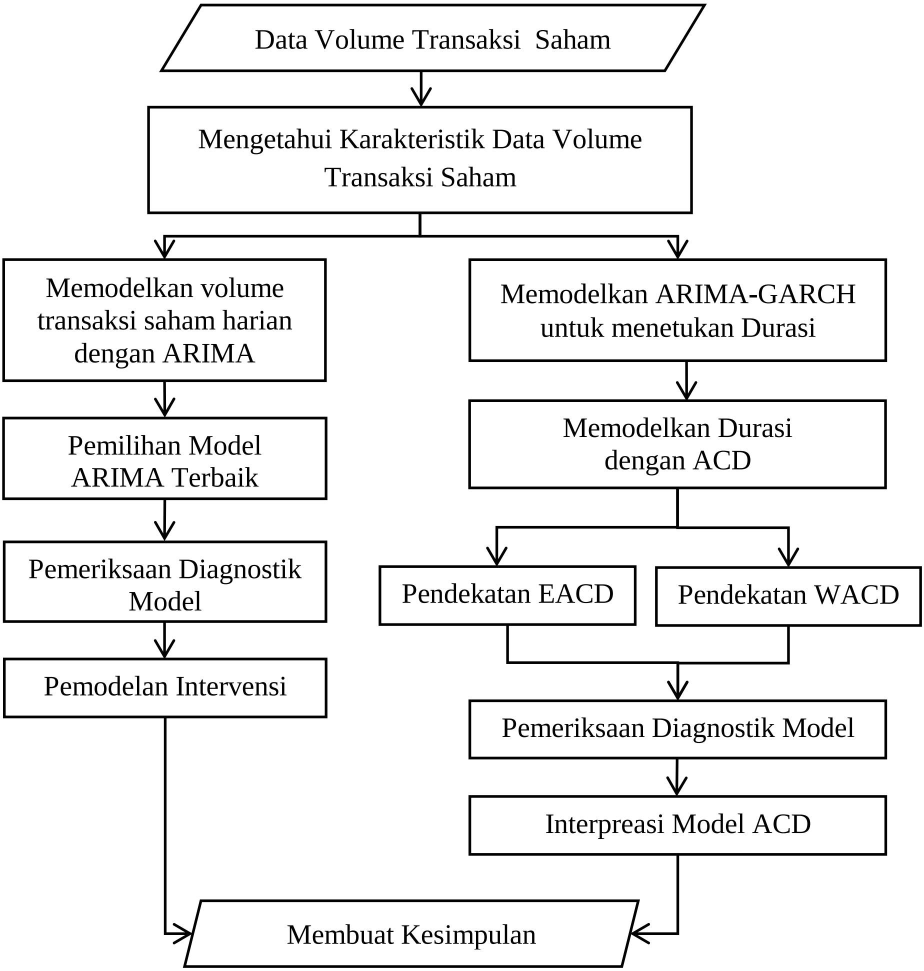

Gambar 3.1 Diagram Alir Analisis

BAB IV
ANALISIS DAN PEMBAHASAN

Bagian ini akan dibahas hasil analisis volume transaksi saham sektor perbankan yaitu Bank Central Asia (BBCA), Bank Mandiri (BMRI), Bank Rakyat Indonesia (BBRI), dan Bank Negara Indonesia (BBNI) yang terdampak *Tax Amnesty*. Hasil analisis meliputi analisis deskriptif, anlisis intervensi untuk mengetahui efek *Tax Amnesty*, dan analisis *Autoregressive Conditional Duration* dari dara durasi untuk mengetahui perubahan likuiditas sebelum dan selama *Tax Amnesty*.

4.1 Deskripsi Volume Transaksi Saham

Analisis deskriptif data volume transaksi saham dilakukan untuk mengetahui karakteristik volume transaksi saham perusahaan BBCA, BMRI, BBRI, dan BBNI. Perhitungan statistik deskriptif keempat perusahaan sesuai gambar 4.1 dan tabel 4.1.

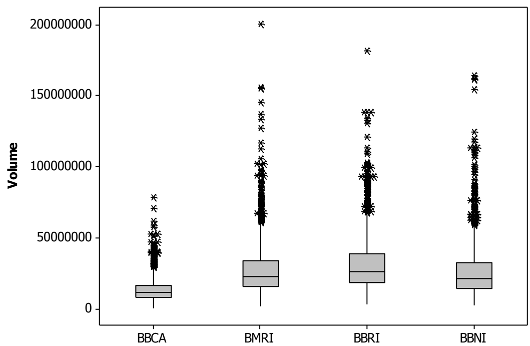

Gambar 4.1 Boxplot Volume Transaksi Saham

Gambar 4.1 diketahui bahwa volume transaksi saham harian BBCA, BMRI, BBRI, dan BBNI menunjukkan median masing-masing yaitu 11801700, 22764000, 26130750, 21644200. Volume transaksi harian BBRI lebih tinggi dibanding tiga saham sektor perbankan lainnya selama periode 4 Januari 2010 sampai 31 Maret 2017. Dilihat secara visual rentang boxplot BBCA lebih kecil dibanding tiga saham lain, yang artinya volatilitas tansaksi saham BBCA lebih rendah dibanding tiga saham yaitu BMRI, BBRI, dan BBNI. Outlier pada volume transaksi saham menunjukan bahwa banyak volume transaksi saham bernilai lebih besar dari batas atas. Nilai batas atas volume transaksi saham harian BBCA, BMRI, BBRI, dan BBNI berturut-turut yaitu 29542400, 61016000, 67932500, 58971700.

Tabel 4.1 Karakteristik Volume Transaksi Saham

Perusahaan	Rata-rata	Standar Deviasi	Koefisien Varians	*Skew.*	*Kurt.*
BBCA	13713658	8252129	60,17	1,95	6,61
BMRI	27690499	18014663	66,19	2,45	10,72
BBRI	31493772	19208546	60,99	1,99	6,12
BBNI	26125796	18328838	68,95	2,46	10,20

Tabel 4.1 menunjukkan bahwa volume transaksi perusahaan BBRI paling tinggi dibanding BBCA, BMRI, dan BBNI. Dilihat dari koefisien varians volume transaksi terendah, diketahui bahwa transaksi perusahaan BBCA lebih stabil dilihat dari volume transaksi saham harian dibanding tiga perusahaan lainnya. Volume transaksi tertinggi BBRI yang juga menunjukkan bahwa transaksi harian BBRI lebih stabil dibanding BMRI dan BBNI. Berdasarkan nilai *skewness* dan *kurtosis*, diketahui bahwa volume transaksi harian saham BBCA, BMRI, BBRI, dan BBNI tidak mengikuti distribusi normal karena nilai *skewness* tidak sama dengan nol dan nilai *kurtosis* tidak sama dengan tiga. Secara visual data yang tidak memenuhi distribusi normal dapat dilihat pada histogram. Gambar 4.2 menjelaskan bahwa secara visual volume transaksi harian saham keempat perusahaan tidak mengikuti distribusi normal karena distribusi menceng kanan.

Setelah diketahui karakteristik volume transaksi saham secara umum, selanjutnya ingin diketahui karakteristik volume transaksi saham sebelum dan selama *Tax Amnesty*. Berikut merupakan karakteristik volume transaksi saham perusahaan

BBCA, BMRI, BBRI, dan BBNI sebelum dan selama *Tax Amnesty* sesuai gambar 4.3 dan tabel 4.2.

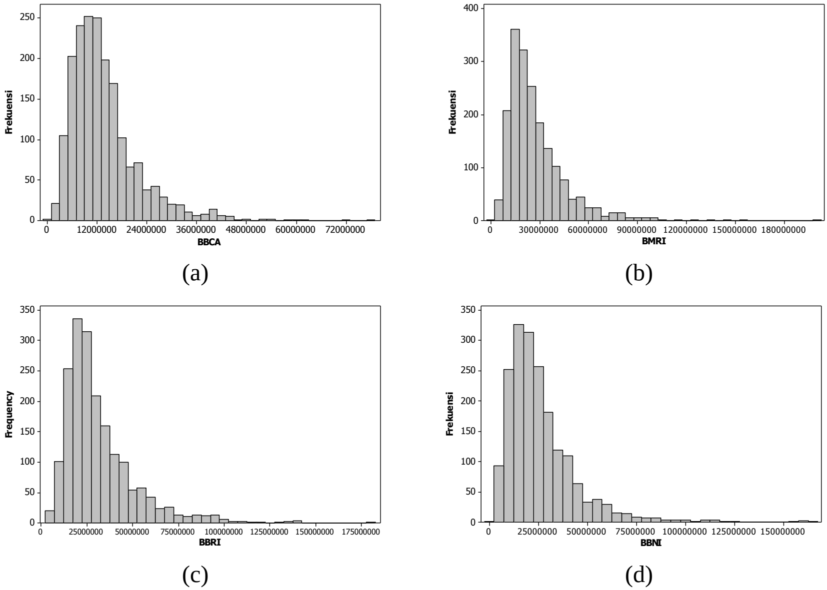

Gambar 4.2 Histogram Volume Transaksi (a) BBCA, (b) BMRI (c) BBRI, dan (d) BBNI

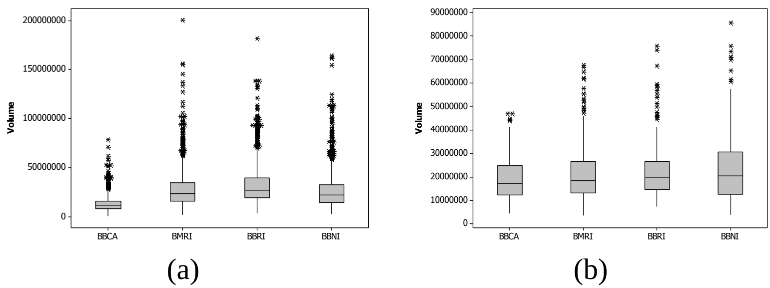

Gambar 4.3 Boxplot Volume Transaksi (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*

Gambar 4.3 menjelaskan bila volume transaksi saham BBCA, BMRI, BBRI, dan BBNI dibagi menjadi dua periode sebelum dan selama *Tax Amnesty*. Volume transaksi dengan volatilitas tertinggi sebelum *Tax Amnesty* adalah volume transaksi BBRI dengan median volume transaksi yaitu 26914400. 25% volume transasksi BBRI lebih kecil atau sama dengan19387975 dan 75% dari volume transaksi BBRI lebih kecil atau sama dengan 39740000. Berbeda dengan periode selama *Tax Amnesty* volume transaksi saham dengan volatilitas tertinggi adalah BBNI dengan median volume transaksi yaitu 20511450. Pada *boxplot* dapat dilihat pula bahwa distribusi volume transaksi saham di keempat bank menceng kanan dan puncak distribusi tidak berada di tengah.

Tabel 4.2 Karakteristik Volume Transaksi Sebelum dan Selama *Tax Amnesty*

	Perusahaan	Rata-rata	Standar Deviasi	Koefisien Varians	*Skew.*	*Kurt.*
Sebelum *Tax Amnesty*	BBCA	13085600	7860985	60,07	2,19	8,88
	BMRI	28349462	18734036	66,08	2,45	10,58
	BBRI	32478421	19615150	60,39	1,95	5,86
	BBNI	26304752	18274259	69,47	2,52	10,54
Selama *Tax Amnesty*	BBCA	19141873	9493288	49,59	0,88	0,38
	BMRI	21995176	13073198	59,44	1,50	2,17
	BBRI	22983596	12352717	53,75	1,87	4,07
	BBNI	24579099	15547367	63,25	1,42	2,07

Tabel 4.2 menunjukkan bahwa sebelum *Tax Amnesty* diberlakukan pada 1 Juli 2016 sampai 31 Maret 2017 volume transaksi saham menunjukkan bahwa saham BBCA yang paling stabil dalam transaksi harian artinya lonjakan dan penurunan volume transaksi tiap harinya tidak terpaut jauh dibanding tiga saham lainnya dilihat dari nilai koefisien variansi terendah. Hal yang sama juga dialami BBCA selama periode *Tax Amnesty* berlangsung. Saham yang paling tidak satbil dalam transaksi harian yaitu BBNI baik selama periode *Tax Amnesty* maupun selama periode sebelum *Tax Amnesty*. Sama halnya dengan hasil pada tabel 4.1, bahwa sebelum dan selama periode *Tax Amnesty* volume transaksi harian saham BBCA, BMRI, BBRI, dan BBNI

tidak mengikuti distribusi normal karena nilai *skewness* tidak sama dengan nol dan nilai *kurtosis* tidak sama dengan tiga. Gambaran diatas tidak menghiraukan adanya runtun waktu yang berpengaruh pada data. Pola pergerakan volume transaksi saham selama periode 4 Januari 2010 sampai 31 Maret 2017 dapat dilihat pada gambar 4.4. Lonjakan volume transaksi pada masa sebelum *Tax Amnesty* menyebabkan rata-rata volume transaksi lebih tinggi pada periode sebelum *Tax Amnesty* dibandingkan pada periode selama Tax Amnesty berlangsung.

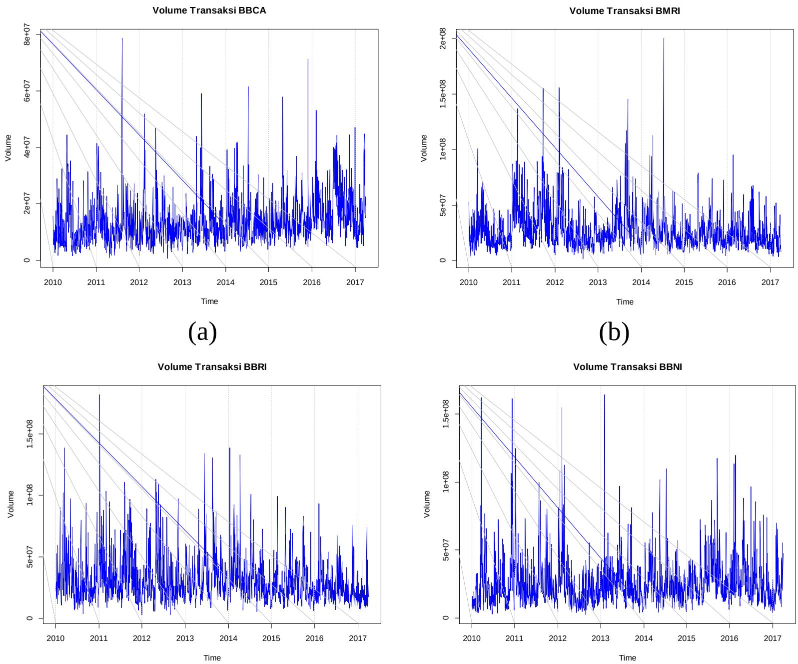

(a) (b) (c) (d)

Gambar 4.4 *Time Series Plot* Volume Transaksi (a) BBCA, (b) BMRI, (c) BBRI, dan (d) BBNI

Gambar 4.4 menggambarkan pergerakan volume transaksi BBCA, BMRI, BBRI, dan BBNI selama periode 4 Januari 2010 sampai dengan 31 Maret 2017 menunjukan lonjakan-lonjakan yang signifikan di waktu tertentu namun yang menjadi fokusan adalah perbedaaan volume sebelum dan selama *Tax Amnesty*. Selain itu, lonjakan pada volume transaksi menyebabkan data volume transaksi tidak stasioner dalam varians dan terdapat klaster volatilitas.

4.2 Pemodelan Volume Transaksi Saham dengan Intervesi

Pemodelan data volume transaksi masing-masing saham dengan model ARIMA dilakukan pada data volume transaksi sebelum kejadian intervensi. Model tersebut akan digunakan sebagai *noise* model untuk membentuk model intervensi. Berikut merupakan pemodelan ARIMA volume transaksi saham.

4.2.1 Pemodelan BBCA dengan Metode Intervensi

Pemodelan ARIMA Box-Jenkins meliputi beberapa tahap yakni tahap identifikasi model, estimasi parameter, uji diagnosa meliputi asumsi white *noise* yaitu identik dan independen serta berdistribusi normal, dan pemilihan model terbaik. Pada tahapan identifikasi model ARIMA mengharuskan bahwa data yang dimodelkan merupakan data yang telah stasioner dalam *mean* dan varians. Pola volume transaksi sebelum dan selama *Tax Amnesty* digambarkan dalam *time series plot* menunjukkan data tidak stasioner dalam varians.

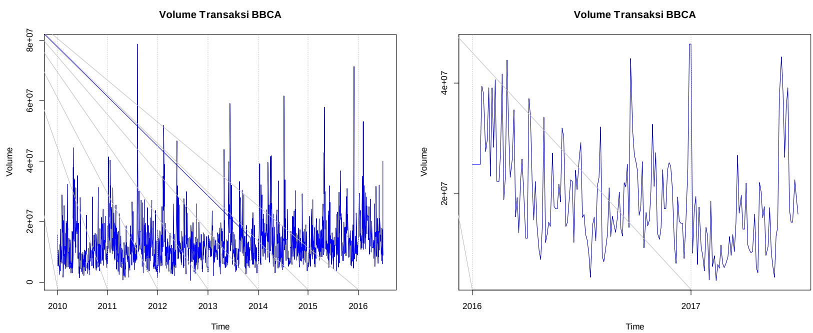

(a) (b)

Gambar 4.5 *Time Series Plot* BBCA (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*

Time series plot memiliki pola fluktuatif dan mengindikasikan bahwa data belum stasioner dalam varians dan belum stasioner dalam *mean*. Stasioneritas data dalam varians menggunakan Box-Cox *plot* yang ditampilkan pada Gambar 4.6 (a). Diketahui bahwa nilai *Rounded Value* sebesar 0,14, *Lower CL* sebesar 0,06 dan *Upper CL* sebesar 0,21 yang belum melewati nilai 1, maka data volume transaksi saham BBCA belum stasioner dalam varians maka dilakukan transformasi dengan lambda (λ) 0,14. Setelah ditransformasi menghasilkan nilai lambda (λ) 1 seperti gambar 4.6 (b).

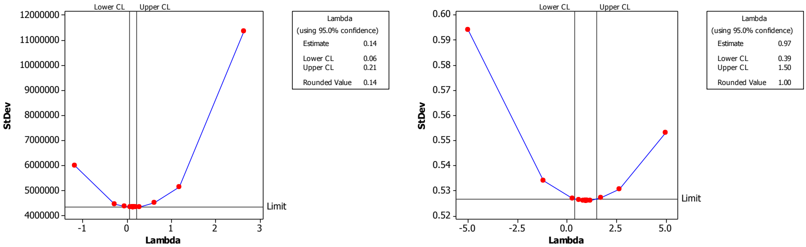

(a) (b)

Gambar 4.6 Box-cox Plot BBCA (a) Data Volume, (b) Data Transformasi

Stasioneritas data dalam *mean* dapat melihat ACF *plot* pada Gambar 4.7, dimana ACF *plot* adalah *dies down* atau turun lambat untuk data volume gambar 4.7(a) dan walaupun telah ditansformasi ACF *plot* tetap *dies down* gambar 4.7(b). Data transformasi dari volume transaksi saham BBCA belum stasioner dalam *mean* sehingga perlu dilakukan proses *differencing* 1 dan diperoleh ACF *plot* seperti gambar 4.7(c) yang telah stasioner dalam *mean* dan varians.

Estimasi parameter ARIMA tidak hanya melibatkan ACF *plot* dalam mengindentifikasi model yang mungkin terbentuk melainkan menggunakan PACF *plot* untuk menentukan orde AR seperti gambar 4.8. ACF *plot* membentuk pola *cut off lag* 1, PACF *plot* membentuk pola *cut off lag* 1 sampai 8. Banyak dugaan model yang mungkin terbentuk, namun hanya dibandingkan dua model terbaik yaitu ARIMA(1,1,1) dan ARIMA ([1,2,5,7],1,1).

