



TUGAS AKHIR - SS 141501

**ANALISIS RISIKO INVESTASI SAHAM SYARIAH
MENGGUNAKAN VALUE AT RISK
DENGAN PENDEKATAN BAYESIAN MIXTURE
NORMAL AUTOREGRESSIVE**

**ULFA MEILINDA PUTRI
NRP 1312 100 047**

**Dosen Pembimbing
Prof. Drs. Nur Iriawan, M. Ikom., Ph. D**

**PROGRAM STUDI S1
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2016**



FINAL PROJECT - SS 141501

RISK INVESTMENT ANALYSIS OF ISLAMIC STOCK USING VALUE AT RISK BY APPROACH OF BAYESIAN MIXTURE NORMAL AUTOREGRESSIVE

ULFA MEILINDA PUTRI
NRP 1312 100 047

Supervisor
Prof. Drs. Nur Iriawan, M. Ikom., Ph. D

UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS AND NATURAL SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2016

LEMBAR PENGESAHAN

**ANALISIS RISIKO INVESTASI SAHAM SYARIAH
MENGGUNAKAN VALUE AT RISK DENGAN
PENDEKATAN BAYESIAN MIXTURE NORMAL**

AUTOREGRESSIVE

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat

Memperoleh Gelar Sarjana Sains

pada

Program Studi S-1 Jurusan Statistika

Fakultas Matematika dan Ilmu Pengetahuan Alam

Institut Teknologi Sepuluh Nopember

Oleh :

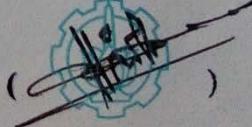
ULFA MEILINDA PUTRI

NRP 1312 100 047

Disetujui oleh Pembimbing Tugas Akhir

Prof. Drs. Nur Iriawan, M. Ikom., Ph. D

NIP : 19621015 198803 1 002

()

Mengetahui

Ketua Jurusan Statistika FMIPA-ITS

Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JULI 2016



ANALISIS RISIKO INVESTASI SAHAM SYARIAH MENGGUNAKAN METODE *VALUE AT RISK* DENGAN PENDEKATAN *MIXTURE NORMAL AUTOREGRESSIVE*

Nama Mahasiswa	: Ulfa Meilinda Putri
NRP	: 1312 100 047
Program Studi	: Sarjana
Jurusan	: Statistika FMIPA-ITS
Dosen Pembimbing	: Prof. Drs. Nur Iriawan, M.Ikom., Ph.D

Abstrak

Investasi merupakan alat bagi manusia untuk menjaga eksistensi kelangsungan hidupnya. Salah satu cara investasi yaitu menanamkan assetnya di pasar modal di Indonesia. Di tengah kemerosotan perekonomian Indonesia yang berimbas ke sektor pasar modal, kini industri pasar modal Indonesia mulai melirik pengembangan prinsip syariah untuk alternatif dalam berinvestasi. Oleh karena itu pada tahun 2000 diluncurkan suatu indeks yang dibuat berdasarkan prinsip syariah yaitu Jakarta Islamic Index. Melalui fluktuasi indeks, investor dapat menghitung berapa potensi risiko pasar dengan melihat return saham. Saham dikenal memiliki karakteristik high risk-high return, dimana saham memberikan peluang keuntungan yang tinggi tapi juga berpotensi menanggung risiko. Salah satu metode perhitungan risiko yang populer digunakan yaitu Value at Risk (VaR). Dalam penelitian ini variabel yang digunakan yaitu data return saham ASII, TLKM dan UNVR. Pola return saham ketiga perusahaan tersebut mengindikasikan adanya nilai ekstrim pada ujung kanan dan kiri serta bersifat leptokurtik. Hal ini berarti bahwa data memuat lebih dari satu distribusi. Oleh karena itu, digunakanlah pendekatan Bayesian MNAR untuk menghitung VaR. Nilai VaR untuk saham ASII sebesar -0,0346, TLKM sebesar -0,04306 dan UNVR sebesar -0,14573. ASII adalah terendah dari ketiga saham tersebut yaitu sebesar -0,0346, yang menunjukkan bahwa dengan tingkat kepercayaan 95%, kemungkinan kerugian maksimum yang dapat ditolerir oleh investor adalah 0,0346 rupiah dari asset yang telah diinvestasikan atau 5% peluang investor tersebut akan mengalami kerugian yang melebihi 0,0346 rupiah dari dana yang telah diinvestasikan dalam 1 hari ke depan.

Kata Kunci : Bayesian, MNAR, Saham Syariah, Value at Risk

(Halaman ini sengaja dikosongkan)

RISK INVESTMENT ANALISYS OF ISLAMIC STOCKS USING VALUE AT RISK BY APPROACH OF BAYESIAN MIXTURE NORMAL AUTOREGRESSIVE

Name of student	: Ulfa Meilinda Putri
NRP	: 1312 100 047
Study Program	: Sarjana
Departement	: Statistika FMIPA-ITS
Supervisor	: Prof. Drs. Nur Iriawan, M.Ikom., Ph.D

Abstract

Investment is tools for people to survive. One of them is to invest their assets in the Indonesian capital market. When Indonesian economic fall-off and affected in capital market sector, now Indonesian capital market industry seems develop to Islamic principle to alternative investment system. Jakarta islamix index that based on islamic principles was launched in 2000. Investor could be calculate the potential market risk through the fluctuation of return. Stocks have known characteristics of the high risk-high return, stocks not only give high profit opportunity, but also potentially at risk. The popular method of risk calculation is Value at Risk (VaR). In this study, the variables used are stock return of PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk and PT Unilever Indonesia Tbk. The pattern of stock returns in these companies indicates leptocurtic and an extreme value on the far right. It's means that the data contains more than one distribution. Therefore, MNAR Bayesian was used to calculate VaR. VaR for ASII at -0.0346, TLKM -0,04306 and UNVR -0,14573. ASII is the third lowest of these stocks amounting to -0.0346, indicate that the 95% confidence level, possibility of the maximum losses that can be tolerated by investors is 0.0346 rupiah of asset that have invested or 5% opportunity that the investor will suffer losses in excess of 0.0346 rupiah of asset that have invested in 1 day ahead.

Keyword : Bayesian, Islamic Stock, MNAR, Value at Risk

(This page is intentionally left blank)

DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	i
TITLE PAGE.....	ii
LEMBAR PENGESAHAN.....	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvii
 BAB I PENDAHULUAN	 1
1.1 Latar Belakang	1
1.2 Perumusan Masalah	5
1.3 Tujuan.....	6
1.4 Manfaat Penelitian.....	7
1.5 Batasan Masalah.....	7
 BAB II TINJAUAN PUSTAKA	 9
2.1 Statistika Deskriptif	9
2.2 Konsep <i>Time Series</i>	11
2.2.1 Kestasioneran Deret Waktu.....	11
2.2.2 Fungsi Autokorelasi (ACF) dan Fungsi Autokorelasi Parsial (PACF)	12
2.2.3 Proses <i>Autoregressive (AR)</i> , <i>Moving Average (MA)</i> dan <i>Autoregressive Moving Average (ARMA)</i>	13
2.2.4 Uji Signifikansi Parameter Model.....	14
2.2.5 <i>Diagnostic Checking</i>	15
2.3 Model <i>Mixture Univariabel</i>	16
2.3.1 Model <i>Mixture Autoregressive</i>	17
2.4 Estimasi Parameter dengan Pendekatan Bayesian	18
2.4.1 Distribusi Prior	19

2.4.2 <i>Marcov Chain Monte Carlo</i> (MCMC) dengan Gibbs Sampling	20
2.4.3 <i>Deviance Information Criteria</i> (DIC)	22
2.5 <i>Value at Risk</i>	22
2.6 <i>Return Saham</i>	24
2.7 <i>Jakarta Islamic Index</i> (JII)	25
2.8 Sikap Investor Terhadap Risiko	28
2.9 Penelitian Sebelumnya	29
BAB III METODOLOGI PENELITIAN	31
3.1 Sumber Data dan Variabel Penelitian	31
3.2 Langkah Penelitian.....	32
BAB IV ANALISIS DAN PEMBAHASAN	37
4.1 Deskripsi Karakteristik <i>Return Saham</i>	37
4.2 Perhitungan Ukuran Risiko dengan <i>Value At Risk</i> (VaR)	40
4.2.1 Model <i>Autoregressive Integrated Moving Average</i> (ARIMA)	40
4.2.2 Identifikasi <i>Mixture</i>	52
4.2.3 Pemodelan <i>Mixture Normal Autoregresive</i>	54
a. PT. Astra International Tbk	54
b. PT. Telekomunikasi Indonesia.....	63
c. PT. Unilever Indonesia	78
4.2.4 Pemilihan Model Terbaik.....	86
4.2.5 Perhitungan <i>Value at Risk</i> Berdasarkan Model Terbaik.....	87
BAB V KESIMPULAN DAN SARAN	91
5.1 Kesimpulan	91
5.2 Saran.....	92
DAFTAR PUSTAKA	93
LAMPIRAN	97
BIODATA PENULIS	141

DAFTAR TABEL

	Halaman
Tabel 3.1 Struktur Data Penelitian.....	31
Tabel 4.1 Karakteristik <i>Return</i> Saham.....	39
Tabel 4.2 Estimasi dan Pengujian Signifikansi Parameter Model <i>Return</i> Saham ASII	47
Tabel 4.3 Estimasi dan Pengujian Signifikansi Parameter Model <i>Return</i> Saham TLMK	47
Tabel 4.4 Estimasi dan Pengujian Signifikansi Parameter Model <i>Return</i> Saham UNVR	48
Tabel 4.5 Pengujian Asumsi Residual <i>Return</i> Saham ASII	49
Tabel 4.6 Pengujian Asumsi Residual <i>Return</i> Saham TLMK.....	50
Tabel 4.7 Pengujian Asumsi Residual <i>Return</i> Saham UNVR	51
Tabel 4.8 Estimasi Parameter Model MNAR(2;[3],[3,6])..	58
Tabel 4.9 Estimasi Parameter model MNAR(3;[3],[3,6],0)	62
Tabel 4.10 Estimasi Parameter Model MNAR(2;[2,3], [3,4])	66
Tabel 4.11 Estimasi Parameter Model MNAR(2;[2],[3])....	68
Tabel 4.12 Estimasi Parameter Model MNAR(2;[2],[4]).....	69
Tabel 4.13 Estimasi Parameter Model MNAR(2;[3],[4])....	71
Tabel 4.14 Estimasi Parameter Model MNAR (3;[2],[3],[4]).....	75
Tabel 4.15 Estimasi Parameter Model MNAR (3;[2,3], [3,4], [2,3,4]).....	76
Tabel 4.16 Estimasi Parameter Model MNAR(2;2,[11]).....	80
Tabel 4.17 Estimasi Parameter Model MNAR(3;1,2,[11])...	85
Tabel 4.18 Perbandingan Nilai DIC Antara Model ARIMA dengan MNAR.....	87
Tabel 4.19 Perhitungan <i>Value at Risk</i> (VaR).....	88

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 1.1	Histogram <i>Return</i> masing-masing Perusahaan 4
Gambar 2.1	Bentuk Keruncingan Distribusi 13
Gambar 2.2	Kurva Indiferen Sikap Investor Terhadap Risiko..... 29
Gambar 3.1	Diagram Alir Penelitian..... 34
Gambar 4.1	<i>Time Series Plot Close Price Saham</i> (a)ASII, (b)TLKM dan (c)UNVR..... 37
Gambar 4.2	<i>Time Series Plot Return Saham</i> (a)ASII, (b)TLKM dan (c) UNVR..... 41
Gambar 4.3	(a) Hisogram, (b) CDF Plot dan (c) <i>Test of Equal Varians</i> dari <i>Return ASII</i> 41
Gambar 4.4	(a) Hisogram, (b) CDF Plot dan (c) <i>Test of Equal Varians</i> dari <i>Return TLKM</i> 42
Gambar 4.5	Transformasi Box-cox <i>Return Saham</i> TLKM . 43
Gambar 4.6	(a) Hisogram, (b) CDF Plot dan (c) <i>Test of Equal Varians</i> dari <i>Return UNVR</i> 44
Gambar 4.7	Plot ACF dan PACF <i>Return Saham</i> (a) ASII, (b)TLKM dan (c) UNVR..... 45
Gambar 4.8	Marginal Plot dari <i>Return Saham</i> (a)ASII, (b) TLKM dan (c) UNVR 52
Gambar 4.9	Data <i>Return Saham</i> (a) ASII, (b) TLKM dan (c) UNVR dengan Pola Normal Univariat..... 53
Gambar 4.10	<i>Doodle</i> untuk model MNAR (2;[3],[3,6]) 55
Gambar 4.11	Distribusi Plot <i>Return ASII</i> 2 Komponen..... 59
Gambar 4.12	<i>Doodle</i> untuk model MNAR (3;[3],[3,6],0) 60
Gambar 4.13	Distribusi Plot <i>Return ASII</i> 3 Komponen..... 63
Gambar 4.14	<i>Doodle</i> untuk model MNAR(2;[2],[3]), MNAR(2;[2],[4]) dan MNAR (2;[3],[4]) 65
Gambar 4.15	Distribusi Plot <i>Return TLKM</i> untuk MNAR (2;[2,3],[3,4]) 67
Gambar 4.16	Distribusi Plot <i>Return TLKM</i> untuk MNAR (2;[2],[3]) 69

Gambar 4.17	Distribusi Plot <i>Return</i> TLKM untuk MNAR (2;[2],[4])	70
Gambar 4.18	Distribusi Plot <i>Return</i> TLKM untuk MNAR (2;[3],[4])	71
Gambar 4.19	<i>Doodle</i> untuk model MNAR(3;[2],[3],[4]).....	72
Gambar 4.20	<i>Doodle</i> untuk model MNAR(3;[2,3],[3,4], [2,3,4])	73
Gambar 4.21	Distribusi Plot <i>Return</i> TLKM untuk MNAR (3;[2],[3],[4])	76
Gambar 4.22	Distribusi Plot <i>Return</i> TLKM untuk MNAR (3;[2],[3],[4])	78
Gambar 4.23	<i>Doodle</i> Untuk Model MNAR(2;2,[11]).....	79
Gambar 4.24	Distribusi Plot <i>Return</i> UNVR 2 Komponen	82
Gambar 4.25	<i>Doodle</i> Untuk Model MNAR(3;1,2,[11]).....	83
Gambar 4.26	Distribusi Plot <i>Return</i> UNVR 3 Komponen	86

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data	97
a. Data <i>Close Price Dan Return</i> Saham PT Astra International Tbk.....	97
b. Data <i>Close Price Dan Return</i> Saham PT Telekomunikasi Indonesia Tbk	98
c. Data <i>Close Price Dan Return</i> Saham PT Unilever Indonesia Tbk.....	99
Lampiran 2 <i>Program Code Model ARIMA Untuk Return Saham ASII</i>	100
a. Model AR[3]	100
b. Model AR[6]	100
c. Model AR[3,6]	101
Lampiran 3 <i>Program Code Model ARIMA Untuk Return Saham TLKM</i>	102
a. Model AR[2]	102
b. Model AR[3]	102
c. Model AR[4]	103
d. Model AR[2,3]	103
e. Model AR[2,4]	104
f. Model AR[3,4]	104
g. Model AR[2,3,4]	105
Lampiran 4 <i>Program Code Model ARIMA Untuk Return Saham UNVR</i>	106
a. Model AR(2).....	106
b. Model AR[11]	106
c. Model AR[1,2,11]	107
Lampiran 5 Hasil <i>Output Pengujian Residual</i>	108
a. <i>Run-Test</i>	108
b. Pengujian <i>Lagrange Multiplier (LM)</i>	110
c. Pengujian <i>Kolmogorov-Smirnov</i>	112
Lampiran 6 Uji Kesesuaian Distribusi.....	114
a. <i>Return</i> Saham ASII	114
b. <i>Return</i> Saham TLMK.....	114

	Halaman
c. <i>Return Saham UNVR</i>	114
Lampiran 7 Model MNAR(2;[3],[3,6]) Untuk <i>Return Saham ASII</i>	115
a. <i>Program Code, Struktur data dan Initial Value</i>	115
b. <i>HistoryPlot</i>	116
c. <i>Autocorrelation Plot</i>	117
d. <i>Kernel Density</i>	118
Lampiran 8 Model MNAR(2;[3],[3,6]) Untuk <i>Return Saham ASII</i>	119
a. <i>Program Code, Struktur data dan Initial Value</i>	119
b. <i>HistoryPlot</i>	120
c. <i>Autocorrelation Plot</i>	122
d. <i>Kernel Density</i>	123
Lampiran 9 <i>Program Code, Struktur Data dan Initial Value Untuk Return Saham TLKM</i>	125
a. Model MNAR(2;[2],[3]).....	125
b. Model MNAR(2;[2],[4]).....	126
c. Model MNAR(2;[3],[4]).....	127
d. Model MNAR(2;[2,3],[3,4]).....	128
e. Model MNAR(3;[2],[3],[4]).....	129
f. Model MNAR(3;[2,3],[3,4],[2,3,4])	130
Lampiran 10 Model MNAR(2;2,[11]) Untuk <i>Return Saham UNVR</i>	131
a. <i>Program Code, Struktur data dan Initial Value</i>	131
b. <i>HistoryPlot</i>	132
c. <i>Autocorrelation Plot</i>	133
d. <i>Kernel Density</i>	134
Lampiran 11 Model MNAR(3;1,2,[11]) Untuk <i>Return Saham</i>	135
a. <i>Program Code, Struktur data dan Initial Value</i>	135
b. <i>HistoryPlot</i>	136
c. <i>Autocorrelation Plot</i>	138
d. <i>Kernel Density</i>	139
e. Lampiran 12 Surat Pernyataan	140

BAB I

PENDAHULUAN

1.1 Latar Belakang

Investasi merupakan kegiatan muamalah yang sangat dianjurkan, karena dengan berinvestasi harta yang dimiliki menjadi produktif dan mendatangkan manfaat bagi pertumbuhan ekonomi dan masyarakat secara luas. Investasi merupakan salah satu alat bagi manusia untuk menjaga eksistensi kelangsungan hidupnya. Banyak pilihan orang untuk menanamkan modalnya dalam bentuk investasi. Salah satu bentuknya adalah menginvestasikan asetnya di pasar modal. Pasar modal pada dasarnya merupakan pasar untuk berbagai instrumen keuangan atau surat-surat berharga jangka panjang yang bisa diperjualbelikan. Keberadaan pasar modal di Indonesia merupakan salah satu faktor terpenting dalam upaya membangun perekonomian nasional. Hal tersebut dapat dibuktikan dengan banyaknya industri dan perusahaan yang menggunakan pasar modal sebagai media untuk menyerap investasi dan untuk memperkuat posisi finansialnya (Laila, 2010).

Salah satu faktor bagi terciptanya pasar modal Indonesia yang tangguh dan berdaya saing global adalah dengan tersedianya fasilitas dan instrumen pasar modal Indonesia yang mampu bersaing dengan instrumen pasar modal negara-negara lain. Sehubungan dengan itu, ditengah kemerosotan tingkat pertumbuhan ekonomi nasional, yang juga berimbas ke sektor pasar modal selaku subsistem dari perekonomian nasional Indonesia, kini industri pasar modal Indonesia mulai melirik pengembangan penerapan prinsip-prinsip syariah sebagai alternatif instrumen investasi dalam kegiatan pasar modal di Indonesia. Dengan kehadiran pasar modal syariah, memberikan kesempatan bagi masyarakat yang ingin menginvestasikan asetnya sesuai dengan prinsip syariah yang memberikan ketenangan dan keyakinan atas transaksi yang halal. Perkembangan pasar modal syariah di Indonesia pun memberikan kabar gembira bagi para pelaku pasar. Pesatnya perkembangan pasar modal syariah, menyebabkan PT. Bursa Efek Indo-

nesia (BEI) bersama dengan PT. *Danareksa Invesment Management* (DIM) meluncurkan Indeks saham yang dibuat berdasarkan syariah Islam, yaitu *Jakarta Islamic Indeks* (JII) yang resmi dibuka pada tahun 2000. Melalui indeks diharapkan dapat meningkatkan kepercayaan investor untuk mengembangkan investasi secara syariah. Indeks dapat memberikan investor gagasan tentang bagaimana kinerja sebuah bursa selama waktu tertentu. Selain itu dengan melihat fluktuasi indeks, investor dapat menghitung berapa potensi risiko pasar dari suatu saham dengan melihat *return* saham.

Saham dikenal memiliki karakteristik *high risk-high return*. Artinya saham merupakan surat berharga yang memberikan peluang keuntungan yang tinggi namun juga berpotensi menanggung risiko tinggi. Saham memungkinkan investor mendapatkan keuntungan dalam jumlah besar dan dalam waktu singkat. Namun seiring dengan berfluktuasinya harga saham, saham juga dapat membuat investor mengalami kerugian dalam waktu singkat. Jadi apabila investor memutuskan untuk berinvestasi dalam bentuk saham, yang perlu ditelaah ulang adalah tingkat risiko yang akan ditanggung oleh investor.

Risiko merupakan besarnya penyimpangan antara *expected return* dengan *actual return* (Halim, 2005). Pengukuran risiko merupakan hal penting yang berkaitan dengan investasi aset yang cukup besar. Oleh sebab itu, pengukuran risiko perlu dilakukan agar risiko berada dalam tingkatan yang terkendali sehingga dapat mengurangi terjadinya kerugian dalam berinvestasi. Salah satu metode yang berkembang pesat dan sangat populer dipergunakan saat ini ialah *Value at Risk* (VaR) yang dipopulerkan oleh J. P. Morgan pada tahun 1994. Salah satu aspek terpenting dalam perhitungan VaR adalah menentukan jenis metode dan asumsi yang sesuai dengan distribusi *return*. Penerapan metode dan asumsi yang tepat akan menghasilkan perhitungan VaR yang akurat untuk digunakan sebagai ukuran risiko.

Metode peramalan adalah cara memperkirakan secara kuantitatif apa yang akan terjadi pada masa yang akan datang, ber-

dasarkan data yang relevan pada masa lalu. Dalam hal ini, serangkaian data masa lalu dikumpulkan dan dianalisis untuk membentuk suatu model yang dapat mendeskripsikan hubungan antara data yang berurutan. Model yang terbentuk selanjutnya digunakan untuk ekstrapolasi data yang akan datang. Model peramalan yang paling populer dan relatif sering digunakan adalah model ARIMA (*Autoregressive Integrated Moving Average*). Model yang dipopulerkan oleh Box dan Jenkins pada tahun 1970 ini, mampu mewakili beberapa model *time series*, seperti AR (*Autoregressive*), MA (*Moving Average*) dan ARMA. Model ARIMA disajikan sebagai fungsi linear dari beberapa data masa lalu dan *error* random. Oleh karena itu, model ini tidak mampu menangkap pola non linear dalam data. Sementara itu, tidak semua data *time series* bersifat linier terhadap nilai pengamatan masa lalu.

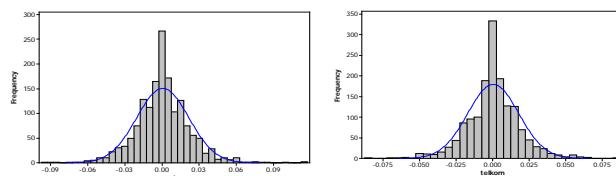
Wong dan Li (2000) menyatakan bahwa dalam kondisi riil, banyak ditemui data *time series* yang non stasioner dalam *mean* yang cenderung membawa sifat multimodal. Banyak juga data *time series* yang membawa sifat heteroskedastisitas yang memberikan pola marginal yang membawa sifat *fat tails* dan leptokurtik, sehingga kenormalan datanya pun sering diabaikan. Data yang membawa sifat leptokurtik memiliki varians lebih kecil dari data yang berdistribusi normal dan mempunyai kurtosis lebih dari nol. Data yang membawa sifat *fat tails* mempunyai nilai varian yang lebih besar dan nilai kurtosis kurang dari nol.

Wong dan Li (2000) sangat inovatif dalam memandang data *time series* sebagai bentuk *mixture*, sehingga dikembangkanlah suatu model *time series* non linier yang berkaitan dengan sifat multimodal yang kemudian dikenal dengan model *Mixture Autoregressive* (MAR). Model ini merupakan suatu model yang terdiri dari *mixture M*-komponen Gaussian *Autoregressive* (AR). Beberapa kelebihan model MAR, yaitu mampu mengadaptasi sifat data yang *fat tails*, leptokurtik, platikurtik dan multimodal serta mampu mengakomodir sifat kemiringan data.

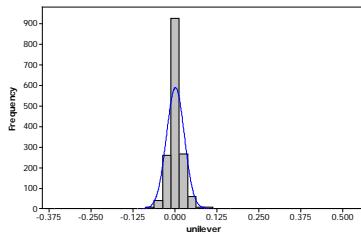
Penelitian mengenai *Mixture Autoregression* pernah dilakukan oleh Purwandi (2008) pada indeks saham Han Seng yang

mempunyai pola *random* dan mengandung *fat tails* dan leptokurtik. Rahman (2008) menerapkan metode Bayesian *Mixture Autoregressive* pada data indeks NASDAQ dan mendapatkan hasil bahwa model MAR mempunyai nilai MSE yang lebih kecil dibanding dengan model ARIMA, sehingga dapat disimpulkan model MAR lebih baik dari model ARIMA dalam memodelkan indeks NASDAQ. Sedangkan penelitian mengenai *Value at Risk* (VaR) pernah dilakukan oleh Laila (2010) yang menyatakan bahwa VaR dapat digunakan sebagai *early warning system* dimana investor mempunyai pilihan untuk menggunakan model VaR tersebut sebagai rasio kecukupan modal. Wijayanti (2007) melakukan perbandingan analisis risiko investasi saham dengan metode VaR dengan pendekatan distribusi uni-modal dan *mixture*, diperoleh kesimpulan bahwa pendekatan distribusi *mixture* dalam menghitung risiko investasi menghasilkan nilai VaR yang lebih kecil dibandingkan dengan pendekatan uni-modal. Valecky (2012) melakukan penelitian tentang pengukuran risiko dari beberapa portofolio di Pasar Eropa dengan menggunakan VaR *mixture normal* dan didapatkan hasil bahwa perkiraan risiko dengan VaR *mixture normal* menghasilkan nilai estimasi risiko yang akurat.