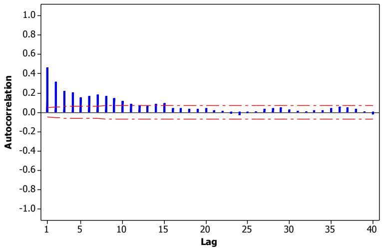

(a)

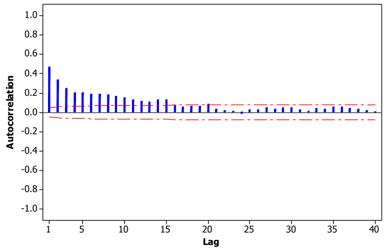

(b)

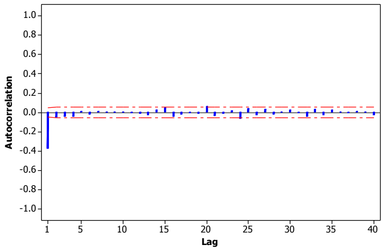

(c)

Gambar 4.7 ACF *Plot* BBCA (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing*

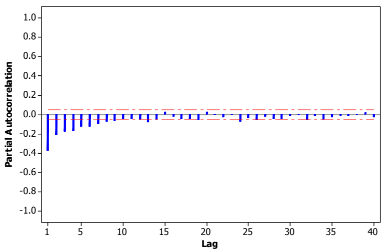

Gambar 4.8 PACF *Plot* BBCA

Setelah melakukan pendugaan model ARIMA, dilakukan estimasi parameter dugaan dan uji signifikansi parameter. Taksiran parameter serta pengujian signifikansi parameter dari dugaan model ARIMA ditampilkan pada tabel 4.3. Hasil pengujian signifikansi parameter menunjukkan bahwa parameter model ARIMA (1,1,1) dan ARIMA ([1,2,5,7],1,1) signifikan pada taraf 10%.

Tabel 4.3 Estimasi dan Uji Signifikansi Parameter BBCA

Model	**Parameter**	**Estimasi**	**t_{hitung}**	**P-*value***
ARIMA (1,1,1)	ϕ_1	0,34520	12,88	<0,001
	θ_1	0,92439	85,59	<0,001
ARIMA ([1,2,5,7],1,1)	ϕ_1	0,38076	15,58	<0,0001
	ϕ_2	0,11587	4,70	<0,0001
	ϕ_5	0,06359	2,73	0,0064
	ϕ_7	0,06213	2,568	0,0074
	θ_1	0,99116	287,09	<0,0001

Model yang telah signifikan diuji diagnosa residual meliputi uji *white noise* dan uji residual berdistribusi normal. Berdasarkan tabel 4.4 asumsi *white noise* pada model ARIMA (1,1,1) tidak terpenuhi tetapi ARIMA ([1,2,5,7],1,1) sudah memenuhi asumsi *white noise* walaupun kedua model masih belum memenuhi asumsi distribusi normal pada taraf signifikan 5%.

Tabel 4.4 Uji Diagnosa Model ARIMA BBCA

Model	**Uji *White Noise***			**Uji Kolmogorov Smirnov**	
	Lag	χ^2_{hitung}	**P-*value***	**D_{hit}**	**P-*value***
ARIMA (1,1,1)	6	9,35	0,0530	0,035891	<0,01
	12	11,53	0,3175		
	18	21,68	0,1537		
	24	44,35	0,0032		
	30	48,32	0,0099		
ARIMA ([1,2,5,7],1,1)	6	1,67	0,1969	0,035967	<0,01
	12	5,07	0,6509		
	18	14,74	0,3239		
	24	26,68	0,1123		
	30	29,76	0,2336		

Sebelumnya telah diperoleh dua model yang parameternya telah signifikan. Namun model ARIMA belum memenuhi asumsi ditribusi normal dan salah satunya juga tidak memenuhi uji asumsi *white noise*. Ingin ditentukan model terbaik yang akan digunakan sebagai *noise* model untuk pemodelan intervensi, dimana kriteria kebaikan model yang digunakan adalah AIC dan SBC.

Tabel 4.5 Kriteria Kebaikan Model ARIMA BBCA

Model	AIC	SBC
ARIMA (1,1,1)	3430,561	3441,430
ARIMA ([1,2,5,7],1,1)	3406,431	3433,602

Model ARIMA terbaik pada data volume transaksi BBCA yaitu ARIMA ([1,2,5,7],1,1) karena memiliki nilai AIC dan SBC terkecil. Model ARIMA ([1,2,5,7],1,1) volume transaksi saham BBCA secara matematis dapat ditulisakan sebagai berikut.

$$\hat{V}_t = \frac{(1-0,99116B)a_t}{(1-0,38076B-0,11587B^2-0,06359B^5-0,06213B^7)(1-B)}$$

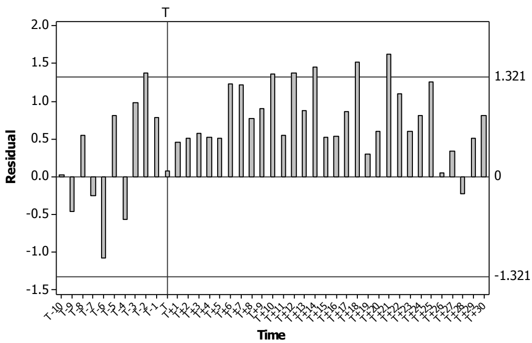

Gambar 4.9 Diagram Residual BBCA Terhadap T Intervensi

Selanjutnya dilakukan pemodelan intervensi pada data volume transaksi BBCA. Menganalisis data volume transaksi BBCA dengan memasukkan pengaruh intervensi dapat dilakukan dengan melihat diagram residual. Diagram residual pada gambar 4.9 dapat dilihat bahwa dibukanya *Tax Amnesty* menyebabkan *response impulse* keluar dari batas $\pm 2\sigma$. Berdasarkan batas terlihat *lag* yang pertama kali keluar adalah lag ke T+10 selanjutnya T+12 dan T+14. Ditentukan dugaan orde intervensi yaitu b=10, r=1, s=0 yang digunakan dalam pemodelan.

Estimasi dan pengujian signifikansi parameter model intervensi ditunjukkan pada tabel 4.6. Hasil pengujian dari signifikansi parameter untuk model intervensi menunjukkan model intervensi tidak signifikan dan hanya model ARIMA saja yang signifikan.

Tabel 4.6 Estimasi dan Uji Signifikansi Model Intervensi BBCA

Parameter	**Estimasi**	**T_{hitung}**	**P-*value***
ϕ_1	0,38561	16,68	<0,001
ϕ_2	0,11363	4,87	<0,001
ϕ_5	0,06779	3,09	0,0021
ϕ_7	0,05579	2,56	0,0105
θ_1	0,99526	373,06	<0,001
ω_0	0,80188	1,31	0,1920
ω_1	0,59738	0,97	0,3308

Uji diagnosa model *white noise* normal untuk model intervensi seperti tabel 4.8 pada taraf 5%. Selain tidak signifikan model intervensi juga tidak memenuhi asumsi residual berdistribusi normal namun memenuhi uji asumsi *white noise*. Pemodelan intervensi sebelum dan selama *Tax Amnesty* pada volume transaksi BBCA menunjukkan bahwa tidak terdapat efek intervensi. *Time series plot* secara visual juga menunjukkan bahwa tidak terdapat lonjakan dan turunan yang signifikan pada periode *Tax Amnesty* dimulai pada 1 Juli 2016.

Tabel 4.7 Uji Diagnosa Model Intervensi BBCA

Uji *White Noise*			**Uji Kolmogorov Smirnov**	
Lag	χ^2_{hitung}	**P-*value***	**D_{hit}**	**P-*value***
6	2,53	0,1119		
12	7,55	0,3741		
18	17,20	0,1902	0,034354	<0,0100
24	27,47	0,0942		
30	31,22	0,1819		

4.2.2 Pemodelan BMRI dengan Metode Intervensi

Pola volume transaksi BMRI sebelum dan selama *Tax Amnesty* digambarkan dalam *time series plot* menunjukkan data tidak stasioner dalam varians seperti gambar 4.10. Pemodelan ARIMA yang digunakan dalam analisis intervensi menggunakan data sebelum *Tax Amnesty*. Pada tahapan identifikasi model ARIMA mengharuskan bahwa data yang dimodelkan merupakan data yang telah stasioner dalam *mean* dan varians. Sehingga dilakukan transformasi agar data stasioner dalam varians.

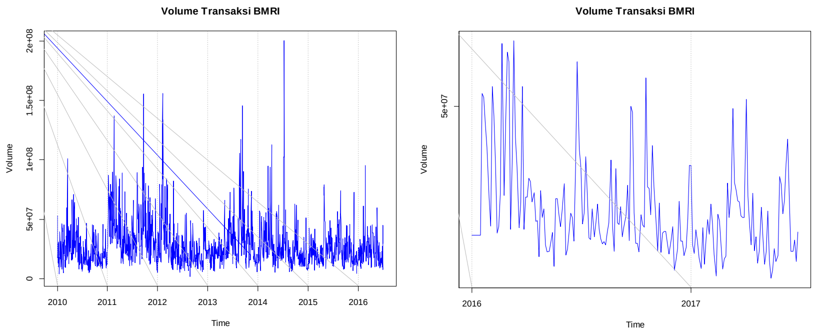

(a) (b)

Gambar 4.10 Time Series Plot BMRI (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*

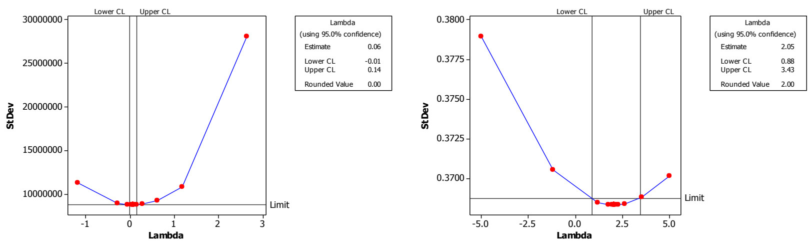

(a) (b)

Gambar 4.11 Box-cox Plot BMRI (a) Data Volume, (b) Data Transformasi

Box-Cox plot pada gambar 4.11(a) menjelaskan bahwa nilai *Rounded Value* sebesar 0,00, *Lower CL* sebesar -0,01 dan *Upper CL* sebesar 0,14 yang belum melewati nilai 1, maka data volume transaksi saham BMRI belum stasioner dalam varians maka dilakukan transformasi. Transformasi dengan lambda (λ) 0,00 yaitu transformasi ln. Hasil transformasi menghasilkan nilai lambda (λ) 2 seperti gambar 4.11 (b) dengan *Lower CL* sebesar 0,88 dan *Upper CL* sebesar 3,43.

Setelah stasioner dalam varians selanjutnya stasioner dalam *mean*. Data volume trasaksi BMRI tidak stasioner dalam *mean* sama halnya dengan data volume transaksi yang telah ditransformasi sebab ACF *plot* tetap *dies down*. Kedua plot ACF dapat dilihat berturut-turut pada gambar 4.12 (a) dan (b). Karena belum stasioner maka dilakukan *differenching* 1 sehingga dapat digambarkan ACF *plot* yang telah stasioner dalam *mean* dan varians pada gambar 4.12 (c).

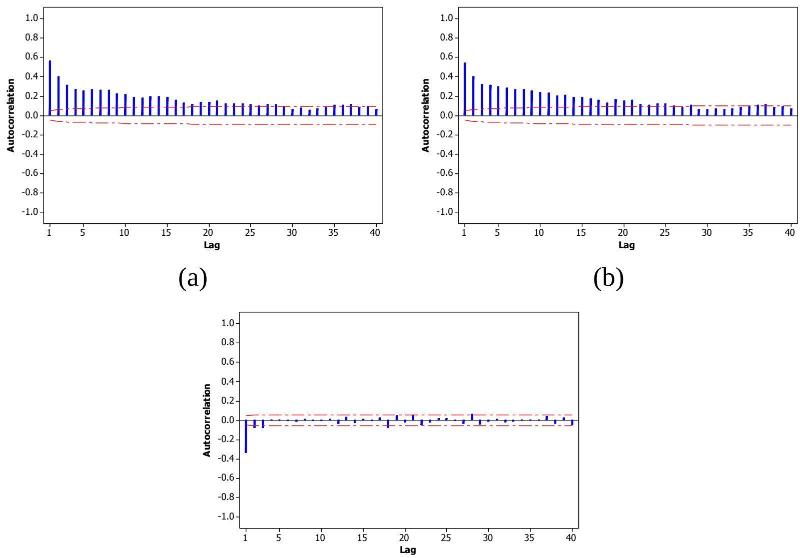

(c)

Gambar 4.12 ACF *Plot* BMRI (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing*

Data yang telah stasioner kemudian di gambarkan PACF *plot* seperti pada gambar 4.13. Estimasi parameter model ARIMA diidentifikasi menggunakan ACF plot gambar 4.12 (c) dan PACF plot. Orde AR diperoleh dari PACF *plot* dan orde MA diperoleh dari ACF *plot*. ACF *plot* membentuk pola *cut off lag* 1 sampai 3 dan PACF *plot* membentuk pola *cut off lag* 1 sampai 8. Banyak dugaan model yang mungkin terbentuk, namun hanya membandingkan dua model terbaik yaitu ARIMA(1,1,1) dan ARIMA ([1,2,4],1,1).

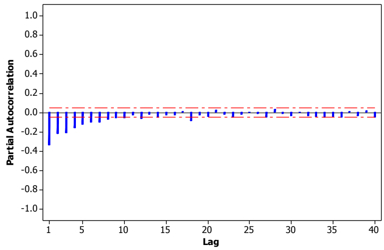

Gambar 4.13 PACF *Plot* BMRI

Estimasi parameter dugaan dan uji signifikansi parameter dilakukan setelah model dugaan diketahui. Taksiran parameter serta pengujian signifikansi parameter dari dugaan model ARIMA ditampilkan pada tabel 4.8. Hasil pengujian signifikansi parameter model menunjukkan bahwa parameter model ARIMA (1,1,1) dan ARIMA ([1,2,4],1,1) telah signifikan.

Tabel 4.8 Estimasi dan Uji Signifikansi Parameter BMRI

Model	Parameter	Estimasi	t_{hitung}	P-*value*
ARIMA (1,1,1)	ϕ_1	0,34942	12,38	<0,0001
	θ_1	0,90114	69,40	<0,0001
ARIMA ([1,2,4],1,1]	ϕ_1	0,38658	14,35	<0,0001
	ϕ_2	0,05685	2,18	0,0297
	ϕ_4	0,06055	2,41	0,0160
	θ_1	0,94736	86,85	<0,0001

Model yang telah signifikan diuji diagnosa residual meliputi uji *white noise* dan uji residual berdistribusi normal. Berdasarkan tabel 4.8 menunjukkan bahwa asumsi *white noise* pada model

ARIMA (1,1,1) dan ARIMA ([1,2,4],1,1) sudah terpenuhi. Namun, kedua model masih belum memenuhi asumsi distribusi normal. Model yang signifikan saja tidak cukup karena model harus memnuhi asumsi distribusi normal dan asumsi *white noise*. Hasil uji asumsi *white noise* dan uji asumsi distribusi normal dapat dilihat pada tabel 4.9.

Tabel 4.9 Uji Diagnosa Model ARIMA BMRI

Model	Uji *White Noise*			Uji Kolmogorov Smirnov	
	Lag	χ^2_{hitung}	**P-*value***	**D_{hit}**	**P-*value***
ARIMA (1,1,1)	6	3,87	0,4233	0,024168	0,0176
	12	6,02	0,8138		
	18	17,14	0,3765		
	24	26,47	0,2321		
	30	38,63	0,0871		
ARIMA ([1,2,4],1,1]	6	2,55	0,2793	0,026635	<0,0100
	12	6,96	0,5405		
	18	14,77	0,3737		
	24	23,14	0,2822		
	30	33,40	0,1508		

Model ARIMA belum memenuhi asumsi distribusi normal dan walaupun telah memenuhi uji asumsi *white noise*. Ingin ditentukan model terbaik yang akan digunakan sebagai *noise* model untuk pemodelan intervensi, dimana kriteria kebaikan model yang digunakan adalah AIC dan SBC sesuai tabel 4.10.

Tabel 4.10 Kriteria Kebaikan Model ARIMA BMRI

Model	AIC	SBC
ARIMA (1,1,1)	2276,221	2287,089
ARIMA ([1,2,4],1,1]	2274,537	2296,274

Volume transaksi BMRI memiliki model terbaik ARIMA ([1,2,4],1,1) karena memiliki nilai AIC dan SBC terkecil. Model ARIMA ([1,2,4],1,1) volume transaksi saham BMRI secara matematis dapat ditulisakan sebagai berikut.

$$\hat{V}_t = \frac{(1-0,94736B)a_t}{(1-0,38658B-0,05685B^2-0,06055B^4)(1-B)}$$

Pemodelan intervensi pada data volume transaksi BMRI dilakukan dengan melihat orde intervensi BMRI dari diagram residual. Diagram residual pada gambar 4.14 dapat dilihat bahwa dibukanya *Tax Amnesty* menyebabkan adanya *response impulse* keluar dari batas $\pm 2\sigma$. Sehingga ditentukan dugaan orde intervensi yaitu *b*=6, *r*=0, *s*=0. Orde intervensi akan digunakan dalam pemodelan intervensi. Nilai *b*=6 dilihat dari orde pertama yang signifikan yaitu saat T+6.

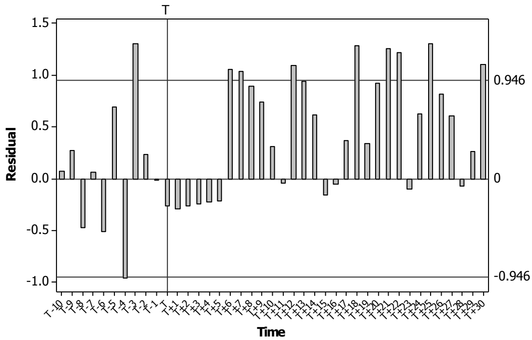

Gambar 4.14 Diagram Residual BMRI Terhadap T Intervensi

Tabel 4.11 Estimasi dan Uji Signifikansi Model Intervensi BMRI

Parameter	Estimasi	T_{hitung}	P-*value*
ϕ_1	0,39771	16,03	<0,0001
ϕ_2	0,04830	1,98	0,0481
ϕ_4	0,08059	3,47	0,0005
θ_1	0,95889	110,93	<0,0001
ω_0	0,64585	2,54	0,0112

Tabel 4.11 menunjukkan bahwa semua variabel baik parameter ARIMA dan parameter interevensi signifikan pada taraf 5%. Volume transaksi BMRI sebelum dan selama *Tax Amnesty* menunjukkan bahwa terdapat efek intervensi walaupun *time series plot* tidak menunjukkan lonjakan dan turunan yang signifikan pada periode *Tax Amnesty* dimulai pada 1 Juli 2016

seperti model intervensi pada umumnya. Model intervensi secara matematis dapat ditulis sebagai berikut.

$$\hat{V}_t = (0,64585B^6)S_t^{1695} + \frac{(1-0,95889B)a_t}{(1-0,39771B-0,04830B^2-0,08059B^4)(1-B)}$$

Uji diagnosa model *white noise* normal untuk model intervensi BMRI seperti tabel 4.12. Model intervensi yang telah signifikan diuji diagnostik model. Hasil menunjukkan bahwa model tidak memenuhi asumsi residual berdistribusi normal namun memenuhi uji asumsi *white noise*.

Tabel 4.12 Uji Diagnosa Model Intervensi BMRI

Uji *White Noise*			**Uji Kolmogorov Smirnov**	
Lag	χ^2_{hitung}	**P-*value***	$\mathbf{D_{hit}}$	**P-*value***
6	0,90	0,6362		
12	5,97	0,6509		
18	14,64	0,4034	0,02557	<0,0100
24	23,92	0,2460		
30	32,04	0,1917		

4.2.3 Pemodelan BBRI dengan Metode Intervensi

Sebelum dilakukan analisis intervensi terhadap volume transaksi terlebih dahulu dilakukan pemodelan ARIMA. Identifikasi model ARIMA mensyaratkan data yang dimodelkan stasioner dalam *mean* dan varians. Pola volume transaksi BBRI sebelum dan selama *Tax Amnesty* digambarkan dalam *time series plot* menunjukkan data tidak stasioner dalam varians seperti gambar 4.15.

Box-Cox plot pada gambar 4.16 (a) menjelaskan bahwa nilai *Rounded Value* sebesar 0,00, *Lower CL* sebesar -0,07 dan *Upper CL* sebesar 0,09 yang belum melewati nilai 1, maka data volume transaksi saham BBRI belum stasioner dalam varians sehingga dilakukan transformasi. Transformasi dengan lambda (λ) 0,00 yaitu transformasi ln. Hasil transformasi dengan lambda 0 menghasilkan nilai lambda (λ) 1 seperti gambar 4.16 (b) dengan *Lower CL* sebesar -0,11 dan *Upper CL* sebesar 2,70.

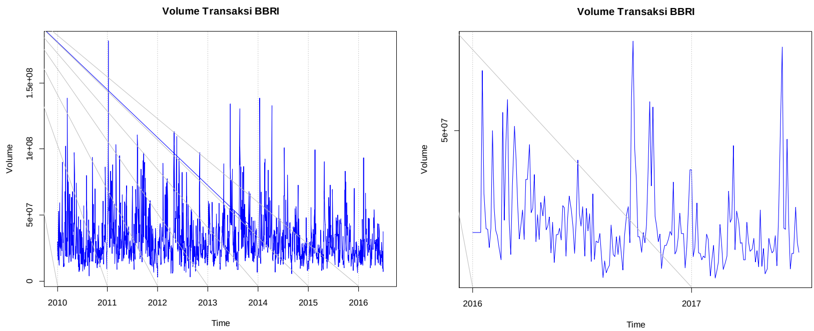

(a) (b)

Gambar 4.15 *Time Series Plot* BBRI (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*

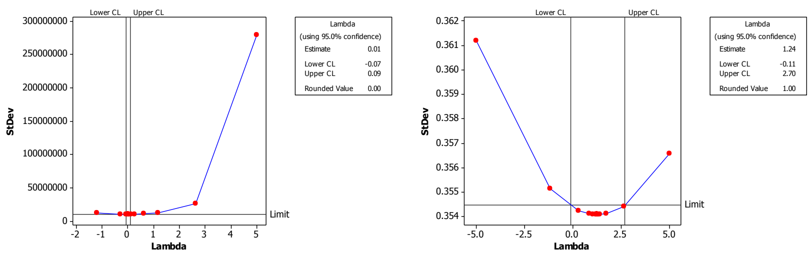

(a) (b)

Gambar 4.16 Box-cox Plot BBRI (a) Data Volume, (b) Data Transformasi

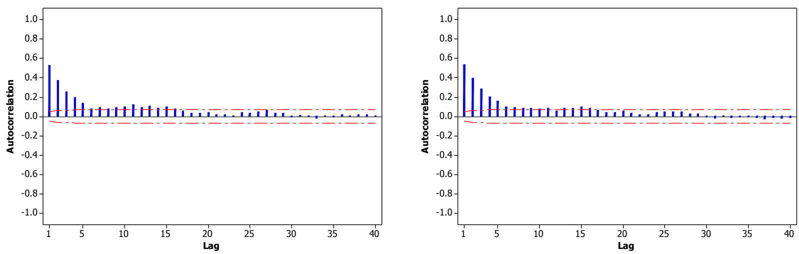

(a) (b)

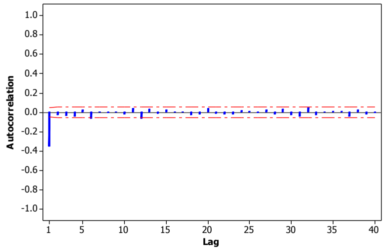

(c)

Gambar 4.17 ACF *Plot* BBRI (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing*

Setelah stasioner dalam varians selanjutnya adalah stasioner dalam *mean*. Dimana, data volume trasaksi tidak stasioner dalam *mean* sama halnya dengan data volume transaksi yang telah ditransformasi sebab ACF *plot* tetap *dies down* berturut-turut pada gambar 4.17 (a) dan (b). Karena belum stasioner maka dilakukan *differenching* 1, hasilnya digambarkan ACF *plot* yang telah stasioner dalam mean dan varians pada gambar 4.17 (c).

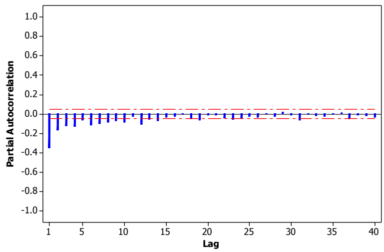

Gambar 4.18 PACF *Plot* BBRI

PACF *plot* seperti pada gambar 4.18 membentuk pola *cut off lag* 1 sampai 8, 10, dan 12. Estimasi parameter model ARIMA juga diidentifikasi menggunakan ACF plot gambar 4.17 (c). Orde AR diperoleh dari PACF *plot* dan orde MA diperoleh dari ACF *plot*. ACF *plot* membentuk pola *cut off lag* 1. Dugaan model yang mungkin terbentuk adalah kombinasi pola *cut off* pada PACF *plot* dan ACF *plot*, namun pada analisis ini hanya membandingkan dua model terbaik yaitu ARIMA(1,1,1) dan ARIMA (2,1,1).

Hasil pengujian signifikansi parameter model menunjukkan bahwa parameter model ARIMA (1,1,1) dan ARIMA (2,1,1) telah signifikan. Estimasi parameter dugaan dan uji signifikansi parameter dilakukan setelah model dugaan diketahui. Taksiran parameter serta pengujian signifikansi parameter dari dugaan model ARIMA ditampilkan pada tabel 4.13.

Tabel 4.13 Estimasi dan Uji Signifikansi Parameter BBRI

Model	Parameter	Estimasi	t_{hitung}	P-*value*
ARIMA (1,1,1)	ϕ_1	0,50184	22,22	<0,0001
	θ_1	0,97617	174,40	<0,0001
ARIMA (2,1,1)	ϕ_1	0,45075	18,59	<0,0001
	ϕ_2	0,14988	6,18	<0,0001
	θ_1	0,99357	377,97	<0,0001

Model yang telah signifikan diuji diagnosa residual meliputi uji *white noise* dan uji residual berdistribusi normal. Berdasarkan tabel 4.14 menunjukkan bahwa asumsi *white noise* pada model ARIMA (2,1,1) sudah terpenuhi namun belum terpenuhi pada model ARIMA (1,1,1). Kedua model masih belum memenuhi asumsi distribusi normal.

Tabel 4.14 Uji Diagnosa Model ARIMA BBRI

Model	Uji *White Noise*			Uji Kolmogorov Smirnov	
	Lag	χ^2_{hitung}	P-*value*	D_{hit}	P-*value*
ARIMA (1,1,1)	6	35,76	<0,0001	0,028965	<0,01
	12	41,66	<0,0001		
	18	46,68	<0,0001		
	24	51,07	0,0004		
	30	55,13	0,0016		
ARIMA (2,1,1)	6	5,12	0,1635	0,034137	<0,01
	12	10,18	0,3362		
	18	18,01	0,2620		
	24	23,37	0,3244		
	30	28,11	0,4052		

Model ARIMA belum memenuhi asumsi ditribusi normal walaupun ada yang telah memenuhi uji asumsi *white noise*.

Menentukan model terbaik yang akan digunakan sebagai *noise* model untuk pemodelan intervensi dilakukan dengan melihat AIC dan SBC sebagai kriteria kebaikan model yang digunakan sesuai tabel 4.15.

Tabel 4.15 Kriteria Kebaikan Model ARIMA BBRI

Model	AIC	SBC
ARIMA (1,1,1)	2199,819	2210,688
ARIMA (2,1,1)	2165,697	2182

Volume transaksi BBRI memiliki model terbaik ARIMA (2,1,1) karena memiliki nilai AIC dan SBC terkecil. Model ARIMA (2,1,1) volume transaksi saham BBRI secara matematis dapat ditulisakan sebagai berikut.

$$\hat{V}_t = \frac{(1-0,99357B)a_t}{(1-0,45075B-0,14988B^2)(1-B)}$$

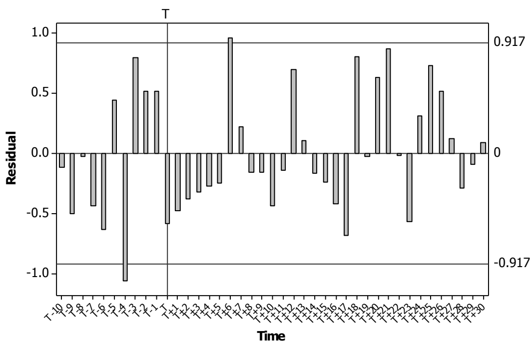

Gambar 4.19 Diagram Residual BBRI Terhadap T Intervensi

Pemodelan intervensi pada data volume transaksi BBRI dilakukan setelah memilih model ARIMA terbaik. Orde intervensi BBRI dilihat dengan melihat diagram residual. Diagram residual pada gambar 4.19 dapat dilihat bahwa dibukanya *Tax Amnesty* menyebabkan *response impulse* pada T+6 keluar dari batas $\pm 2\sigma$. Oleh karena itu orde intervensi yaitu b=6, r=0, s=0 untuk volume transaksi BBRI.

Tabel 4.16 Estimasi dan Uji Signifikansi Model Intervensi BBRI

Parameter	Estimasi	T_{hitung}	P-*value*
ϕ_1	0,43767	18,60	<0,0001
ϕ_2	0,13553	5,78	<0,0001
θ_1	0,98016	196,13	<0,0001
ω_0	0,16100	0,81	0,4208

Tabel 4.16 menunjukkan bahwa parameter ARIMA signifikan dan parameter interevensi tidak signifikan. Volume transaksi BBRI sebelum dan selama *Tax Amnesty* menunjukkan bahwa tidak terdapat efek intervensi dan *time series plot* tidak menunjukkan lonjakan dan turunan yang signifikan. Uji diagnosa model *white noise* normal untuk model intervensi BBRI seperti tabel 4.17 menunjukkan bahwa model tidak memenuhi asumsi residual berdistribusi normal namun memenuhi uji asumsi *white noise*.

Tabel 4.17 Uji Diagnosa Model Intervensi BBRI

Uji *White Noise*			Uji Kolmogorov Smirnov	
Lag	χ^2_{hitung}	P-*value*	D_{hit}	P-*value*
6	4,35	0,2265		
12	8,01	0,5334		
18	13,89	0,5342	0,033623	<0,0100
24	19,53	0,5509		
30	24,18	0,6201		

4.2.4 Pemodelan BBNI dengan Metode Intervensi

Tahap awal pemodelan ARIMA adalah identifiksi model. Identifikasi model ARIMA mengharuskan data yang dimodelkan telah stasioner dalam *mean* dan varians. Stasioner dalam *mean* dan varians dapat dilihat secara visual melalui *time series plot*. Pola volume transaksi sebelum dan selama *Tax Amnesty* digambarkan dalam *time series plot* menunjukkan data tidak stasioner dalam varians.

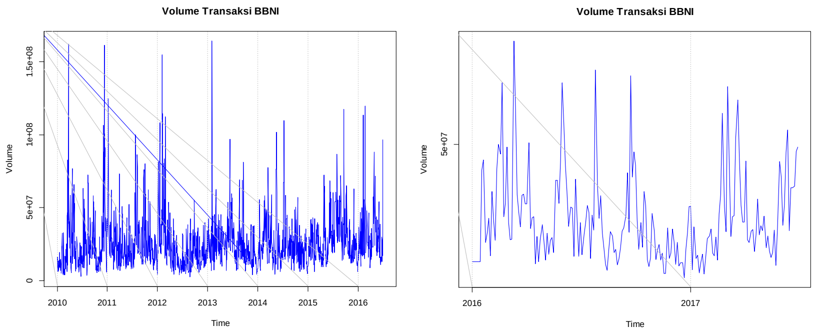

(a) (b)

Gambar 4.20 *Time Series Plot* BBNI (a) Sebelum *Tax Amnesty* dan (b) Selama *Tax Amnesty*

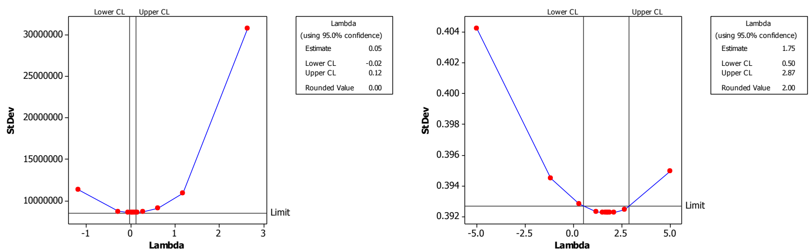

(a) (b)

Gambar 4.21 Box-cox Plot BBNI (a) Data Volume, (b) Data Transformasi

Stasioneritas dalam varians dilihat dari box-cox *plot*. Box-Cox *plot* pada gambar 4.11(a) menjelaskan bahwa nilai *Rounded Value* sebesar 0,00, *Lower CL* sebesar -0,02 dan *Upper CL* sebesar 0,12 yang belum melewati nilai 1, maka data volume transaksi saham BBNI belum stasioner dalam varians maka dilakukan transformasi. Karena nilai lambda (λ) 0,00 maka dilakukan transformasi ln. Hasil transformasi menghasilkan nilai lambda (λ) 2 seperti gambar 4.21 (b) dengan *Lower CL* sebesar 0,50 dan *Upper CL* sebesar 2,87.

Setelah stasioner dalam varians selanjutnya adalah stasioner dalam *mean* dimana data volume trasaksi tidak stasioner dalam *mean* sama halnya dengan data volume transaksi yang telah ditransformasi sebab ACF *plot* tetap *dies down*. Kedua plot ACF dapat dilihat berturut-turut pada gambar 4.22 (a) dan (b). Karena belum stasioner maka dilakukan *differenching* 1 sehingga dapat digambarkan ACF *plot* yang telah stasioner dalam mean dan varians pada gambar 4.22 (c).

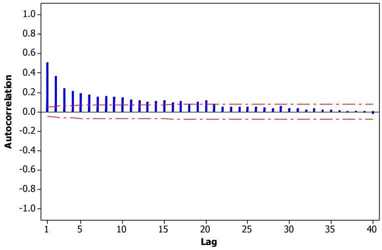

(a)

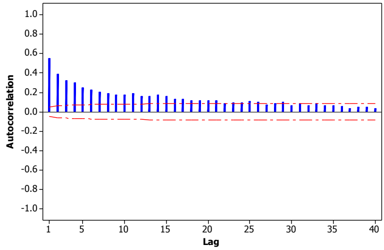

(b)

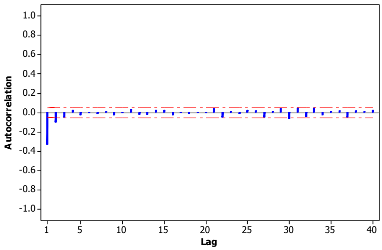

(c)

Gambar 4.22 ACF *Plot* BBNI (a) Data Volume, (b) Data Transformasi, (c) Data *Differencing*

Data yang telah stasioner kemudian di gambarkan PACF *plot* seperti pada gambar 4.23. Estimasi parameter model ARIMA diidentifikasi menggunakan ACF plot gambar 4.22 (c) dan PACF plot. Orde AR diperoleh dari PACF *plot* dan orde MA diperoleh dari ACF *plot*. ACF *plot* membentuk pola *cut off lag* 1 sampai 3 dan PACF *plot* membentuk pola *cut off lag* 1 sampai 7, 9, 10, dan 13. Banyak dugaan model yang mungkin terbentuk, namun hanya membandingkan dua model terbaik yaitu ARIMA (1,1,1) dan ARIMA (2,1,2).

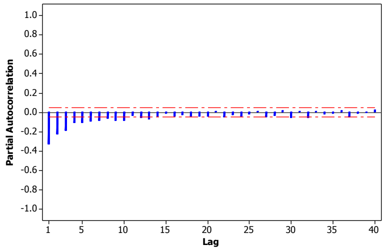

Gambar 4.23 PACF *Plot* BBNI

Estimasi parameter dugaan dan uji signifikansi parameter dilakukan setelah model dugaan diketahui. Taksiran parameter serta pengujian signifikansi parameter dari dugaan model ARIMA ditampilkan pada tabel 4.18. Hasil pengujian signifikansi parameter model menunjukkan bahwa parameter model ARIMA (1,1,1) dan ARIMA (2,1,2) telah signifikan.

Tabel 4.18 Estimasi dan Uji Signifikansi Parameter BBNI

Model	Parameter	Estimasi	t_{hitung}	P-*value*
ARIMA (1,1,1)	ϕ_1	0,40680	15,32	<0,001
	θ_1	0,92670	85,60	<0,001
ARIMA (2,1,2)	ϕ_1	1,25926	19,59	<0,0001
	ϕ_2	-0,30860	-6,70	<0,0001
	θ_1	1,80130	32,42	<0,0001
	θ_2	-0,80351	-14,60	<0,0001

Model yang telah signifikan diuji diagnosa residual meliputi uji *white noise* dan uji residual berdistribusi normal. Berdasarkan tabel 4.19 menunjukkan bahwa asumsi *white noise* pada model ARIMA (1,1,1) dan ARIMA (2,1,2) sudah terpenuhi. Namun, kedua model masih belum memenuhi asumsi distribusi normal. Volume transaksi BBNI memiliki model terbaik ARIMA (2,1,2) karena memiliki nilai AIC dan SBC terkecil sesuai tabel 4.20. Model ARIMA (2,1,2) volume transaksi saham BBNI secara matematis dapat ditulisakan sebagai berikut.

$$\hat{V}_t = \frac{(1-1,80130B+0,80351B^2)a_t}{(1-1,25926B+0,30860B^2)(1-B)}$$

Tabel 4.19 Uji Diagnosa Model ARIMA BBNI

Model	Uji *White Noise*			Uji Kolmogorov Smirnov	
	Lag	χ^2_{hitung}	**P-*value***	$\mathbf{D_{hit}}$	**P-*value***
ARIMA (1,1,1)	6	7,27	0,1225	0,029595	<0,0100
	12	10,59	0,3904		
	18	14,62	0,5528		
	24	20,38	0,5594		
	30	29,15	0,4049		
ARIMA (2,1,2)	6	2,35	0,3091	0,028748	<0,0100
	12	6,10	0,6363		
	18	9,45	0,8009		
	24	13,45	0,8571		
	30	21,67	0,7065		

Tabel 4.20 Kriteria Kebaikan Model ARIMA BBNI

Model	AIC	SBC
ARIMA (1,1,1)	2527,572	2538,44
ARIMA (2,1,2)	2516,832	2538,569

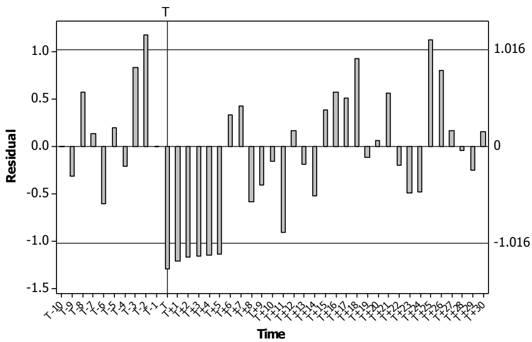

Gambar 4.24 Diagram Residual BBNI Terhadap T Intervensi

Setelah mengetahui model *noise* terbaik maka selanjutnya melakukan pemodelan intervensi. Pemodelan intervensi dilakukan dengan melihat orde intervensi dari diagram residual. Diagram residual pada gambar 4.24 dapat dilihat bahwa dibukanya *Tax Amnesty* menyebabkan *response impulse* pada T sampai T+5 keluar dari batas $\pm 2\sigma$. Oleh karena itu orde intervensi yaitu *b*=0, *r*=0, *s*=0.