Pada penelitian tugas akhir ini, model *Mixture Normal Autoregressive* (MNAR) akan diimplementasikan pada 3 perusahaan yang tergabung dalam JII dengan kapitalisasi terbesar, diantaranya PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLMK) dan PT. Unilever Indonesia Tbk(UNVR). Identifikasi awal distribusi *return* dari masing-masing perusahaan dilakukan menggunakan histogram yang disajikan pada Gambar 1.1.



Gambar 1.1 Histogram *Return* masing-masing Perusahaan



Gambar 1.1 (Lanjutan)

Dari histogram pada Gambar 1.1 diketahui bahwa *return* saham ketiga perusahaan memiliki variabilitas yang berbeda karena adanya nilai ekstrim pada ujung kanan dan kiri. Selain itu terlihat bahwa ketiga *return* saham juga tidak normal, yang ditunjukkan dengan distribusi *return* yang lebih runcing daripada distribusi normal atau biasa disebut leptokurtik. Dengan demikian data memuat lebih dari satu distribusi. Oleh karena itu, digunakanlah MNAR untuk memodelkan sifat-sifat tersebut dengan melakukan penumpukan distribusi normal yang dicirikan oleh nilai masing-masing parameter μ_i dan σ_i^2 , dengan $i=1,2,\dots$. Selain itu apabila dilihat dari segi risiko, ketiga perusahaan tersebut memiliki *return* yang berfluktuasi tinggi.

Dalam estimasi parameter model MNAR, dimungkinkan menemui kesulitan jika menggunakan metode misalkan MPLE (*Maximum Partial Likelihood Estimation*), karena masing-masing fungsi distribusi harus dilikelihoodkan dan akan menghasilkan persamaan yang rumit, sehingga untuk mempermudah digunakan pendekatan analisis *Bayesian Markov Chain Monte Carlo (MCMC)*. Berdasarkan uraian di atas, dilakukanlah penelitian mengenai analisis risiko saham syariah menggunakan metode *Value at Risk* (VaR) dengan pendekatan Bayesian *Mixture Normal Autoregressive* (MNAR).

1.2 Rumusan Masalah

Di tengah kemerosotan perekonomian Indonesia yang berimbas ke sektor pasar modal sebagai subsistem perekonomian nasional, industri pasar modal Indonesia mulai melirik pengem-

bangun penerapan prinsip-prinsip syariah sebagai alternatif instrumen investasi dalam kegiatan pasar modal di Indonesia. Oleh karena itu pada tahun 2000 diluncurkanlah suatu indeks yang dibuat berdasarkan prinsip syariah yaitu *Jakarta Islamic Index*. Melalui fluktuasi indeks, investor dapat menghitung berapa potensi risiko pasar dari suatu saham dengan melihat *return* saham. Saham dikenal memiliki karakteristik *high risk-high return*, artinya bahwa saham memberikan peluang keuntungan yang tinggi namun juga berpotensi menanggung risiko tinggi. Jadi apabila investor memutuskan untuk berinvestasi dalam bentuk saham, yang perlu ditelah ulang adalah tingkat risiko yang akan ditanggung oleh investor. Salah satu metode pengukuran risiko yang saat ini popular digunakan adalah *Value at Risk* (VaR).

Di Tiga perusahaan yang tergabung dalam JII yaitu PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLMK) dan PT. Unilever Indonesia Tbk (UNVR), mempunyai pola *return* yang diindikasi mengandung sifat *skewness*, fat tail dan leptokurtik. Hal ini berarti bahwa pada data terdapat lebih dari satu distribusi. Oleh karena itu, digunakanlah MNAR untuk memodelkan sifat-sifat tersebut. Dalam melakukan estimasi model MNAR, akan mengalami kesulitan karena persamaan yang dihasilkan rumit. Oleh karena itu untuk mempermudah digunakanlah pendekatan analisis *Bayesian Markov Chain Monte Carlo* (*MCMC*).

1.3 Tujuan Penelitian

Berdasarkan permasalahan yang telah diuraikan diatas, maka tujuan yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

1. Mengetahui karakteristik *return* saham PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLMK) dan PT. Unilever Tbk (UNVR).
2. Memperoleh hasil pengukuran risiko investasi saham pada PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLMK) dan PT. Unilever Tbk (UNVR)

menggunakan metode *Value at Risk* (VaR) dengan pendekatan Bayesian *Mixture Normal Autoregressive* (MNAR).

1.4 Manfaat Penelitian

Beberapa manfaat yang dapat diperoleh dari penelitian ini adalah sebagai berikut.

a. Pemegang Saham

Dapat memberikan tambahan informasi mengenai penge-lolaan investasi dan pengukuran risiko harga saham sehingga dapat menjadi acuan dalam pengambilan keputusan strategi investasi pada saham dalam rangka mengoptimal-kan *return*.

b. Calon Investor

Dapat memberikan tambahan informasi sehingga memudahkan calon investor dalam memutuskan untuk berinvestasi dengan mempertimbangkan *Value at Risk* (VaR) pada saham-saham emiten yang tercatat di *Jakarta Islamic Index* (JII) khususnya pada perusahaan yang dijadikan sampel, sehingga dapat dijadikan solusi berinvestasi pada saham-saham tersebut.

1.5 Batasan Penelitian

Terkait dengan beberapa kondisi yang ada, analisis yang dilakukan dalam penelitian ini memiliki batasan masalah sebagai berikut.

1. Estimasi parameter model MNAR menggunakan analisis Bayesian *Monte Carlo Marcov Chain* (MCMC) dengan *Gibbs Sampling*.
2. Distribusi *prior* yang digunakan adalah *conjugate* dan *non-informative prior*
3. Komponen *mixture* yang digunakan adalah 2 dan 3 komponen.
4. Dari hasil indentifikasi plot ACF dan PACF, orde yang digunakan untuk pemodelan berasal dari orde model *Autoregressive* (AR).

(Halaman ini sengaja dikosongkan)

BAB II

TINJAUAN PUSTAKA

Pada bagian ini akan diuraikan tinjauan pustaka yang digunakan dalam penelitian ini, diantaranya yaitu Konsep *Time Series*, Model *Autoregressive Integrated Moving Average* (ARIMA) beserta dengan prosedurnya, Model *Mixture Normal Autoregressive* (MNAR), Estimasi parameter dengan pendekatan Bayesian, *Value at Risk* (VaR) serta tinjauan non-Statistika seperti *return* saham, *Jakarta Islamic Index* (JII) serta sikap investor terhadap risiko.

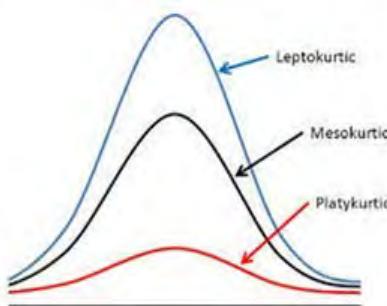
2.1 Statistika Deskriptif

Statistika deskriptif merupakan metode-metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data sehingga memberikan informasi yang berguna. Beberapa penyajian data yang sering digunakan adalah dalam bentuk tabel, grafik, diagram dan lain sebagainya yang mampu mendeskripsikan data tersebut.

Skewness merupakan derajat letak kesimetrisan dari suatu distribusi. Jika kurva frekuensi suatu distribusi mempunyai ekor yang lebih panjang ke kanan, maka distribusi tersebut mempunyai kemiringan positif. Sebaliknya jika distribusi mempunyai ekor yang lebih panjang ke kiri, maka mempunyai kemiringan negatif. Nilai skewness dari distribusi normal adalah nol (Dajan, 1991).

Ukuran keruncingan atau biasa disebut kurtosis adalah suatu bilangan yang dapat menunjukkan runcing atau tidaknya bentuk kurva distribusi frekuensi. Kurtosis adalah derajat keruncingan suatu distribusi (biasanya diukur relatif terhadap distribusi normal). Distribusi yang lebih runcing dari distribusi normal dengan kurtosis positif dinamakan leptokurtik, yang lebih datar dengan kurtosis negatif disebut platikurtik dan distribusi normal disebut mesokurtik. Distribusi leptokurtik memiliki puncak lebih tinggi di sekitar mean yang menunjukkan probabilitas nilai di sekitar mean lebih tinggi daripada variabel berdistribusi normal dan ekor tebal (*fat tails*) yang menunjukkan probabilitas adanya

nilai ekstrim juga lebih tinggi. Distribusi yang platkurtik memiliki puncak lebih rendah di sekitar mean yang menunjukkan probabilitas nilai di sekitar mean lebih rendah daripada variabel distribusi normal dan ekor yang tipis (*thin tails*) yang menunjukkan probabilitas adanya nilai ekstrim juga lebih rendah. Untuk melihat lebih jelas bagaimana bentuk kurtosis dapat dilihat pada Gambar 2.1.



Gambar 2.1 Bentuk Keruncingan Distribusi
Secara umum, kurtosis dapat dirumuskan dalam persamaan (2.1).

$$\text{kurtosis} = \frac{\sum_{t=1}^n (Z_t - \bar{Z})^4}{(n-1)s^4}, \quad (2.1)$$

dimana \bar{Z} adalah mean dari data observasi, s adalah standar deviasi dan n adalah jumlah observasi. Kurtosis untuk distribusi normal adalah tiga. Namun kemudian dilakukan modifikasi sehingga kurtosis untuk normal adalah nol, sehingga persamaan kurtosis dituliskan dalam persamaan (2.2).

$$\text{kurtosis} = \frac{\sum_{t=1}^n (Z_t - \bar{Z})^4}{(n-1)s^4} - 3. \quad (2.2)$$

Pada tugas akhir ini, pemeriksaan kurtosis dilakukan dengan paket program Minitab, dengan kurtosis seperti pada persamaan (2.2), maka kurtosis untuk normal adalah nol.

2.2 Konsep Time Series

Data *time series* atau deret waktu adalah serangkaian data dimana nilai pengamatan diukur selama kurun waktu tertentu berdasarkan interval waktu yang sama. Pada metode *time series*, tiap pengamatan diambil dari suatu variabel yang berkorelasi linier dengan variabel itu sendiri. Beberapa sifat berkaitan dengan data *time series* yaitu setiap pengamatan dianggap saling berkaitan atau saling berkorelasi antara pengamatan satu dengan pengamatan lainnya dan kumpulan pengamatan dalam *time series* untuk setiap waktu t dinyatakan sebagai variabel *random* (dinotasikan sebagai Z_t).

2.2.1 Stasioneritas Deret Waktu

Kestasioneran suatu data diperlukan sebagai asumsi yang harus dipenuhi dalam analisis deret waktu. Stasioneritas memiliki arti bahwa tidak terdapat kenaikan atau penurunan pada data (data berfluktuasi di sekitaran nilai rata-rata yang konstan, tidak tergantung pada waktu dan varians dari fluktuasi tersebut dan tetap konstan setiap waktu) (Wei, 2006). Apabila pengamatan z_1, z_2, \dots, z_n dianggap sebagai proses stokastik, maka variabel random $z_{t_1}, z_{t_2}, \dots, z_{t_n}$ dikatakan stasioner apabila seperti dalam persamaan (2.3).

$$F(z_{t_1}, z_{t_2}, \dots, z_{t_n}) = F(z_{t_1+k}, z_{t_2+k}, \dots, z_{t_n+k}). \quad (2.3)$$

Suatu deret waktu dikatakan tidak stasioner dalam *mean* jika deret tersebut tidak berfluktuasi di sekitar nilai *mean*. Untuk mengatasi ketidakstasioneran dalam *mean* maka perlu dilakukan pembedaan atau *differencing* pada data deret waktu tersebut. Indikator kestasioneran dalam *mean* adalah ACF suatu deret Z_t yang menurun dengan lambat atau *dies down*. Suatu deret waktu dikatakan tidak stasioner dalam *varians* jika deret tersebut tidak berfluktuasi dalam *varians* yang konstan. Untuk melakukan pengecekan apakah deret sudah stasioner dalam varian adalah dengan melakukan uji kesamaan varian terhadap persamaan (2.4). uji kesesuaian varian dapat dilakukan dengan menggunakan uji Levene, dimana pengujian ini lebih robust terhadap data yang

tidak berdistribusi normal. Hipotesis dalam pengujian ini adalah sebagai berikut.

$$H_0: \sigma_1 = \sigma_2 = \dots = \sigma_k$$

$$H_1: \exists \sigma_i \neq \sigma_j$$

dengan statistik uji seperti dalam persamaan (2.4)

$$L = \frac{(N - k) - \sum_{i=1}^k n_i (\bar{Z}_{i\cdot} - \bar{Z}_{..})}{k - 1 \sum_{i=1}^k \sum_{j=1}^{n_i} (\bar{Z}_{ij} - \bar{Z}_{i\cdot})^2}, \quad (2.4)$$

dimana N adalah jumlah observasi, k adalah banyaknya kelompok, Z_{ij} adalah $|Y_{ij} - Y_{i\cdot}|$, $\bar{Y}_{i\cdot}$ adalah rata-rata dari kelompok ke- i , $\bar{Z}_{i\cdot}$ adalah kelompok dari $Z_{i\cdot}$, $\bar{Z}_{..}$ adalah rata-rata menyeluruh dari Z_{ij} (Levene, 1960). Sementara itu, untuk menstabilkan *varians* suatu deret waktu yang tidak stasioner, maka perlu dilakukan transformasi terlebih dahulu (Wei, 2006).

2.4.1 Fungsi Autokorelasi (ACF) dan Fungsi Autokorelasi Parsial (PACF)

Fungsi autokorelasi atau *Autocorrelation Function* (ACF) menggambarkan korelasi antara pengamatan saat ini (Z_t) dan pengamatan sebelumnya (Z_{t-k}) yang dipisahkan oleh k lag (Wei, 2006). Secara umum ACF dirumuskan dalam persamaan (2.5).

$$\rho_k = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)\text{Var}(Z_{t+k})}}. \quad (2.5)$$

Dalam keadaan stasioner, $\text{var}(Z_t) = \text{var}(Z_{t+k}) = \gamma_0$ dan γ_k yang disebut sebagai fungsi autokovarians. Sedangkan ρ_k disebut sebagai fungsi autokorelasi (ACF), seperti yang disajikan dalam persamaan (2.6).

$$\rho_k = \frac{\gamma_k}{\gamma_0}. \quad (2.6)$$

Jika fungsi autokorelasi tidak bisa dihitung dari populasi, maka dihitung melalui sampel pengambilan data dan fungsi autokorelasi dapat ditaksir sebagaimana dalam persamaan (2.7).

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^{n-k} (Z_t - \bar{Z})^2}. \quad (2.7)$$

Fungsi autokorelasi parsial atau *Partial Autocorrelation Function* (PACF) berguna dalam mengukur tingkat keeratan hubungan antara pasangan data Z_t dan Z_{t+k} setelah dependensi linier antar variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t-k-1}$ dihilangkan (Wei, 2006). Untuk fungsi autokorelasi parsial dapat ditaksir menggunakan persamaan (2.8)

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

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

2.4.2 Proses Autoregresive (AR), Moving Average (MA) dan Autoregressive Moving Average (ARMA)

Proses Autoregresive (AR) menggambarkan keadaan bahwa nilai Z_t pada saat ini bergantung pada nilai-nilai sebelumnya ditambah dengan suatu proses *white noise* $\{\alpha_t\}$. Model AR dengan order p atau dapat AR (p) secara umum dapat dirumuskan pada persamaan (2.9).

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \phi_2 \dot{Z}_{t-2} + \dots + \phi_p \dot{Z}_{t-p} + a_t, \quad (2.9)$$

atau

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

dengan $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B_p)$ atau $\dot{Z}_t = Z_t - \mu$.

Proses *Moving Average* (MA) menggambarkan bahwa nilai prediksi variabel dependen Z_t dipengaruhi oleh nilai *error* pada periode sebelumnya. Model MA dengan order q atau dapat dituliskan MA (q) dirumuskan dalam persamaan (2.10).

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (2.10)$$

atau

$$Z_t(B)a_t,$$

dengan $\theta_p(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$.

Karena $1 + \theta_1^2 + \dots + \theta_q^2 < \infty$, proses MA(q) selalu stasioner. Suatu proses yang stasioner dan invertible dapat direpresentasikan pada kedua proses AR dan MA. Model gabungan AR dan MA disebut *Autoregressive Moving Average* (ARMA). Model ARMA (p,q) secara umum dapat dituliskan dalam persamaan (2.11).

$$Z_t = \phi Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}, \quad (2.11)$$

atau

$$\phi_p(B)Z_t = \theta_q(B)a_t.$$

Perluasan dari model-model tersebut mencakup proses non stasioner (ARIMA). Model *Autoregressive Integrated Moving Average* (ARIMA) bertujuan untuk memecahkan permasalahan *time series* yang mencakup proses non stasioner. Model ini merupakan gabungan antara model AR dan MA ditambah *differencing* orde d . Sebuah model umum untuk ARIMA (p,d,q) terdapat dalam persamaan (2.12) (Wei, 2006).

$$\phi_p(B)(1-B)^d Z_t = \theta_q(B)a_t. \quad (2.12)$$

2.2.2 Uji Signifikansi Parameter Model

Pengujian signifikansi parameter digunakan untuk mengetahui parameter mana yang signifikan sehingga dapat digunakan dalam model. Pengujian parameter hasil estimasi dengan Bayesian MCMC untuk setiap parameter yang diperoleh digunakan pengujian hipotesis sebagai berikut.

$$H_0 : \phi = 0$$

$$H_1 : \phi \neq 0$$

Penolakan H_0 didasarkan pada selang interval 95 persen dari distribusi *posterior*, yaitu dengan melihat *interval credible*, jika *interval credible* tidak memuat 0 (nol).

2.2.3 Diagnostic Checking

Dalam menentukan model ARIMA yang terbaik, harus dipilih model yang seluruh parameternya signifikan dan memenuhi asumsi residual yaitu *white noise* dan berdistribusi normal. Uji asumsi residual yang pertama adalah residual *white noise*. residual dari suatu model dikatakan telah *white noise* apabila antar residual $\{a_t\}$ saling independen (tidak saling berkorelasi antar lag) dan identik (variansi residual homogen), dengan mean=0 dan varians konstan var $(a_t) = \sigma_a^2$. Pengujian yang digunakan untuk melihat residual independen atau menyebar secara acak (*random*) dengan *run-test*. hipotesis yang digunakan adalah:

H_0 : tidak ada korelasi antar residual

H_1 : residual saling berkorelasi

dengan statistik *run-test* dalam persamaan (2.13):

$$z = \frac{r - \left[\left\{ \frac{2n_1 n_2}{n_1 + n_2} \right\} + 1 \right]}{\sqrt{\frac{2n_1 n_2 (2n_1 n_2 - n_1 - n_2)}{(n_1 + n_2)^2 (n_1 + n_2 - 1)}}, \quad (2.13)$$

dimana, r merupakan banyaknya runtun data yang terjadi, n_1 adalah banyaknya data bertanda (+) dan n_2 adalah banyaknya data bertanda (-). Keputusan tolak H_0 jika, $Z \geq Z_{1-\frac{\alpha}{2}}$ atau $Z < Z_{1-\frac{\alpha}{2}}$ atau $p\text{-value} > \alpha$. (Daniel, 1989).

Untuk pengujian residual identik (varian residual homogen) dapat dilakukan dengan uji *Lagrange Multiplier*. Hipotesis yang digunakan adalah:

$H_0: a_1 = a_2 = \dots = a_t = 0$ (residual homogen)

$H_1: \exists \sigma_i \neq 0$ (residual tidak homogen)

Statistik uji untuk pengujian ini terdapat dalam persamaan (2.14):

$$LM = TR^2, \quad (2.14)$$

dengan T merupakan banyaknya data dan R^2 merupakan koefisien determinasi. Keputusan H_0 ditolak apabila $LM > \chi^2_{\alpha,(K-p-q)}$ atau $p\text{-value} < \alpha$, yang berarti bahwa varian residual tidak homogen atau terjadi kasus heteroskesdastisitas. p dan q adalah orde dari AR dan MA.

Setelah uji residual *white noise*, maka selanjutnya adalah uji residual mengikuti distribusi normal. Pengujian residual normal dilakukan dengan menggunakan uji *Kolmogorov-Smirnov*. Uji hipotesis yang digunakan adalah :

$$H_0 : F(a_t) = F_0(a_t) \text{ (Residual berdistribusi normal)}$$

$$H_1 : F(a_t) \neq F_0(a_t) \text{ (Residual tidak berdistribusi normal)}$$

dengan statistik uji pada persamaan (2.15):

$$D = \sup_{a_t} |S(a_t) - F_0(a_t)|, \quad (2.15)$$

dengan :

$S(a_t)$ = fungsi distribusi frekuensi kumulatif yang dihitung dari data sampel

$F_0(a_t)$ = fungsi distribusi frekuensi kumulatif distribusi normal.

$F(a_t)$ = fungsi distribusi populasi yang diwakili oleh sampel

Keputusan yang diambil adalah tolak H_0 apabila $D > D_{\alpha,n}$ dengan D_{α} adalah nilai tabel *Kolmogorov-Smirnov* satu sampel dan n adalah banyaknya pengamatan (Daniel, 1989).

2.3 Model *Mixture* Normal Univariabel

Model *mixture* merupakan model gabungan dari beberapa sub-populasi yang masing-masing berpola univariabel. Setiap sub-populasi merupakan komponen penyusun dari model *mixture* serta mempunyai proporsi yang bervariasi untuk masing-masing komponennya. Pola model *mixture* ini dapat didekati dengan formula seperti dalam persamaan (2.16) (Iriawan, 2001).

$$f_{mix}(z | \theta, P) = \sum_{i=1}^M P_i g_i(z | \theta_i), \quad (2.16)$$

dengan $f_{mix}(z | \theta, P)$ merupakan fungsi densitas dari model *mixture*. $g_i(z | \theta_i)$ merupakan densitas ke- i dari sebanyak M komponen model *mixture*. θ_i merupakan vektor parameter setiap komponen penyusun model *mixture* ($\theta_1, \theta_2, \dots, \theta_M$), $i=1,2,\dots,M$. P merupakan vektor parameter proporsi dengan elemen-elemen (P_1, P_2, \dots, P_M) . P_i merupakan parameter proporsi komponen *mixture* dengan $\sum_{i=1}^M P_i = 1$ serta $0 \leq P_i \leq 1, j = 1, 2, \dots, M$. k merupakan banyaknya komponen penyusun model *mixture*. Jika terdapat suatu data pengamatan yang mempunyai sub-populasi sebanyak M yang masing-masing berdistribusi normal, maka dapat ditulis dalam persamaan (2.17).

$$f_{mix}(z | P\mu, \sigma^2) = P_1 N(z | \mu_1, \sigma_1^2) + \dots + P_M N(z | \mu_M, \sigma_M^2) \quad (2.17)$$

2.3.1 Model *Mixture Normal Autoregressive*

Pada dasarnya model MNAR merupakan gabungan dari M Gaussian model AR. Karena mean dari komponen bergantung pada nilai dimasa lalu suatu *time series*, maka dibentuk distribusi bersyarat dari data. Suatu data yang mempunyai distribusi multimodal ataupun unimodal tetapi tidak normal sebagai akibat dari adanya *tails* maupun kurtosis yang besar, maka bisa dipecahkan menjadi beberapa distribusi normal, sehingga salah satu penyelesaiannya dapat diatasi dengan model MNAR yang dikembangkan oleh Wong dan Li pada tahun 2000. Suatu model MNAR dengan M -komponen penyusun yang dapat dirumuskan dalam persamaan (2.18).

$$\dot{Z}_t | \mathcal{F}_{t-1} = \sum_{i=1}^M P_i \left(\frac{\dot{Z}_t - \phi_{i,1} Z_{t-1} - \dots - \phi_{i,p_i} Z_{t-p_i}}{\sigma_i} \right) \quad (2.18)$$

Persamaan (2.18) akan disebut sebagai model MNAR $(M; p_1, \dots, p_i)$. Dalam hal ini, $F(Z_t | \mathcal{F}_{t-1})$ adalah *conditional cumulative distribution function (cdf)* dari Z_t dengan diketahui in-

formasi sebelum pengamatan z_t , \mathcal{F}_{t-1} adalah informasi data pengamatan hingga $t-1$, $\Phi(\cdot)$ adalah *cdf* dari distribusi normal standar, σ_i adalah standar deviasi komponen ke- M dan $P_1 + P_2 + \dots + P_M = 1$, $P_i > 0$, $i = 1, \dots, M$ (Iriawan, 2012). Jika z_t merupakan komponen MNAR dalam persamaan (2.19), maka berarti,

$$\dot{Z}_t = \begin{cases} \sum_{l=1}^{p_1} \phi_{1,l} z_{t-l} + \sigma_1 \varepsilon_1(t) & , \text{probabilitas } w_1 \\ \sum_{l=1}^{p_2} \phi_{2,l} z_{t-l} + \sigma_2 \varepsilon_2(t) & , \text{probabilitas } w_2 \\ \dots \\ \sum_{l=1}^{p_M} \phi_{M,l} z_{t-l} + \sigma_M \varepsilon_M(t) & , \text{probabilitas } w_M. \end{cases} \quad (2.19)$$

Model MNAR mempunyai *conditional mean* seperti dalam persamaan (2.20).

$$\begin{aligned} E(\dot{Z}_t | \mathcal{F}_{t-1}) &= \sum_{i=1}^M P_i \left(\dot{Z}_t - \phi_{i,1} Z_{t-1} - \dots - \phi_{i,p_i} Z_{t-p_i} \right) \\ &= \sum_{i=1}^M P_i \mu_{i,t}, \end{aligned} \quad (2.20)$$

dan *conditional varian*, yang dapat dihitung dengan rumus seperti pada persamaan (2.21).

$$Var(\dot{Z}_t | \mathcal{F}_{t-1}) = \sum_{i=1}^M P_i \sigma_i^2 + \sum_{i=1}^M P_i \mu_{i,t}^2 - \left(\sum_{i=1}^M P_i \mu_{i,t} \right)^2. \quad (2.21)$$

2.4 Estimasi Parameter dengan Pendekatan Bayesian

Dalam teori estimasi, dikenal dua pendekatan yaitu pendekatan statistika klasik dan pendekatan statistika Bayesian. Statistika klasik sepenuhnya mengandalkan proses inferensia pada data sampel yang diambil dari populasi. Sedangkan statistika Bayesian, disamping memanfaatkan data sampel yang diperoleh dari populasi juga memperhitungkan suatu distribusi awal yang disebut *prior*. Pendekatan klasik memandang parameter θ sebagai pa-

rameter yang bernilai tetap. Sedangkan pendekatan statistika Bayesian memandang parameter θ sebagai variabel *random* yang memiliki distribusi, yang disebut sebagai distribusi *prior*. Pemodelan menggunakan metode Bayesian didasarkan pada model *posterior* yang memadukan data masa lalu sebagai informasi *prior* dan data pengamatan yang digunakan sebagai penyusun fungsi *likelihood*.