Tabel 4.21 Estimasi dan Uji Signifikansi Model Intervensi BBNI

Parameter	Estimasi	T_{hitung}	P-*value*
ϕ_1	1,23598	19,04	<0,0001
ϕ_2	-0,29293	-6,40	<0,0001
θ_1	1,77758	31,24	<0,0001
θ_2	-0,78010	-13,85	<0,0001
ω_0	-0,50251	-2,04	0,0414

Tabel 4.21 menunjukkan bahwa parameter model signifikan pada taraf 5%. Hal ini berarti, volume transaksi BBNI sebelum dan selama *Tax Amnesty* menunjukkan bahwa terdapat efek intervensi. Uji diagnosa model *white noise* normal untuk model intervensi BBRI seperti tabel 4.22 menunjukkan bahwa model tidak memenuhi asumsi residual berdistribusi normal namun memenuhi uji asumsi *white noise*. Model intervensi dapat ditulis dalam persamaan seperti:

$$\hat{V}_t = (-0,50251)S_t^{1695} + \frac{(1-1,77758B+0,78010B^2)a_t}{(1-1,23598B+0,29293B^2)(1-B)}$$

Tabel 4.22 Uji Diagnosa Model Intervensi BBRI

Uji *White Noise*			Uji Kolmogorov Smirnov	
Lag	χ^2_{hitung}	P-*value*	D_{hit}	P-*value*
6	1,18	0,5556		
12	4,50	0,8095		
18	7,90	0,8947	0,029206	<0,0100
24	12,85	0,8836		
30	19,36	0,8210		

4.3 Pemodelan Durasi dengan ACD

Data volume transaksi saham sektor perbankan yang telah dimodelkan dengan ARIMA Intervensi tidak dapat memenuhi distribusi normal. Oleh karena itu, dilakukan pemodelan lain dengan *Autoregressive Conditional Duration* (*ACD*). Model *ACD* yang digunakan adalah model dengan distribusi eksponensial dan weibull. Pemodelan ACD dilakukan sebagai model pembanding dari analisis intervensi.

Sebelum memperoleh data durasi, terlebih dahulu volume transaksi saham dimodelkan dengan ARMA-GARCH. Data yang dimodelkan ARMA-GARCH adalah volume yang telah ditransformasi dan dilakukan *differenching* 1 agar data stasioner dalam *mean* dan varians. *Time series plot* data durasi sebelum *Tax Amnesty* seperti gambar 4.25 berikut dan selama *Tax Amnesty* seperti gambar 4.26.

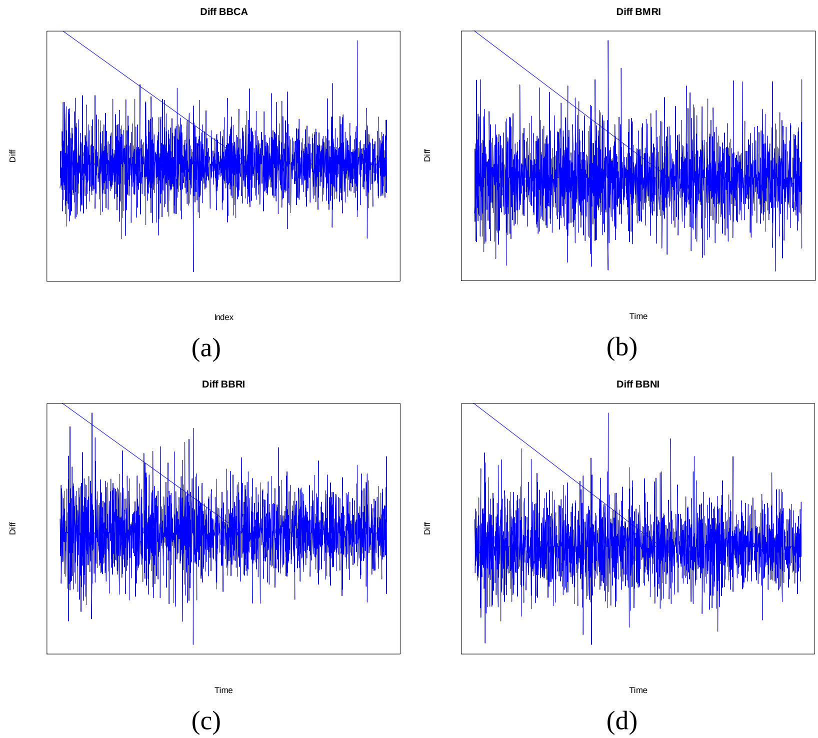

Gambar 4.25 *Time Series Plot* Data *diff* Sebelum *Tax Amnesty* (a) BBCA, (b) BMRI, (c) BBRI, dan (d) BBNI

Setelah dilakukan transformasi dan *differencing* terhadap volume transaksi masing-masing saham perusahaan dapat diketahui bahwa data telah stasioner dalam *mean*. Klaster volatilitas belum dapat ditanggulangi bila hanya menggunakan model ARMA sehingga dilakukan pemodelan GARCH terhadap residual model ARMA. Pemodelan GARCH untuk memodelkan volatilitas yang ditunjukkan pada parameter varian.

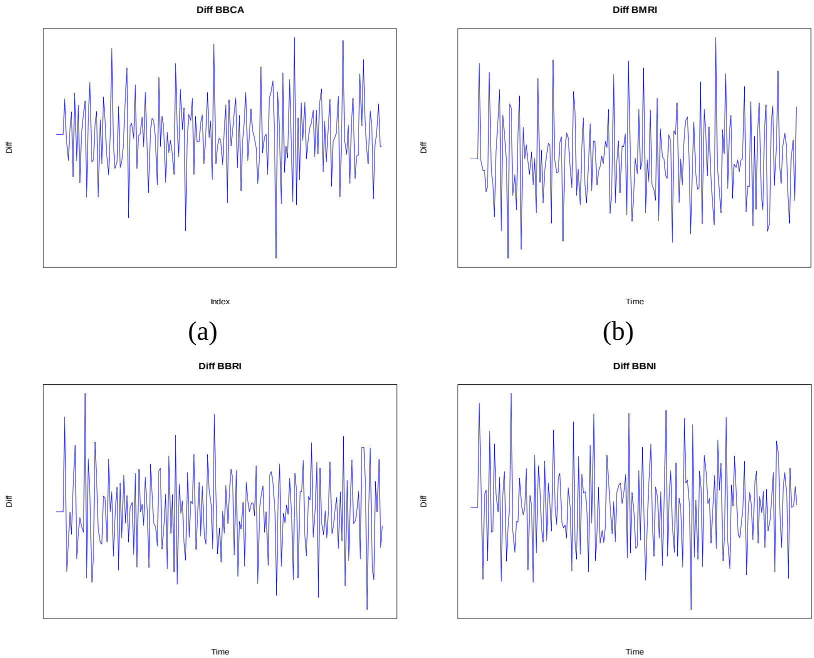

(a) (b)

(c) (d)

Gambar 4.26 *Time Series Plot* Data *diff* Selama *Tax Amnesty* (a) BBCA, (b) BMRI, (c) BBRI, dan (d) BBNI

Dugaan model ARMA diperoleh dari plot ACF dan PACF pada sub bab 4.2. Namun, dalam penelitian ini akan ditetapkan model ARMA yang didasarkan pada prinsip *parcimony* karena bila menggunakan model pada lag signifikan seperti model intervensi terlalu rumit dan *packages syntax* yang tersedia di R tidak dapat digunakan. Maka dari itu terdapat tiga model ARMA dugaan yang ditetapkan yaitu ARMA (1,1), ARMA(1,0), da ARMA(0,1). Hal yang sama juga digunakan dalam pemodelan GARCH dimana terdapat tiga model GARCH yang diduga yaitu GARCH (1,1), GARCH (1,0), da GARCH (0,1).

Tabel 4.23 Estimasi dan Uji Signifikansi Parameter ARIMA-GARCH Sebelum *Tax Amnesty*

Saham	Model	Parameter	Estimasi	t_{hitung}	P-*value*
BBCA	ARMA (1,1) GARCH (1,1)	ϕ_1	0,346119	7,6468	0,00000
		θ_1	-0,927441	-31,2292	0,00000
		ω	0,009338	6,8134	0,00000
		τ_1	0,085517	2,5939	0,00949
		β_1	0,905537	27,3163	0,00000
BMRI	ARMA (1,1) GARCH (1,1)	ϕ_1	0,353677	10,6785	0,000000
		θ_1	-0,911161	-53,9094	0,000000
		ω	0,004141	2,2673	0,023373
		τ_1	0,087701	3,2028	0,001361
		β_1	0,904372	35,9646	0,000000
BBRI	ARMA (1,1) GARCH (1,1)	ϕ_1	0,529778	25,2912	0,000000
		θ_1	-0,986617	-4898,1831	0,000000
		ω	0,003910	3,9207	0,000088
		τ_1	0,017505	5,3784	0,000000
		β_1	0,964194	270,2276	0,000000
BBNI	ARMA (1,1) GARCH (0,1)	ϕ_1	0,406045	13,458	0,000
		θ_1	-0,926244	-60,820	0,000
		ω	0,001145	21,067	0,000
		β_1	0,995380	5588,425	0,000

Sama halnya dengan prosedur Box-Jenkins, setelah mendapatkan model GARCH pada masing-masing saham kemudian dilakukan estimasi dan pengujian signifikansi parameter GARCH. Pengujian parameter GARCH dilakukan dengan menyertakan model ARMA karena dalam pemodelan serentak dimungkinkan terjadinya perubahan model maupun estimastor. Tabel 4.23 merupakan model ARMA-GARCH pada data sebelum *Tax Amnesty* masing-masing saham. Diketahui bahwa semua saham menghasilkan model ARMA-GARCH yang telah signifikan pada taraf 10%.

Tabel 4.24 Estimasi dan Uji Signifikansi Parameter ARIMA-GARCH Selama *Tax Amnesty*

Saham	Model	Parameter	Estimasi	t_{hitung}	P-*value*
BBCA	ARMA (0,1) GARCH (1,0)	θ_1	-0,72897	-10,2423	0,00000
		ω	0,29951	6,9819	0,00000
		τ_1	0,22976	2,0738	0,038099
BMRI	ARMA (1,1) GARCH (0,1)	ϕ_1	0,441860	4,5712	0,000005
		θ_1	-0,944891	-18,0404	0,000000
		ω	0,000975	1,9963	0,045905
		β_1	0,995875	460,1206	0,000000
BBRI	ARMA (1,1) GARCH (0,1)	ϕ_1	0,404029	6,1205	0,000
		θ_1	-0,974910	-228,2920	0,000
		ω	0,000767	5,8605	0,000
		β_1	0,995750	1224,2531	0,000
BBNI	ARMA (1,1) GARCH (0,1)	ϕ_1	0,265866	2,0692	0,038527
		θ_1	-0,772434	0,092929	0,000000
		ω	0,001052	0,000612	0,085515
		β_1	0,995535	0,002395	0,000000

Pemodelan ARMA-GARCH data selama *Tax Amnesty* dapat dilihat pada tabel 4.24. Diketahui bahwa pada saham BBCA, BMRI, BBRI, dan BBNI memiliki parameter model ARMA-GARCH yang telah signifikan pada taraf 10%. Residual model yang lebih kecil dari nol bernilai 1 dan yang lebih besar dari nol diberi nilai 0. Hal ini dilakukan untuk menghitung durasi yang nantinya digunakan dalam pemodelan ACD.

Setelah dilakukan perhitungan durasi dari residual model ARMA-GARCH maka data durasi terlebih dahulu diuji distribusi.

Uji distribusi yang dilakukan adalah uji distribusi data memenuhi distribusi eksponensial atau weibull. Hasil menunjukkan bahwa data sebelum dan selama *Tax Amnesty* di semua perusahaan memenuhi ditribusi eksponensial. Namun, dalam penelitian ini tetap dilakukan pemodelan dengan distribusi weibull sehingga dapat dibandingkan model terbaik yang diperoleh.

4.3.1 Pemodelan BBCA dengan ACD

Data durasi diperoleh dari hasil residual model ARIMA-GARCH kemudian diuji efek ACD sebelum data dimodelkan. Uji efek ACD dilihat pada plot ACF dari data durasi. Gambar 4.27 menunjukkan bahwa ACF *plot* dari data durasi saham BBCA sebelum *Tax Amnesty* membentuk pola *cut off lag* 8 namun, tidak ada *cut off lag* pada data selama *Tax Amnesty*. Secara visual diketahui bahwa durasi BBCA sebelum *Tax Amnesty* dan memiliki efek ACD tetapi pada periode selama *Tax Amnesty* tidak memiliki efek ACD.

Sebelum melakukan estimasi parameter, terlebih dahulu dilakukan identifikasi model ACD menggunakan plot ACF dan PACF dari durasi kuadrat. Berdasarkan PACF yang ditunjukkan Gambar 4.28 lag 24 dari data durasi kuadrat saham BBCA sebelum *Tax Amnesty* mengalami *cut off*. ACF dan PACF durasi kuadrat saham BBCA selama *Tax Amnesty* tidak mengalami *cut off*.

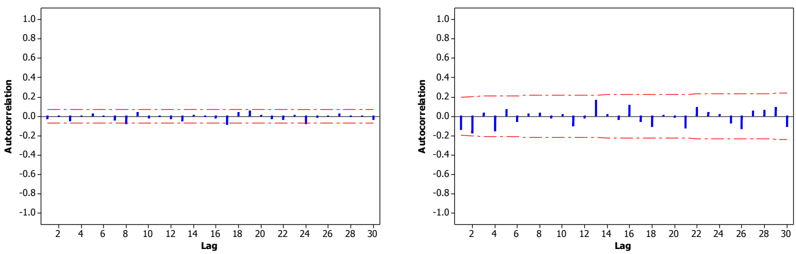

(a) (b)

Gambar 4.27 ACF *Plot* Durasi BBCA (a) Sebelum dan (b) Selama *Tax Amnesty*

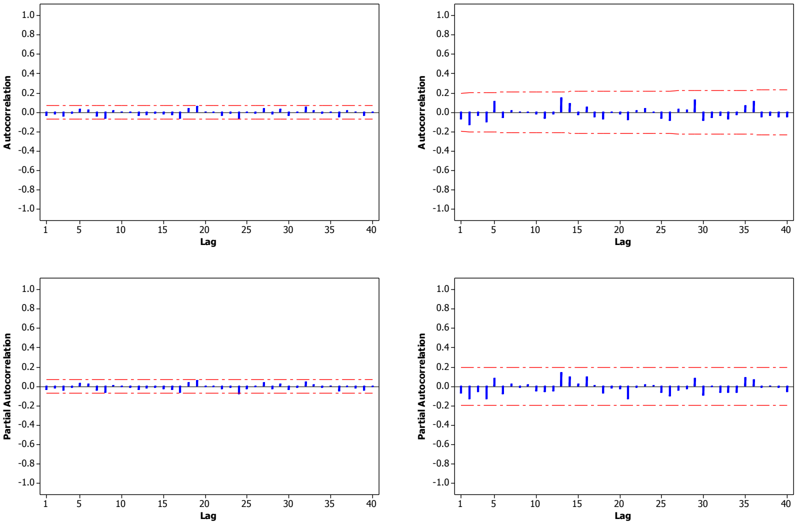

(a) (b)

Gambar 4.28 ACF dan PACF *Plot* Durasi Kuadrat BBCA (a) Sebelum dan (b) Selama *Tax Amnesty*

Pemodelan ACD juga menggunakan prinsip *parcimony* sehingga model dugaan adalah ACD (1,1) dan ACD (1,0). Model ACD yang dibentuk mengikuti distribusi eksponensial dan weibull.

Hasil pengujian signifikansi parameter disajikan pada tabel 4.25. Berdasarkan tabel tersebut diketahui bahwa semua model data sebelum *Tax Amnesty* dan model WACD selama *Tax Amnesty* memiliki nilai P-*value* lebih kecil dari taraf signifikan 10%. Hal ini menunjukkan bahwa nilai parameter model telah signifikan. Model EACD pada data data selama *Tax Amnesty* tidak signifikan disebabkan oleh parameter omega yang tidak signifikan pada taraf 10%.

Nilai Q pada model EACD dan WACD dari data durasi BBCA lebih kecil dari *Chi-square* tabel dengan db 20. Artinya model telah memenuhi asumsi *white noise* dilihat dari 20 lag pertama dengan Uji Ljung Box sesuai tabel 4.26. Model telah memenuhi asumsi selanjunya dipilih model terbaik dengan kriteris AIC dan SBC.

Tabel 4.25 Estimasi dan Uji Signifikansi Parameter ACD BBCA

Periode	Model	Parameter	Estimasi	P-*value*
Sebelum	EACD (1,1)	ω	0,0991	0,068
		τ_1	-0,0329	0,040
		β_1	0,9831	0,000
	WACD (1,1)	ω	0,1229	0,003
		τ_1	-0,0398	0,001
		β_1	0,9784	0,000
		γ	1,5493	0,000
Selama	EACD(1,1)	ω	0,660	0,145
		τ_1	-0,187	0,013
		β_1	0,839	0,000
	WACD (1,1)	ω	0,662	0,011
		τ_1	-0,203	0,000
		β_1	0,856	0,000
		γ	1,616	0,000

Tabel 4.26 Uji *White Noise* ACD BBCA

Periode	Model	Uji *White Noise*		
		Q	db	P-*value*
Sebelum	EACD (1,1)	23,283	20	0,2751
	WACD (1,1)	23,469	20	0,2664
Selama	EACD (1,1)	11,055	20	0,9448
	WACD (1,1)	11,365	20	0,9362

Durasi data saham BBCA sebelum dan selama *Tax Amnesty* memiliki model terbaik WACD(1,1) karena memiliki nilai AIC dan SBC terkecil. Model terbaik yang telah dipilih pada masing-masing periode diperoleh nilai durasi taksiran. Model WACD (1,1) dari durasi volume transaksi saham BBCA sebelum dan selama *Tax Amnesty* secara matematis dapat ditulisakan sebagai berikut.

1. BBCA sebelum *Tax Amnesty* :

WACD (1,1) : $x_i = \psi_i \in_i$, $\psi_i = 0{,}1229 - 0{,}0398 x_{i-1} + 0{,}9784 \psi_{i-1}$

2. BBCA selama *Tax Amnesty* :

WACD (1,1) : $x_i = \psi_i \in_i$, $\psi_i = 0,662 - 0,203 x_{i-1} + 0,856 \psi_{i-1}$

Tabel 4.27 Kriteria Kebaikan Model ACD BBCA

Periode	**Model**	**AIC**	**SBC**
Sebelum	EACD (1,1)	2873,347950	2887,587186
	WACD (1,1)	2617,315893	2636,301541
Selama	EACD (1,1)	325,886234	333,671593
	WACD (1,1)	293,748902	304,129381

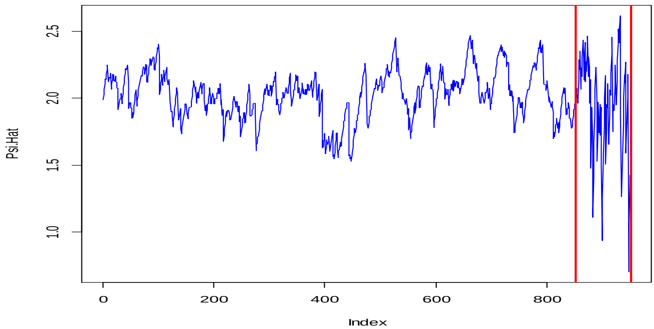

Gambar 4.29 Durasi Taksiran Model ACD BBCA

Durasi taksiran menggambarkan jarak antara kejadian nilai volume transaksi yang rendah. Durasi taksiran dari model sebelum *Tax Amnesty* ditunjukkan pada gambar 4.29 disebelah kiri garis merah. Durasi taksiran selama *Tax Amnesty* dapat digambarkan seperti di dalam batas garis merah. Gambar tersebut menjelaskan bahwa selama periode sebelum *Tax Amnesty* durasi berada pada rentang 1,5 sampai 2,5 yang artinya likuiditas saham relatif stagnan. Periode awal *Tax Amnesty* durasi tinggi sering terjadi dan pada pertengahan likuiditas sempat turun drastis. Namun, di akhir periode nilai durasi meningkat yang artinya saham semakin liukuid. *Tax amnesty* mengakibatkan likuiditas saham BBCA menjadi lebih fluktuatif.

4.3.2 Pemodelan BMRI dengan ACD

Gambar ACF *plot* 4.30 menunjukkan bahwa ACF *plot* mengelami *cut off*. Sebaliknya pada durasi sebelum *Tax Amnesty*. Secara visual didapat bahwa durasi saham BMRI sebelum *Tax Amnesty* tidak memiliki efek ACD sedangkan durasi selama *Tax Amnesty* memiliki efek ACD.