Informasi yang diketahui tentang parameter θ sebelum pengamatan dilakukan disebut sebagai *prior* θ atau $p(\theta)$. Selanjutnya untuk menentukan distribusi *posterior* θ , yaitu $p(\theta|z)$ pada aturan probabilitas dalam Teorema Bayes pada persamaan (2.22).

$$p(\theta|z) = \frac{f(\theta|z)p(\theta)}{f(z)}, \quad (2.22)$$

dengan $f(z) = E(f(z|\theta)) = \begin{cases} \int f(z|\theta)f(\theta)d\theta, & \text{jika } \theta \text{ kontinyu} \\ \sum f(z|\theta)p(\theta), & \text{jika } \theta \text{ diskrit}, \end{cases}$
 $f(\theta|z)$ adalah fungsi *likelihood* data yang berisi informasi sampel dan $f(z)$ adalah fungsi densitas sebagai distribusi *prior*. Selanjutnya persamaan (2.23) dapat dituliskan dalam persamaan (2.23).

$$p(\theta|z) \propto f(\theta|z)p(\theta). \quad (2.23)$$

Persamaan (2.24) menunjukkan bahwa *posterior* adalah proporsional *likelihood* dikalikan dengan *prior* dari parameter model.

2.4.1 Distribusi *Prior*

Berdasarkan teorema Bayes seperti yang diungkapkan sebelumnya, informasi awal suatu parameter sebelum dilakukan observasi distribusi *prior* menjadi hal yang penting dalam analisis Bayesian. Distribusi *prior* merupakan distribusi awal yang harus ditentukan terlebih dahulu sebelum merumuskan distribusi *posteriornya*. Distribusi *prior* adalah distribusi subyektif berdasarkan pada keyakinan seseorang dan dirumuskan sebelum data sampel diambil.

Terdapat 4 tipe distribusi *prior* Bayesian, diantaranya.

1. *Conjugate prior* dan *non-conjugate prior*

Disebut sebagai *conjugate prior* apabila distribusi *posterior* berasal dari keluarga distribusi yang sama dengan distribusi *prior* dimana penentuan distribusi *prior* didasarkan pada pola fungsi *likelihood* data. Sebaliknya, *non conjugate prior* merupakan penentuan distribusi *prior* yang tidak didasarkan pada pola fungsi *likelihood* (Box dan Tiao, 1973).

2. *Proper prior* atau *improper prior*, yaitu *prior* yang terkait pada pemberian pembobotan/densitas disetiap titik untuk setiap titik di sepanjang domain parameter dengan pertimbangan *uniformly distributed* atau tidak (Box dan Tiao, 1973).
3. *Informative prior* dan *Non-informative prior*, yaitu *prior* terkait dengan informasi dari pola/frekuensi distribusi data. penentuan distribusi *prior* yang pola distribusi datanya telah diketahui disebut dengan *informative prior*, sedangkan penentuan distribusi *prior* yang sebelumnya tidak diketahui informasi mengenai pola distribusi datanya disebut *non-informative prior* (Box dan Tiao, 1973).
4. *Pseudo prior*, yaitu *prior* yang berkaitan dengan pemberian nilai yang disertakan dengan hasil elaborasi dari *frequentist* (Charlin dan Chib, 1995).

2.4.2 *Markov Chain Monte Carlo* (MCMC) dengan *Gibbs Sampling*

Metode *Markov Chain Monte Carlo* (MCMC) memudahkan pemodelan yang cukup kompleks sehingga dianggap sebagai suatu alternatif dalam penggunaan analisis bayesian. *Markov Chain Monte Carlo* (MCMC) adalah sebuah metode untuk membangkitkan variabel *random* yang didasarkan pada rantai markov. Dengan MCMC akan diperoleh sebuah barisan sampel *random* yang berkorelasi, yakni nilai ke- ϑ_k dari barisan yang disampling dari sebuah densitas yang bergantung pada nilai sebelumnya $\{\vartheta_{k-1}\}$.

Distribusi eksak dari $\{\vartheta_k\}$ umumnya tidak diketahui, namun distribusi pada setiap iterasi dalam barisan nilai sampel tersebut akan konvergen pada distribusi yang sesungguhnya untuk

nilai k yang cukup besar. Oleh karena itu, jika ukuran sampel yang diperbarui cukup besar maka kelompok terakhir dari nilai yang disampling dalam barisan tersebut, misal $\{\vartheta^{(P+1)}, \vartheta^{(P+2)}, \dots\}$ akan mendekati sebuah sampel yang berasal dari distribusi yang diinginkan. Notasi P biasanya disebut sebagai *burn in period*.

Gibbs Sampling merupakan pembangkit yang efisien, sehingga sering digunakan sebagai pembangkit variabel *random* pada penggunaan metode MCMC. *Gibbs sampling* adalah teknik untuk membangkitkan variabel *random* dari suatu distribusi *marginal* secara langsung tanpa harus menghitung fungsi kepadatan distribusi tersebut. Proses *Gibbs sampling* meliputi pengambilan sampel dengan cara membangkitkan serangkaian *Gibbs* variabel *random* (*Gibbs sequence*) berdasarkan sifat-sifat dasar proses *Markov Chain* (Casella dan George, 1992).

Setiap iterasi MCMC akan memberikan satu vektor parameter (μ, σ, P) dan pada setiap iterasi nilai (μ, σ, P) selalu diperbarui sesuai dengan sifat stokastik dalam proses *Markov Chain*. Untuk memberikan jaminan konvergensi dan stasioneritas data bangkitan parameter *mixture*, maka sebanyak P iterasi awalnya akan dibuang sebagai kondisi *burn-in*. sehingga data yang akan digunakan sebagai penduga setiap parameter adalah bangkitan setelah kondisi *burn in*.

Algoritma untuk tahapan estimasi *mixture* dengan *Gibbs sampling* adalah sebagai berikut.

1. Diberikan state : $\vartheta^t = (\mu, \sigma, w)^t$ pada iterasi ke $t=0$
2. Bangkitkan parameter komponen setiap *mixture*
 - a. Bangkitkan $\mu^{(t+1)}$ dari $p(\mu|z, \sigma^{(t)}, w^{(t)})$
 - b. Bangkitkan $\sigma^{(t+1)}$ dari $p(\sigma|z, \mu^{(t+1)}, w^{(t)})$
 - c. Bangkitkan $w^{(t+1)}$ dari $p(w|z, \mu^{(t+1)}, \sigma^{(t+1)})$
3. Ulangi langkah 2 diatas hingga T kali, dimana $T \rightarrow \infty$

Pada langkah 2 harus dilakukan estimasi sebanyak M komponen *mixture* dari sebuah parameter baik μ, σ maupun w . Data yang dibangkitkan dengan menggunakan Algoritma 1 di atas akan mempunyai pola data yang konvergen dan stasioner serta akan proporsional mengikuti distribusi masing-masing.

2.4.3 Deviance Information Criteria (DIC)

Pemilihan model terbaik dilakukan apabila terdapat lebih dari satu model yang layak untuk digunakan. Banyak kriteria yang dapat digunakan dalam menentukan model terbaik, salah satunya yaitu menggunakan DIC (*Deviance Information Criteria*). Spiegelhalter, Best, Carlin dan Linde (2002) memperkenalkan DIC sebagai kriteria dalam pemilihan model terbaik dengan mempertimbangkan kompleksitas model. Ukuran kompleksitas model dinyatakan dengan P_D yang merupakan selisih antara rata-rata *posterior* dari *deviance* \bar{D} dan *deviance posterior* taksiran parameter. Rumus untuk memperoleh nilai *deviance* dapat dituliskan seperti persamaan (2.24).

$$D(\vartheta) = -2 \log(L(z) | \vartheta)), \quad (2.24)$$

dengan $L(z|\vartheta)$ adalah fungsi *likelihood* z dengan syarat ϑ diketahui. Rata-rata *deviance posterior* dinyatakan dalam bentuk persamaan (2.25).

$$\bar{D}(\vartheta) = E(D(\vartheta)), \quad (2.25)$$

dan *deviance* yang dihitung pada rata-rata *posterior* $\bar{\vartheta}$ seperti dalam persamaan (2.26)

$$D(\bar{\vartheta}) = D(E(\vartheta)). \quad (2.26)$$

Banyaknya parameter yang efektif dalam model dapat dihitung dengan menggunakan persamaan (2.27).

$$P_D = \widehat{D(\vartheta)} - D(\bar{\vartheta}). \quad (2.27)$$

Sehingga diperoleh DIC seperti dalam persamaan (2.28).

$$\begin{aligned} DIC &= D(\bar{\vartheta}) = +2P_D \\ DIC &= \bar{D}(\vartheta) + P_D \end{aligned} \quad (2.28)$$

Model dengan DIC lebih kecil merupakan model yang lebih baik dibandingkan model alternatif lainnya.

2.5 Value at Risk (VaR)

Secara umum, menurut Hanggraeni (2010), risiko merupakan peristiwa yang berpotensi terjadi yang mungkin dapat menimbulkan kerugian yang disebabkan adanya ketidakpastian di masa mendatang, penyimpangan maupun terjadinya sesuatu yang diharapkan. Jorion (2007) mendefinisikan risiko sebagai volatili-

tas dari hasil yang tidak diharapkan atas nilai suatu asset. Maka di bidang finansial, risiko dapat diartikan sebagai standar deviasi atau volatilitas dari *return*. Semakin besar volatilitas *return*, maka semakin besar pula kemungkinan mengalami keuntungan maupun kerugian. Sehingga risiko dapat dikatakan sebagai besarnya penyimpangan antara *expected return* dengan *actual return*. Risiko dapat menimbulkan kerugian apabila tidak diantisipasi serta tidak dikelola dengan semestinya. Sebaliknya risiko yang dikelola dengan baik akan memberikan ruang pada terciptanya peluang untuk memperoleh suatu keuntungan.

Metode pengukuran risiko yang saat ini banyak digunakan adalah metode *Value at Risk* (VaR) yang dikembangkan J.P Morgan pada tahun 1994. VaR merupakan sebuah konsep yang digunakan dalam pengukuran risiko dalam *risk management*. Secara sederhana VaR ingin menjawab pertanyaan “seberapa besar (dalam persen atau sejumlah uang tertentu) investor dapat merugi selama waktu investasi T dengan tingkat kepercayaan sebesar $(1-\alpha)$ ”. Sehingga dapat dikatakan bahwa VaR digunakan untuk mengukur perkiraan kerugian minimum yang mungkin terjadi pada suatu periode waktu tertentu dalam kondisi pasar normal dengan *confidence level* tertentu.

Bodie, Kane dan Marcus (2009) menyebutkan bahwa VaR merupakan nama lain dari kuantil suatu distribusi. VaR_α dinyatakan sebagai bentuk kuantil α dari distribusi keuntungan atau kerugian *return* (R), dengan $f(R)$ sebagai fungsi densitas dari $R(t)$ dan $F(R)$ sebagai fungsi distribusi kumulatifnya. Nilai suatu asset akan mengalami perubahan di pasar yang tidak sepenuhnya berdistribusi normal. Asumsi distribusi normal digunakan untuk mempermudah perhitungan volatilitas pada *confidence level* tertentu yang dikehendaki. Jika *return* mengikuti sebuah fungsi normal, dengan rata-rata μ dan standart deviasi σ , maka fungsinya dapat dituliskan dalam persamaan (2.29).

$$f(R) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2}\left(\frac{R-\mu}{\sigma}\right)^2}. \quad (2.29)$$

Secara sederhana, VaR dari $r(t)$ tersebut pada tingkat kepercayaan $(1-\alpha)$ dapat dituliskan dalam persamaan (2.30).

$$P(R \leq VaR) = \int_{-\infty}^{VaR} f(R)dR == P\left(Z \leq \frac{VaR - \mu}{\sigma\sqrt{t}}\right) = \alpha, \quad (2.30)$$

dengan Z merupakan variabel berdistribusi normal dengan *mean* 0 dan standar deviasi 1, $N(0,1)$. Sehingga persamaan (2.30) juga dapat dituliskan dalam persamaan (2.31).

$$\begin{aligned} \frac{VaR - \mu}{\sigma\sqrt{t}} &= \Phi^{-1}(\alpha) \\ VaR &= \mu + \sigma\sqrt{t}\Phi^{-1}(\alpha), \end{aligned} \quad (2.31)$$

dengan :

- μ = rata-rata dari *return*
- $\Phi^{-1}(\alpha)$ = kuantil- α dari distribusi *return*
- σ = standar deviasi dari *return*

Dengan demikian, VaR dengan pendekatan *mixture* dapat dihitung melalui persamaan (3.32).

$$\begin{aligned} VaR_{mix} &= P_1 VaR_1 + P_2 VaR_2 + P_3 VaR_3 + \dots + P_M VaR_M \\ VaR_{mix} &= \sum_{i=1}^M P_i (\mu_i + (\sigma_i)\sqrt{t})^{-1} \alpha \end{aligned} \quad (2.32)$$

dengan P_i merupakan proporsi untuk komponen ke- i , μ_i merupakan rata-rata *return* untuk komponen ke- i , σ_i merupakan standar deviasi untuk komponen ke- i , $\Phi^{-1}(\alpha)$ merupakan kuantil dari distribusi *return* dan t merupakan *holding periode* investasi (Valecky, 2012).

2.6 Return Saham

Saham adalah tanda bukti memiliki perusahaan dimana pemiliknya disebut juga sebagai pemegang saham (*shareholder* atau *stockholder*) (Samsul, 2006). Sedangkan menurut Darmadji dan Fakhruddin (2008) saham dapat didefinisikan sebagai tanda penyertaan atau kepemilikan investor individual maupun institusi-

onal atau trader atas investasi atau sejumlah dana yang diinvestasikan dalam suatu perusahaan. Karakteristik saham antara lain dapat memperoleh deviden, memiliki hak suara dalam RUPS, dimungkinkan untuk memiliki Hak Memesan Efek Terlebih Dahulu (HMETD) atau *right issue* dan terdapat potensial *capital gain* atau *capital loss*. Menurut Koetin (2002), saham adalah kertas yang dicetak dengan bagus, yang membuktikan bahwa pemegangnya turut serta atau berpartisipasi dalam modal suatu perusahaan, biasanya suatu Perseroan Terbatas (PT). Dengan demikian dapat dikatakan saham adalah selembar kertas yang menerangkan bahwa pemilik kertas tersebut adalah pemilik perusahaan yang menerbitkan surat berharga tersebut. Porsi kepemilikan ditentukan oleh seberapa besar penyertaan yang ditanamkan di perusahaan.

Saham dikenal memiliki karakteristik *high risk-high return*. hal ini berarti bahwa saham memberikan peluang keuntungan yang tinggi tetapi juga berpotensi menganggung risiko yang tinggi pula. *Return* merupakan salah satu faktor yang memotivasi investor untuk melakukan investasi. *Return* merupakan imbalan atas keberanian investor dalam menanggung risiko atas investasi yang dilakukannya (Tandelilin, 2001). *Return* dibedakan menjadi dua yaitu *return* yang telah terjadi (*actual return*) yang dihitung berdasarkan historis dan *return* yang diharapkan (*Expected return*) akan diperoleh investor dimasa mendatang (Halim, 2005). Pengukuran *return* saham dapat dituliskan pada persamaan (2.33).

$$R_t = \frac{d_t - d_{t-1}}{d_{t-1}}, \quad (2.33)$$

dengan

R_t : *Return* harga saham pada hari ke- t

d_{t-1} : Harga saham pada hari ke- $t-1$

d_t : Harga saham pada hari ke- t

2.7 Jakarta Islamic Index (JII)

Pada tanggal 3 juli 2000, PT Bursa Efek Indonesia bekerja sama dengan PT Danareksa Investment Management (DIM) me-

luncurkan indeks saham yang dibuat berdasarkan syariah islam yaitu *Jakarta Islamic Index* (JII). Penentuan kriteria dalam pemilihan saham dalam JII melibatkan Dewan Pengawas Syariah PT DIM. Saham-saham yang akan masuk ke JII harus melalui filter syariah terlebih dahulu. Berdasarkan arahan Dewan Pengawas Syariah PT DIM, ada 4 syarat yang harus dipenuhi agar saham-saham tersebut dapat masuk ke JII.

1. Emiten tidak menjalankan usaha perjudian dan permainan yang tergolong judi atau perdagangan yang dilarang.
2. Bukan lembaga keuangan konvensional yang menerapkan sistem riba, termasuk perbankan dan asuransi konvensional.
3. Usaha yang dilakukan bukan memproduksi, mendistribusikan, dan memperdagangkan makanan/minuman yang haram.
4. Tidak menjalankan usaha memproduksi, mendistribusikan, dan menyediakan barang/jasa yang merusak moral dan bersifat mudharat.

Selain filter syariah, saham yang masuk ke dalam JII harus melalui beberapa proses penyaringan (*filter*) terhadap saham yang listing, yaitu:

1. Memilih kumpulan saham dengan jenis usaha utama yang tidak bertentangan dengan prinsip syariah dan sudah tercatat lebih dari 3 bulan, kecuali termasuk dalam 10 kapitalisasi besar.
2. Memilih saham berdasarkan laporan keuangan tahunan atau tengah tahun berakhir yang memiliki rasio Kewajiban terhadap Aktiva maksimal sebesar 90%.
3. Memilih 60 saham berdasarkan urutan rata-rata kapitalisasi pasar (*market capitalization*) terbesar selama 1 (satu) tahun terakhir.
4. Memilih 30 saham dengan urutan berdasarkan tingkat likuiditas rata-rata nilai perdagangan reguler selama 1 (satu) tahun terakhir.

Pengkajian ulang akan dilakukan 6 (enam) bulan sekali dengan penentuan komponen indeks pada awal bulan Januari dan Juli setiap tahunnya. Sedangkan perubahan pada jenis usaha uta-

ma emiten akan dimonitor secara terus menerus berdasarkan data publik yang tersedia. Perusahaan yang mengubah lini bisnisnya menjadi tidak konsisten dengan prinsip syariah akan dikeluarkan dari indeks. Sedangkan saham emiten yang dikeluarkan akan diganti oleh saham emiten lain (Laila, 2010).

Dari 30 perusahaan saham yang terdaftar di Bursa Efek Indonesia, konsentrasi penelitian ini berdasarkan nilai kapitalisasi pasar terbesar. Didapatkanlah saham-saham perusahaan PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk dan PT Unilever Indonesia Tbk. Berikut merupakan profil dari ketiga perusahaan tersebut.

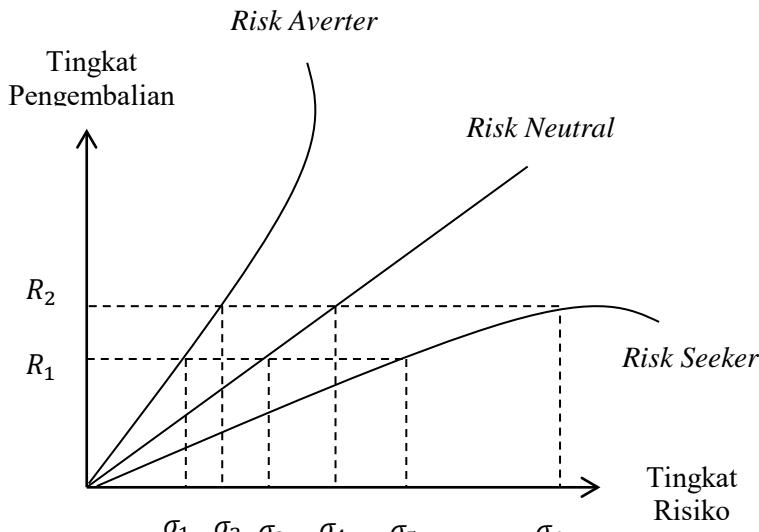
1. PT Astra International Tbk adalah perusahaan yang bergerak dalam bidang otomotif. Saham perusahaan ini tergolong ke dalam subsektor industri manufaktur dengan kelompok industri otomotif. PT Astra Internasional didirikan pada tahun 1957 di Jakarta. Pada tahun 1969, PT Astra Internasional menjadi perusahaan distribusi kendaraan Toyota dan distributor tunggal sepeda motor Honda di Indonesia. Perusahaan ini telah tercatat kedalam Bursa Efek Indonesia sejak 4 April 1990. Nilai kapitalisasi pasar PT Astra International Tbk dipenghujung tahun 2015 sebesar Rp 300,6 triliun (Astra Internasional, 2016).
2. PT Telekomunikasi Indonesia atau yang biasa dikenal dengan PT Telkom merupakan perusahaan BUMN yang bergerak di bidang jasa layanan telekomunikasi dan jaringan di wilayah Indonesia. Pada tanggal 14 November 1995 dilakukan Penawaran Umum Perdana saham Telkom. Sejak itu saham Telkom tercatat dan diperdagangkan di Bursa Efek Indonesia, Bursa Saham New York (NYSE) dan Bursa Saham London (LSE). Saham Telkom juga diperdagangkan tanpa pencatatan di Bursa Saham Tokyo. Jumlah saham yang terjual saat itu adalah 933 juta lembar saham (Telkom, 2015).
3. Unilever adalah perusahaan multinasional yang memproduksi barang konsumen yang bermarkas di Rotterdam, Belanda. Unilever Indonesia telah tumbuh menjadi salah satu per-

sahaan terdepan untuk produk Home and Personal Care serta Foods & Ice Cream di Indonesia. Unilever Indonesia didirikan pada 5 Desember 1933. PT Unilever Indonesia Tbk menawarkan saham perseroan kepada masyarakat pertama kali pada tahun 1981 dan tercatat di Bursa Efek Indonesia sejak 11 Januari 1982. Perusahaan ini tercatat sebagai perusahaan dengan kapitalisasi pasar yang besar, terbukti dengan rata-rata kapitalisasi pasar sekitar Rp 170 triliun dalam kurun waktu 2010 hingga 2014 (Unilever, 2016).

2.8 Sikap Investor Terhadap Risiko

Bagaimana seseorang bereaksi terhadap risiko menggambarkan preferensi risiko mereka (Rozak, 2009). Ada tiga tipe investor/ preferensi seseorang terhadap risiko, antara lain investor yang menyukai risiko (*risk seeker*), investor yang netral terhadap risiko (*risk neutral*) dan investor yang tidak menyukai adanya risiko (*risk averter*). Investor *Risk Seeker* apabila dihadapkan dua pilihan investasi yang memberikan tingkat keuntungan yang sama dengan risiko yang berbeda, maka investor ini secara ekstrem akan lebih senang mengambil investasi yang memiliki risiko lebih besar. Sementara itu, *risk averter* akan lebih senang memilih investasi yang memiliki risiko lebih kecil dengan tingkat keuntungan yang sama. *Risk neutral* akan meminta kenaikan tingkat keuntungan yang sama untuk setiap kenaikan risiko. Gambar 2.2 menyajikan kurva indiferen dari ketiga sikap investor. Kurva indiferen merupakan serangkaian kombinasi antara berbagai tingkat risiko dan keuntungan yang diharapkan (*expected return*) yang memberikan kepuasan yang sama terhadap investor.

Untuk *return* sebesar R_1 , *risk seeker* akan berani menanggung risiko sebesar σ_5 , lebih tinggi dibandingkan tingkat risiko yang ditanggung oleh *risk neutral* dengan tingkat risiko sebesar σ_3 dan *risk averse* sebesar σ_1 . Untuk mendapatkan *return* sebesar R_2 , *risk averse* akan menolaknya apabila tingkat risiko yang akan ditanggung lebih besar dari σ_2 , sedangkan *risk seeker* berani menanggung risiko yang lebih besar yaitu sebesar σ_6 .



Gambar 2.2 Kurva Indiferen Sikap Investor terhadap Risiko

2.9 Penelitian Sebelumnya

Penelitian sebelumnya mengenai *Value at Risk* pernah dilakukan oleh Laila (2010) yang menyatakan bahwa VaR dapat digunakan sebagai *early warning system*, dimana investor mempunyai pilihan untuk menggunakan model VaR tersebut sebagai rasio kecukupan modal. Nurharyanto (2011) melakukan pengukuran risiko pasar atas investasi saham baik individual maupun secara portofolio dengan metode VaR *variance covariance* dan *historical simulation*, didapatkan hasil bahwa metode *variance covariance* menghasilkan nilai risiko yang lebih besar dibandingkan dengan *historical simulation*. Sedangkan Wijayanti (2007) melakukan perbandingan analisis risiko investasi saham dengan metode VaR dengan pendekatan distribusi uni-modal dan *mixture*. Kesimpulan yang diperoleh yaitu pendekatan distribusi *mixture* dalam menghitung risiko investasi menghasilkan nilai VaR yang lebih kecil dibandingkan dengan pendekatan uni-modal.

Selanjutnya, penelitian tentang *Mixture Autoregressive* pernah dilakukan Rahman (2008) menerapkan metode Bayesian *Mixture Autoregressive* pada data indeks NASDAQ dan mendapatkan hasil bahwa model MAR mempunyai nilai MSE yang lebih kecil dibanding dengan model ARIMA. Maka disimpulkan bahwa model MAR lebih baik dari model ARIMA dalam memodelkan indeks NASDAQ. Valecky (2012) melakukan penelitian tentang pengukuran risiko dari beberapa portofolio di Pasar Eropa dengan menggunakan VaR *mixture normal* dan didapatkan hasil bahwa perkiraan risiko dengan VaR *mixture normal* menghasilkan nilai estimasi risiko yang tepat.