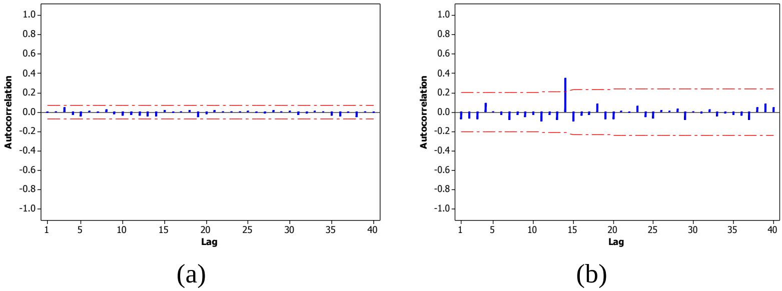

Gambar 4.30 ACF *Plot* Durasi BMRI (a) Sebelum dan (b) Selama *Tax Amnesty*

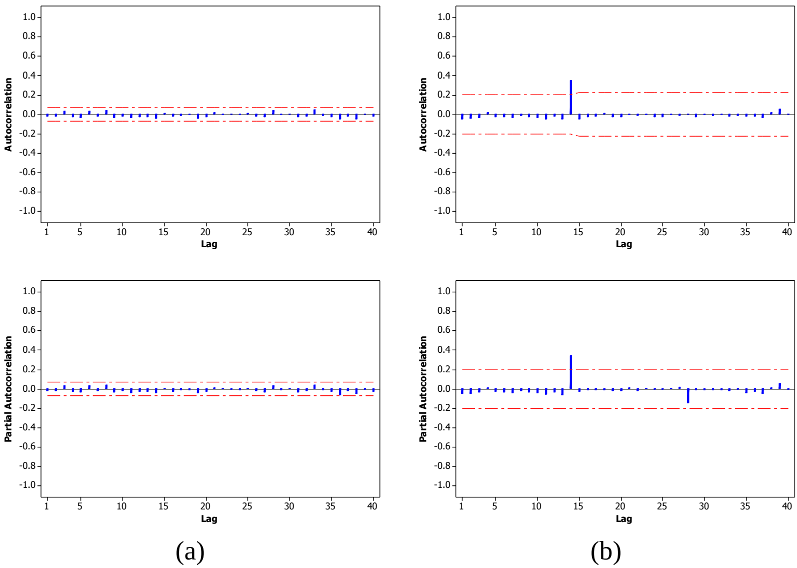

Gambar 4.31 ACF dan PACF *Plot* Durasi Kuadrat BMRI (a) Sebelum dan (b) Selama *Tax Amnesty*

Identifikasi model ACD menggunakan plot ACF dan PACF dari data durasi kuadrat. Berdasarkan ACF dan PACF yang ditunjukkan pada Gambar 4.31, diketahui bahwa data durasi kuadrat selama *Tax Amnesty* pada plot ACF mengalami *cut off* . Plot PACF tidak megalami *cut off* pada periode sebelum *Tax Amnesty* dan mengalami *cut off* pada periode selama *Tax Amnesty*. Model ACD yang dibentuk berdasarkan prinsip *parsimony* mengikuti distribusi eksponensial dan weibull.

Hasil pengujian signifikansi parameter disajikan pada tabel 4.28. Berdasarkan tabel tersebut diketahui bahwa semua model dari data sebelum *Tax Amnesty* dan model selama *Tax Amnesty* memiliki nilai P-*value* lebih kecil dari taraf signifikan 10%. Hal ini menunjukkan bahwa nilai parameter model telah signifikan.

Tabel 4.28 Estimasi dan Uji Signifikansi Parameter ACD BMRI

Periode	**Model**	**Parameter**	**Estimasi**	**P-*value***
Sebelum	EACD (0,1)	ω	0,260	0,000
		β_1	0,868	0,000
	WACD (1,1)	ω	0,0201	0,014
		τ_1	-0,0162	0,001
		β_1	1,0057	0,000
		γ	1,5352	0,000
Selama	EACD (0,1)	ω	0,217	0,000
		β_1	0,883	0,000
	WACD (1,1)	ω	0,0542	0,024
		τ_1	-0,0985	0,000
		β_1	1,0776	0,000
		γ	1,7009	0,000

Model telah memenuhi asumsi *white noise* dilihat dari 20 lag pertama dengan Uji Ljung Box sesuai tabel 4.29. Hal itu dilihat dari nilai Q pada model EACD dan WACD dari data durasi BMRI lebih kecil dari Chi-square tabel dengan db 20. Model telah memenuhi asumsi selanjunya dipilih model terbaik dengan kriteris AIC dan SBC.

Tabel 4.29 Uji *White Noise* ACD BMRI

Periode	Model	Uji *White Noise*		
		Q	db	P-*value*
Sebelum	EACD (1,1)	13,003	20	0,8772
	WACD (1,1)	10,651	20	0,9548
Selama	EACD (1,1)	23,322	20	0,2733
	WACD (1,1)	17,751	20	0,6038

Tabel 4.30 Kriteria Kebaikan Model ACD BMRI

Periode	Model	AIC	SBC
Sebelum	EACD (0,1)	2887,637046	2897,148584
	WACD (1,1)	2631,771117	2650,794193
Selama	EACD (0,1)	323,457687	328,627622
	WACD (1,1)	283,957335	294,297205

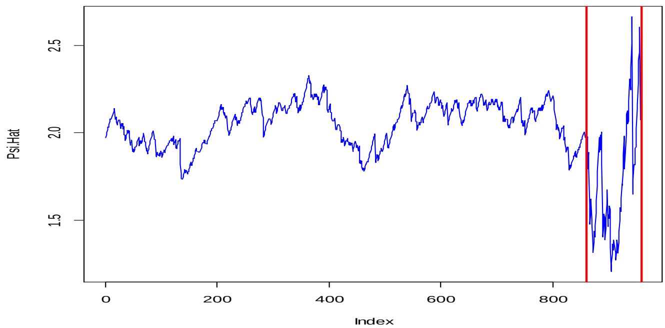

Gambar 4.32 Durasi Taksiran Model ACD BMRI

Sama seperti durasi data saham BBCA, durasi saham BMRI sebelum dan selama *Tax Amnesty* memiliki model terbaik WACD (1,1) karena memiliki nilai AIC dan SBC terkecil. Dari model terbaik yang telah dipilih pada masing-masing periode diperoleh nilai durasi taksiran. Model WACD (1,1) durasi transaksi saham BMRI sebelum dan selama *Tax Amnesty* secara matematis dapat ditulisakan sebagai berikut.

1. BMRI sebelum *Tax Amnesty* :

WACD (1,1) : $x_i = \psi_i \in_i$, $\psi_i = 0{,}0201 - 0{,}0162 x_{i-1} + 1{,}0057 \psi_{i-1}$

2. BMRI selama *Tax Amnesty* :

WACD (1,1) : $x_i = \psi_i \in_i$, $\psi_i = 0,0542 - 0,0985 x_{i-1} + 1,0776 \psi_{i-1}$

Durasi taksiran dari model ditunjukkan pada gambar 4.32. Durasi taksiran selama *Tax Amnesty* dapat digambarkan seperti di dalam batas garis merah. Gambar tersebut menjelaskan bahwa selama periode sebelum *Tax Amnesty* durasi yang menggambarkan likuditas saham berada di sekitar 2,0. Pada periode awal *Tax Amnesty* likuiditas saham BMRI menurun namun, menjelang penutupan *Tax Amnesty* nilai durasi meningkat tajam diatas 2,5. Peningkatan di akhir periode menunjukkan bahwa saham BMRI semakin likuid menjelang penutupan kebijakan dibelakukannya *Tax Amnesty*.

4.3.3 Pemodelan BBRI dengan ACD

Gambar 4.33 menunjukkan bahwa ACF *plot* menunjukkan *cut off* pada durasi sebelum dan selama *Tax Amnesty*. Secara visual didapat bahwa data durasi saham BBRI sebelum *Tax Amnesty* dan selama *Tax Amnesty* memiliki efek ACD.

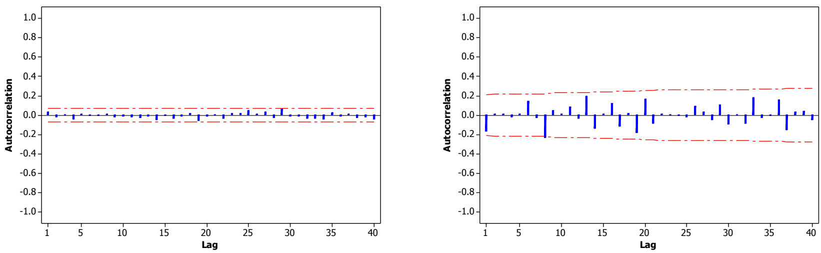

(a) (b)

Gambar 4.33 ACF *Plot* Durasi BBRI (a) Sebelum dan (b) Selama *Tax Amnesty*

Sebelum melakukan estimasi parameter, terlebih dahulu dilakukan identifikasi model ACD menggunakan plot ACF dan PACF dari durasi kuadrat. Berdasarkan ACF dan PACF yang ditunjukkan pada gambar 4.34, diketahui bahwa terdapat lag data durasi kuadrat saham BBRI mengalami *cut off* baik sebelum dan selama *Tax Amnesty*. Model ACD dugaan adalah ACD (1,1), ACD (1,0), dan ACD (0,1).

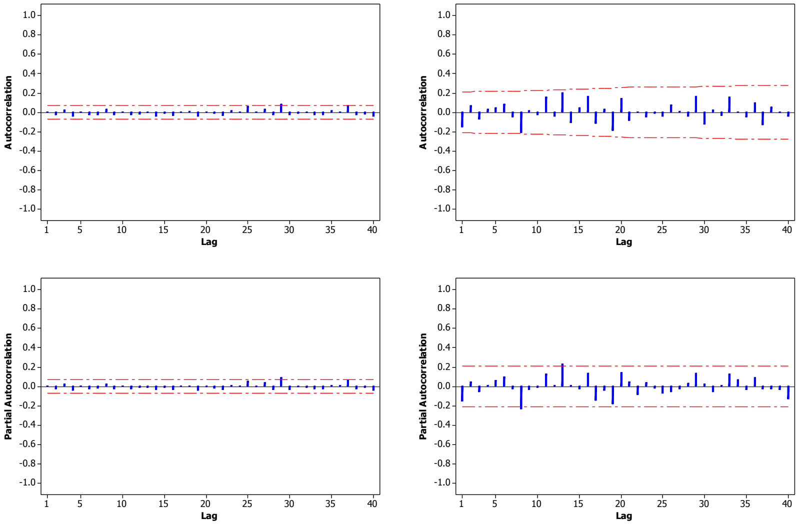

(a) (b)

Gambar 4.34 ACF dan PACF *Plot* Durasi Kuadrat BBRI (a) Sebelum dan (b) Selama *Tax Amnesty*

Tabel 4.31 Estimasi dan Uji Signifikansi Parameter ACD BBRI

Periode	Model	Parameter	Estimasi	P-*value*
Sebelum	EACD (1,1)	ω	1,1896	0,619
		τ_1	0,0344	0,417
		β_1	0,3564	0,774
	WACD (0,0)	ω	1,98	0,000
		γ	1,51	0,000
Selama	EACD(1,1)	ω	2,6290	0,160
		τ_1	0,0859	0,558
		β_1	-0,6025	0,538
	WACD (1,0)	ω	2,452	0,000
		τ_1	-0,163	0,067
		γ	2,126	0,000

Hasil pengujian signifikansi parameter disajikan pada tabel 4.31. Berdasarkan tabel tersebut diketahui bahwa model WACD dari data sebelum *Tax Amnesty* dan model selama *Tax Amnesty* memiliki nilai P-*value* lebih kecil dari taraf signifikan 10%. Hal ini menunjukkan bahwa nilai parameter model telah signifikan. Namun, model EACD (1,1) pada periode sebelum dan selama *Tax Amnesty* tidak signifikan dilihat dari nilai P-*value* yang lebih besar dari taraf signifikan 10%.

Sebelum dipilih model terbaik dengan kriteria AIC dan SBC model terlebih dahulu diuji asumsi *white noise*. Nilai Q pada model EACD dan WACD dari data durasi BBRI lebih kecil dari *Chi-square tabel* dengan db 20. Artinya model telah memenuhi asumsi *white noise* dilihat dari 20 lag pertama sesuai tabel 4.32.

Tabel 4. 32 Uji *White Noise* ACD BBRI

Periode	**Model**	**Uji *White Noise***		
		Q	**db**	**P-*value***
Sebelum	EACD (1,1)	11,145	20	0,9424
	WACD (1,1)	10,862	20	0,9497
Selama	EACD (1,1)	26,300	20	0,1561
	WACD (1,1)	23,214	20	0,2784

Durasi saham BBRI sebelum *Tax Amnesty* memiliki model terbaik WACD (0,0) dan selama *Tax Amnesty* model terbaik yang terpilih adalah WACD (1,0). Pemilihan model terbaik karena memiliki nilai AIC dan SBC terkecil. Model WACD (0,0) durasi transaksi saham BBRI sebelum *Tax Amnesty* dan model WACD (1,0) selama *Tax Amnesty* secara matematis dapat ditulisakan sebagai berikut.

1. BBRI sebelum *Tax Amnesty* :

WACD (0,0) : $x_i = \psi_i \in_i,\ \psi_i = 1{,}98$

2. BBRI selama *Tax Amnesty* :

WACD (1,0) : $x_i = \psi_i \in_i,\ \psi_i = 2{,}452 - 0{,}163 x_{i-1}$

Model terbaik yang telah dipilih pada masing-masing periode digunakan untuk memperoleh nilai durasi taksiran. Karena data sebelum *Tax Amnesty* modelnya hanya konstanta saja maka dapat dikatan data durasi tidak memiliki efek ACD baik EACD maupun WACD dilihat dari parameter model yang tidak signifikan. Nilai durasi taksiran yang seharusnya dapat digunakan untuk membandingkan menjadi tidak berguna.

Tabel 4. 33 Kriteria Kebaikan Model ACD BBRI

Periode	Model	AIC	SBC
Sebelum	EACD (1,1)	2891,954044	2906,242233
	WACD (0,0)	2642,661111	2652,184256
Selama	EACD (1,1)	342,398814	350,472858
	WACD (1,0)	256,041832	263,541261

4.3.4 Pemodelan BBNI dengan ACD

Secara visual didapat bahwa data durasi saham BBNI sebelum *Tax Amnesty* dan selama *Tax Amnesty* memiliki efek ACD. Berikut merupakan gambar ACF plot pada saham BBNI sebelum *Tax Amnesty* dan selama *Tax Amnesty*. Gambar 4.35 menunjukkan bahwa ACF *plot* mengalami *cut off*.

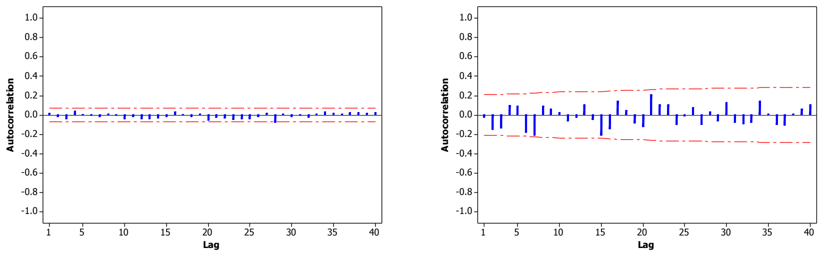

(a) (b)

Gambar 4.35 ACF *Plot* Durasi BBNI (a) Sebelum dan (b) Selama *Tax Amnesty*

ACF dan PACF yang ditunjukkan pada gambar 4.36, diketahui bahwa data durasi kuadrat saham BBNI selama *Tax Amnesty* pada plot ACF mengalami *cut off* . Plot PACF tidak megalami *cut off* pada periode sebelum *Tax Amnesty* dan periode selama *Tax Amnesty*. Walaupun begitu tetap dilakukan pemodelan ACD dimana model dugaan adalah ACD (1,1) dan ACD (1,0).

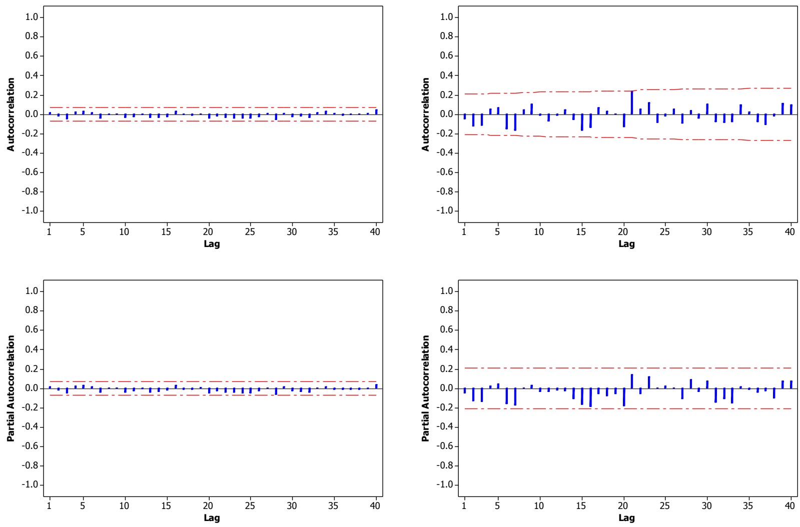

(a) (b)

Gambar 4.36 ACF dan PACF *Plot* Durasi Kuadrat BBNI (a) Sebelum dan (b) Selama *Tax Amnesty*

Tabel 4.34 Estimasi dan Uji Signifikansi Parameter ACD BBNI

Periode	**Model**	**Parameter**	**Estimasi**	**P-*value***
Sebelum	EACD (0,1)	ω	0,262	0,000
		β_1	0,865	0,000
	WACD (1,1)	ω	0,0920	0,011
		τ_1	-0,0273	0,004
		β_1	0,9804	0,000
		γ	1,5492	0,000
Selama	EACD(1,1)	ω	0,366	0,019
		τ_1	-0,263	0,000
		β_1	1,077	0,000
	WACD (1,1)	ω	0,399	0,000
		τ_1	-0,281	0,000
		β_1	1,079	0,000
		γ	1,959	0,000

Hasil pengujian signifikansi parameter disajikan pada tabel 4.34. Diketahui bahwa model WACD dan EACD dari data sebelum *Tax Amnesty* dan model selama *Tax Amnesty* memiliki nilai P-*value* lebih kecil dari taraf signifikan 10%. Hal ini menunjukkan bahwa nilai parameter model telah signifikan. Model telah memenuhi asumsi *white noise* dilihat dari 20 lag pertama dengan Uji Ljung Box. Nilai Q pada model EACD dan WACD dari data durasi BBNI lebih kecil dari *Chi-square* tabel dengan db 20 sesuai tabel 4.35. Model telah memenuhi asumsi selanjunya dipilih model terbaik dengan kriteris AIC dan SBC.