BAB III **METODOLOGI PENELITIAN**

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan untuk menunjukkan kinerja MNAR dalam menangkap pola *return* saham yang merupakan komposit dari beberapa model AR adalah data sekunder diperoleh dari publikasi resmi di laman www.finance.yahoo berupa data *return* saham yang dihitung dari *close price* saham harian mulai Januari 2010-29 Februari 2016. Variabel yang digunakan adalah *return* saham di 3 perusahaan yang tergabung di *Jakarta Islamic Index* (JII) yaitu PT Astra Internasional Tbk (ASII), PT Telekomunikasi Indonesia Tbk (TLMK) dan PT Unilever Indonesia Tbk (UNVR). Pemilihan saham pada ketiga perusahaan tersebut didasarkan atas beberapa hal diantaranya.

1. Memiliki kapitalisasi pasar terbesar, sehingga dapat mewakili perdagangan pasar harian, bahkan mampu menjadi *index mover* dalam pembentukan JII maupun IHSG (Indeks Harga Saham Gabungan) di Bursa Efek Indonesia
2. Merupakan saham-saham aktif dan likuid yang memenuhi kriteria JII selama 6 tahun terakhir
3. Merupakan salah satu *market leader* pada sektor industrinya, sehingga dapat dijadikan *benchmark*.

Struktur data dalam penelitian ini disajikan dalam Tabel 3.1.

Tabel 3.1 Struktur Data Penelitian

<i>t</i>	<i>Close price</i> saham ASII ($X_{t,1}$)	<i>Return</i> Saham ASII ($Z_{t,1}$)	<i>T</i>	<i>Close price</i> saham ASII ($X_{t,2}$)	<i>Return</i> Saham ASII ($Z_{t,2}$)	<i>Close price</i> saham ASII ($X_{t,3}$)	<i>Return</i> Saham ASII ($Z_{t,3}$)
1	$X_{1,1}$	-	1	$X_{1,1}$	-	$X_{1,1}$	-
2	$X_{2,1}$	$Z_{1,1}$	2	$X_{2,1}$	$Z_{1,1}$	$X_{2,1}$	$Z_{1,1}$
3	$X_{3,1}$	$Z_{2,1}$	3	$X_{3,1}$	$Z_{2,1}$	$X_{3,1}$	$Z_{2,1}$
4	$X_{4,1}$	$Z_{3,1}$	4	$X_{4,1}$	$Z_{3,1}$	$X_{4,1}$	$Z_{3,1}$
:	:	:	:	:	:	:	:
1589	$X_{1589,1}$	$Z_{1588,1}$	1575	$X_{1575,1}$	$Z_{1574,1}$	$X_{1575,1}$	$Z_{1574,1}$

3.2 Langkah Penelitian

Berdasarkan sumber data dan variabel penelitian yang telah dipaparkan, Langkah analisis yang dilakukan adalah sebagai berikut.

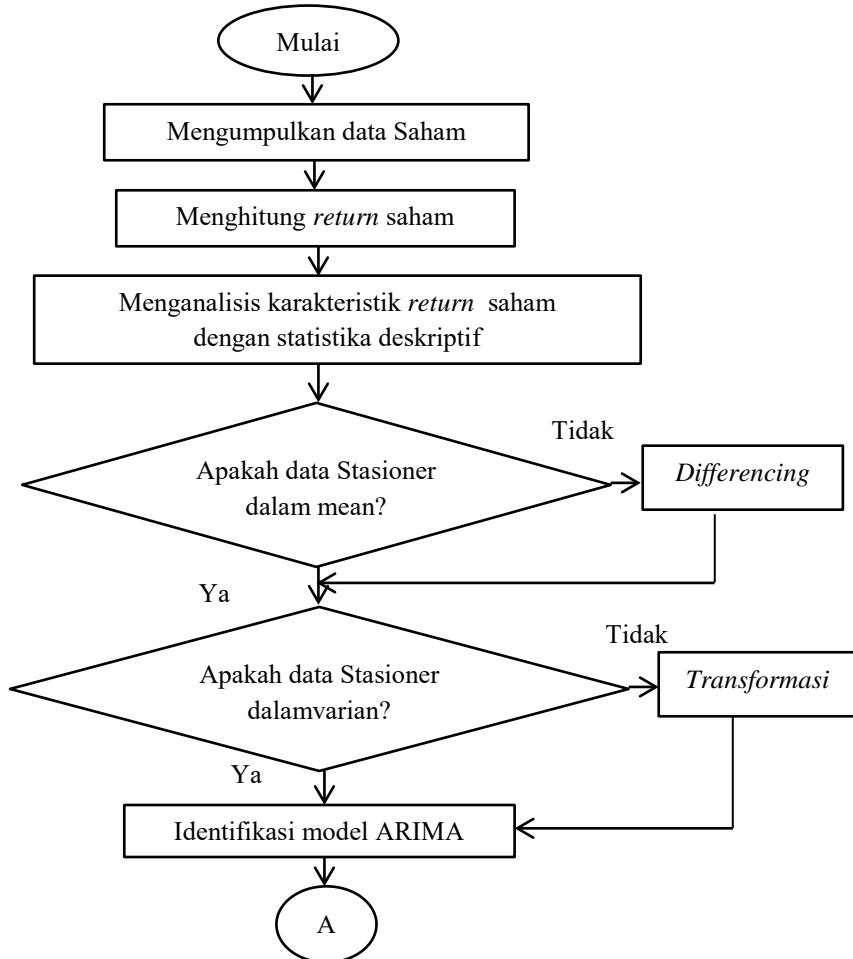
1. Mendeskripsikan karakteristik data *return* saham ASII, TLKM dan UNVR dengan langkah sebagai berikut.
 - a. Mendeskripsikan data *close price* saham ASII, TLKM dan UNVR
 - b. Mengitung nilai *return* untuk masing-masing saham menggunakan persamaan (2.1).
 - c. Menghitung nilai mean, varians, *skewness* dan kurtosis dari masing-masing *return* saham untuk mengetahui karakteristik data.
2. Memperoleh hasil ukuran risiko investasi saham ASII, TLKM dan UNVR. Adapun langkah analisis yang dapat dilakukan adalah sebagai berikut.
 - a. Mendapatkan model ARIMA dari masing-masing *return* saham dengan langkah-langkah sebagai berikut.
 - i. Identifikasi awal data dengan menggunakan *time series* plot, ACF dan PACF untuk melihat pola kestasioneran data. Dilakukan *differencing* apabila data tidak stasioner dalam *mean*.
 - ii. Mengidentifikasi model ARIMA melalui plot ACF dan PACF.
 - iii. Estimasi dan uji signifikansi parameter model ARIMA menggunakan pendekatan Bayesian.
 - iv. *Diagnostic Checking* yang terdiri dari pengujian apakah residual sudah *white noise* dengan persamaan (2.14) dan (2.15) serta pengujian distribusi normal dengan persamaan (2.16).

Jika ternyata asumsi ARIMA sudah memenuhi semua, maka analisis berhenti. Apabila ternyata asumsi ARIMA tidak memenuhi maka pemodelan lanjut ke model MNAR.

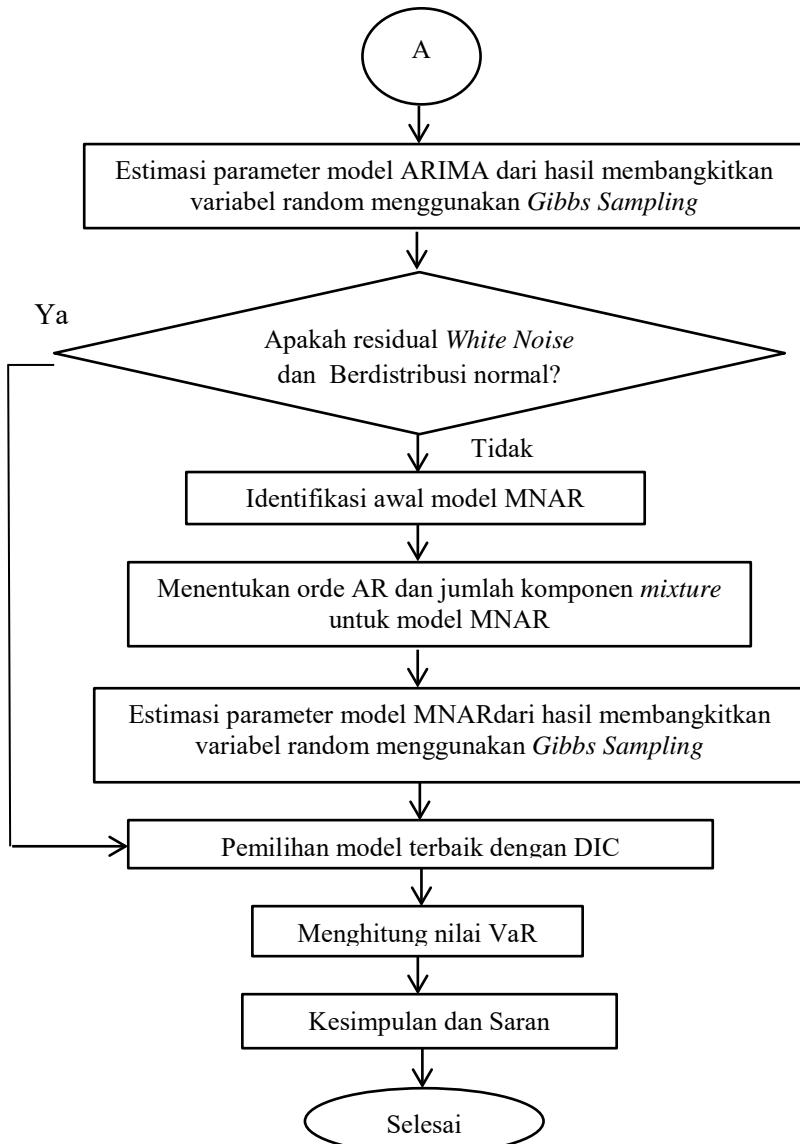
- b. Pembentukan model *Mixture Normal Autoregresive* (MNAR) dengan proses Bayesian dapat dilakukan dengan langkah berikut.
- i. Identifikasi *mixture* pada data yang stasioner dengan menggunakan histogram dan marginal *plot* serta melakukan uji distribusi.
 - ii. Menentukan orde AR dan jumlah komponen *mixture* untuk model MNAR.
 - iii. Estimasi dan uji signifikansi parameter model MNAR dengan pendekatan Bayesian.
Estimasi parameter model ARIMA dan MNAR dengan pendekatan analisis Bayesian dapat dilakukan dengan langkah sebagai berikut.
- (a) Membangun struktur ARIMA dan MNAR dengan Bayesian *full conditional distribution* secara iteratif dengan metode *Gibbs Sampling* untuk menaksir setiap parameter. Pembuatan struktur ARIMA dan MNAR dimulai dengan penentuan distribusi *prior conjugate* dan *non-informative* serta *likelihood* data.
 - (b) Menyusun implementasi model ARIMA dan MNAR pada *doodle* WinBUGS.
 - (c) Menerjemahkan struktur *doodle* WINBUGS kedalam program kode sekaligus menyusun input data sesuai strukturnya dan menyusun initial parameter model.
 - (d) Menggunakan alat bantu spesifikasi model dalam program WinBUGS untuk melakukan pengecekan terhadap *syntax* kode model, data *loading*, *compiling* model, menyusun inisial model dan menentukan jumlah iterasi MCMC untuk proses pembangkitan
 - (e) Menyusun atau mengatur parameter model yang akan diestimasi
 - (f) Melakukan *updating* data parameter dengan metode MCMC dalam program WinBUGS
- iv. Pemilihan model terbaik dengan menggunakan DIC

- v. Menghitung besar risiko investasi saham dengan menggunakan *Value at Risk* (VaR)
- vi. Menarik kesimpulan dan memberikan saran.

Dari langkah-langkah penelitian diatas, secara umum dapat digambarkan dengan alur seperti pada Gambar 3.1.



Gambar 3.1 Diagram Alir Penelitian



Gambar 3.1 (Lanjutan)

(Halaman ini sengaja dikosongkan)

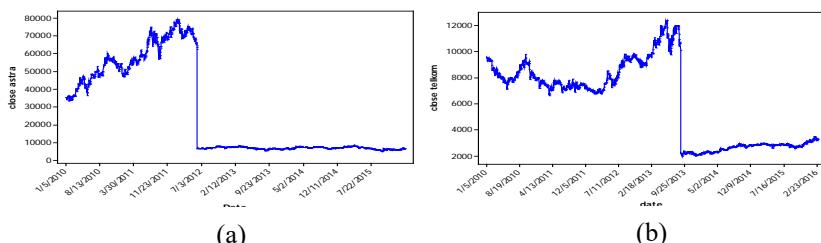
BAB IV

ANALISIS DAN PEMBAHASAN

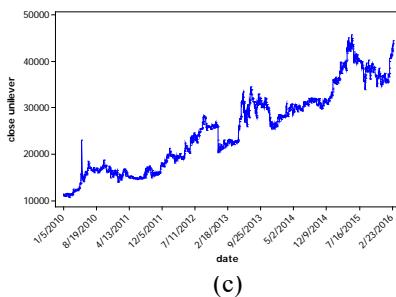
Pada bab ini akan dilakukan analisis dan pembahasan *Value at Risk (VaR)* dengan pendekatan *Mixture Normal Auto-regressive* (MNAR) pada data *return* saham tiga perusahaan yang tergabung dalam *Jakarta Islamic Index* (JII) dengan kapitalisasi pasar terbesar yaitu PT Astra International Tbk (ASII), PT Telekomunikasi Indonesia Tbk (TLKM) dan PT Unilever Indonesia Tbk (UNVR). Analisis diawali dengan deskripsi karakteristik data *close price* dan *return* pada masing-masing saham, kemudian dilakukan pemodelan ARIMA. Dari hasil identifikasi model ARIMA, orde model AR digunakan untuk melakukan pemodelan MNAR. Estimasi parameter model MNAR dilakukan dengan metode Bayesian *Markov Chain Monte Carlo* (MCMC). Setelah itu, dilakukan pemilihan model MNAR terbaik, dimana model MNAR terbaik digunakan untuk menghitung risiko menggunakan *Value at Risk (VaR)*.

4.1 Deskripsi Karakteristik *Return* Saham

Sebelum dilakukan analisis terhadap karakteristik *return* saham pada ketiga perusahaan tersebut, dapat dilakukan analisis deskriptif terhadap *close price* (harga penutupan) saham menggunakan *time series plot* yang disajikan pada Gambar 4.1. *Time series plot* yang disajikan ini digunakan untuk melihat pergerakan harga penutupan saham pada periode Januari 2010-Februari 2016.



Gambar 4.1 Time Series Plot Close Price Saham (a) ASII, (b) TLKM
dan (c) UNVR

**Gambar 4.1 (Lanjutan)**

Gambar 4.1(a) menunjukkan *close price* saham PT Astra International Tbk yang memiliki pola trend naik. Pada 4 Januari 2010 harga saham ASII Rp 35.300,- hingga mencapai harga tertinggi pada 27 Januari 2012 yaitu sebesar Rp 79.400,-. Hal tersebut dapat dikarenakan merek-merek mobil yang tergabung dalam group Astra mendominasi pasar dalam hal penjualan. Pada Juni 2012, ASII melakukan *stock split* atau pemecahan saham dengan rasio 1:10. Adanya *stock split* ini menjadikan harga saham ASII yang pada 4 Juni 2012 dikisaran Rp 62.400 menjadi Rp 6.600 per lembar saham pada 5 Juni 2012. Kondisi tersebut bertahan hingga saat ini, dengan harga saham tertinggi pada 14 April 2015 yaitu sebesar Rp 8.200,-.

Close price saham PT Telekomunikasi Tbk disajikan dalam Tabel 4.1(b). Terlihat bahwa harga saham TLKM memiliki pola trend naik. Selama periode Januari 2010-Agustus 2013, harga saham TLKM pernah mencapai harga tertinggi hingga sebesar Rp 12.400,- pada 29 Mei 2013. Sama seperti halnya PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk juga melakukan *stock split*, dengan rasio 1:5 pada Agustus 2013. Dihari pertama pelaksanaan, pada saat pembukaan harga saham TLKM mengalami kenaikan 6.17 persen dari harga pembukaan Rp 2.025 per lembar saham menjadi Rp 2.150. Di negara dengan penduduk lebih dari dua ratus dua puluh juta, pertumbuhan industri telekomunikasi jaringan akan mengalami perkembangan yang pesat, diiri-

ngi dengan perkembangan teknologi gadget yang pesat. Hal ini akan berimbas pada peningkatan kebutuhan jaringan komunikasi.

Split stock yang dilakukan oleh PT Astra International Tbk dan PT Telekomunikasi Indonesia Tbk karena harga saham yang mahal. Dengan *split stock* harga saham akan menjadi lebih rendah sehingga menarik para investor untuk membeli saham tersebut serta untuk menjaga agar saham tetap likuid.

Gambar 4.1(c) menunjukkan bahwa harga saham PT Unilever Indonesia Tbk juga mempunyai pola trend naik. Pada 4 Januari 2010 harga saham UNVR sebesar Rp 11.050,- dan terus bertambah hingga mencapai kisaran harga Rp 45.000,-. Harga saham tertinggi terjadi pada 26 Mei 2015 dengan nominal sebesar Rp 45.725,-. Industri barang konsumsi diproyeksikan akan terus mengalami pertumbuhan yang signifikan. Hal ini dikarenakan fungsi rumah tangga keluarga di Indonesia masih sebagai konsumen. Selain itu kondisi Indonesia yang mempunyai populasi pertumbuhan masyarakat yang tinggi juga ditambah dengan kondisi Indonesia yang notabennya merupakan negara berkembang, menjadikan sasaran para pelaku industri barang untuk mendapatkan laba dan menyerap modal.

Selanjutnya, untuk mengetahui karakteristik *return* saham dari masing-masing perusahaan, maka dilakukanlah analisis deskriptif melalui *mean*, standar deviasi, nilai maksimum dan minimum, serta kemencenggan (*skewness*) dan keruncingan (*kurtosis*) yang ditampilkan dalam Tabel 4.1.

Tabel 4.1 Karakteristik *Return* Saham

Karakteristik <i>Return</i>	ASII	TLKM	UNVR
Mean	0,000598	0,000451	0,001229
Standar Deviasi	0,021016	0,017509	0,02663
Minimum	-0,094457	-0,086093	-0,36788
Maksimum	0,112903	0,083333	0,550134
Skewness	0,23	-0,01	4,08
Kurtosis	2,57	1,83	138,65

Dari Tabel 4.1 dapat diketahui bahwa PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk dan PT Unilever Indonesia Tbk memiliki *mean return* yang positif. Hal ini berarti

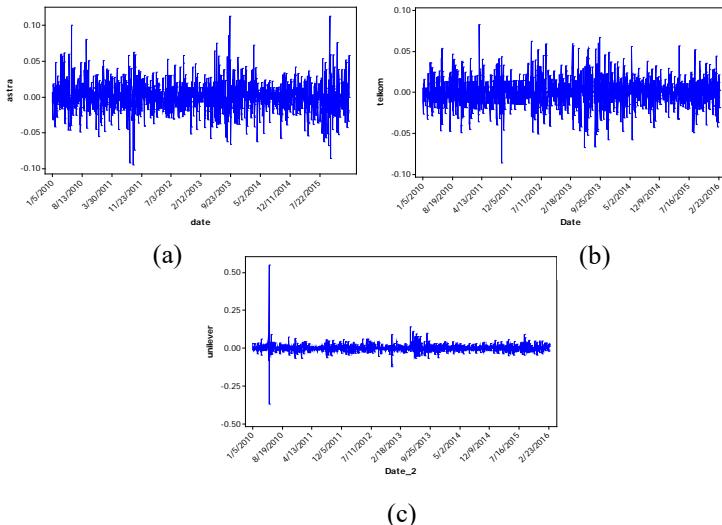
bahwa ketiga perusahaan tersebut relatif konstan memberikan keuntungan yaitu masing-masing 0,000598, 0,000451 dan 0,001229. Jika dilihat nilai minimum dan maksimum *return* masing-masing saham diperoleh selisih yang cukup besar, sehingga mengindikasi terjadi keragaman atau variabilitas *return* yang cukup besar pula. Hal ini dapat diketahui dari standar deviasi yaitu sebesar 0,021 untuk PT Astra Internasional Tbk, 0,0175 untuk PT Telekomunikasi Indonesia Tbk dan 0,0267 untuk PT Unilever Indonesia Tbk. Nilai kurtosis pada ketiga *return* saham menunjukkan nilai yang positif. Hal ini menunjukkan bahwa distribusi *return* lebih runcing dari distribusi normal atau biasa disebut dengan leptokurtik. Sedangkan untuk nilai *skewness* pada PT Telekomunikasi Indonesia Tbk mempunyai ekor yang lebih panjang ke kiri atau kemiringannya negatif dengan nilai sebesar -0,01. Untuk PT Astra International Tbk dan PT Unilever Indonesia Tbk memiliki nilai *skewness* sebesar 0,23 dan 4,08 yang berarti distribusi *return* mempunyai ekor yang panjang ke kanan atau kemiringannya positif.

4.2 Perhitungan Ukuran Risiko dengan *Value at Risk* (VaR)

Pemodelan MNAR dapat dilakukan dengan melalui pemodelan ARIMA terlebih dahulu. Dalam pemodelan ARIMA membutuhkan asumsi-asumsi yang perlu dipenuhi diantaranya residual *white noise* dan berdistribusi normal. Apabila salah satu asumsi tidak dapat terpenuhi, maka dapat dilanjutkan dalam pemodelan MNAR. Model MNAR yang diperoleh akan digunakan dalam perhitungan nilai VaR sebagai pengukuran risiko investasi.

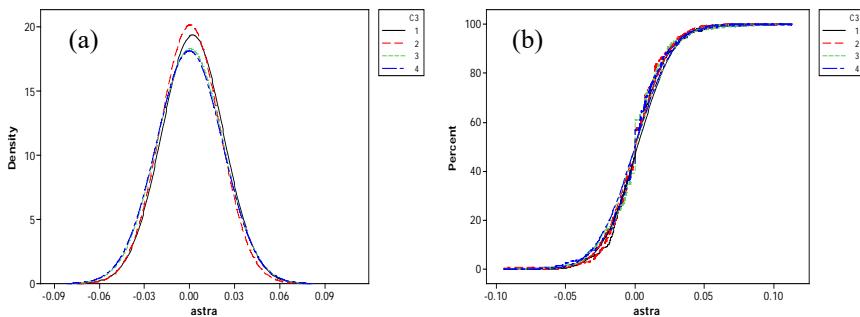
4.2.1 Model Autoregressive Integrated Moving Average (ARIMA)

Langkah pertama dalam pemodelan ARIMA yaitu melakukan identifikasi model. Identifikasi model ini diawali dengan melihat kestasioneran data *return* masing-masing saham dengan menggunakan *time series plot* yang ditunjukkan pada Gambar 4.2.

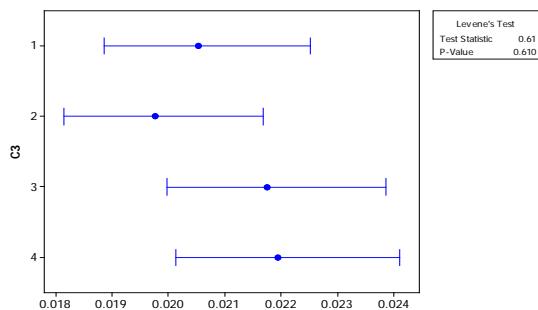


Gambar 4.2 Time Series Plot Return Saham (a)ASII, (b)TLKM dan (c)UNVR

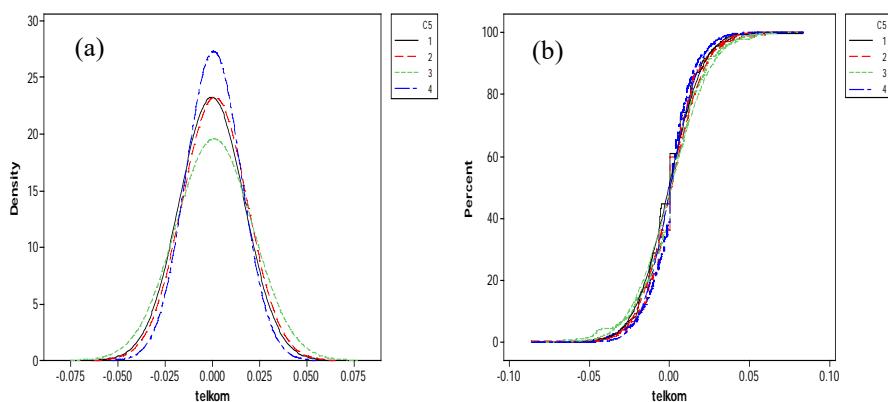
Gambar 4.2 memberikan informasi bahwa data *return* saham ASII, TLKM dan UNVR berfluktuasi disekitar *mean*. Dengan demikian, secara visual data *return* saham ASII, TLKM dan UNVR dapat dikatakan telah stasioner dalam *mean*. Setelah diketahui bahwa ketiga data *return* saham telah stasioner dalam *mean*. Selanjutnya melakukan uji stasioneritas dalam varian yang disajikan pada Gambar 4.3.

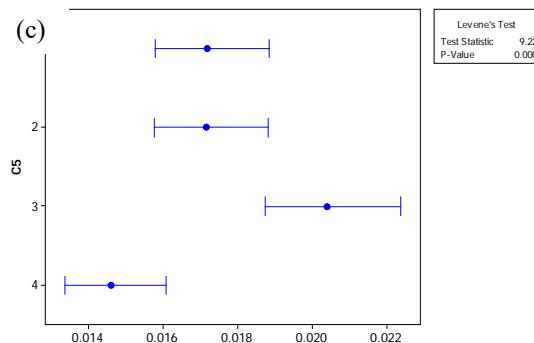


Gambar 4.3 (a) Hisogram (b) CDF Plot dan (c) *Test of Equal Varians* dari *Return* ASII

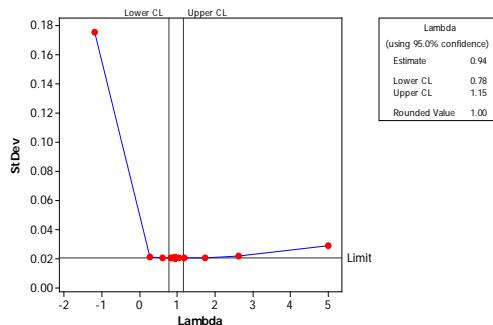
**Gambar 4.3 (Lanjutan)**

Gambar 4.3 memberikan informasi bahwa data *return* saham ASII telah stasioner dalam varian. Hal ini ditunjukkan oleh histogram dan CDF plot yang saling berhimpit antar kelompok. Begitu pula apabila dilihat dari uji kesamaan varian menggunakan pengujian Levene diperoleh *p-value* (0,319) yang lebih besar dari $\alpha=0,05$ yang berarti bahwa varian antar kelompok sama. Untuk stasioneritas varian dari *return* saham TLKM dapat dilihat pada Gambar 4.4.

**Gambar 4.4 (a) Hisogram (b) CDF Plot dan (c) *Test of Equal Varians* dari *Return* TLKM**

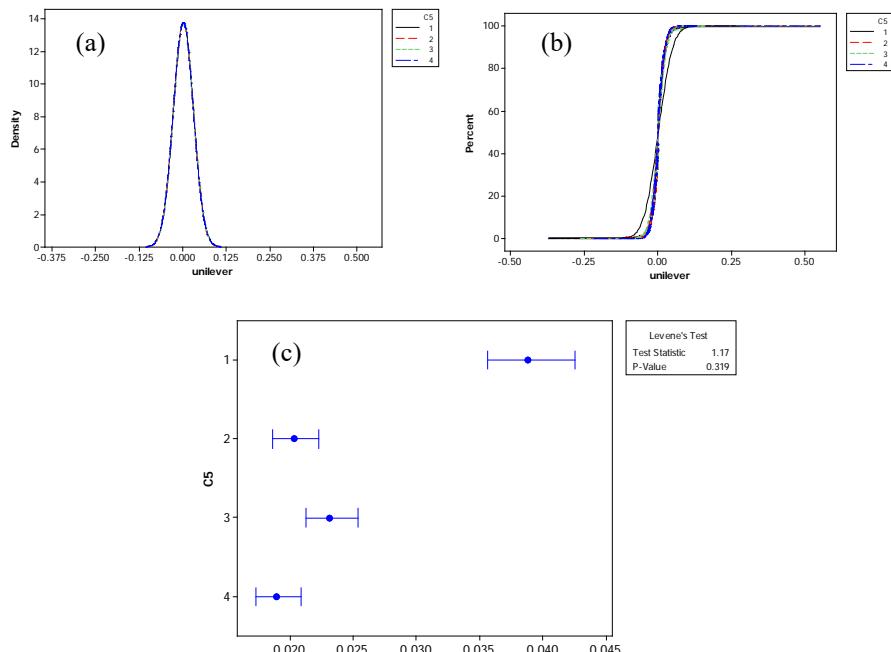
**Gambar 4.4 (Lanjutan)**

Berdasarkan Gambar 4.4 dapat dilihat bahwa *return* saham TLKM mempunyai varian yang berbeda antar kelompok. Hal ini dapat ditunjukkan oleh histogram dan CDF plot yang tidak saling berhimpit antar kelompok serta pengujian Levene yang diperoleh *p-value* kurang dari $\alpha=0.05$. Dengan demikian dapat dikatakan bahwa *return* saham TLKM telah belum stasioner dalam varian. Oleh karena itu perlu dilakukan proses transformasi data yang kemudian disajikan pada Gambar 4.5.

**Gambar 4.5** Transformasi Box-cox *Return* Saham TLKM

Setelah dilakukan proses transformasi, Gambar 4.5 menunjukkan bahwa *rounded value* bernilai 1 atau selang interval memuat nilai 1. Hal ini menunjukkan bahwa *return* saham TLKM

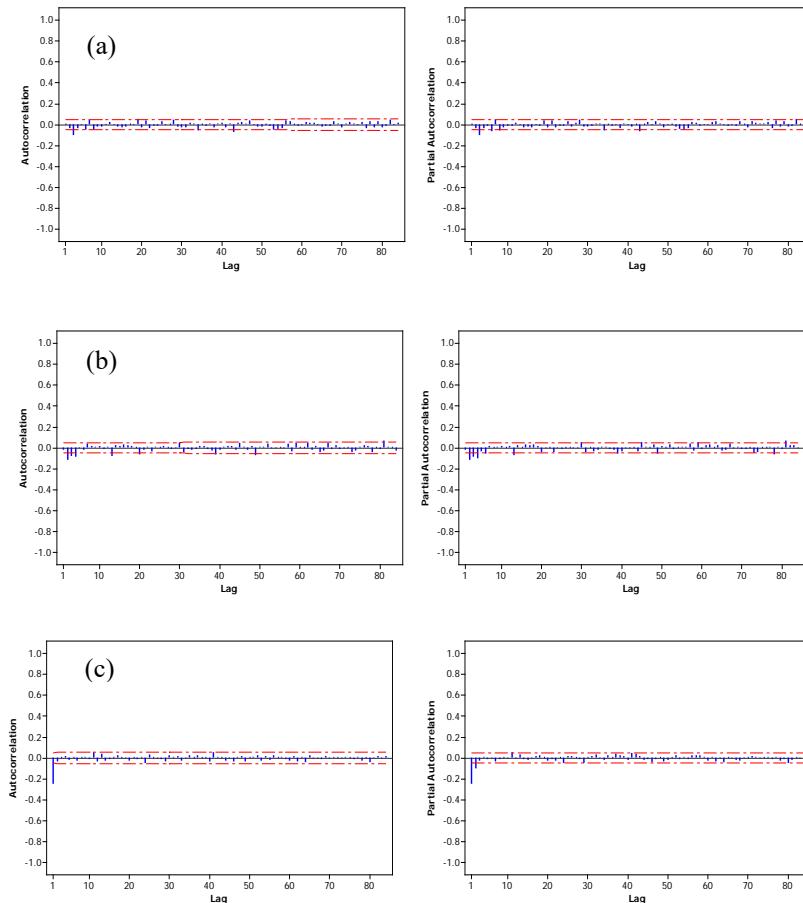
telah stasioner dalam varian. Berikunya dilakukan uji stasioner varian untuk *return* saham UNVR seperti yang ditampilkan pada Gambar 4.6.



Gambar 4.6 (a) Histogram, (b) CDF Plot dan (c) *Test of Equal Varians* dari *Return* UNVR

Gambar 4.6 menunjukkan bahwa *return* saham UNVR telah stasioner dalam varian. Hal ini dapat dilihat dari histogram dan CDF plot yang saling berhimpit antar kelompok serta pada pengujian Levene diperoleh *p-value* (0,319) lebih besar dari $\alpha=0,05$ yang berarti bahwa antar kelompok memiliki varian yang sama.

Setelah dilakukan pengujian stationer dalam mean dan varian, langkah berikutnya yaitu melakukan identifikasi model ARIMA dengan melihat *plot ACF* dan *PACF* yang ditampilkan dalam Gambar 4.7.



Gambar 4.7 Plot ACF dan PACF *Return* Saham (a) ASII, (b) TLKM dan (c) UNVR

Pada Gambar 4.7(a) menunjukkan bahwa plot ACF dari *return* saham PT Astrac International Tbk signifikan pada lag 3

dan lag 6, sehingga diperkirakan model mengandung model *Moving Average* (MA). Hal yang sama terjadi pada plot PACF yang signifikan pada lag 3 dan lag 6, sehingga diperkirakan model memuat model *Autoregressive* (AR), yang berarti *return* saham PT Astra International Tbk hari ini dipengaruhi oleh *return* saham 3 hari yang lalu dan 6 hari yang lalu. Dengan demikian dugaan model sementara yang terbentuk untuk *return* saham PT Astra International Tbk adalah model ARIMA([3],0,0), model ARIMA ([6],0,0), model ARIMA ([3,6],0,0) atau kombinasi dari lag-lag yang signifikan.

Identifikasi model untuk PT Telekomunikasi Indonesia Tbk pada Gambar 4.7(b) menunjukkan bahwa plot ACF dari *return* saham PT Telekomunikasi Indonesia Tbk signifikan pada lag 2, lag 3 dan lag 4, sehingga diduga model mengandung model *Moving Average* (MA). Untuk plot PACF terlihat bahwa PACF signifikan pada lag 2, lag 3 dan lag 4, maka diduga model memuat model *Autoregressive* (AR), yang artinya bahwa *return* saham TLKM hari ini dipengaruhi oleh *return* saham 2 hari, 3 hari dan 4 hari yang lalu. Dugaan model sementara yang terbentuk untuk *return* saham PT Telekomunikasi Indonesia Tbk adalah model ARIMA ([2],0,0), ARIMA([3],0,0), ARIMA ([4],0,0) atau kombinasi dari lag-lag yang signifikan.

Selanjutnya pada PT Unilever Indonesia Tbk didapatkan model sementara dari plot ACF dan PACF dalam Gambar 4.7(c), dimana pada plot ACF dari *return* saham PT Unilever Indonesia Tbk *cut off after* lag-1. Hal ini diduga bahwa model mengandung model *Moving Average* (MA) dengan orde 1 atau MA(1). Untuk plot PACF menunjukkan bahwa PACF signifikan pada lag 1, lag 2 dan lag 11, sehingga model sementara yang terbentuk dapat mengandung model *Autoregressive* (AR), yang berarti bahwa *return* saham UNVR hari ini dipengaruhi oleh *return* saham 1 hari, 2 hari dan 11 hari yang lalu. Pendugaan model sementara dari *return* saham PT Unilever Indonesia Tbk yaitu ARIMA (2,0,0), ARIMA ([11],0,0) atau kombinasi dari lag-lag yang signifikan.

Berdasarkan hasil identifikasi model dari masing-masing *return* saham, selanjutnya dilakukan estimasi parameter dan pengujian dari parameter model yang terbentuk. Tabel 4.2 menyajikan estimasi parameter model dan hasil pengujian signifikansi parameter model untuk PT Astra Internasional Tbk.

Tabel 4.2 Estimasi dan Pengujian Signifikansi Parameter Model pada *Return Saham ASII*

Model	Parameter	Estimasi	2,50%	97,50%
ARIMA ([3],0,0)	ϕ_3	-0,1029	-0,1513	-0,05323
ARIMA ([6],0,0)	ϕ_6	-0,04838	-0,09713	0,001568*
ARIMA ([3,6],0,0)	ϕ_3	-0,1086	-0,1573	-0,0593
	ϕ_6	-0,0593	-0,109	-0,00943

*tidak signifikan

Tabel 4.2 memberikan informasi bahwa parameter pada model ARIMA([3],0,0) dan ARIMA([3,6],0,0) memiliki *credible interval* 95 persen yang tidak memuat 0 (nol), sehingga parameter ϕ_3 dalam model ARIMA([3],0,0) serta ϕ_3 dan ϕ_6 dalam model ARIMA([3,6],0,0) berpengaruh signifikan terhadap *return* saham ASII. Sedangkan untuk model ARIMA ([6],0,0), diperoleh nilai koefisien parameter ϕ_6 sebesar -0,04838, dengan *credible interval* 95 persen memuat 0 (nol). Dengan demikian parameter ϕ_6 tidak berpengaruh signifikan terhadap *return* saham ASII. Dengan demikian model ARIMA([3],0,0) dan ARIMA([3,6],0,0) telah memenuhi untuk dilakukan analisis lebih lanjut.

Untuk estimasi parameter pada model *return* saham PT Telekomunikasi Indonesia Tbk disajikan dalam Tabel 4.3.

Tabel 4.3 Estimasi dan Pengujian Signifikansi Parameter Model pada *Return Saham TLKM*

Model	Parameter	Estimasi	2,50%	97,50%
ARIMA ([2],0,0)	ϕ_2	-0,1148	-0,1633	-0,06506
ARIMA ([3],0,0)	ϕ_3	-0,07855	-0,1273	-0,02863

Tabel 4.3 (Lanjutan)

Model	Parameter	Estimasi	2,50%	97,50%
ARIMA ([4],0,0)	ϕ_4	-0,08269	-0,1314	-0,03277
ARIMA ([2,3],0,0)	ϕ_2	-0,1162	-0,1648	-0,06677
	ϕ_3	-0,08063	-0,13	-0,03109
ARIMA ([2,4],0,0)	ϕ_2	-8,859	-457,4	370,3*
	ϕ_4	3,285	-653,3	711,7*
ARIMA ([3,4],0,0)	ϕ_3	-0,08042	-0,1292	-0,03082
	ϕ_4	-0,08417	-0,1337	-0,03445
ARIMA ([2,3,4],0,0)	ϕ_2	-0,1268	-0,1753	-0,07824
	ϕ_3	-0,08272	-0,132	-0,03369
	ϕ_4	-0,09868	-0,1481	-0,04862

*tidak signifikan

Dari Tabel 4.3 dapat diketahui bahwa untuk model ARIMA ([2,3,4],0,0), semua parameter model tidak memuat 0 (nol) pada *credible interval* 95 persen. Hal yang sama terjadi pada model ARIMA([2],0,0), ARIMA([3],0,0), ARIMA([4],0,0), ARIMA ([2,3],0,0) dan ([3,4],0,0) yang menunjukkan bahwa *credible interval* 95 persen tidak memuat 0 (nol). Sehingga dapat dikatakan bahwa semua parameter pada masing-masing model tersebut signifikan terhadap *return* saham TLKM. Sedangkan untuk kedua parameter model ARIMA([2,3],0,0) memuat 0 (nol) pada *credible interval* 95 persen, maka parameter model tidak berpengaruh signifikan terhadap *return* saham TLKM. Dengan demikian semua model kecuali model ARIMA([2,4],0,0) telah memenuhi untuk dilakukan analisis selanjutnya.

Hasil estimasi parameter dan pengujian signifikansi dari model *return* saham PT Unilever Indonesia Tbk ditampilkan dalam Tabel 4.4.

Tabel 4.4 Estimasi dan Pengujian Signifikansi Parameter Model pada *Return Saham UNVR*

Model	Parameter	Rata-rata	2,50%	97,50%
ARIMA (2,0,0)	ϕ_1	-0,2731	-0,3222	-0,2242
	ϕ_2	-0,09671	-0,1463	-0,04697

Tabel 4.4 (Lanjutan)

Model	Parameter	Estimasi	2,50%	97,50%
ARIMA ([11],0,0)	ϕ_{11}	0,05872	0,009852	0,1088
ARIMA ([1,2,11],0,0)	ϕ_1	-0,2725	-0,3216	-0,2235
	ϕ_2	-0,09673	-0,1464	-0,04725
	ϕ_{11}	0,05787	0,009862	0,1065

Pada Tabel 4.4 memberikan informasi bahwa model ARIMA(2,0,0), memiliki parameter ϕ_1 dan ϕ_2 yang signifikan terhadap *return* saham TLKM. Hal ini dapat dilihat dari *credible interval* 95 persen yang tidak memuat 0 (nol). Demikian juga dengan model ARIMA([11],0,0) dan ARIMA([1,2,11],0,0), dimana semua parameter modelnya memiliki *credible interval* 95 persen yang tidak memuat 0 (nol) atau dengan kata lain model berpengaruh signifikan terhadap saham TLKM. Sehingga dapat disimpulkan bahwa ketiga model ARIMA tersebut telah memenuhi untuk dilakukan analisis lebih lanjut.

Langkah selanjutnya setelah dilakukan estimasi dan pengujian signifikansi parameter yaitu cek dignosa (*diagnostic checking*). Dalam hal ini akan dilakukan pengecekan asumsi residual pada masing-masing model yang terdiri dari residual *white-noise* (residual independen dan identik) serta berdistribusi normal.

Untuk mengetahui apakah residual *return* saham PT Astra International Tbk telah *white-noise* dan berdistribusi normal dapat dilihat pada Tabel 4.5.

Tabel 4.5 Pengujian Asumsi Residual *Return* Saham ASII

Model	Residual <i>White-noise</i>		Residual Normal
	Independen	Identik	
ARIMA([3],0,0)	Memenuhi	Tidak memenuhi	Tidak memenuhi
ARIMA([3,6],0,0)	Memenuhi	Tidak memenuhi	Tidak memenuhi

Dari Tabel 4.5 dapat diketahui bahwa residual *return* saham ASII untuk model ARIMA([3],0,0) dan ARIMA([3,6],0,0) telah memenuhi asumsi *white-noise* yaitu residual yang saling independen. Hal ini terlihat dari hasil *run test* pada lampiran 6.a yang menunjukkan *p-value* lebih besar dari $\alpha(0,05)$. Maka dengan

kata lain bahwa residual model saling acak (*random*) atau saling independen. Untuk pengujian varian homogen (identik) pada lampiran 5.b, diperoleh nilai *p-value* kurang dari $\alpha(0,05)$, sehingga diputuskan tolak H_0 yang berarti residual model belum memenuhi asumsi identik atau terjadi kasus heteroskesdastisitas. Pada pengujian residual normal dapat diketahui melalui pengujian *Kolmogorov-Smirnov* pada Lampiran 5.c yang menunjukkan *p-value* lebih kecil dari $\alpha(0,05)$. Sehingga disimpulkan bahwa residual model ARIMA ([3],0,0) dan ARIMA([3,6],0,0) tidak memenuhi asumsi distribusi normal.

Untuk pengecekan asumsi residual pada model *return* saham PT Telekomunikasi Indonesia Tbk telah ditampilkan pada Tabel 4.6.

Tabel 4.6 Pengujian Asumsi Residual *Return* Saham TLKM

Model	Residual White-noise		Residual Normal
	Independen	Identik	
ARIMA([2],0,0)	Memenuhi	Tidak memenuhi	Tidak memenuhi
ARIMA([3],0,0)	Tidak memenuhi	Tidak memenuhi	Tidak memenuhi
ARIMA([4],0,0)	Tidak memenuhi	Tidak memenuhi	Tidak memenuhi
ARIMA([2,3],0,0)	Memenuhi	Tidak memenuhi	Tidak memenuhi
ARIMA([3,4],0,0)	Memenuhi	Tidak memenuhi	Tidak memenuhi
ARIMA([2,3,4],0,0)	Memenuhi	Tidak memenuhi	Tidak memenuhi

Tabel 4.6 menunjukkan bahwa dari keenam model yang terbentuk, terdapat satu model yang tidak memenuhi asumsi independen, yaitu pada model ARIMA([2,3],0,0). Hal ini dikarenakan hasil *run test* pada Lampiran 5.a menunjukkan *p-value* yang lebih kecil dari $\alpha=0,05$, sehingga residual model *return* saham TLKM tidak menyebar secara *random* atau saling dependen. Untuk asumsi identik yang dilakukan dengan pengujian *Lagrange Multiplier*, diperoleh *p-value* kurang dari $\alpha(0,05)$ untuk semua dugaan model *return* saham TLKM yang terbentuk. Oleh karena itu, disimpulkan bahwa residual model *return* saham TLKM tidak memenuhi asumsi identik. Hal yang sama terjadi pada asumsi residual normal yang ditunjukkan melalui pengujian *Kolmogorov-*

smirnov yang menghasilkan *p-value* lebih kecil dari $\alpha(0,05)$ untuk semua model. Hal ini berarti bahwa residual model tidak mengikuti distribusi normal.

Untuk pengecekan asumsi identik dan independen atau *white-noise* dan pengujian normal pada residual model *return* PT Unilever Indonesia Tbk dapat dilihat pada Tabel 4.7.

Tabel 4.7 Pengujian Asumsi Residual *Return* Saham UNVR

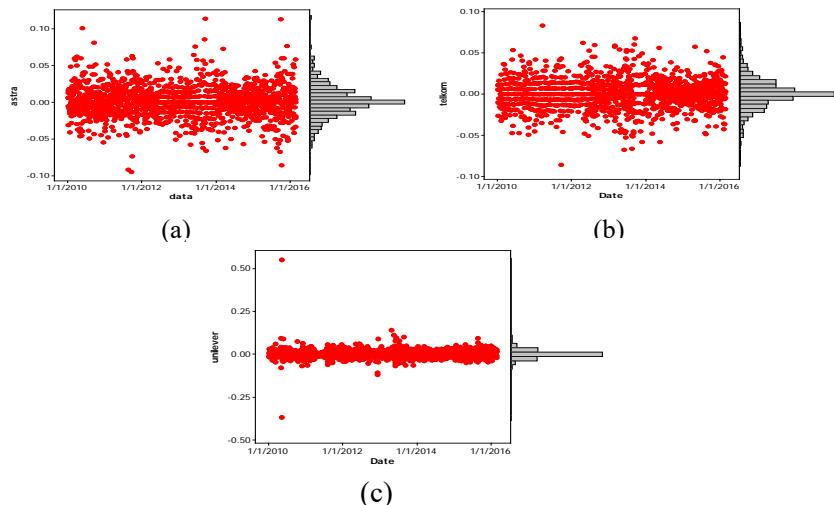
Model	<i>Residual White-noise</i>		Residual Normal
	Independen	Identik	
ARIMA (2,0,0)	Tidak memenuhi	memenuhi	Tidak memenuhi
ARIMA ([11],0,0)	Tidak memenuhi	memenuhi	Tidak memenuhi
ARIMA ([1,2,11],0,0)	Tidak Memenuhi	Tidak memenuhi	Tidak memenuhi

Tabel 4.7 memberikan informasi bahwa residual *return* saham UNVR pada ketiga model yang terbentuk tidak memenuhi asumsi *white-noise* independen maupun identik. Hal ini dikarenakan pada pengujian *run test* diperoleh *p-value* lebih kecil dari $\alpha(0,05)$, yang berarti residual model tidak menyebar *random* atau saling dependen. Begitu pula pada pengujian varian identik, diperoleh *p-value* lebih kecil dari $\alpha=0,05$ yang berarti telah terjadi kasus heteroskesdastisitas, dimana varian residual tidak homogen. Untuk uji kenormalan residual yang dilakukan dengan pengujian *Kolmogorov-Smirnov*, didapatkan hasil bahwa *p-value* lebih kecil dari $\alpha(0,05)$, sehingga residual model *return* saham UNVR tidak memenuhi asumsi distribusi normal. Dengan demikian pemodelan ARIMA pada *return* saham UNVR tidak memenuhi asumsi residual *white noise* dan berdistribusi normal.

Berdasarkan uraian sebelumnya, diketahui bahwa dengan memodelkan *return* saham PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk dan PT Unilever Indonesia Tbk menggunakan metode ARIMA, diperoleh hasil untuk semua model tidak memenuhi asumsi varian residual identik dan normal.

4.2.2 Identifikasi Mixture

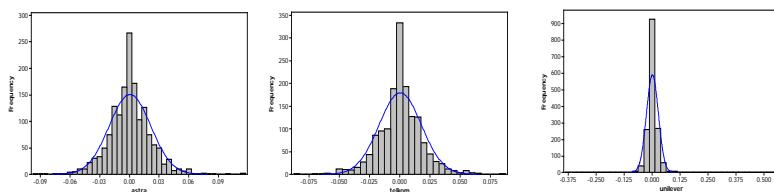
Hasil pemodelan *return* saham PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk dan PT Unilever Indonesia Tbk menggunakan model ARIMA diperoleh parameter model yang signifikan terhadap *return* saham, namun residual model dari ketiga saham tersebut tidak memenuhi asumsi identik (varian residual tidak homogen) atau masih mengandung unsur heteroskedastisitas. Hal tersebut mengindikasikan bahwa model yang diperoleh belum sesuai untuk merepresentasikan data *return* saham ASII, TLKM dan UNVR. Oleh karena itu perlu dilakukan analisis lebih lanjut untuk mendapatkan model yang lebih bisa menerangkan atau mengakomodir data karena adanya kasus heteroskedastisitas yang disebabkan adanya data *outlier*, sehingga mengakibatkan distribusi pada data menjadi tidak normal. Marginal plot pada Gambar 4.8 menggambarkan fluktuasi dari *return* masing-masing saham.



Gambar 4.8 Marginal Plot dari *Return* Saham (a)ASII, (b)TLKM dan (c)UNVR

Gambar 4.8 memperlihatkan bahwa data *return* saham PT Astra International Tbk, PT Telekomunikasi Indonesia Tbk dan

PT Unilever Indonesia Tbk membawa sifat kemiringan dan kurtosis yang mengindikasi adanya ketidaknormalan pada data *return* saham. Selain itu ditunjukkan bahwa variabilitas *return* cukup tinggi, sehingga menyebabkan *return* saham memiliki ekor yang ekstrim pada ujung kiri maupun kanan. Apabila *return* dipaksa menggunakan pola univariat normal unimodal terlihat adanya penyimpangan seperti yang ditunjukkan pada Gambar 4.9.



Gambar 4.9 Data *Return* Saham (a) ASII, (b) TLKM dan (c) UNVR dengan Pola Normal Univariat

Penyimpangan atau ketidaksesuaian yang terjadi ini disebabkan karena adanya data *return* yang cukup ekstrem atau *outlier*, sehingga mengakibatkan kemiringannya bernilai lebih besar dari nol. Banyaknya *return* yang bernilai disekitar nol membuat pola *return* mempunyai puncak yang tinggi yang biasa disebut dengan leptokurtik. Akibatnya dugaan bahwa pada pola *return* saham ASII, TLKM dan UNVR mempunyai bentuk distribusi *mixture* atau distribusi campuran cukup jelas. Hal ini didukung oleh hasil pengujian kesesuaian distribusi (*goodness of fit*) yang telah dilakukan pada *software* Minitab seperti pada Lampiran 6. Hasil pengujian distribusi tersebut menunjukkan *p-value* yang lebih kecil dari 0,05, yang berarti bahwa tidak ada satupun distribusi unimodal yang mampu merepresentasikan data *return* saham ASII, TKMK dan UNVR. Hal inilah yang mendasari digunakannya pemodelan *Mixture Normal Autoregressive* (MNAR). MNAR dapat memodelkan sifat-sifat seperti adanya nilai ekstrim dan leptokurtik dengan melakukan penumpukan beberapa pola distribusi normal dengan masing-masing nilai parameter μ dan σ^2 .