Tabel 4. 35 Uji *White Noise* ACD BBNI

Periode	**Model**	**Uji *White Noise***		
		Q	**db**	**P-*value***
Sebelum	EACD (1,1)	13,856	20	0,8377
	WACD (1,1)	14,102	20	0,8253
Selama	EACD (1,1)	18,856	20	0,5312
	WACD (1,1)	18,682	20	0,5425

Tabel 4.36 Kriteria Kebaikan Model ACD BBNI

Periode	**Model**	**AIC**	**SBC**
Sebelum	EACD (1,1)	2892,268491	2901,798569
	WACD (1,1)	2631,959725	2651,019880
Selama	EACD (1,1)	307,894425	315,427003
	WACD (1,1)	257,352861	267,396299

Sama seperti durasi data saham sebelumnya, durasi saham BBNI sebelum dan selama *Tax Amnesty* memiliki model terbaik WACD (1,1) karena memiliki nilai AIC dan SBC terkecil sesuai tabel 4.36. Dari model terbaik yang telah dipilih pada masing-masing periode diperoleh nilai durasi taksiran. Model WACD (1,1) durasi transaksi saham BBNI sebelum dan selama *Tax Amnesty* secara matematis dapat ditulisakan

1. BBNI sebelum *Tax Amnesty* :

WACD (1,1) : $x_i = \psi_i \in_i$, $\psi_i = 0,0920 - 0,0273 x_{i-1} + 0,9804 \psi_{i-1}$

2. BBNI selama *Tax Amnesty* :

WACD (1,1) : $x_i = \psi_i \in_i$, $\psi_i = 0,399 - 0,281 x_{i-1} + 1,079 \psi_{i-1}$

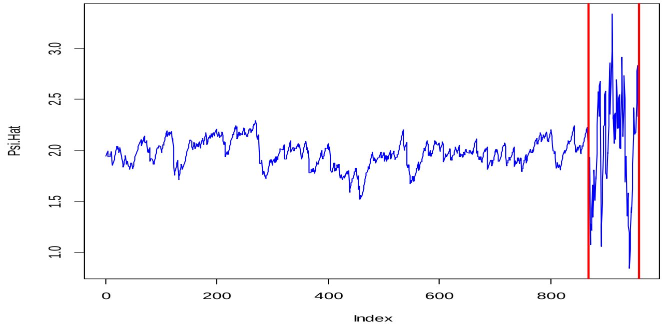

Gambar 4.37 Durasi Taksiran Model ACD BBNI

Nilai durasi taksian merupakan taksiran antara kejadian volume transaksi rendah. Durasi taksiran dari model sebelum *Tax Amnesty* ditunjukkan pada gambar 4.37 disebelah kiri gris merah. Durasi taksiran selama *Tax Amnesty* dapat digambarkan seperti di dalam batas garis merah. Gambar tersebut menjelaskan bahwa selama periode sebelum *Tax Amnesty* durasi relatif stabil disekitar 2,0 yang atinya likuiditas saham juga relatif stabil sama halnya dengan saham BBCA dan BMRI. Periode awal *Tax Amnesty* jarak nilai durasi semakin rendah artinya saham BBNI semakin tidak likuid. Saham BBNI mengalami likuiditas tertinggi pada pertengahan kebijakan *Tax Amnesty* berlangsung dan sempet mengalami penurunan kemudian mengalami peningkatan tajam menjelang penutupan *Tax Amnesty*.

(Halaman ini sengaja dikosongkan)

BAB V
KESIMPULAN DAN SARAN

5.1 Kesimpulan

Hasil analisis karakteristik data dilihat dari *skewness* dan *kurtosis* volume transaksi harian saham tidak mengikuti distribusi normal. Transaksi perusahaan BBCA lebih stabil dilihat dari nilai koefisien variansi volume transaksi saham terendah. Saham yang paling tidak satbil dalam transaksi harian yaitu BBNI baik selama periode *Tax Amnesty* maupun selama periode sebelum *Tax Amnesty*. Hasil analisis intervensi menjunjukan tidak terdapat efek intervensi akibat adanya kebijakan *Tax Amnesty* pada BBCA dan BBRI namun, terdapat efeknya pada volume saham BMRI dan BBNI. Analisis intervensi yang dilakukan belum memenuhi distribusi normal walaupun asumsi *white noise* terpenuhi. Model pembanding dari analisis intervensi adalah model ACD. Model ACD yang terbentuk dapat menggambarkan bahwa volume transaksi menghasilkan nilai durasi tinggi pada periode *Tax Amnesty* artinya saham lebih likuid selama periode *Tax Amnesty*. Hanya saja, pada saham BBRI tidak dapat dibandingkan karena data sebelum *Tax Amnesty* tidak terdapat efek ACD dilihat dari parameter konstanta saja yang signifikan.

5.2 Saran

Sebaiknya pihak perbankan penerima dana repatriasi mengetahui dan melakukan analisa setelah diketahui bila saham semakin likuid atau semakin banyak mengalami profit dibanding loss. Analisis proyeksi saham dilakukan secara periodik bila terdapat kejadian-kejain yang diduga berpengaruh pada likuiditas saham. Selain itu data pada analisis sebaiknya menggunakan data i*ntraday* dimana transaksi yang tercatat bukan harian tapi per tiap kali transaksi. Pengembangan metode penelitian berkaitan juga sangat diperlukan yaitu menggunakan pendekatan distrubusi gamma atau distribusi burr, selain itu perbedaan likuiditas sebelum dan selama *Tax Amnesty* sebaiknya diuji secara statistik jika memungkinkan. Penelitian ini pada model EACD dan

WACD masih terdapat estimasi parameter bernilai negatif (-) maka, disarankan dilakukan penelitian lanjutan tentang optimasi numerik sehingga penaksir parameter yang dihasilkan positif (0) atau lebih besar dari 0 sesuai teori.

DAFTAR PUSTAKA

Apriyani. (2016, Februari 16). *Menilik Saham Bank Pilihan di 2016*. Diakses Oktober 3, 2016, dari http://infobanknews. com/?s= Menilik+Saham+Bank+Pilihan+di+2016

Chandra, A. A. (2017, April 01). *detik finance*. Diakses April 22, 2017, dari https://finance.detik.com/berita-ekonomi bisnis /3462172/program-tax-amnesty-berakhir-ini-hasilnya

Christoffersen, P., & Pelletier, D. (2003, Oktober 24). A Duration-Based Approach. (E. Renault, Ed.) *Backtesting Value-at-Risk*, 4-5. doi: 10.1093/jjfinec/nbh004

Cryer, J., & Chan, K. (2008). *Time Series Analysis With Application in R.* New York: Springer Science.

Douglas, A. L., William, G. M., & Samuel, A. W. (2007). *Teknik-teknik Statistika dalam Bisnis dan Ekonomi Menggunakan Kelompok Data Global.* Jakarta: Salemba Empat.

Engle, R. (2002). New Frontiers For ARCH Models. *Journal of Applied Econometrics, 17,* 425-446. doi: 10.1002/jae.683

Engle, R., & Russell, J. (1998). Autoregressive Conditional Duration : A New Model For Irregularly Spaced Transaction Data. *Econometrica, 66*, 1127-1162. doi: 10. 2307/2999632

Fitriyah, Q. (2009). *Model Autoregressive Conditional Duration (ACD) dan Penerapannya.* Skripsi, Universitas Negeri Yogyakarta, Jurusan Pendidikan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Yogyakarta.

Hautsch, N. (2012). *Econometrics of Financial High-Frequency Data.* New York, Berlin, Heidelberg: Springer Verlag.

Iin, I., & Mulyani, D. (2011). Analisis Perbandingan Harga Saham dan Volume Perdagangan Saham Sebelum dan Sesudah Stock Split. *Aset, 13*(1), 57-63.

Indonesia Stock Exchange. (2016, Februari). IDX LQ45 Februari 2016. pp. 1-187.

Islami, A. C. (2016). *Peramalan Nilai Tukar Dolar Amerika Serikat terhadap Rupiah Menggunakan Intervensi dan ANFIS*. Institut Teknologi Sepuluh Nopember, Statistika. Suarabaya: ITS.

Meitz, M., & Terasvirta, T. (2004, Desember). Evaluating Models of Autoregressive Conditional Duration. *SSE/EFI Working Paper Series in Economics and Finance*, 1-36. doi: 10.1198/073500105000000081

Mubarokah, F. (2011). *Analisis Pengaruh Harga Saham, Return Saham, dan Volume Perdagangan Terhadap Likuiditas Saham Pada Perusahaan Go Public yang Melakukan Stock Split di Bursa Efek Indonesia Periode Januari 2007 sampai dengan Maret 2011*. Skripsi, Universitas Semarang, Fakultas Ekonomi, Semarang.

Napitupulu, V., & Syahsunan. (2012). *Pengaruh Return Saham, Volume Perdagangan dan Volatilitas Harga Saham Terhadap Bid-Ask Spread pada Perusahaan yang Melakukan Stock Split di Bursa Efek Indonesia.*

Nisaputra, R. (2016, November 7). *OJK: Syarat Sudah Terpenuhi, CIMB Niaga Masuk BUKU IV*. Retrieved Desember 15, 2016, from http://infobanknews.com/ojk-syarat-sudah-terpenuhi-cimb-masuk-buku-iv/

Oliveira, M. A., Bueno, R. L., Kotsubo, L. S., & Bergmann, D. R. (2016). Autoregressive Conditional Duration Models: An Application in the Brazilian Stock Market. *Applied Mathematical Sciences, X*, 1573 - 1594. doi: 10.12988/ams.2016.510672

Otoritas Jasa Keuangan. (2016). *Statistik Perbankan Indonesia (Indonesian Banking Statistics)*. Jakarta: Departemen Perizinan dan Informasi Perbankan.

Presiden Republik Indonesia. (1995). Undang-Undang Republik Indonesia Tentang Pasar Modal. *Rapat Dewan Perwakilan Rakyat Indonesia*, (pp. 1-81). Indonesia.

Ruppert, D. (2004). *Statistics and Finance An Introduction* (1st ed.). New York: Springer Science.

Tsay, R. S. (2013). *An Introduction to Analysis of Financial Data with R* (1st ed.). Hoboken, New Jersey: John Wiley & Sons, Inc.

Tse, Y. K., & Yang, T. (2010, Mei). Estimation of High-Frequency Volatility: An Autoregressive Conditional Duration Models Approach. *Research Collection School of Economics*, 1-48. doi: 10.1080/07350015.2012.707582

Walpole, R. (1995). *Pengantar Statistika.* (B. Sumantri, Trans.) Jakarta: PT. Gramedia Pustaka Utama.

Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). Canada: Addison Wesley Publishing Company.

Yoga, P. (2015, Desember 22). *Saham 3 Bank Ini Paling Diincar Investor*. Diakses Oktober 3, 2016, dari http://infobank news.com/?s=Saham+3+Bank+Ini+Paling+Diincar+Inves tor

(Halaman ini sengaja dikosongkan)

LAMPIRAN

Lampiran 1 Data Volume Sebelum *Tax Amnesty*

Tanggal	BBCA	BBNI	BBRI	BMRI
1/4/2010	15562500	8642900	22744000	53101600
1/5/2010	8888500	15508400	29753000	27767100
1/6/2010	5556500	16018900	19062000	17484400
1/7/2010	7726500	10575900	18533000	29576300
...	...	...	...	...
...	...	...	...	...
...	...	...	...	...
6/23/2016	6050400	13121000	9510700	9893200
6/24/2016	17376700	21174200	22675700	27189100
6/27/2016	8863200	17152800	7109500	7515100
6/28/2016	24371200	44684800	30635400	45056700
6/29/2016	40029400	96649700	37635400	29786800
6/30/2016	37354100	44907800	51831600	23601700

Lampiran 2 Data Volume Selama *Tax Amnesty*

Tanggal	BBCA	BBNI	BBRI	BMRI
7/1/2016	25339100	9469400	20531700	15184700
7/4/2016	25339100	9469400	20531700	15184700
7/5/2016	25339100	9469400	20531700	15184700
...	...	...	...	...
...	...	...	...	...
...	...	...	...	...
3/28/2017	14904800	34912500	14397600	10844200
3/29/2017	22529100	35464300	27752000	13914500
3/30/2017	19297600	47605300	17703400	8040400
3/31/2017	16328500	49095300	14813000	15996400

Lampiran 3 Statistika Deskriptif Volume Transaksi

a. Sebelum dan Selama *Tax Amnesty*

Descriptive Statistics: BBCA, BMRI, BBRI, BBNI

Variable	Mean	StDev	CoefVar	Skewness	Kurtosis
BBCA	13713658	8252129	60.17	1.95	6.61
BMRI	27690499	18328838	66.19	2.45	10.72
BBRI	31493772	19208546	60.99	1.99	6.12
BBNI	26125796	18014663	68.95	2.46	10.20

b. Sebelum *Tax Amnesty*

Descriptive Statistics: BBCA, BMRI, BBRI, BBNI

Variable	Mean	StDev	CoefVar	Skewness	Kurtosis
BBCA	13085600	7860985	60.07	2.19	8.88
BMRI	28349462	18734036	66.08	2.45	10.58
BBRI	32478421	19615150	60.39	1.95	5.86
BBNI	26304752	18274259	69.47	2.52	10.54

c. Selama *Tax Amnesty*

Descriptive Statistics: BBCA, BMRI, BBRI, BBNI

Variable	Mean	StDev	CoefVar	Skewness	Kurtosis
BBCA	19141873	9493288	49.59	0.88	0.38
BMRI	21995176	13073198	59.44	1.50	2.17
BBRI	22983596	12352717	53.75	1.87	4.07
BBNI	24579099	15547367	63.25	1.42	2.07

Lampiran 4 *Time Series Plot* Semua Periode Data Volume

```
data=read.csv("D:/TA/data TA fix/all data volume
.csv",sep=",",header=TRUE)
BBCA=as.numeric(data$BBCA)
BBNI=as.numeric(data$BBNI)
BBRI=as.numeric(data$BBRI)
BMRI=as.numeric(data$BMRI)
Volume.BBCA=data.frame(data$Date,data$BBCA)
Volume.BBNI=data.frame(data$Date,data$BBNI)
Volume.BBRI=data.frame(data$Date,data$BBRI)
Volume.BMRI=data.frame(data$Date,data$BMRI)

#Plot data Volume BBCA
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBCA[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBCA")
labels=as.numeric(format(as.Date(Volume.BBCA[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,80000000,by=20000000),label=seq(0,80000000,by=20000000)
,lwd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BBNI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBNI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBNI")
labels=as.numeric(format(as.Date(Volume.BBNI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
```

Lampiran 5 *Time Series Plot* Semua Periode Data Volume (Lanjutan)

```
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BBRI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBRI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBRI")
labels=as.numeric(format(as.Date(Volume.BBRI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BMRI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BMRI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BMRI")
labels=as.numeric(format(as.Date(Volume.BMRI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")
```

Lampiran 6 *Time Series Plot* Volume Sebelum *Tax Amnesty*

```
data=read.csv("D:/TA/data TA fix/data volume sebelum
tax.csv",sep=",",header=TRUE)
BBCA=as.numeric(data$BBCA)
BBNI=as.numeric(data$BBNI)
BBRI=as.numeric(data$BBRI)
BMRI=as.numeric(data$BMRI)
Volume.BBCA=data.frame(data$Date,data$BBCA)
Volume.BBNI=data.frame(data$Date,data$BBNI)
Volume.BBRI=data.frame(data$Date,data$BBRI)
Volume.BMRI=data.frame(data$Date,data$BMRI)

#Plot data Volume BBCA
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBCA[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBCA")
labels=as.numeric(format(as.Date(Volume.BBCA[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,80000000,by=20000000),label=seq(0,80000000,by=20000000)
,lwd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BBNI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBNI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBNI")
labels=as.numeric(format(as.Date(Volume.BBNI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
```

Lampiran 7 *Time Series Plot* Volume Sebelum *Tax Amnesty* (Lanjutan)

```
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BBRI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBRI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBRI")
labels=as.numeric(format(as.Date(Volume.BBRI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BMRI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BMRI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BMRI")
labels=as.numeric(format(as.Date(Volume.BMRI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")
```

Lampiran 8 *Time Series Plot* Volume Selama *Tax Amnesty*

```
data=read.csv("D:/TA/data TA fix/data volume selama
tax.csv",sep=",",header=TRUE)
BBCA=as.numeric(data$BBCA)
BBNI=as.numeric(data$BBNI)
BBRI=as.numeric(data$BBRI)
BMRI=as.numeric(data$BMRI)
Volume.BBCA=data.frame(data$Date,data$BBCA)
Volume.BBNI=data.frame(data$Date,data$BBNI)
Volume.BBRI=data.frame(data$Date,data$BBRI)
Volume.BMRI=data.frame(data$Date,data$BMRI)

#Plot data Volume BBCA
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBCA[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBCA")
labels=as.numeric(format(as.Date(Volume.BBCA[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,80000000,by=20000000),label=seq(0,80000000,by=20000000)
,lwd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BBNI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBNI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBNI")
labels=as.numeric(format(as.Date(Volume.BBNI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
```

Lampiran 9 *Time Series Plot* Volume Selama *Tax Amnesty* (Lanjutan)

```
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BBRI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BBRI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BBRI")
labels=as.numeric(format(as.Date(Volume.BBRI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")

#Plot data Volume BMRI
win.graph()
par(mfrow=c(1,1))
plot(Volume.BMRI[,2], type="l", col = "blue", frame=T, axes=F,
xlab="Time",
    ylab="Volume",main="Volume Transaksi BMRI")
labels=as.numeric(format(as.Date(Volume.BMRI[,1],"%m/%d/%Y"),
"%Y"))
where.put=c(1,which(diff(labels) ==1)+1)
axis(side=1, at=where.put,label=labels[where.put], lwd=0.5)
axis(side=2,
at=seq(0,200000000,by=50000000),label=seq(0,200000000,50000000),l
wd=1)
abline(v=where.put, lty="dotted", lwd=0.5, col = "grey")
```

Lampiran 10 *Syntax* Model ARIMA BBCA

```
data TA;
input BBCA;
datalines;
10.15993925
9.393684869
8.795735977
9.211229293
8.779914177
9.206967228
9.63816334
9.520366254
8.822629904
8.704571306
.
.
.
8.901224861
10.3179976
9.389936967
10.81839335
11.59666392
11.48490372
;
proc arima data=TA;
identify var=BBCA(1);
estimate p=(1,2,5,7) q=1 noconstant method=cls;
forecast out=ramalan lead=196;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 11 *Output* Model ARIMA BBCA

```
The SAS System                              11:22 Thursday, May 6, 2017 598

                          The ARIMA Procedure
                 Conditional Least Squares Estimation

                           Standard                 Approx
Parameter       Estimate          Error    t Value    Pr > |t|      Lag

MA1,1            0.99116      0.0034524     287.09      <.0001        1
AR1,1            0.38076        0.02445      15.58      <.0001        1
AR1,2            0.11587        0.02463       4.70      <.0001        2
AR1,3            0.06359        0.02331       2.73      0.0064        5
AR1,4            0.06213        0.02317       2.68      0.0074        7


                     Variance Estimate      0.436591
                     Std Error Estimate      0.66075
                     AIC                    3406.431
                     SBC                    3433.602
                     Number of Residuals        1693

                    Autocorrelation Check of Residuals

                       To        Chi-             Pr >
 Lag       Square     DF    ChiSq    --------------------Autocorrelations--------------------

   6         1.67      1    0.1969    -0.007    -0.015     0.016     0.014    -0.010     0.012
  12         5.07      7    0.6509    -0.023     0.018     0.021     0.022     0.014     0.000
  18        14.74     13    0.3239    -0.010     0.043     0.055    -0.020    -0.016    -0.004
  24        26.68     19    0.1123     0.008     0.049    -0.026    -0.028    -0.005    -0.055
  30        29.76     25    0.2336     0.013    -0.014     0.025    -0.011     0.010     0.024
  36        34.54     31    0.3023    -0.004    -0.034     0.023    -0.013     0.027     0.014
  42        36.76     37    0.4801     0.004     0.007    -0.000    -0.029    -0.003    -0.019
  48        41.47     43    0.5376     0.023     0.018    -0.001    -0.025    -0.020    -0.029
                          Tests for Normality

     Test                  --Statistic---    -----p Value------

     Shapiro-Wilk          W      0.991861    Pr < W      <0.0001
     Kolmogorov-Smirnov    D      0.035967    Pr > D      <0.0100
     Cramer-von Mises      W-Sq   0.440435    Pr > W-Sq   <0.0050
     Anderson-Darling      A-Sq   2.738484    Pr > A-Sq   <0.0050
```

Lampiran 12 *Syntax* Model ARIMA BMRI

```
data TA;
input BMRI;
datalines;
17.78771762
17.13936242
16.67681961
17.20248392
16.39644683
16.77478111
17.24775754
16.09478608
16.70921011
16.36350155
.
.
.
16.5966749
16.10735821
17.11832672
15.83242489
17.62343225
17.2095759
16.9768293
;
proc arima data=TA;
identify var=BMRI(1);
estimate p=(1,2,4) q=1 noconstant method=cls;
forecast out=ramalan lead=196;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 13 *Output* Model ARIMA BMRI

The SAS System 08:01 Saturday, May 8, 2017 2084

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.94736	0.01091	86.85	<.0001	1
AR1,1	0.38658	0.02693	14.35	<.0001	1
AR1,2	0.05685	0.02612	2.18	0.0297	2
AR1,3	0.06055	0.02510	2.41	0.0160	4

Variance Estimate	0.223858
Std Error Estimate	0.473137
AIC	2274.537
SBC	2296.274
Number of Residuals	1693

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.55	2	0.2793	-0.002	-0.001	-0.009	-0.021	0.022	0.022
12	6.96	8	0.5405	0.019	0.032	0.019	0.014	0.018	-0.017
18	14.77	14	0.3937	0.027	-0.012	0.007	0.001	0.003	-0.060
24	23.14	20	0.2822	0.027	-0.005	0.038	-0.039	-0.034	0.002
30	33.40	26	0.1508	0.006	-0.018	-0.035	0.027	-0.048	-0.036
36	38.64	32	0.1947	-0.016	-0.041	-0.030	-0.011	-0.003	0.009
42	51.05	38	0.0766	0.027	-0.025	0.007	-0.044	0.033	-0.052
48	53.39	44	0.1569	-0.006	0.015	0.006	-0.026	0.014	-0.014

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.996529	Pr < W	0.0007
Kolmogorov-Smirnov	D	0.026635	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.271512	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.686857	Pr > A-Sq	<0.0050

Lampiran 14 *Syntax* Model ARIMA BBRI

```
data TA;
input BBRI;
datalines;
16.93981193
17.20844053
16.76320738
16.73506348
16.57937382
16.87534376
17.77949963
16.81682721
16.29061937
16.38880958
.
.
.
16.39282925
16.06792804
16.93680442
15.77694248
17.23766676
17.44345565
17.76351056
;
proc arima data=TA;
identify var=BBRI(1);
estimate p=2 q=1 noconstant method=cls;
forecast out=ramalan lead=196;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 15 *Output* Model ARIMA BBRI

The SAS System 08:01 Saturday, May 8, 2017 1363

The ARIMA Procedure
Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > |t|	Lag
MA1,1	0.99357	0.0026287	377.97	<.0001	1
AR1,1	0.45075	0.02425	18.59	<.0001	1
AR1,2	0.14988	0.02425	6.18	<.0001	2

Variance Estimate	0.210043
Std Error Estimate	0.458305
AIC	2165.697
SBC	2182
Number of Residuals	1693

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	5.12	3	0.1635	-0.004	-0.014	0.015	0.002	0.036	-0.035
12	10.18	9	0.3362	0.005	0.015	0.018	0.006	0.037	-0.032
18	18.01	15	0.2620	0.034	0.016	0.041	0.030	0.015	-0.019
24	23.37	21	0.3244	-0.009	0.045	0.002	-0.022	-0.015	0.018
30	28.11	27	0.4052	0.017	0.010	0.028	-0.003	0.027	-0.029
36	32.67	33	0.4835	-0.037	0.028	-0.018	-0.001	0.012	0.003
42	35.70	39	0.6212	-0.036	0.006	-0.016	-0.009	-0.003	0.006
48	37.28	45	0.7865	-0.013	0.014	0.004	0.017	-0.010	-0.012

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.994474	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.034137	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.399094	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	2.298949	Pr > A-Sq	<0.0050

Lampiran 16 *Syntax* Model ARIMA BBNI

```
data TA;
input BBNI;
datalines;
15.97224873
16.55689237
16.58927983
16.17408839
15.61609762
16.42115883
16.14632347
15.74078059
16.03813211
16.42830458
.
.
.
17.12952928
16.38972456
16.86829402
16.65767198
17.61514396
18.38660366
17.62012206
;
proc arima data=TA;
identify var=BBNI(1);
estimate p=2 q=2 noconstant method=cls;
forecast out=ramalan lead=196;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 17 *Output* Model ARIMA BBNI

```
The SAS System                                    08:01 Saturday, May 8, 2017 766

                              The ARIMA Procedure
                       Conditional Least Squares Estimation

                         Standard                    Approx
Parameter       Estimate            Error    t Value    Pr > |t|      Lag

MA1,1            1.80130          0.05556      32.42      <.0001        1
MA1,2           -0.80351          0.05505     -14.60      <.0001        2
AR1,1            1.25926          0.06429      19.59      <.0001        1
AR1,2           -0.30860          0.04603      -6.70      <.0001        2


                     Variance Estimate      0.258302
                     Std Error Estimate     0.508234
                     AIC                    2516.832
                     SBC                    2538.569
                     Number of Residuals        1693
```

Autocorrelation Check of Residuals

Lag	To Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	2.35	2	0.3091	-0.004	0.010	-0.003	0.030	-0.015	-0.011
12	6.10	8	0.6363	-0.015	-0.005	-0.031	-0.008	0.028	-0.012
18	9.45	14	0.8009	-0.011	0.028	0.027	-0.017	0.001	-0.009
24	13.45	20	0.8571	0.001	0.002	0.031	-0.036	0.008	-0.002
30	21.67	26	0.7065	0.026	0.019	-0.030	0.012	0.038	-0.036
36	28.57	32	0.6407	0.037	-0.022	0.040	-0.012	0.012	0.016
42	34.29	38	0.6416	-0.031	0.017	0.017	0.021	-0.035	-0.007
48	37.10	44	0.7598	-0.022	0.020	-0.023	0.009	0.012	0.000

Tests for Normality

Test	--Statistic---		-----p Value------	
Shapiro-Wilk	W	0.995719	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.028748	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.263299	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.528917	Pr > A-Sq	<0.0050

Lampiran 18 *Syntax* Model Intervensi BBCA

```
data TA;
input x s;
datalines;
9.393684869     0
8.795735977     0
9.211229293     0
8.779914177     0
9.206967228     0
9.63816334      0
.
.
.
10.30998977     1
10.09870443     1
10.09870443     1
10.70000888     1
10.47057331     1
10.22851251     1
;
proc arima data=TA;
identify var=x(1) crosscorr=(s(1)) noprint;
estimate input= input=(10$(1)/(0)s) noint
noconstant method=cls;
estimate p=(1,2,5,7) q=1 input=(10$(1)/(0)s) noint
noconstant method=cls;
run;
forecast out=ramalan lead=1 printall;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 19 *Syntax* Model Intervensi BMRI

```
data TA;
input x s;
datalines;
17.78771762     0
17.13936242     0
16.67681961     0
17.20248392     0
16.39644683     0
16.77478111     0
.
.
.
17.05048018     1
16.19914093     1
16.19914093     1
16.44844202     1
15.89998939     1
16.58787425     1
;
proc arima data=TA;
identify var=x(1) crosscorr=(s(1)) noprint;
estimate input= input=(6$(0)/(0)s) noint
noconstant method=cls;
estimate p=(1,2,4) q=1 input=(6$(0)/(0)s) noint
noconstant method=cls;
run;
forecast out=ramalan lead=1 printall;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 20 *Syntax* Model Intervensi BBRI

```
data TA;
input x s;
datalines;
16.93981193     0
17.20844053     0
16.76320738     0
16.73506348     0
16.57937382     0
16.87534376     0
.
.
.
16.10580037     1
16.48257208     1
16.48257208     1
17.13881847     1
16.68926727     1
16.51101573     1
;
proc arima data=TA;
identify var=x(1) crosscorr=(s(1)) noprint;
estimate input= input=(6$(0)/(0)s) noint
noconstant method=cls;
estimate p=2 q=1 input=(6$(0)/(0)s) noint
noconstant method=cls;
run;
forecast out=ramalan lead=1 printall;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 21 *Syntax* Model Intervensi BBNI

```
data TA;
input x s;
datalines;
15.97224873     0
16.55689237     0
16.58927983     0
16.17408839     0
15.61609762     0
16.42115883     0
.
.
.
16.82212342     1
17.36835549     1
17.36835549     1
17.38403711     1
17.67845466     1
17.70927387     1
;
proc arima data=TA;
identify var=x(1) crosscorr=(s(1)) noprint;
estimate input= input=(0$(0)/(0)s) noint
noconstant method=cls;
estimate p=2 q=2 input=(0$(0)/(0)s) noint
noconstant method=cls;
run;
forecast out=ramalan lead=1 printall;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Lampiran 22 *Time Series Plot* Data *Diff* Sebelum *Tax Amnesty*

```
data=read.csv("D:/TA/data TA fix/data diff sebelum
tax.csv",sep=",",header=TRUE)
BBCA=(data$BBCA)
BBNI=(data$BBNI)
BBRI=(data$BBRI)
BMRI=(data$BMRI)

#Plot data Diff BBCA
win.graph()
plot(BBCA, type="l", col = "blue", frame=T, axes=F,
    ylab="Diff",main="Diff BBCA")

#Plot data Diff BBNI
win.graph()
plot(BBNI, type="l", col = "blue", frame=T, axes=F, xlab="Time",
    ylab="Diff",main="Diff BBNI")

#Plot data Diff BBRI
win.graph()
plot(BBRI, type="l", col = "blue", frame=T, axes=F, xlab="Time",
    ylab="Diff",main="Diff BBRI")

#Plot data Diff BMRI
win.graph()
plot(BMRI, type="l", col = "blue", frame=T, axes=F, xlab="Time",
    ylab="Diff",main="Diff BMRI")
```

Lampiran 23 *Time Series Plot* Data *Diff* Selama *Tax Amnesty*

```
data=read.csv("D:/TA/data TA fix/data diff selama
tax.csv",sep=",",header=TRUE)
BBCA=(data$BBCA)
BBNI=(data$BBNI)
BBRI=(data$BBRI)
BMRI=(data$BMRI)

#Plot data Diff BBCA
win.graph()
plot(BBCA, type="l", col = "blue", frame=T, axes=F,
    ylab="Diff",main="Diff BBCA")

#Plot data Diff BBNI
win.graph()
plot(BBNI, type="l", col = "blue", frame=T, axes=F, xlab="Time",
    ylab="Diff",main="Diff BBNI")

#Plot data Diff BBRI
win.graph()
plot(BBRI, type="l", col = "blue", frame=T, axes=F, xlab="Time",
    ylab="Diff",main="Diff BBRI")

#Plot data Diff BMRI
win.graph()
plot(BMRI, type="l", col = "blue", frame=T, axes=F, xlab="Time",
    ylab="Diff",main="Diff BMRI")
```

Lampiran 24 *Syntax* Model ARIMA-GARCH dan ACD BBCA

```
==============================================
Periode 04 Januari 2010-30 Juni 2016
==============================================
#estimasi parameter dan distribusi model ACD dapat diganti exponential
atau weibull

library(rugarch)
trans1=read.csv("D:/TA/data TA fix/BBCA
stasioner1.csv",sep=",",header=TRUE)
trans.BBCA1=trans1[,3]
BBCA1=diff(trans.BBCA1)
x=length(trans.BBCA1)
m1=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
        variance.model = list(garchOrder=c(1,1)),distribution.model =
"norm")
ma1=ugarchfit(spec = m1,data=BBCA1,solver = "nloptr")
ma1
resi1= residuals(ma1)
write.csv(resi1,"D:/TA/hasil loss/Residual ARMA GARCH
BBCA1.csv")
a=0
lx1=c(1:x)[resi1<a]
ux1=c(1:x)[resi1>=a]
durasi1=diff(lx1)
durasi1
write.csv(durasi1,"D:/TA/hasil loss/Durasi BBCA1e.csv")
library(ACDm)
n1= acdFit(durations = durasi1, model = "ACD", dist = "exponential",
      order = c(1,1),optimFnc="solnp")
resid1=n1$residuals
psi.Hat1=n1$muHats
write.csv(resid1,"D:/TA/hasil loss/Residual BBCA1e.csv")
```

Lampiran 25 *Syntax* Model ARIMA-GARCH dan ACD BBCA (Lanjutan)

```
=============================================
Periode 01 Januari 2013-31 Maret 2017
=============================================
library(rugarch)
trans2=read.csv("D:/TA/data TA fix/BBCA
stasioner2.csv",sep=",",header=TRUE)
trans.BBCA2=trans2[,3]
BBCA2=diff(trans.BBCA2)
y=length(trans.BBCA2)
m2=ugarchspec(mean.model =
list(armaOrder=c(0,1),include.mean=FALSE),
            variance.model = list(garchOrder=c(1,0)),distribution.model =
"norm")
ma2=ugarchfit(spec = m2,data=BBCA2,solver = "nloptr")
ma2
resi2= residuals(ma2)
write.csv(resi2,"D:/TA/hasil loss/Residual ARMA GARCH
BBCA2.csv")
a=0
lx2=c(1:y)[resi2<a]
ux2=c(1:y)[resi2>=a]
durasi2=diff(lx2)
durasi2
write.csv(durasi2,"D:/TA/hasil loss/Durasi BBCA2e.csv")
library(ACDm)
n2= acdFit(durations = durasi2, model = "ACD", dist = "exponential",
         order = c(1,1),optimFnc="solnp")
resid2=n2$residuals
psi.Hat2=n2$muHats
write.csv(resid2,"D:/TA/hasil loss/Residual BBCA2e.csv")

length(psi.Hat1)
length(psi.Hat2)
plot.hat=c(psi.Hat1,psi.Hat2)
plot(plot.hat,type="l",ylab="Psi.Hat",col="blue")
abline(v=seq(852,951,by=99),lty="solid",lwd=2,col="red")
```

Lampiran 26 *Syntax* Uji Distribusi Durasi BBCA Sebelum *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BBCA1.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 27 *Syntax* Uji Distribusi Durasi BBCA Selama *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BBCA2.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 28 *Output* Model ARIMA-GARCH BBCA Sebelum *Tax Amnesty*

```
*---------------------------------*
*          GARCH Model Fit        *
*---------------------------------*

Conditional Variance Dynamics
-----------------------------------
GARCH Model      : sGARCH(1,1)
Mean Model       : ARFIMA(1,0,1)
Distribution     : norm

Optimal Parameters
------------------------------------
        Estimate  Std. Error  t value Pr(>|t|)
ar1     0.346119    0.045263   7.6468  0.00000
ma1    -0.927441    0.029698 -31.2292  0.00000
omega   0.009338    0.001371   6.8134  0.00000
alpha1  0.085517    0.032969   2.5939  0.00949
beta1   0.905537    0.033150  27.3163  0.00000

Robust Standard Errors:
        Estimate  Std. Error   t value Pr(>|t|)
ar1     0.346119    0.112766   3.06935 0.002145
ma1    -0.927441    0.079495 -11.66667 0.000000
omega   0.009338    0.017430   0.53574 0.592138
alpha1  0.085517    0.127167   0.67248 0.501279
beta1   0.905537    0.130439   6.94222 0.000000

LogLikelihood : -1735.439

Information Criteria
------------------------------------

Akaike       2.0560
Bayes        2.0721
Shibata      2.0560
Hannan-Quinn 2.0620

Weighted Ljung-Box Test on Standardized Residuals
------------------------------------
                        statistic p-value
Lag[1]                     0.4375  0.5083
Lag[2*(p+q)+(p+q)-1][5]    3.1528  0.3792
Lag[4*(p+q)+(p+q)-1][9]    4.1693  0.6509
d.o.f=2
H0 : No serial correlation
```

Lampiran 29 *Output* Model ARIMA-GARCH BBCA Selama *Tax Amnesty*

```
*---------------------------------*
*          GARCH Model Fit        *
*---------------------------------*

Conditional Variance Dynamics
-----------------------------------
GARCH Model      : sGARCH(1,0)
Mean Model       : ARFIMA(0,0,1)
Distribution     : norm

Optimal Parameters
------------------------------------
        Estimate  Std. Error  t value Pr(>|t|)
ma1     -0.72897    0.071172 -10.2423 0.000000
omega    0.29951    0.042899   6.9819 0.000000
alpha1   0.22976    0.110791   2.0738 0.038099

Robust Standard Errors:
        Estimate  Std. Error  t value Pr(>|t|)
ma1     -0.72897    0.098042  -7.4353 0.000000
omega    0.29951    0.038292   7.8218 0.000000
alpha1   0.22976    0.082829   2.7739 0.005539

LogLikelihood : -180.3744

Information Criteria
------------------------------------

Akaike       1.8808
Bayes        1.9311
Shibata      1.8803
Hannan-Quinn 1.9012

Weighted Ljung-Box Test on Standardized Residuals
------------------------------------
                        statistic   p-value
Lag[1]                      5.318 0.0211021
Lag[2*(p+q)+(p+q)-1][2]     5.486 0.0001383
Lag[4*(p+q)+(p+q)-1][5]     6.129 0.0416741
d.o.f=1
H0 : No serial correlation
```

Lampiran 30 *Output* Uji Distribusi Durasi BBCA

```
SEBELUM TAX AMNESTY
$b
[1] 2

$uLL
[1] -1e+10

$rLL
[1] -1e+10

$LRp
[1] 1

$H0
[1] "Duration Between Exceedances have no memory
(Weibull b=1 = Exponential)"

$Decision
[1] "Fail to Reject H0"

SELAMA TAX AMNESTY
$b
[1] 2

$uLL
[1] -1e+10

$rLL
[1] -1e+10

$LRp
[1] 1

$H0
[1] "Duration Between Exceedances have no memory
(Weibull b=1 = Exponential)"

$Decision
[1] "Fail to Reject H0"
```

Lampiran 31 *Output* Model EACD BBCA Sebelum *Tax Amnesty*

```
ACD model estimation by (Quasi) Maximum Likelihood

Call:
  acdFit(durations = durasi1, model = "ACD", dist =
"exponential",      order = c(1, 1), optimFnc =
"solnp")

Model:
  ACD(1, 1)

Distribution:
  exponential

N: 851

Parameter estimate:
          Coef     SE    PV robustSE
omega   0.0991 0.0544 0.068   0.0427
alpha1 -0.0329 0.0160 0.040   0.0115
beta1   0.9831 0.0150 0.000   0.0129


The fixed/unfree mean distribution parameter:
 lambda: 1

QML robust correlations:
        omega alpha1  beta1
omega   1.000 -0.857 -0.888
alpha1 -0.857  1.000  0.525
beta1  -0.888  0.525  1.000


Goodness of fit:
                     value
LogLikelihood -1433.673975
AIC             2873.347950
BIC             2887.587186
MSE                2.208807

Convergence: 0

Number of log-likelihood function evaluations: 176

Estimation time: 0.067 secs
```

Lampiran 32 *Output* Model EACD BBCA Selama *Tax Amnesty*

```
ACD model estimation by (Quasi) Maximum Likelihood

Call:
  acdFit(durations = durasi2, model = "ACD", dist =
"exponential",      order = c(1, 1), optimFnc =
"solnp")

Model:
  ACD(1, 1)

Distribution:
  exponential

N: 99

Parameter estimate:
         Coef     SE    PV robustSE
omega   0.660 0.4526 0.145   0.2719
alpha1 -0.187 0.0757 0.013   0.0458
beta1   0.839 0.2079 0.000   0.1158


The fixed/unfree mean distribution parameter:
 lambda: 1

QML robust correlations:
        omega alpha1  beta1
omega   1.000 -0.666 -0.933
alpha1 -0.666  1.000  0.359
beta1  -0.933  0.359  1.000


Goodness of fit:
                    value
LogLikelihood -159.943117
AIC            325.886234
BIC            333.671593
MSE              1.879401

Convergence: 0

Number of log-likelihood function evaluations: 107

Estimation time: 0.035 secs
```

Lampiran 33 *Output* Model WACD BBCA Sebelum *Tax Amnesty*

```
ACD model estimation by Maximum Likelihood

Call:
  acdFit(durations = durasi1, model = "ACD", dist =
"weibull",      order = c(1, 1), optimFnc = "solnp")

Model:
  ACD(1, 1)

Distribution:
  weibull

N: 851

Parameter estimate:
          Coef     SE    PV
omega   0.1229 0.0410 0.003
alpha1 -0.0398 0.0117 0.001
beta1   0.9784 0.0119 0.000
gamma   1.5493 0.0370 0.000

Note: The p-value for the distribution parameter
gamma is from the 2-tailed test H0: gamma = 1.

The fixed/unfree mean distribution parameter:
 theta: 0.8485652

Goodness of fit:
                    value
LogLikelihood -1304.657946
AIC             2617.315893
BIC             2636.301541
MSE                2.210358

Convergence: 0

Number of log-likelihood function evaluations: 227

Estimation time: 0.149 secs
```