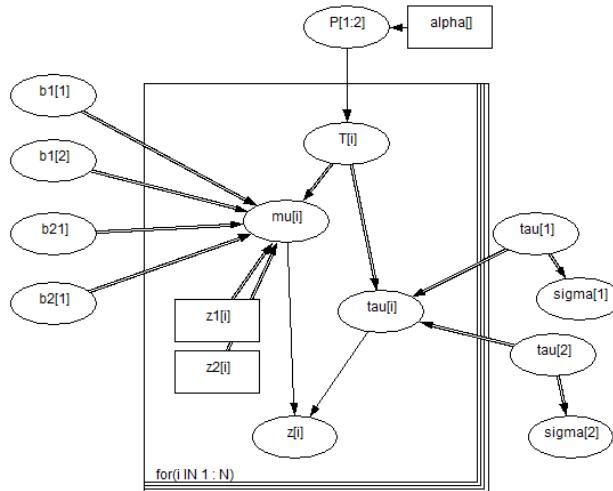
4.2.3 Pemodelan *Mixture Normal Autoregressive* (MNAR)

Pada penelitian tugas akhir ini akan diimplementasikan komponen *mixture* yang telah ditentukan yaitu sebanyak 2 dan 3 komponen. Penentuan komponen *mixture* ini didasarkan pada banyaknya lag yang signifikan saat identifikasi model ARIMA. Komponen *mixture* sebanyak 2 komponen diharapkan mampu menangkap pola data *return* yang membawa sifat leptokurtik pada komponen pertama dan menangkap pola data *return* yang mempunyai nilai ekstrim pada komponen kedua. Sedangkan komponen *mixture* sebanyak 3 komponen diharapkan mampu mengakomodir / menangkap data *return* yang mempunyai nilai ekstrim, sehingga digunakan distribusi normal dengan varian yang besar pada komponen pertama. Komponen kedua untuk menangkap pola data *return* dengan sifat kurtosis yang tinggi atau biasa disebut leptokurtik, sehingga digunakan komponen normal yang mempunyai varian cukup kecil. Untuk komponen ketiga digunakan komponen normal dengan varian yang berada diantara keduanya, sehingga dapat menangkap pola data *return* dengan sifat mesokurtik.

a. PT Astra Internationl Tbk

Pemodelan ARIMA *return* saham ASII menunjukkan hasil yang kurang baik karena asumsi yang dibutuhkan dalam pemodelan ARIMA tidak terpenuhi, sehingga dilakukan pemodelan dengan menggabungkan sejumlah model AR(p) atau yang sering disebut dengan model MNAR. Hasil identifikasi model ARIMA pada *return* saham ASII yang ditunjukkan oleh plot PACF, terdapat dua lag yang keluar dari batas signifikansi yaitu pada lag 3 dan lag 6. Sehingga pemodelan MNAR akan dilakukan menggunakan 2 dan 3 komponen AR(p) yang berbeda untuk setiap komponen. Untuk model MNAR 2 komponen dapat ditulis menjadi MNAR(2;[3],[3,6]). Pembentukan model MNAR dimplementasikan menggunakan *software* WinBUGS, dimana estimasi parameter model dilakukan dengan metode *gibbs sampling*. Dalam estimasi parameter model MNAR dimulai dengan membentuk struktur parameter model yang dapat disajikan menggunakan

Directed Acyclic Graph (DAG). DAG memberikan gambaran mengenai hubungan antara distribusi prior, data yang digunakan dan parameter model yang dinyatakan dengan suatu *node*. Untuk model MNAR(2;[3],[3,6]) dapat disusun struktur modelnya menggunakan DAG seperti yang ditampilkan pada Gambar 4.10.



Gambar 4.10 Doodle untuk model MNAR (2;[3],[3,6])

Pada Gambar 4.10 ditunjukkan bahwa setiap bulatan yang berbentuk ellips dinamakan *node*. Terdapat *node* yang memiliki indeks i , yaitu $z[i]$, $\mu[i]$, $\tauau[i]$ dan $T[i]$ dengan $i=1, 2, \dots, N$. $z[i]$ merupakan data *return* saham ASII yang berdistribusi normal dengan parameter $\mu[i]$ dan $\tauau[i]$, dimana $\mu[i]$ merupakan *node logical* yang dipengaruhi oleh *node* yang ditandai dengan anak panah yang masuk kedalamnya, yaitu b_1 , b_2 , $z_1[i]$, $z_2[i]$ dan $T[i]$. *node* $\mu[i]$ mengikuti perintah berikutnya yang diterjemahkan sesuai dengan *logical* dalam *doodle* pada Gambar 4.10. $\mu[i]$ diidentifikasi oleh nilai $T[i]$ yang berubah sesuai dengan distribusi *dirichlet*, $P[1:2]$, yang diatur agar mempunyai domain nilai 1 dan 2 saja. $\mu[i]$ merupakan persamaan model AR(p) yang dibentuk menjadi persamaan $\mu[i] = b_1[T[i]] * z_1[i] + b_2[T[i]] * z_2[i]$, dengan

$z_1[i]$ merupakan gabungan lag 3 dari $z[i]$ yang merepresentasikan model AR[3] pada komponen pertama dan kedua. Sementara itu, $z_2[i]$ merupakan gabungan nilai 0 (nol) pada komponen pertama dan lag 6 dari $z[i]$ yang merepresentasikan model AR[6] pada komponen kedua.

Sama seperti halnya *node mu[i]*, *node tau [i]* juga diidentifikasi oleh nilai $T[i]$ yang berubah sesuai dengan distribusi *dirichlet*, $P[1:2]$, yang diatur agar mempunyai domain nilai 1 dan 2 saja. Sehingga *node tau* yang terbentuk sebanyak 2. *Node tau* mengikuti distribusi gamma, dimana *node tau* ini berpengaruh dalam mengestimasi nilai standar deviasi dari masing-masing komponen yang direpresentasikan melalui *node sigma*. *Node sigma* akan mengikuti perintah berikutnya, sesuai dengan yang telah diterjemahkan dalam *doodle* yaitu $1/\sqrt{\tau[j]}$, dimana $j=1,2$.

Sesuai dengan prinsip Bayesian, semua *node* yang ada diluar kotak merepresentasikan distribusi prior dari masing-masing parameter. *Prior* untuk parameter $b_1[j]$ (mewakili AR[3] pada komponen pertama dan kedua) dan $b_2[j]$ (mewakili AR[6] pada komponen kedua) yang digunakan dalam proses pembangkitan menggunakan distribusi normal dengan *mean* 0 dan presisi 1×10^{-6} .

Nilai estimasi parameter dalam model MNAR diperoleh dari distribusi *posterior*, dimana proses pengambilan sampel parameter dilakukan menggunakan metode MCMC dengan *Gibbs Sampling*. Dalam penelitian ini proses MCMC dilakukan sebanyak 10.000 iterasi dengan proses *burn-in* sebanyak 99 iterasi, sehingga total sampel yang digunakan untuk mengestimasi parameter model sebanyak 9901 sampel. Setelah proses pengambilan sampel dilakukan, maka dilakukan diagnosa untuk mengetahui kesesuaian nilai parameter dengan sifat rantai *markov* yang *ergodic* dan konvergen. Untuk memperkirakan apakah sifat rantai markov yang ergodic dan konvergen sudah tercapai atau belum dapat dilihat melalui *history plot* yang disajikan dalam Lampiran 7. *History plot* merupakan plot antara banyaknya iterasi yang dijalankan dengan sampel yang dibangkitkan. Gambar pada Lam-

piran 7.b menunjukkan bahwa *history plot* memiliki pola linier yang bersifat stasioner dan random. Hal ini menunjukkan bahwa seluruh sampel berada pada suatu interval domain yang memiliki nilai tertentu dan tetap. Hal tersebut mengindikasi bahwa sampel yang digunakan memenuhi sifat *irreducible*, yaitu selama iterasi estimasi parameter, proses mempunyai pergerakan nilai yang acak (*random*) sebagai representasi dari *communicate* antar *state* dalam rantai markov. Selain itu *history plot* juga cenderung rapat dan *fastly mixing* sehingga mampu merespon semua kemungkinan nilai parameter. Gambar pada Lampiran 7.b juga membuktikan bahwa hasil estimasi parameter juga memenuhi sifat *aperiodic* karena selama iterasi estimasi parameter, proses MCMC tidak menunjukkan adanya pola tertentu, dimana nilai-nilai yang dibangkitkan sudah berada dalam daerah tanpa keperiodikan yang kuat. Selain itu, rantai markov juga memenuhi sifat yang *recurrent* karena pola random yang dihasilkan selama proses iterasi MCMC, nilai parameter yang dibangkitkan (*state i*) ada kemungkinan untuk kembali pada *state i*. Karena pada *history plot* telah menunjukkan sifat-sifat rantai markov yang *irreducible*, *aperiodic* dan *recurrent*, maka dapat dikatakan bahwa rantai markov telah memenuhi sifat rantai markov yang *ergodic*. Selanjutnya untuk mengidentifikasi kuat lemahnya korelasi yang terjadi diantara nilai-nilai sampel yang dibangkitkan dapat dilihat melalui *autocorrelation plot* pada Lampiran 7.c. *Autocorrelation plot* memperlihatkan bahwa nilai autokorelasi pada lag nol mendekati satu, sedangkan untuk lag-lag selanjutnya mendekati nol. Hal ini menunjukkan bahwa korelasi diantara nilai-nilai sampel yang dibangkitkan telah berada di daerah distribusi *posterior*. Hal ini didukung oleh *kernel density* yang menunjukkan estimasi *density posterior* untuk parameter model memberikan hasil plot yang bagus karena bentuk dari densitasnya cenderung halus dan pola distribusi dari masing-masing parameter model cenderung memiliki pusat di tengah (*bell shape*). Dengan demikian hasil estimasi parameter telah memenuhi sifat rantai markov yang *ergodic* dan konvergen. Hal ini telah membuktikan bahwa sampel yang dibangkitkan dari proses

MCMC tersebut merupakan sampel yang berasal dari distribusi *posterior* target parameter.

Berikutnya dilakukan pengujian berdasarkan hasil estimasi untuk masing-masing parameter dalam model MNAR. Hipotesis yang digunakan untuk parameter ϕ adalah sebagai berikut.

$H_0 : \phi_i = 0$ yang artinya parameter model *Autoregressive* tidak signifikan untuk digunakan, dengan $i=3$ dan 6

$H_1 : \phi_i \neq 0$ yang artinya parameter model *Autoregressive* signifikan untuk digunakan $i=3$ dan 6

Sedangkan hipotesis yang digunakan untuk parameter σ pada masing-masing komponen *mixture* adalah:

$H_0 : \sigma_j = 0$ yang artinya parameter σ pada komponen *mixture* ke- j tidak signifikan untuk digunakan, dengan $j=1$ dan 2

$H_1 : \sigma_j \neq 0$ yang artinya parameter σ pada komponen *mixture* ke- j signifikan untuk digunakan, dengan $j=1$ dan 2

Hipotesis untuk parameter P adalah sebagai berikut.

$H_0 : P_j = 0$ yang artinya parameter P pada komponen *mixture* ke- j tidak signifikan untuk digunakan, dengan $j=1$ dan 2

$H_1 : P_j \neq 0$ yang artinya parameter P pada komponen *mixture* ke- j signifikan untuk digunakan, dengan $j=1$ dan 2

Penolakan H_0 didasarkan pada selang interval 95 persen dari distribusi *posterior* hasil estimasi, yaitu dengan melihat *credible interval*. Jika *credible interval* dari distribusi *posterior* tidak memuat 0 (nol) maka H_0 ditolak, yang berarti bahwa parameter model signifikan untuk digunakan. Hasil estimasi parameter model MNAR(2;[3],[3,6]) ditampilkan dalam Tabel 4.8.

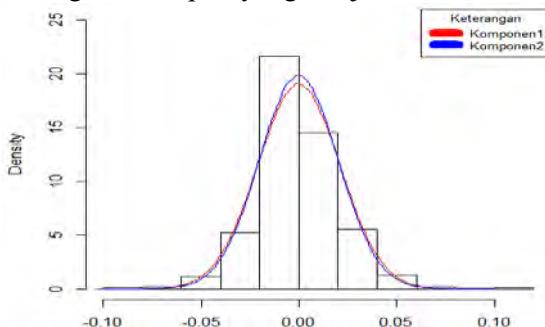
Tabel 4.8 Estimasi Parameter Model MNAR(2;[3],[3,6])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,5009	0,008886	0,4832	0,5181
P[2]	0,4991	0,008886	0,4819	0,5168
b1[1]	-0,103	0,02512	-0,1518	-0,05456
b1[2]	-0,1054	0,02524	-0,1547	-0,05562
b2[2]	-0,06002	0,02504	-0,1097	-0,01056
sigma[1]	0,02097	$3,75 \times 10^{-4}$	0,02025	0,02172
sigma[2]	0,02092	$3,72 \times 10^{-4}$	0,02019	0,02166

Berdasarkan Tabel 4.8 diperoleh informasi bahwa $b_1[1]$ yang merepresentasikan parameter ϕ_3 pada model AR[3], $b_1[2]$ dan $b_2[2]$ yang merepresentasikan parameter ϕ_3 dan ϕ_6 pada model AR[3,6] berpengaruh signifikan karena *credible interval* 95 persen tidak memuat 0 (nol). Hal ini berarti bahwa *return* saham ASII hanya dipengaruhi oleh *return* saham 3 hari dan 6 hari yang lalu. Tabel 4.8 juga menunjukkan hasil estimasi untuk parameter σ dan P pada masing-masing komponen *mixture*. Terlihat bahwa *sigma* [1] atau σ_1 yang merepresentasikan nilai standar deviasi pada komponen pertama dan *sigma*[2] atau σ_2 yang merepresentasikan nilai standar deviasi pada komponen *mixture* kedua tidak memuat 0 (nol) pada *credible interval* 95 persen, sehingga dapat dikatakan bahwa parameter σ pada komponen ke- j signifikan untuk digunakan. Hal yang sama terjadi pada parameter P yang merupakan proporsi untuk masing-masing komponen *mixture*. *Credible interval* 95 persen untuk parameter P tidak memuat 0 (nol), sehingga parameter P pada komponen ke- j signifikan untuk digunakan, dengan $j=1,2$. Berdasarkan hasil pengujian estimasi parameter, maka model MNAR(2,[3],[3,6]) yang terbentuk dapat digunakan untuk analisis selanjutnya. Sesuai dengan persamaan (2.22), model MNAR (2,[3],[3,6]) adalah sebagai berikut:

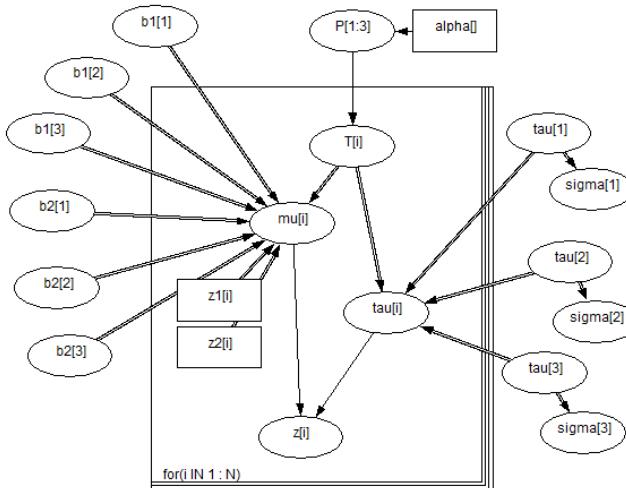
$$(Z_t | \mathcal{F}_{t-1}) \Phi 0,5009 \left(\frac{Z_t + 0,103Z_{t-3}}{0,02097} \right) + 4991 \Phi \left(\frac{Z_t + 0,1054Z_{t-3} + 0,06002Z_{t-6}}{0,02092} \right).$$

Sehingga menghasilkan plot yang disajikan di Gambar 4.11.



Gambar 4.11 Distribusi Plot *Return* ASII 2 Komponen

Untuk pemodelan *return* saham PT Astra International Tbk yang terdiri dari 3 komponen *mixture* dengan menggabungkan model AR[3] dan AR [3,6], sehingga model dapat ditulis menjadi MNAR(3;[3],[3,6],0). Sama seperti halnya menggunakan 2 komponen *mixture*, dalam pemodelan 3 komponen *mixture* ini, pengestimasi parameter model MNAR diawali dengan penyusunan struktur *doodle* pada *software* WinBUGS yang ditampilkan pada Gambar 4.12.



Gambar 4.12 *Doodle* untuk model MNAR (3;[3],[3,6],0)

Strukur *doodle* dalam WinBUGS disusun oleh *node* dan garis-garis penghubung *node* yang menyatakan keterkaitan antar *node*. Pada Gambar 4.11 terdapat *node* z_i yang menyatakan gabungan dari 3 komponen *mixture* pada data *return* saham ASII. *Node* $z_1[i]$ dan $z_2[i]$ berbentuk kotak, artinya nilai $z_1[i]$ dan $z_2[i]$ bersifat konstan. *Node* z_i diatur sebagai *node* yang bersifat stokastik dengan parameter distribusi $\mu[i]$ dan $\tauau[i]$, $i=1,2,\dots,N$ yang bersifat *logical*. $\mu[i]$ dan $\tauau[i]$ diidentifikasi oleh nilai $T[i]$ yang berubah sesuai dengan distribusi *dirichlet*, $P[1:3]$, yang diatur agar mempunyai domain nilai 1 hingga 3. *Hyperparameter* terdalam adalah *node* $T[i]$, terdiri dari 2 level, dengan $P[1:3]$ di

level pertama dan *alpha*[] di level kedua. *Node P* merepresentasikan proporsi untuk masing-masing komponen *mixture*. *mu[i]* dihubungkan oleh *z₁[i]*, *z₂[i]* serta *node b₁* dan *b₂* sebagai parameter model *autoregressive* yang berdistribusi normal dengan *mean* 0 dan presisi 1×10^{-6} . Pada *node mu[i]* akan dibentuk persamaan $\mu[i] = b_1[T[i]] * z_1[i] + b_2[T[i]] * z_2[i]$, sedangkan *node tau[i]* berisi *logical tau[T[i]]*. *Prior* dari *node tau* ini adalah distribusi Gamma. *Node tau* ini kemudian dihubungkan dengan *node sigma*, dimana *node sigma* mengikuti *node logical*, yaitu $1/\sqrt{\tau[j]}$, dengan $j=1,2$ dan 3. *node sigma* merepresentasikan nilai standar deviasi dari masing-masing komponen *mixture*.

Metode MCMC dengan *Gibbs Sampling* digunakan dalam proses pengambilan sampel untuk mengestimasi parameter model MNAR yang diperoleh dari distribusi *posterior*. Dalam penelitian ini proses MCMC dilakukan sebanyak 10.000 i terasi dengan proses *burn-in* sebanyak 99 iterasi, sehingga total sampel yang digunakan untuk mengestimasi parameter model sebanyak 9901 sampel. Selanjutnya untuk mengetahui kesesuaian nilai parameter dengan sifat-sifat rantai markov yang *ergodic* dan konvergen dapat dilihat pada Lampiran 8. Pada *history plot* menunjukkan bahwa proses *burn-in* telah selesai karena *history plot* memperlihatkan pola linier yang bersifat random, stasioner dan cenderung rapat sehingga mampu merespon semua kemungkinan nilai parameter. Selain itu, melalui *history plot* dapat diketahui bahwa proses MCMC, untuk estimasi parameter model telah memenuhi sifat rantai markov yang *ergodic* yaitu *irreducible*, *aperiodic* dan *recurrent*. Disebut *irreducible* karena selama iterasi estimasi parameter, proses mempunyai pergerakan nilai yang acak (*random*) sebagai representasi dari *communicate* antar *state* dalam rantai markov. Selama iterasi estimasi parameter, proses MCMC tidak menunjukkan adanya pola tertentu, karena nilai-nilai sampel yang dibangkitkan sudah berada dalam suatu daerah tanpa keperiodikan yang kuat, maka rantai markov memenuhi sifat *aperiodic*. Selain itu, rantai markov juga memenuhi sifat yang *recurrent*, dimana selama proses iterasi MCMC, nilai parameter yang dibangkit-

kan (*state i*) memungkinkan untuk kembali pada *state i*. Sedangkan pada *autocorrelation plot* menunjukkan bahwa korelasi antara nilai-nilai sampel yang dibangkitkan lemah. Hal ini ditunjukkan dari lag nol yang signifikan, sementara untuk lag-lag lainnya tidak signifikan. Pada *kernel density* memberikan informasi bahwa *density posterior* untuk masing-masing estimasi parameter model membentuk pola densitas yang cenderung halus dan memiliki pusat di tengah (*bell shape*). Dengan demikian dapat dikatakan bahwa sampel yang dibangkitkan dari proses MCMC tersebut merupakan sampel yang berasal dari distribusi *posterior* target parameter. Selanjutnya, dilakukan pengujian dari masing-masing hasil estimasi parameter model MNAR yang ditampilkan pada Tabel 4.9.

Tabel 4.9 Estimasi Parameter model MNAR(3;[3],[3,6],0)

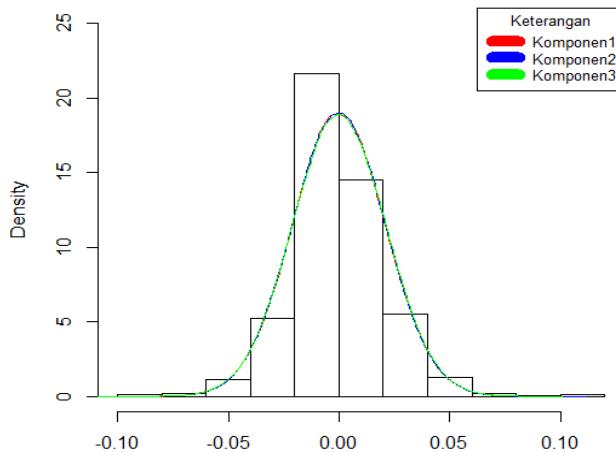
Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,3332	0,006806	0,3199	0,3466
P[2]	0,3326	0,006887	0,3192	0,3462
P[3]	0,3341	0,006865	0,3208	0,3475
b1[1]	-0,1029	0,02488	-0,1523	-0,05408
b1[2]	-0,1084	0,0252	-0,1575	-0,0589
b1[3]	9,464	990,5	-1902	1956
b2[2]	-0,05962	0,02525	-0,1089	-0,01059
b2[3]	-7,663	994,5	-1954	1947
sigma[1]	0,02096	$3,75 \times 10^{-4}$	0,02024	0,02171
sigma[2]	0,02095	$3,73 \times 10^{-4}$	0,02023	0,0217
sigma[3]	0,02107	$3,75 \times 10^{-4}$	0,02034	0,02182

Dari Tabel 4.9 dapat diketahui bahwa $b_1[1]$ dan $b_1[2]$ yang merepresentasikan parameter ϕ_3 pada model AR[3] untuk komponen pertama dan kedua serta $b_2[2]$ yang merepresentasikan parameter ϕ_6 pada model AR[6] berpengaruh signifikan karena *credible interval* 95 persen tidak memuat 0 (nol). Oleh karena itu, dapat dikatakan bahwa *return* saham ASII dipengaruhi oleh *return* saham 3 hari dan 6 hari yang lalu. Sedangkan untuk parameter P

yang menyatakan proporsi komponen ke- j dan parameter σ yang menyatakan nilai standar deviasi dari komponen ke- j , dengan $j=1,2,3$ menunjukkan hasil yang signifikan. Hal ini dikarenakan *credible interval* 95 persen dari distribusi *posterior* parameter P dan σ tidak memuat 0 (nol). Sehingga untuk masing-masing komponen *mixture* akan memiliki nilai standar deviasi yang berbeda dengan proporsi yang berbeda pula. Berdasarkan pengujian estimasi yang dilakukan, maka model MNAR(3;[3], [3,6], 0) dapat dituliskan menjadi persamaan sebagai berikut:

$$(Z_t | \mathcal{F}_{t-1}) \Phi\left(\frac{\dot{Z}_t + 0,1029Z_{t-1}}{0,02096}\right) + \Phi\left(\frac{\dot{Z}_t + 0,1084Z_{t-3} + 0,05962Z_{t-6}}{0,02095}\right) + \\ 0,3341\Phi\left(\frac{\dot{Z}_t}{0,02107}\right).$$

Hasil model ASII 3 komponen akan menghasilkan distribusi plot pada Gambar 4.13.



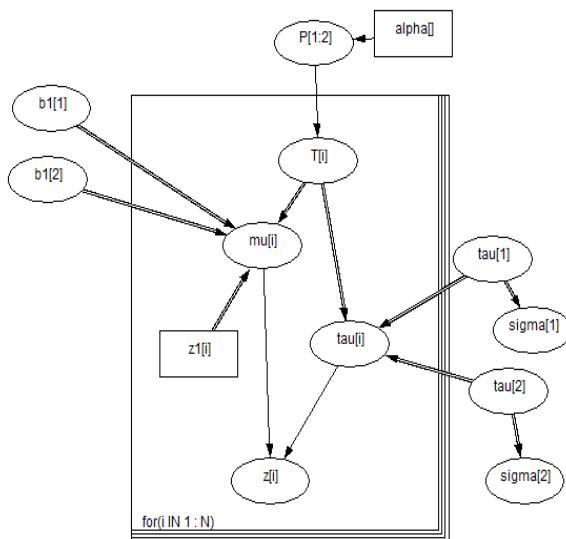
Gambar 4.13 Distribusi Plot *Return* ASII 3 Komponen

b. PT Telekomunikasi Indonesia Tbk

Pemodelan MNAR untuk *return* saham PT Telekomunikasi Indonesia Tbk, diperoleh berdasarkan pemodelan ARIMA yang menunjukkan signifikansi pada parameter modelnya. Dari enam

model ARIMA yang terbentuk, terdapat lima model yang semua parameternya menunjukkan hasil yang signifikan. Oleh karena akan dilakukan penggabungan model AR(p) sebanyak 2 dan 3 komponen. Untuk pemodelan MNAR 2 komponen AR(p) akan dibentuk menjadi 4 model yang terdiri dari model MNAR (2;[2,3],[3,4]), MNAR(2;[2],[3]), MNAR(2;[2],[4]) dan MNAR (2;[3],A[4]). implementasi awal yang dalam pengestimasian parameter model MNAR(2;[2,3],[3,4]) dapat dilakukan dengan membentuk struktur *doodle* WinBUGS seperti pada Gambar 4.6. Dalam pemodelan *return* TLKM ini, $z[i]$ merupakan gabungan dari 2 komponen saham *return* TLKM, dimana $z[i]$ bersifat stokastik dengan memiliki distribusi $\mu[i]$ dan $\tau[i]$. $\mu[i]$ dan $\tau[i]$ bersifat *logical* mengikuti perintah sesuai yang telah diterjemahkan dalam *doodle*. $\mu[i]$ akan disusun membentuk persamaan model AR yaitu $\mu[i] = b_1[T[i]]^* z_1[i] + b_2[T[i]]^* z_2[i]$, sedangkan $\tau[i] = \tau[T[i]]$ artinya akan disusun 2 buah *node* $\tau[j]$ yang bersifat stokastik dengan distribusi gamma, yang kemudian dihubungkan dengan *node* $\sigma[j]$, dimana $j=1,2$. $j=1$ dan 2 merupakan hasil identifikasi dari *node* $T[i]$ yang nilainya berubah sesuai dengan distribusi *dirichlet* $P[1:2]$, yang diatur untuk memiliki domain nilai 1 dan 2 saja. Sedangkan $\sigma[j]$ merupakan nilai standar deviasi untuk komponen ke- j , dimana $\sigma[j] = 1/\sqrt{\tau[j]}$. Selanjutnya *node* $z_1[i]$ dan $z_2[i]$ yang diterjemahkan dalam $\mu[i]$ merupakan gabungan lag 3 dan lag 4 dari $z[i]$.

Sesuai dengan prinsip Bayesian, semua *node* yang ada diluar kotak merepresentasikan distribusi prior dari masing-masing parameter model. *Prior* b_1 (mewakili parameter AR[2] pada komponen pertama dan AR[3] pada komponen kedua) dan b_2 (mewakili parameter model AR[3] pada komponen pertama dan AR[4] pada komponen kedua) memiliki distribusi normal dengan *mean* 0 dan presisi 1×10^{-6} . Selanjutnya untuk struktur *doodle* pada model MNAR(2;[2],[3]), MNAR(2;[2],[4]) dan MNAR(2;[3],[4]) dapat dilihat pada Gambar 4.14.



Gambar 4.14 Doodle untuk model $MNAR(2;[2],[3])$, $MNAR(2;[2],[4])$ dan $MNAR(2;[3],[4])$

Berdasarkan Gambar 4.14, Node $z[i]$ merupakan kombinasi 2 komponen data *return* saham TLKM untuk masing-masing model AR(p). Untuk model MNAR (2;[2],[3]), $z[i]$ merupakan kombinasi lag 2 dan lag 3 dari $z[i]$ yang merepresentasikan AR[2] untuk komponen pertama dan AR[3] untuk komponen kedua. Hal yang sama dapat dilakukan pada model MNAR (2;[2],[4]), dimana $z[i]$ merupakan kombinasi lag 2 dari $z[i]$ yang merepresentasikan AR[2] pada komponen pertama dan lag 4 dari $z[i]$ yang merepresentasikan AR[4] pada komponen kedua. Untuk model MNAR (2;[3],[4]), $z[i]$ merupakan kombinasi lag 3 dari $z[i]$ yang merepresentasikan AR[3] pada komponen pertama dan lag 4 dari $z[i]$ yang merepresentasikan AR[4] pada komponen kedua. $z[i]$ merupakan node yang bersifat stokastik dengan distribusi $\mu[i]$ dan $\tau[i]$ yang bersifat *logical*, sehingga harus mengikuti perintah selanjutnya yang diterjemahkan dalam struktur *doodle*. Untuk node $\mu[i]$ akan disusun persamaan $\mu[i] = b_1[T[i]] * z[i]$. Sedangkan untuk node $\tau[i] = \tau[T[i]]$ digunakan

untuk menerjemahkan *node sigma[j]* dengan nilai $1/\sqrt{\text{tau}[j]}$, dimana $j=1,2$. *Prior* untuk parameter b_1 berdistribusi normal dengan *mean* 0 dan presisi 1×10^{-6} , sedangkan *prior* untuk parameter *sigma* dan *P* masing-masing adalah distribusi Gamma dan distribusi *dirichlet*.

Dalam penelitian ini proses MCMC dilakukan sebanyak 10.000 iterasi dengan proses *burn-in* sebanyak 99 iterasi, maka total sampel yang digunakan untuk mengestimasi parameter model sebanyak 9901 sampel. Selanjutnya, dilakukan pengecekan terhadap kekonvergenan rantai *markov* yang dapat dilihat melalui *history plot*, *autocorrelation plot* dan *kernel density*. *History plot*, *autocorrelation plot* dan *kernel density* untuk keempat model MNAR 2 komponen menunjukkan bahwa sampel yang dibangkitkan dari proses MCMC tersebut merupakan sampel yang berasal dari distribusi *posterior* target parameter. Hal ini dibuktikan dengan *histoty plot* dengan pola linier yang bersifat *random* dan *stationer*, sehingga telah memenuhi sifat rantai markov yang *irreducible*, *aperiodic* dan *reccurent*. Pada *autocorrelation plot* hanya keluar atau signifikan pada lag nol dan *kernel density* memiliki pola yang halus dan memiliki pusat ditengah (*bell shape*). Langkah berikutnya yaitu melakukan pengujian pada masing-masing hasil estimasi parameter model MNAR. Untuk estimasi parameter model MNAR (2;[2,3],[3,4]) dapat dilihat pada Tabel 4.10.

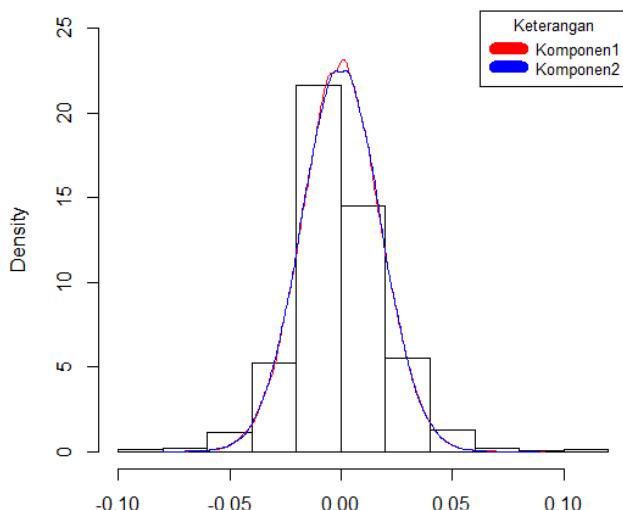
Tabel 4.10 Estimasi Parameter Model MNAR(2;[2,3],[3,4])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,5	0,008923	0,4823	0,5173
P[2]	0,5	0,008923	0,4827	0,5177
b1[1]	-0,116	0,0251	-0,165	-0,06762
b1[2]	-0,08048	0,02498	-0,1301	-0,03109
b2[1]	-0,0803	0,0251	-0,1294	-0,03056
b2[2]	-0,08415	0,02524	-0,1338	-0,03464
sigma[1]	0,0174	$3,12 \times 10^{-4}$	0,01681	0,01804
sigma[2]	0,01746	$3,11 \times 10^{-4}$	0,01685	0,01808

Tabel 4.10 memberikan informasi bahwa untuk parameter $b_1[1]$ dan $b_2[1]$ yang merupakan representasi parameter ϕ_2 dan ϕ_3 pada model AR[2,3] serta $b_1[2]$ dan $b_2[2]$ yang merupakan representasi parameter ϕ_3 dan ϕ_4 pada model AR[3,4], memberikan hasil *credible interval* 95 persen yang tidak memuat 0 (nol). Sehingga dapat dikatakan bahwa *return* saham TLKM dipengaruhi oleh *return* saham 2 hari, 3 hari dan 4 hari yang lalu, Untuk parameter *sigma* dan *P* juga menhasilkan *credible interval* 95 persen yang tidak memuat 0 (nol), sehingga kedua parameter tersebut juga berpengaruh signifikan untuk digunakan dalam model. Persamaan model $MNAR(2;[2,3],[3,4])$ dapat ditulis sebagai berikut:

$$(Z_t | \Phi_{t-1}) = 0,5 \left(\frac{Z_t + 0,116Z_{t-2} + 0,0803Z_{t-3}}{0,0174} \right) + ,5\Phi \left(\frac{Z_t + 0,08048Z_{t-3} + 0,08415Z_{t-4}}{0,01746} \right).$$

Berdasarkan model tersebut diperoleh distribusi plot seperti yang ditampilkan pada Gambar 4.15.



Gambar 4.15 Distribusi Plot *Return* TLKM untuk $MNAR(2;[2,3],[3,4])$

Selanjutnya untuk estimasi parameter model $MNAR(2;[2],[3])$ dapat dilihat pada Tabel 4.11.

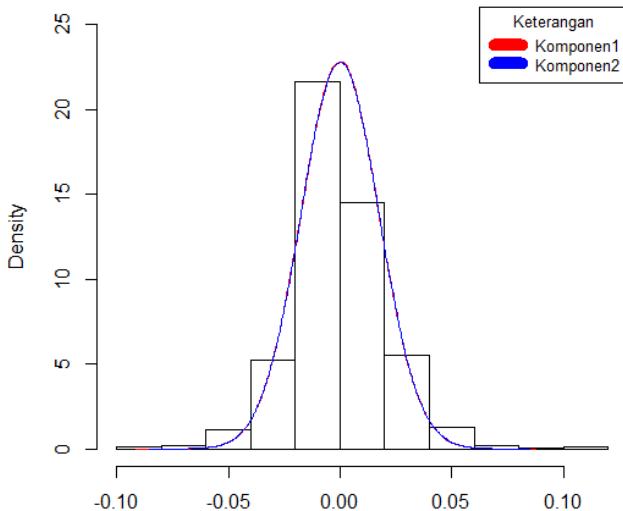
Tabel 4.11 Estimasi Parameter Model MNAR(2;[2],[3])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,5002	0,008956	0,4825	0,5175
P[2]	0,4998	0,008956	0,4825	0,5175
b1[1]	-0,1146	0,02493	-0,1631	-0,06655
b1[2]	-0,07862	0,02518	-0,1273	-0,02875
sigma[1]	0,01746	3,16x10 ⁻⁴	0,01685	0,01809
sigma[2]	0,01751	3,14x10 ⁻⁴	0,01691	0,01816

Tabel 4.11 memberikan informasi bahwa $b_1[1]$ yang merupakan parameter ϕ_2 dari model AR[2] pada komponen pertama dan $b_1[2]$ merupakan parameter ϕ_3 dari model AR[3] pada komponen kedua berpengaruh signifikan terhadap *return* saham TLKM. Hal ini dapat dilihat berdasarkan *credible interval* 95 persen yang tidak memuat 0 (nol). Dengan demikian *return* saham TLKM dipengaruhi oleh *return* saham 2 hari dan 3 hari yang lalu. Untuk parameter *sigma* dan *P* menunjukkan bahwa *credible interval* 95 persen tidak memuat 0 (nol). Dengan kata lain, parameter *sigma* dan *P* signifikan untuk digunakan dalam model *mixture*, dimana untuk masing-masing komponen akan memiliki nilai standar deviasi dan proporsi yang berbeda pada setiap komponen. Persamaan untuk model MNAR(2;[2],[3]) dapat dituliskan sebagai berikut:

$$(Z_t | \mathcal{F}_{t-1}) \Phi 0,5002 \left(\frac{Z_t + 0,1146 Z_{t-1}}{0,4998} \right) + \Phi \left(\frac{Z_t + 0,07862 Z_{t-3}}{0,01751} \right).$$

Dengan demikian diperoleh distribusi plot seperti yang disajikan pada Gambar 4.16.



Gambar 4.16 Distribusi Plot *Return* TLKM untuk $MNAR(2;[2],[3])$

Selanjutnya untuk pengujian estimasi parameter model $MNAR(2;[2],[4])$ disajikan dalam Tabel 4.12.

Tabel 4.12 Estimasi Parameter Model $MNAR(2;[2],[4])$

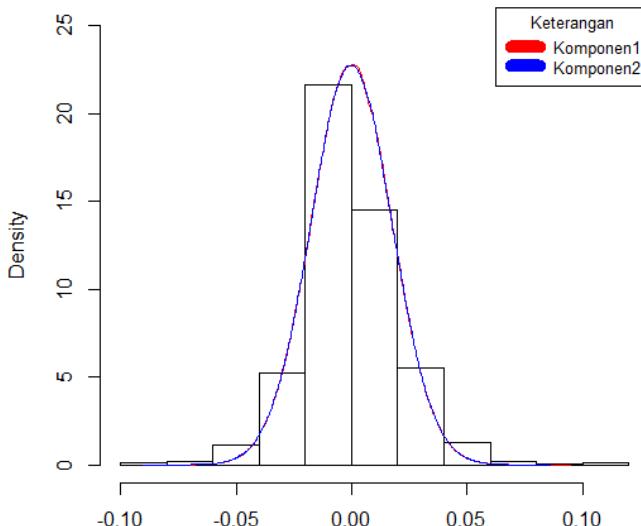
Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,5003	0,008957	0,4827	0,5176
P[2]	0,4997	0,008957	0,4824	0,5173
b1[1]	-0,1146	0,02493	-0,1631	-0,06655
b1[2]	-0,08276	0,02518	-0,1314	-0,0329
sigma[1]	0,01746	$3,16 \times 10^{-4}$	0,01685	0,01809
sigma[2]	0,01751	$3,14 \times 10^{-4}$	0,01691	0,01815

Tabel 4.12 menunjukkan bahwa parameter model AR[2] yang direpresentasikan oleh $b_1[1]$ pada komponen pertama dan parameter model AR[4] yang direpresentasikan oleh $b_1[2]$ pada komponen kedua, menghasilkan *credible interval* 95 persen yang tidak memuat 0 (nol), sehingga dapat dikatakan bahwa parameter model berpengaruh signifikan terhadap *return* saham TLKM. Dengan kata lain, *return* saham TLKM dipengaruhi oleh *return* sa-

ham 2 hari dan 4 hari yang lalu. Untuk parameter *sigma* yang merepresentasikan nilai standar deviasi pada *mixture* ke-*j* dan parameter *P* yang merepresentasikan proporsi pada *mixture* ke-*j*, dengan *j*=1,2, diperoleh *credible interval* 95 persen yang tidak memuat 0 (nol). Hal ini menunjukkan bahwa kedua parameter tersebut berpengaruh signifikan untuk digunakan dalam model MNAR (2;[2],[4]). Persamaan untuk model MNAR(2;[2],[4]) dapat ditulis sebagai berikut:

$$(Z_t | \mathcal{F}_{t-1}) = 0,5003 \left(\frac{Z_t + 0,1146 Z_{t-4}}{0,4997} \right) + \Phi \left(\frac{Z_t + 0,08276 Z_{t-4}}{0,01751} \right).$$

Berdasarkan model tersebut diperoleh distribusi plot seperti yang ditampilkan pada Gambar 4.17



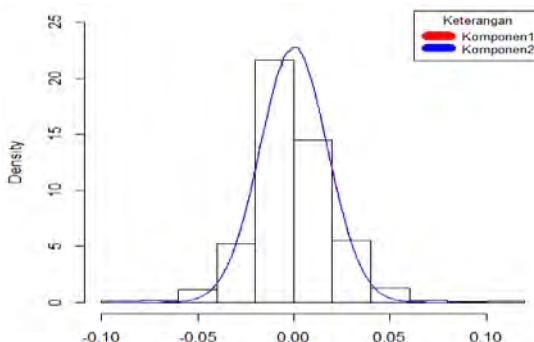
Gambar 4.17 Distribusi Plot *Return* TLKM untuk MNAR(2;[2],[4])

Berikutnya dilakukan pengujian pada hasil estimasi parameter model MNAR(2;[3],[4]) yang dapat dilihat dalam Tabel 4.13.

Tabel 4.13 Estimasi Parameter Model MNAR(2;[3],[4])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,5002	0,00896	0,4825	0,5175
P[2]	0,4998	0,00896	0,4825	0,5175
b1[1]	-0,07838	0,02503	-0,1271	-0,03013
b1[2]	-0,08278	0,02519	-0,1314	-0,0329
sigma[1]	0,01751	$3,17 \times 10^{-4}$	0,01691	0,01815
sigma[2]	0,01751	$3,14 \times 10^{-4}$	0,01691	0,01815

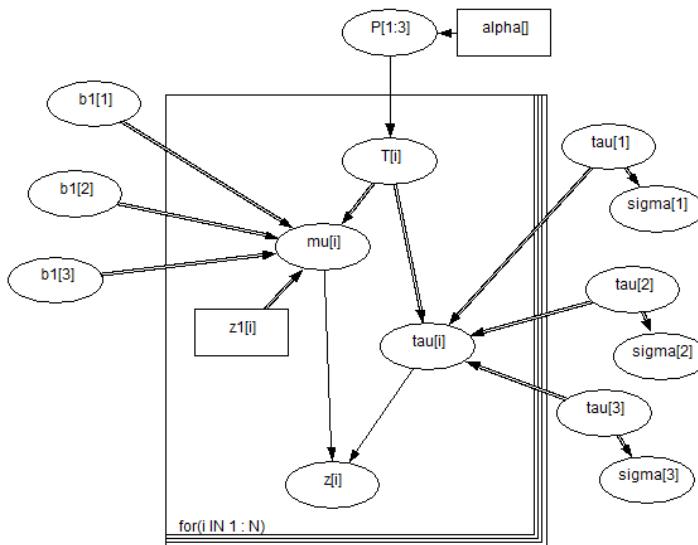
Berdasarkan Tabel 4.13 dapat diketahui bahwa parameter $b_1[1]$ atau ϕ_3 yang mewakili model AR[3] pada komponen pertama dan parameter $b_1[2]$ atau ϕ_4 yang mewakili model AR[4] pada komponen kedua memberikan *credible interval* 95 persen yang tidak memuat 0 (nol). Hal ini menunjukkan bahwa lag 3 dan lag 4 pada *return* saham TLKM berpengaruh signifikan. Sehingga dapat dikatakan bahwa *return* saham TLKM dapat dipengaruhi oleh *return* saham 3 hari dan 4 hari yang lalu. Hal sama terjadi pada parameter *sigma* dan *P* yang memberikan *credible interval* 95 persen yang tidak memuat 0 (nol). Sehingga parameter model tersebut berpengaruh signifikan untuk digunakan dalam pemodelan MNAR. Berdasarkan hasil pengujian estimasi parameter tersebut, distribusi plot dari model MNAR(2;[3],[4]) yang ditampilkan pada Gambar 4.18.

**Gambar 4.18** Distribusi Plot *Return* TLKM untuk MNAR(2;[3],[4])

Dengan persamaan model yang dapat ditulis sebagai berikut:

$$(Z_t | \mathcal{F}_{t-1}) \in \left(\frac{Z_t + 0,07838Z_{t-4}}{0,01751} \right) \quad \left(\frac{Z_t + 0,08278Z_{t-4}}{0,01751} \right)$$

Untuk *return* saham TLKM juga akan dilakukan pemodelan MNAR dengan 3 komponen *mixture* yaitu dengan menggabungkan 3 komponen AR(p) yang berbeda yang didasarkan pada model ARIMA yang signifikan yaitu AR[2], AR[3], AR[4], AR[2,3], AR[3,4] dan AR[2,3,4]. Dalam penelitian ini *return* saham TLMK dimodelkan dengan MNAR(3;[2],[3],[4]) dan MNAR(3;[2,3],[3,4],[2,3,4]). Implementasi awal dalam pengestimasian model MNAR(3;[2],[3],[4]) diawali dengan pembentukan struktur *doodle* yang ditampilkan pada Gambar 4.19.

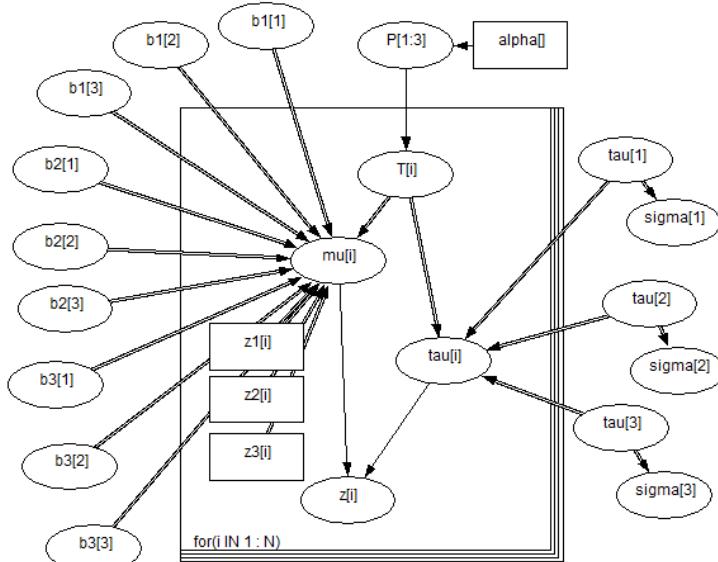


Gambar 4.19 *Doodle* untuk model MNAR (3;[2],[3],[4])

Gambar 4.19 memberikan informasi bahwa $z[i]$ merupakan data *return* saham TLKM dengan kombinasi 3 komponen, dimana $z[i]$ berdistribusi normal dengan parameter $\mu[i]$ dan $\tau[i]$. $\mu[i]$

merupakan *node logical* yang disusun untuk membentuk persamaan model *Autoregressive* untuk masing-masing komponen *mixture* yaitu $\mu[i] = b_1[T[i]] * z_i[i]$. $z_i[i]$ merupakan gabungan lag 2, lag 3 dan lag 4 dari $z[i]$ yang merepresentasikan model AR[2] pada komponen pertama, model AR[3] pada komponen kedua dan model AR[4] pada komponen ketiga. Sedangkan *node tau[i]* yang diidentifikasi oleh $T[i]$ yang berubah sesuai dengan distribusi *dirichlet*, $P[1:3]$, yang diatur agar mempunyai domain nilai 1 hingga 3. Sehingga dibentuk *node tau[j]* untuk menerjemahkan nilai standar deviasi dari masing-masing *mixture* yang disimbolkan dengan *node sigma[j]*, dimana $j=1,2,3$.

Selanjutnya untuk struktur *doodle* model MNAR(3; [2,3],[3,4],[2,3,4]) dapat dilihat pada Gambar 4.20.



Gambar 4.20 Doodle untuk model MNAR (3;[2,3],[3,4],[2,3,4])

Penjelasan untuk struktur *doodle* pada Gambar 4.20 sama seperti penjelasan struktur *doodle* pada Gambar 4.19. Jika pada Gambar 4.19 $\mu[i] = b_1[T[i]] * z_i[i]$, pada Gambar 4.20 $\mu[i]$ diterjemahkan oleh *node* yang arah panahnya menuju *node* $\mu[i]$ yaitu

b_1, b_2, b_3, z_1, z_2 , dan z_3 , sehingga akan dibentuk persamaan yang merepresentasikan 3 komponen AR(p), dengan $mu[i] = b_1[T[i]] * z_1[i] + b_2[T[i]] * z_2[i] + b_3[T[i]] * z_3[i]$. $z_1[i]$ merupakan gabungan AR[2] pada komponen pertama dan ketiga serta AR[3] pada komponen kedua. $z_2[i]$ merupakan gabungan AR[3] pada komponen pertama dan ketiga serta AR[4] pada komponen kedua. $z_3[i]$ merupakan gabungan nilai 0 (nol) pada komponen pertama dan kedua serta AR[4] pada komponen ketiga.

Dalam penelitian ini, proses pengambilan sampel yang digunakan untuk mengestimasi parameter model yang didasarkan pada distribusi *posterior* dari proses MCMC sebanyak 10.000 iterasi dengan proses *burn-in* sebanyak 99 iterasi. Oleh karena itu, total sampel yang digunakan dalam pengestimasian parameter model sebanyak 9901 sampel. Selanjutnya dilakukan diagnosa terhadap sifat rantai markov yang *ergodic* dan konvergen yang dapat dilihat melalui *history plot*, *autocorrelation plot* dan *kernel density*. Ketiga plot tersebut menunjukkan sifat rantai markov yang konvergen. Hal ini dibuktikan dengan *history plot* yang memperlihatkan bahwa rantai markov bersifat *irreducible*, *aperiodic* dan *recurrent*. *Irreducible* yaitu selama iterasi estimasi parameter, proses mempunyai pergerakan nilai yang acak (*random*). Bersifat *aperiodic* karena selama iterasi estimasi parameter, proses MCMC tidak menunjukkan adanya pola tertentu. Serta *recurrent* yang ditunjukkan melalui pola random yang dihasilkan selama proses iterasi MCMC, nilai parameter yang dibangkitkan (*state i*) memungkinkan untuk kembali pada *state i*. Selanjutnya untuk *autocorrelation plot* menunjukkan nilai autokorelasi pada lag nol mendekati satu, sedangkan untuk lag-lag selanjutnya mendekati nol. Hal ini berarti bahwa korelasi diantara nilai-nilai sampel yang dibangkitkan telah berada di daerah distribusi *posterior*. Hal ini diperkuat dengan *kernel density* yang menunjukkan estimasi *density posterior* untuk parameter model membentuk pola yang halus dan cenderung memiliki pusat di tengah (*bell shape*). Dengan demikian hasil estimasi parameter telah memenuhi sifat rantai markov yang *ergodic* dan konvergen atau dapat dikatakan

sampel yang dibangkitkan dari proses MCMC tersebut merupakan sampel yang berasal dari distribusi *posterior* target parameter.

Selanjutnya akan dilakukan pengujian hasil estimasi parameter model MNAR 3 komponen untuk *return* saham TLKM. Hasil pengujian dapat dilihat pada Tabel 4.14.