Lampiran 34 *Output* Model WACD BBCA Selama *Tax Amnesty*

```
ACD model estimation by Maximum Likelihood

Call:
  acdFit(durations = durasi2, model = "ACD", dist =
"weibull",      order = c(1, 1), optimFnc = "solnp")

Model:
  ACD(1, 1)

Distribution:
  weibull

N: 99

Parameter estimate:
         Coef     SE    PV
omega   0.662 0.2590 0.011
alpha1 -0.203 0.0443 0.000
beta1   0.856 0.1189 0.000
gamma   1.616 0.1151 0.000

Note: The p-value for the distribution parameter
gamma is from the 2-tailed test H0: gamma = 1.

The fixed/unfree mean distribution parameter:
 theta: 0.8371075

Goodness of fit:
                    value
LogLikelihood -142.874451
AIC            293.748902
BIC            304.129381
MSE              1.879907

Convergence: 0

Number of log-likelihood function evaluations: 143

Estimation time: 0.041 secs
```

Lampiran 35 *Syntax* Model ARIMA-GARCH dan ACD BMRI

```
==============================================
Periode 04 Januari 2010-30 Juni 2016
==============================================
#estimasi parameter dan distribusi model ACD dapat diganti exponential
atau weibull

library(rugarch)
trans1=read.csv("D:/TA/data TA fix/BMRI
stasioner1.csv",sep=",",header=TRUE)
trans.BMRI1=trans1[,3]
BMRI1=diff(trans.BMRI1)
x=length(trans.BMRI1)
m1=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
        variance.model = list(garchOrder=c(1,1)),distribution.model =
"norm")
ma1=ugarchfit(spec = m1,data=BMRI1,solver = "nloptr")
ma1
resi1= residuals(ma1)
write.csv(resi1,"D:/TA/hasil loss/Residual ARMA GARCH
BMRI1.csv")
a=0
lx1=c(1:x)[resi1<a]
ux1=c(1:x)[resi1>=a]
durasi1=diff(lx1)
durasi1
write.csv(durasi1,"D:/TA/hasil loss/Durasi BMRI1e.csv")
library(ACDm)
n1= acdFit(durations = durasi1, model = "ACD", dist = "exponential",
      order = c(0,1),optimFnc="solnp")
resid1=n1$residuals
psi.Hat1=n1$muHats
write.csv(resid1,"D:/TA/hasil loss/Residual BMRI1e.csv")
```

Lampiran 36 *Syntax* Model ARIMA GARCH dan ACD BMRI (Lanjutan)

```
=============================================
Periode 01 Januari 2013-31 Maret 2017
=============================================
library(rugarch)
trans2=read.csv("D:/TA/data TA fix/BMRI
stasioner2.csv",sep=",",header=TRUE)
trans.BMRI2=trans2[,3]
BMRI2=diff(trans.BMRI2)
y=length(trans.BMRI2)
m2=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
        variance.model = list(garchOrder=c(0,1)),distribution.model =
"norm")
ma2=ugarchfit(spec = m2,data=BMRI2,solver = "nloptr")
ma2
resi2= residuals(ma2)
write.csv(resi2,"D:/TA/hasil loss/Residual ARMA GARCH
BMRI2.csv")
a=0
lx2=c(1:y)[resi2<a]
ux2=c(1:y)[resi2>=a]
durasi2=diff(lx2)
durasi2
write.csv(durasi2,"D:/TA/hasil loss/Durasi BMRI2e.csv")
library(ACDm)
n2= acdFit(durations = durasi2, model = "ACD", dist = "exponential",
      order = c(0,1),optimFnc="solnp")
resid2=n2$residuals
psi.Hat2=n2$muHats
write.csv(resid2,"D:/TA/hasil loss/Residual BMRI2e.csv")

length(psi.Hat1)
length(psi.Hat2)
plot.hat=c(psi.Hat1,psi.Hat2)
plot(plot.hat,type="l",ylab="Psi.Hat",col="blue")
abline(v=seq(860,958,by=98),lty="solid",lwd=2,col="red")
```

Lampiran 37 *Syntax* Uji Distribusi Durasi BMRI Sebelum *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BMRI1.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 38 *Syntax* Uji Distribusi Durasi BMRI Selama *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BMRI2.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 39 *Syntax* Model ARIMA GARCH dan ACD BBRI

```
==============================================
Periode 04 Januari 2010-30 Juni 2016
==============================================
#estimasi parameter dan distribusi model ACD dapat diganti exponential
atau weibull

library(rugarch)
trans1=read.csv("D:/TA/data TA fix/BBRI
stasioner1.csv",sep=",",header=TRUE)
trans.BBRI1=trans1[,3]
BBRI1=diff(trans.BBRI1)
x=length(trans.BBRI1)
m1=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
            variance.model = list(garchOrder=c(1,1)),distribution.model =
"norm")
ma1=ugarchfit(spec = m1,data=BBRI1,solver = "nloptr")
ma1
resi1= residuals(ma1)
write.csv(resi1,"D:/TA/hasil loss/Residual ARMA GARCH
BBRI1.csv")
a=0
lx1=c(1:x)[resi1<a]
ux1=c(1:x)[resi1>=a]
durasi1=diff(lx1)
durasi1
write.csv(durasi1,"D:/TA/hasil loss/Durasi BBRI1e.csv")
library(ACDm)
n1= acdFit(durations = durasi1, model = "ACD", dist = "exponential",
         order = c(1,1),optimFnc="solnp")
resid1=n1$residuals
psi.Hat1=n1$muHats
write.csv(resid1,"D:/TA/hasil loss/Residual BBRI1e.csv")
```

Lampiran 40 *Syntax* Model ARIMA GARCH dan ACD BBRI (Lanjutan)

```
===========================================
Periode 01 Januari 2013-31 Maret 2017
===========================================
library(rugarch)
trans2=read.csv("D:/TA/data TA fix/BBRI
stasioner2.csv",sep=",",header=TRUE)
trans.BBRI2=trans2[,3]
BBRI2=diff(trans.BBRI2)
y=length(trans.BBRI2)
m2=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
        variance.model = list(garchOrder=c(0,1)),distribution.model =
"norm")
ma2=ugarchfit(spec = m2,data=BBRI2,solver = "nloptr")
ma2
resi2= residuals(ma2)
write.csv(resi2,"D:/TA/hasil loss/Residual ARMA GARCH
BBRI2.csv")
a=0
lx2=c(1:y)[resi2<a]
ux2=c(1:y)[resi2>=a]
durasi2=diff(lx2)
durasi2
write.csv(durasi2,"D:/TA/hasil loss/Durasi BBRI2e.csv")
library(ACDm)
n2= acdFit(durations = durasi2, model = "ACD", dist = "exponential",
       order = c(1,1),optimFnc="solnp")
resid2=n2$residuals
psi.Hat2=n2$muHats
write.csv(resid2,"D:/TA/hasil loss/Residual BBRI2e.csv")

length(psi.Hat1)
length(psi.Hat2)
plot.hat=c(psi.Hat1,psi.Hat2)
plot(plot.hat,type="l",ylab="Psi.Hat",col="blue")
abline(v=seq(866,975,by=109),lty="solid",lwd=2,col="red")
```

Lampiran 41 *Syntax* Uji Distribusi Durasi BBRI Sebelum *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BBRI1.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 42 *Syntax* Uji Distribusi Durasi BBRI Selama *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BBRI2.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 43 *Syntax* Model ARIMA GARCH dan ACD BBNI

```
=============================================
Periode 04 Januari 2010-30 Juni 2016
=============================================
#estimasi parameter dan distribusi model ACD dapat diganti exponential
atau weibull

library(rugarch)
trans1=read.csv("D:/TA/data TA fix/BBNI
stasioner1.csv",sep=",",header=TRUE)
trans.BBNI1=trans1[,3]
BBNI1=diff(trans.BBNI1)
x=length(trans.BBNI1)
m1=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
            variance.model = list(garchOrder=c(0,1)),distribution.model =
"norm")
ma1=ugarchfit(spec = m1,data=BBNI1,solver = "nloptr")
ma1
resi1= residuals(ma1)
write.csv(resi1,"D:/TA/hasil loss/Residual ARMA GARCH
BBNI1.csv")
a=0
lx1=c(1:x)[resi1<a]
ux1=c(1:x)[resi1>=a]
durasi1=diff(lx1)
durasi1
write.csv(durasi1,"D:/TA/hasil loss/Durasi BBNI1e.csv")
library(ACDm)
n1= acdFit(durations = durasi1, model = "ACD", dist = "exponential",
         order = c(0,1),optimFnc="solnp")
resid1=n1$residuals
psi.Hat1=n1$muHats
write.csv(resid1,"D:/TA/hasil loss/Residual BBNI1e.csv")
```

Lampiran 44 *Syntax* Model ARIMA GARCH dan ACD BBNI (Lanjutan)

```
==============================================
Periode 01 Januari 2013-31 Maret 2017
==============================================
library(rugarch)
trans2=read.csv("D:/TA/data TA fix/BBNI
stasioner2.csv",sep=",",header=TRUE)
trans.BBNI2=trans2[,3]
BBNI2=diff(trans.BBNI2)
y=length(trans.BBNI2)
m2=ugarchspec(mean.model =
list(armaOrder=c(1,1),include.mean=FALSE),
            variance.model = list(garchOrder=c(0,1)),distribution.model =
"norm")
ma2=ugarchfit(spec = m2,data=BBNI2,solver = "nloptr")
ma2
resi2= residuals(ma2)
write.csv(resi2,"D:/TA/hasil loss/Residual ARMA GARCH
BBNI2.csv")
a=0
lx2=c(1:y)[resi2<a]
ux2=c(1:y)[resi2>=a]
durasi2=diff(lx2)
durasi2
write.csv(durasi2,"D:/TA/hasil loss/Durasi BBNI2e.csv")
library(ACDm)
n2= acdFit(durations = durasi2, model = "ACD", dist = "exponential",
         order = c(1,1),optimFnc="solnp")
resid2=n2$residuals
psi.Hat2=n2$muHats
write.csv(resid2,"D:/TA/hasil loss/Residual BBNI2e.csv")

length(psi.Hat1)
length(psi.Hat2)
plot.hat=c(psi.Hat1,psi.Hat2)
plot(plot.hat,type="l",ylab="Psi.Hat",col="blue")
abline(v=seq(868,959,by=91),lty="solid",lwd=2,col="red")
```

Lampiran 45 *Syntax* Uji Distribusi Durasi BBNI Sebelum *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BBNI1.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
  C=c(1,C)
  D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
  C=c(C,1)
  D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 46 *Syntax* Uji Distribusi Durasi BBNI Selama *Tax Amnesty*

```
I=read.csv("D:/TA/hasil loss/Residual ARMA GARCH
BBNI2.csv",sep=",",header=TRUE)
I=I[,1]
U=length(I)
M=rep(0,U)
Durasi=ifelse(I<M,1,0)
N=sum(Durasi)
TN=length(Durasi)
D=diff(which(Durasi==1))
C=rep(0,length(D))
if (Durasi[1]==0)
{
 C=c(1,C)
 D=c(which(Durasi==1)[1],D)
}
if(Durasi[TN]==0)
{
 C=c(C,1)
 D=c(D,TN-tail(which(Durasi==1),1))
}
N=length(D)

#Test dist. Durasi
UjiDist=VaRDurTest(0.1,I,M,conf.level = 0.9)
print(UjiDist)
```

Lampiran 47 *Syntax* Uji Asumsi *White Noise*

```
residual1.1=read.csv("D:/TA/hasil loss/Residual
BBCA1.csv",sep=",",header=TRUE)
residual1.2=read.csv("D:/TA/hasil loss/Residual
BBCA1e.csv",sep=",",header=TRUE)
residual2.1=read.csv("D:/TA/hasil loss/Residual
BBCA2.csv",sep=",",header=TRUE)
residual2.2=read.csv("D:/TA/hasil loss/Residual
BBCA2e.csv",sep=",",header=TRUE)
residual3.1=read.csv("D:/TA/hasil loss/Residual
BMRI1.csv",sep=",",header=TRUE)
residual3.2=read.csv("D:/TA/hasil loss/Residual
BMRI1e.csv",sep=",",header=TRUE)
residual4.1=read.csv("D:/TA/hasil loss/Residual
BMRI2.csv",sep=",",header=TRUE)
residual4.2=read.csv("D:/TA/hasil loss/Residual
BMRI2e.csv",sep=",",header=TRUE)
residual5.1=read.csv("D:/TA/hasil loss/Residual
BBRI1.csv",sep=",",header=TRUE)
residual5.2=read.csv("D:/TA/hasil loss/Residual
BBRI1e.csv",sep=",",header=TRUE)
residual6.1=read.csv("D:/TA/hasil loss/Residual
BBRI2.csv",sep=",",header=TRUE)
residual6.2=read.csv("D:/TA/hasil loss/Residual
BBRI2e.csv",sep=",",header=TRUE)
residual7.1=read.csv("D:/TA/hasil loss/Residual
BBNI1.csv",sep=",",header=TRUE)
residual7.2=read.csv("D:/TA/hasil loss/Residual
BBNI1e.csv",sep=",",header=TRUE)
residual8.1=read.csv("D:/TA/hasil loss/Residual
BBNI2.csv",sep=",",header=TRUE)
residual8.2=read.csv("D:/TA/hasil loss/Residual
BBNI2e.csv",sep=",",header=TRUE)
BBCA1.1=as.numeric(residual1.1$x)
BBCA1.2=as.numeric(residual1.2$x)
```

Lampiran 48 *Syntax* Uji Asumsi *White Noise* (Lanjutan)

```
BBCA2.1=as.numeric(residual2.1$x)
BBCA2.2=as.numeric(residual2.2$x)
BMRI1.1=as.numeric(residual3.1$x)
BMRI1.2=as.numeric(residual3.2$x)
BMRI2.1=as.numeric(residual4.1$x)
BMRI2.2=as.numeric(residual4.2$x)
BBRI1.1=as.numeric(residual5.1$x)
BBRI1.2=as.numeric(residual5.2$x)
BBRI2.1=as.numeric(residual6.1$x)
BBRI2.2=as.numeric(residual6.2$x)
BBNI1.1=as.numeric(residual7.1$x)
BBNI1.2=as.numeric(residual7.2$x)
BBNI2.1=as.numeric(residual8.1$x)
BBNI2.2=as.numeric(residual8.2$x)

Box.test(BBCA1.1,lag=20,type="Ljung-Box")
Box.test(BBCA1.2,lag=20,type="Ljung-Box")
Box.test(BBCA2.1,lag=20,type="Ljung-Box")
Box.test(BBCA2.2,lag=20,type="Ljung-Box")
Box.test(BMRI1.1,lag=20,type="Ljung-Box")
Box.test(BMRI1.2,lag=20,type="Ljung-Box")
Box.test(BMRI2.1,lag=20,type="Ljung-Box")
Box.test(BMRI2.2,lag=20,type="Ljung-Box")
Box.test(BBRI1.1,lag=20,type="Ljung-Box")
Box.test(BBRI1.2,lag=20,type="Ljung-Box")
Box.test(BBRI2.1,lag=20,type="Ljung-Box")
Box.test(BBRI2.2,lag=20,type="Ljung-Box")
Box.test(BBNI1.1,lag=20,type="Ljung-Box")
Box.test(BBNI1.2,lag=20,type="Ljung-Box")
Box.test(BBNI2.1,lag=20,type="Ljung-Box")
Box.test(BBNI2.2,lag=20,type="Ljung-Box")
```

Lampiran 49 *Output* Uji Asumsi *White Noise*

WEIBULL BBCA1
Box-Ljung test
data: BBCA1.1
X-squared = 23.469, df = 20, p-value = 0.2664

EKSPONENSIAL BBCA1
Box-Ljung test
data: BBCA1.2
X-squared = 23.283, df = 20, p-value = 0.2751

WEIBULL BBCA2
Box-Ljung test
data: BBCA2.1
X-squared = 11.055, df = 20, p-value = 0.9448

EKSPONENSIAL BBCA2
Box-Ljung test
data: BBCA2.2
X-squared = 11.365, df = 20, p-value = 0.9362

WEIBULL BMRI1
Box-Ljung test
data: BMRI1.1
X-squared = 10.651, df = 20, p-value = 0.9548

EKSPONENSIAL BMRI1
Box-Ljung test
data: BMRI1.2
X-squared = 13.003, df = 20, p-value = 0.8772

WEIBULL BMRI2
Box-Ljung test
data: BMRI2.1
X-squared = 17.751, df = 20, p-value = 0.6038

EKSPONENSIAL BMRI2
Box-Ljung test
data: BMRI2.2
X-squared = 23.322, df = 20, p-value = 0.2733

Lampiran 50 *Output* Uji Asumsi *White Noise* (Lanjutan)

WEIBULL BBRI1
Box-Ljung test
data: BBRI1.1
X-squared = 10.862, df = 20, p-value = 0.9497

EKSPONENSIAL BBRI1
Box-Ljung test
data: BBRI1.2
X-squared = 11.145, df = 20, p-value = 0.9424

WEIBULL BBRI2
Box-Ljung test
data: BBRI2.1
X-squared = 23.214, df = 20, p-value = 0.2784

EKSPONENSIAL BBRI2
Box-Ljung test
data: BBRI2.2
X-squared = 26.3, df = 20, p-value = 0.1561

WEIBULL BBNI1
Box-Ljung test
data: BBNI1.1
X-squared = 14.102, df = 20, p-value = 0.8253

EKSPONENSIAL BBNI1
Box-Ljung test
data: BBNI1.2
X-squared = 13.856, df = 20, p-value = 0.8377

WEIBULL BBNI2
Box-Ljung test
data: BBNI2.1
X-squared = 18.682, df = 20, p-value = 0.5425

EKSPONENSIAL BBNI2
Box-Ljung test
data: BBNI2.2
X-squared = 18.856, df = 20, p-value = 0.5312

*Output edited

(Halaman ini sengaja dikosongkan)

Lampiran 51

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Jurusan Statistika FMIPA ITS:

Nama : Luh Putu Shintya Handayani

NRP : 1315 105 016

menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data sekunder yang diambil dari publikasi yaitu:

Sumber : Situs resmi *finance.yahoo.com*

Keterangan : Volume transaksi harian Bank BCA (BBCA), Bank Mandiri (BMRI), Bank BRI (BBRI), dan Bank BNI (BBNI) periode 4 Januari 2010 sampai dengan 31 Maret 2017.

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui Pembimbing Tugas Akhir	Surabaya, Juni 2017
	Shinty 29/4
Dr.rer.pol. Dedy Dwi Prastyo NIP. 19831204 200812 1 002	Luh Putu Shintya Handayani NRP. 1315105016

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS

Penulis terlahir sebagai anak pertama dari dua bersaudara pada 24 Maret 1994 di di pulau dewata Bali yaitu Bangli. Penulis menyelesaikan pendidikan formal di TK Kemala Bhayangkari Bangli, SDN 5 Kawan, SMPN 1 Bangli, dan SMAN 1 Bangli tahun 2012. Selanjutnya penulis diterima di Jurusan Statistika sebagai angkatan ke 23 (Sigma 23) dan terdaftar dengan NRP 1312 030 025. Kemudian melanjutkan studi Lintas Jalur dan terdaftar dengan NRP 1315 105 016. Aktif dalam beberapa kegiatan maupun organisasi merupakan usaha penulis untuk menjadi orang yang berarti bagi orang lain dan mengembangkan diri di luar aktivitas akademik yang sedemikian padat. Aktif di TPKH-ITS periode 2012-2013 dan 2013-2014, HIMADATA-ITS periode 2014-2015. Penulis sangat gemar membaca buku motivasi dan psikologi sejak masa SMA, karena dari buku tersebut penulis mendapat inspirasi dan motivasi untuk membangun. Buku motivasi, prikologi, dan pengembangan diri dapat membangun karakter dan sikap menuju kesuksesan dan bagimana orang lain bersikap sebelum kesuksesan menghampirinya. Bagi pembaca yang memiliki saran, kritik dan lain sebagainya bisa disampaikan melalui e-mail: shintyahandayani24@gmail.com.

(Halaman ini sengaja dikosongkan)