Tabel 4.14 Estimasi Parameter Model MNAR(3;[2],[3],[4])

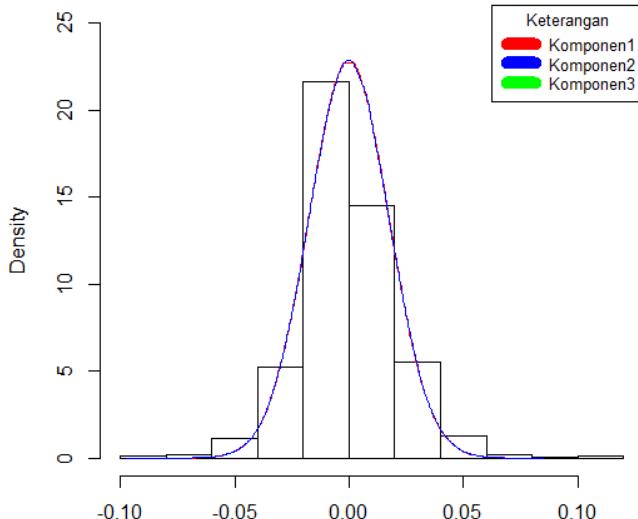
Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,3337	0,006885	0,3203	0,3474
P[2]	0,3334	0,006989	0,3195	0,3471
P[3]	0,333	0,006913	0,3193	0,3465
b1[1]	-0,1148	0,02534	-0,1647	-0,0653
b1[2]	-0,07819	0,02532	-0,1279	-0,02881
b1[3]	-0,08273	0,02527	-0,1322	-0,03249
sigma[1]	0,01746	$3,12 \times 10^{-6}$	0,01686	0,01809
sigma[2]	0,01751	$3,14 \times 10^{-6}$	0,01691	0,01815
sigma[3]	0,01751	$3,10 \times 10^{-6}$	0,0169	0,01813

Tabel 4.14 memberikan hasil estimasi masing-masing parameter model MNAR 3 komponen dengan metode Bayesian, dimana parameter dikatakan tidak signifikan jika *credible interval* 95 persen dari distribusi *posterior* tidak memuat 0 (nol). Terlihat bahwa untuk semua parameter model MNAR memiliki *credible interval* 95 persen yang tidak memuat 0 (nol), yang berarti bahwa semua parameter model signifikan untuk digunakan. Dalam hal ini parameter $b_1[1]$ mewakili parameter ϕ_2 dari model AR[2] pada komponen pertama, $b_1[2]$ parameter ϕ_3 dari model AR[3] pada komponen kedua dan $b_1[3]$ parameter ϕ_2 dari model AR[4] pada komponen ketiga. Oleh karena ketiga parameter model tersebut signifikan, maka dapat dikatakan bahwa *return* saham TLKM dipengaruhi oleh *return* saham 2 hari, 3 hari dan 4 hari yang lalu. Sedangkan untuk parameter P dan $sigma$ yang signifikan menunjukkan bahwa proporsi dan nilai standar deviasi dalam setiap komponen *mixture* akan memiliki nilai yang berbeda. Berdasarkan hasil pengujian estimasi parameter tersebut dapat disimpulkan

kan bahwa model MNAR(3;[2],[3],[4]) dapat digunakan untuk analisis selanjutnya. Persamaan untuk model MNAR(3;[2],[3],[4]) dapat ditulis sebagai berikut:

$$(Z_t | \mathcal{F}_{t-1}) = 0,3337\Phi\left(\frac{Z_t + 0,1148Z_{t-2}}{0,01746}\right) + 0,3334\Phi\left(\frac{Z_t + 0,07819Z_{t-3}}{0,01751}\right) + 0,333\Phi\left(\frac{Z_t + 0,08273Z_{t-4}}{0,01751}\right),$$

dengan distribusi plot yang ditampilkan dalam Gambar 4.21.



Gambar 4.21 Distribusi Plot Return TLKM untuk MNAR(3;[2],[3],[4])

Langkah berikutnya dilakukan pengujian estimasi parameter model MNAR(3;[2,3],[3,4],[2,3,4]) yang disajikan pada Tabel 4.15.

Tabel 4.15 Estimasi Parameter Model MNAR(3;[2,3],[3,4],[2,3,4])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%	Keterangan
P[1]	0,3336	6,87 x10 ⁻³	0,3202	0,3472	Signifikan
P[2]	0,3333	6,78 x10 ⁻³	0,3198	0,3465	Signifikan
P[3]	0,3332	6,89 x10 ⁻³	0,3197	0,3467	Signifikan
b1[1]	-0,1158	2,52 x10 ⁻²	-0,1655	-0,0661	Signifikan
b1[2]	-0,08023	2,47 x10 ⁻²	-0,1296	-0,03157	Signifikan

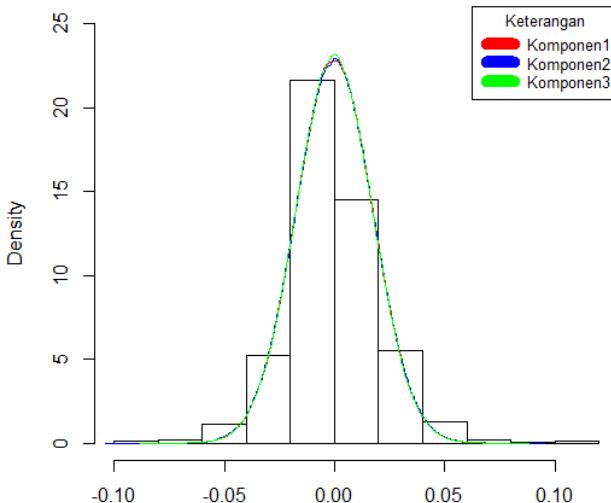
Tabel 4.15 (Lanjutan)

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
b1[3]	-0,1269	2,49 x10 ⁻²	-0,1759	-0,07806
b2[1]	-0,08032	0,02517	-0,1298	-0,03139
b2[2]	-0,08433	0,02522	-0,1331	-0,0346
b2[3]	-0,08272	0,02487	-0,1316	-0,03399
b3[3]	-0,09925	0,02528	-0,1487	-0,0499
sigma[1]	0,01739	3,09 x10 ⁻⁴	0,0168	0,01801
sigma[2]	0,01746	3,13 x10 ⁻⁴	0,01685	0,01808
sigma[3]	0,01732	3,13 x10 ⁻⁴	0,0167	0,01795

Berdasarkan Tabel 4.15 didapatkan informasi bahwa semua parameter model MNAR(3;[2,3],[3,4],[2,3,4]) berpengaruh signifikan. Hal ini dapat dibuktikan dengan *credible interval* 95 persen yang tidak memuat 0 (nol), dengan $b_1[1]$ dan $b_2[1]$ merepresentasikan parameter AR[2,3] pada komponen pertama, $b_1[2]$ dan $b_2[2]$ merepresentasikan parameter AR[3,4] pada komponen kedua dan $b_1[3]$, $b_2[3]$ dan $b_3[3]$ merepresentasikan parameter AR[2,3,4] pada komponen ketiga. Sedangkan P merepresentasikan proporsi komponen ke- j dan σ merepresentasikan nilai standar deviasi komponen ke- j , dengan $j=1,2$ dan 3. Tabel 4.15 juga memperlihatkan bahwa proporsi dan nilai standar deviasi dari masing-masing komponen memiliki nilai yang berbeda. Persamaan untuk model MNAR(3;[2,3],[3,4],[2,3,4]) dapat dituliskan sebagai berikut:

$$\begin{aligned} (\dot{Z}_t | \mathcal{F}_{t-1}) &= 0,3336 \left(\frac{\dot{Z}_t + 0,1158Z_{t-2} + 0,0803Z_{t-3}}{0,01739} \right) + \\ &0,3332\Phi \left(\frac{\dot{Z}_t + 0,1269Z_{t-2} + 0,08272Z_{t-3} + 0,09925Z_{t-4}}{0,01732} \right). \end{aligned}$$

Berdasarkan model MNAR tersebut, dapat diperoleh distribusi plot seperti pada Gambar 4.22.

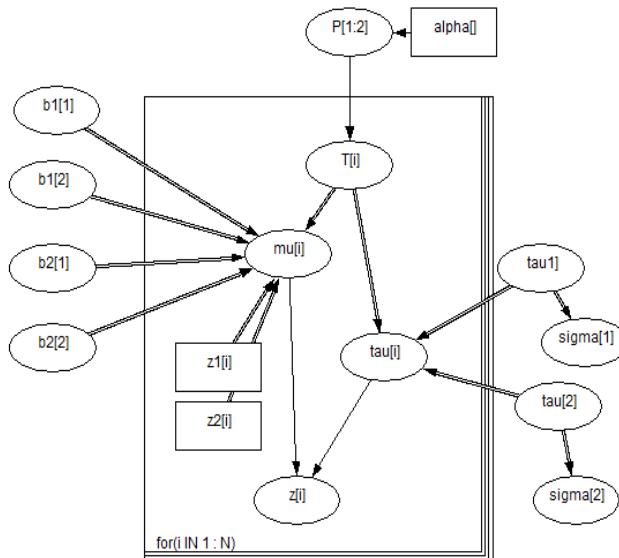


Gambar 4.22 Distribusi Plot *Return* TLKM untuk MNAR(3;[2],[3],[4])

c. PT Unilever Indonesia Tbk

Pemodelan MNAR untuk *return* saham UNVR dilakukan dengan 2 dan 3 komponen *mixture*. Untuk 2 komponen *mixture* akan dibentuk model yang menggabungkan antara AR(2) dan AR[11] atau dapat ditulis menjadi MNAR(2;2,[11]). Gambar 4.23 menyajikan struktur *doodle* untuk mengestimasi parameter model MNAR(2;2,[11]). Struktur *doodle* model MNAR(2;2,[11]) pada Gambar 4.23 menunjukkan bahwa $z[i]$ merupakan gabungan dari dua data *return* saham UNVR. $z[i]$ merupakan *node* stokastik yang berdistribusi normal, dengan parameter distribusi $\mu[i]$ dan $\tauau[i]$. $\mu[i]$ dan $\tauau[i]$ akan diidentifikasi dengan $T[i]$ yang akan berubah sesuai dengan distribusi *dirichlet* $P[1:2]$, yang diatur agar mempunyai domain nilai 1 dan 2, di mana 1 merupakan komponen *mixture* pertama dan 2 merupakan komponen *mixture* kedua. $\mu[i]$ merupakan *node logical* yang akan disusun dalam sebuah persamaan model AR yaitu $\mu[i]=b_1[T[i]]^*z_1[i]+b_2[T[i]]^*z_2[i]$. *Node* $z_1[i]$ merupakan gabungan lag 1 dan lag 11 dari $z[i]$,

sedangkan $z_2[i]$ merupakan gabungan lag 2 dari $z[i]$ pada komponen pertama dan nol pada komponen kedua. Sedangkan *node tau*[i] = τ [$T[i]$], berarti bahwa akan dibentuk τ [j] yang akan dihubungkan dengan *node sigma*[j], dengan $j=1,2$. $Sigma[j]$ merepresentasikan standar deviasi dari komponen ke- j yang didapatkan dari $1/\sqrt{\tau[j]}$.



Gambar 4.23 Doodle Untuk Model MNAR(2;2,[11])

Prior untuk masing-masing parameter b_1 dan b_2 yang digunakan dalam proses pembangkitan menggunakan distribusi yang sama yaitu normal dengan *mean* 0 dan presisi sebesar 1×10^{-6} . Proses kerja model secara hirarki dimulai dari pembangkitan data parameter dari semua *prior* secara independen. Setiap kali pembangkitan satu nilai *prior* parameter tertentu selalu mengikutkan sejumlah N data yang berada dalam struktur kotak (*looping*) sebagai bahan untuk menghitung *likelihood* dalam proses *full conditional*-nya. Selanjutnya hasil nilai bangkitan tersebut akan digunakan untuk mengestimasi setiap komponen model.

Proses MCMC dengan *Gibbs Sampling* yang digunakan dalam proses pengambilan sampel untuk estimasi parameter model yang diperoleh dari distribusi *posterior* dilakukan sebanyak 10.000 iterasi dengan proses *burn-in* sebanyak 99 iterasi. Sehingga total sampel yang digunakan untuk estimasi parameter model sebanyak 9901 sampel. Untuk mengetahui kesesuaian nilai parameter dengan sifat rantai markov yang *ergodic* dan konvergen dapat dilihat pada Lampiran 11. *History plot* menunjukkan pola linier yang bersifat *random*, stasioner dan cenderung rapat sehingga mampu merespon semua kemungkinan nilai parameter. Selama iterasi estimasi parameter, proses mempunyai pergerakan nilai yang acak (*random*), tidak menunjukkan adanya pola tertentu dan nilai parameter yang dibangkitkan (*state i*) akan ada kemungkinan untuk kembali pada *state i*. Dengan demikian rantai markov telah memenuhi sifat *ergodic* yaitu *irreducible*, *aperiodic* dan *recurrent*. Untuk *autocorrelation plot* menunjukkan bahwa lag pertama hampir mendekati satu atau signifikan sedangkan lag-lag lainnya mendekati nol, dengan kata lain korelasi diantara nilai-nilai sampel yang dibangkitkan telah berada di daerah distribusi posterior. Hal ini didukung oleh *kernel density* yang memperlihatkan pola halus dan cenderung memiliki pusat di tengah (*bell shape*). oleh karena itu dapat dikatakan bahwa rantai markov telah mencapai kekonvergenan. Sehingga disimpulkan bahwa sampel yang dibangkitkan dari proses MCMC tersebut merupakan sampel yang berasal dari distribusi *posterior* target parameter. Selanjutnya akan dilakukan pengujian hasil estimasi model MNAR untuk masing-masing parameter. Tabel 4.16 menyajikan hasil estimasi dari model MNAR(2;2,[11]).

Tabel 4.16 Estimasi Parameter Model MNAR(2;2,[11])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,5013	0,008931	0,4836	0,5186
P[2]	0,4987	0,008931	0,4814	0,5164
b1[1]	-0,2729	0,02516	-0,3231	-0,2239
b1[2]	0,05838	0,02512	0,008485	0,108

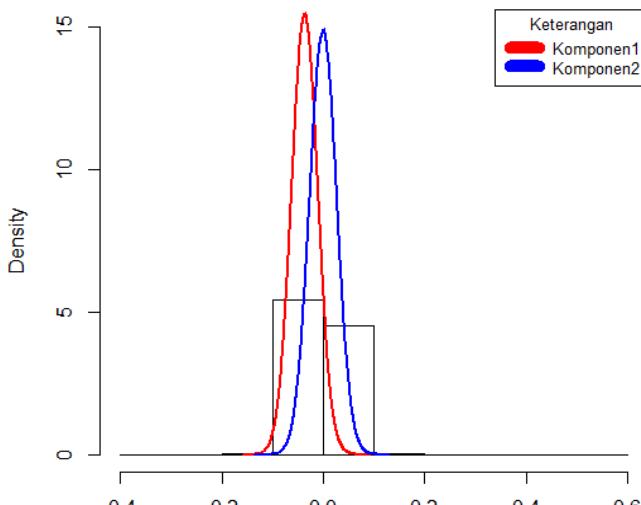
Tabel 4.16 (Lanjutan)

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
b2[1]	-0,09637	0,02519	-0,1456	-0,04644
sigma[1]	0,02576	$4,62 \times 10^{-4}$	0,02488	0,0267
sigma[2]	0,02672	$4,77 \times 10^{-4}$	0,02579	0,02768

Tabel 4.16 memberikan informasi bahwa parameter $b_1[1]$ Tabel 4.15 memberikan informasi bahwa parameter $b_1[1]$ dan $b_2[1]$ yang merepresentasikan parameter ϕ_1 dan ϕ_2 dari model AR(2) pada komponen pertama memiliki *credible interval* 95 persen yang tidak memuat 0 (nol). Sedangkan untuk parameter $b_1[2]$ yang merepresentasikan parameter ϕ_{11} pada model AR[11] memiliki *credible interval* 95 persen yang tidak memuat 0 (nol) juga. Dengan kata lain parameter AR dalam model MNAR berpengaruh signifikan. Sehingga dapat dikatakan bahwa *return* saham UNVR dipengaruhi oleh *return* saham 1 hari, 2 hari dan 11 hari yang lalu. Untuk proporsi dari masing-masing komponen yang direpresentasikan oleh parameter P dan nilai standar deviasi dari masing-masing komponen yang direpresentasikan oleh parameter $sigma$, tidak memuat 0 (nol) pada *credible interval* 95 persen. Dengan demikian parameter P dan $sigma$ berpengaruh signifikan untuk digunakan dalam model. Berdasarkan hasil pengujian yang dilakukan, model MNAR(2;2,[11]) dapat digunakan untuk analisis selanjutnya. Persamaan model MNAR(2;(2),[11]) dapat ditulis menjadi sebagai berikut:

$$(\dot{Z}_t | \mathcal{F}_{t-1}) \Phi = 0,5013 \left(\frac{\dot{Z}_t + 0,2729Z_{t-1} + 0,09637Z_{t-2}}{0,02576} \right) + ,4987\Phi \left(\frac{\dot{Z}_t + 0,05838Z_{t-11}}{0,02672} \right).$$

Dengan demikian diperoleh distribusi plot *return* saham UNVR 2 komponen yang ditampilkan dalam Gambar 4.24.

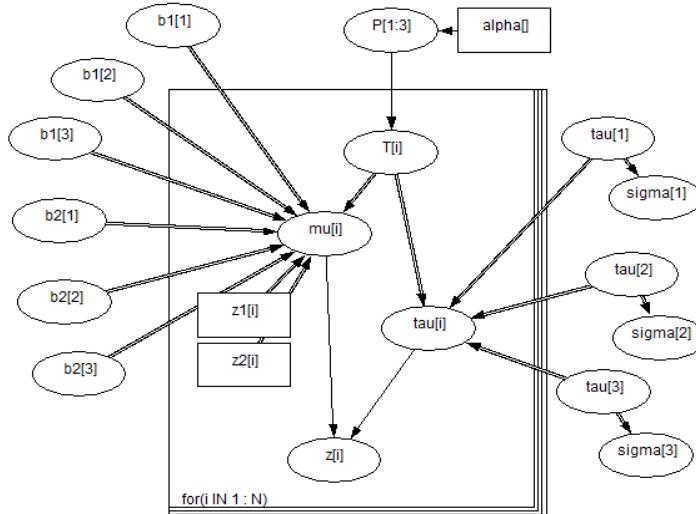


Gambar 4.24 Distribusi Plot *Return* UNVR 2 Komponen

Berikutnya akan dilakukan pemodelan 3 komponen AR(p) terhadap *return* saham UNVR, dengan melibatkan lag-lag yang signifikan yaitu lag 1, lag 2 dan lag 11. Sehingga pemodelan MNAR dengan 3 komponen ini terdiri dari gabungan model AR(1), AR(2) dan AR[11] atau dapat dituliskan menjadi MNAR (3;1,2,[11]). Implementasi model MNAR diawali dengan pembentukan struktur *doodle* yang disajikan dalam Gambar 4.24.

Gambar 4.25 menampilkan struktur *doodle* model MNAR (3;1,2,[11]) sebagai langkah awal dalam pengestimasi parameter model, dimana $z[i]$ merupakan gabungan dari 3 komponen data *return* saham UNVR. Sedangkan $z_1[i]$ merupakan gabungan lag 1 dari $z[i]$ pada komponen pertama dan kedua serta lag 11 dari $z[i]$ pada komponen ketiga. Untuk $z_2[i]$ merupakan gabungan dari nilai 0 (nol) pada komponen pertama dan ketiga serta lag 2 dari $z[i]$ pada komponen kedua. $Node\ mu[i]$ merupakan *node logical* yang akan mengikuti perintah berikutnya, sesuai dengan yang diterjemahkan dalam *doodle*, dimana *logical* tersebut disusun untuk membentuk persamaan model AR(p) pada masing-masing komponen. Dengan demikian persamaan yang dibentuk

yaitu $\mu[i] = b_1[T[i]] * z_1[i] + b_2[T[i]] * z_2[i]$. Node yang berada diluar kotak merupakan parameter-parameter yang akan diestimasi dengan berdasarkan pada distribusi posteriornya. Distribusi *prior* untuk parameter $b_1[1]$ dan $b_2[1]$ (mewakili model AR(1)), $b_1[2]$ dan $b_2[2]$ (mewakili AR(2)) serta $b_1[3]$ dan $b_2[3]$ (mewakili AR[11]) menggunakan *prior* distribusi normal dengan mean 0 dan presisi 1×10^{-6} . Sedangkan untuk node $\tauau[j]$ yang dihubungkan dengan node $\sigmaigma[j]$, dimana $j=1,2,3$ memiliki distribusi Gamma. $\Sigmaigma[j]$ didapatkan dari hasil penerjemahan *logical* $1/\sqrt{\tauau[j]}$, sehingga akan diperoleh nilai standar deviasi dari masing-masing komponen *mixture*. Untuk parameter P menunjukkan proporsi dari masing-masing komponen *mixture* dengan mengikuti distribusi *dirichlet*.



Gambar 4.25 Doodle Untuk Model MNAR(3;1,2,[11])

Dalam penelitian ini akan dilakukan proses pengambilan sampel yang digunakan untuk mengestimasi parameter model. Estimasi parameter model yang diperoleh didasarkan pada distribusi *posterior* dari proses MCMC sebanyak 10.000 iterasi dengan proses *burn-in* sebanyak 99 iterasi. Oleh karena itu, total sampel

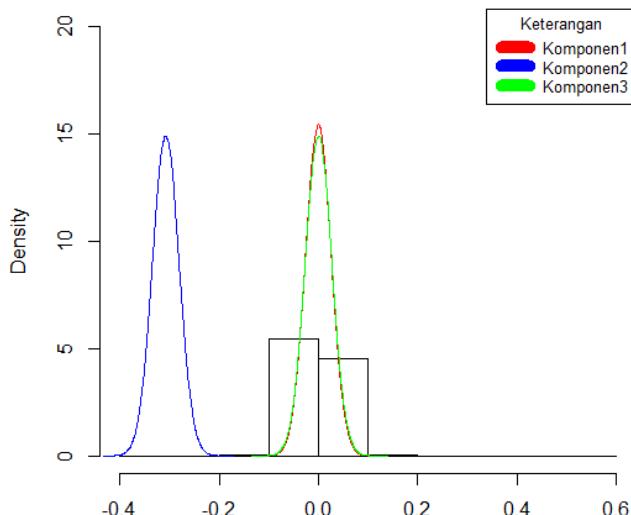
yang digunakan dalam pengestimasi parameter model sebanyak 9901 sampel. Setelah proses pengambilan sampel dilakukan, maka dilakukan diagnosa untuk mengetahui kesesuaian nilai parameter dengan sifat rantai *markov* yang konvergen. Untuk memperkirakan apakah kekonvergenan suatu rantai *markov* terhadap kestasioneran distribusinya sudah tercapai atau belum dapat dilihat melalui *history plot* yang disajikan dalam Lampiran 12. *history plot* memperlihatkan pola linier yang random dan stasioner. Hal ini menunjukkan bahwa proses *burn-in* telah selesai yang berarti sampel yang dibangkitkan telah berada dalam distribusi target. Oleh karena itu dapat dikatakan bahwa proses iterasi telah mencapai kondisi konvergen. Selain itu, *history plot* juga menunjukkan bahwa rantai markov telah memenuhi sifat *irreducible*, *aperiodic* dan *recurrent* karena selama iterasi estimasi parameter, proses mempunyai pergerakan nilai yang acak (*random*) (representasi sifat *irreducible*), tidak menunjukkan adanya pola tertentu (representasi sifat *aperiodic*) dan pola random yang dihasilkan selama proses iterasi MCMC, nilai parameter yang dibangkitkan (*state i*) memungkinkan untuk kembali pada *state i* (representasi sifat *recurrent*). Sehingga sifat rantai markov *ergodic* telah terpenuhi. Selanjutnya pada *autocorrelation plot* memperlihatkan bahwa nilai autokorelasi pada lag nol mendekati satu, sedangkan untuk lag-lag lainnya mendekati nol. Hal ini menunjukkan bahwa korelasi diantara nilai-nilai sampel yang dibangkitkan telah berada di daerah distribusi *posterior*. Hal ini diperkuat oleh *kernel density* yang menunjukkan estimasi *density posterior* untuk parameter model yang memberikan pola distribusi yang halus dan cenderung memiliki pusat di tengah (*bell shape*). Dengan demikian hasil estimasi parameter telah memenuhi sifat yang konvergen. Hal ini telah membuktikan bahwa sampel yang dibangkitkan dari proses MCMC tersebut merupakan sampel yang berasal dari distribusi *posterior* target parameter. Berikutnya dilakukan pengujian estimasi untuk masing-masing parameter model. Hasil pengujian estimasi yang diperoleh berdasarkan distribusi *posterior*nya dapat dilihat pada Tabel 4.17.

Tabel 4.17 Estimasi Parameter Model MNAR(3;1,2,[11])

Parameter	Rata-Rata	Standar Deviasi	2,50%	97,50%
P[1]	0,334	0,006829	0,3206	0,3475
P[2]	0,3338	0,006926	0,3203	0,3474
P[3]	0,3321	0,006878	0,3188	0,3455
b1[1]	-0,2489	0,02428	-0,2971	-0,2014
b1[2]	-0,2729	0,02511	-0,3224	-0,2239
b1[3]	0,05898	0,02509	0,0105	0,1082
b2[2]	-0,09693	0,0252	-0,1461	-0,04813
sigma[1]	0,02585	4,64 x10 ⁻⁴	0,02496	0,02678
sigma[2]	0,02576	4,61 x10 ⁻⁴	0,02487	0,02669
sigma[3]	0,02673	4,80 x10 ⁻⁴	0,02579	0,0277

Tabel 4.17 memberikan informasi bahwa semua parameter model MNAR memiliki *credible interval* 95 persen yang tidak memuat 0 (nol). Hal ini berarti bahwa parameter model telah signifikan untuk digunakan. Dari Tabel 4.15 terlihat bahwa terdapat 4 parameter yang diestimasi yaitu parameter $b_1[j]$, $b_2[j]$, $P[j]$ dan $\sigma[j]$, dengan $j=1,2,3$. $b_1[1]$ merupakan estimasi parameter dari model AR(1) pada komponen pertama, $b_1[2]$ dan $b_2[2]$ merupakan estimasi parameter dari model AR(2) pada komponen kedua serta $b_1[3]$ merupakan estimasi parameter dari model AR[11] pada komponen ketiga. Karena semua parameter model AR signifikan maka dapat dikatakan bahwa *return* saham UNVR ini dipengaruhi oleh *return* saham 1 hari, 2 hari atau 11 hari yang lalu. Parameter P dan σ yang signifikan menunjukkan bahwa proporsi dan nilai standar deviasi masing-masing komponen berbeda. Sehingga persamaan model MNAR(3;1,2,[11]) dapat ditulis seperti berikut:

$$(\dot{Z}_t | \mathcal{F}_{t-1}) = 0,334 \left(\frac{\dot{Z}_t + 0,2489}{0,02585} \right) + \Phi \left(\frac{\dot{Z}_t + 0,2729 Z_{t-1} + 0,09693 Z_{t-2}}{0,02576} \right) + \\ 0,3321 \Phi \left(\frac{\dot{Z}_t + 0,05898 Z_{t-11}}{0,02673} \right).$$



Gambar 4.26 Distribusi Plot *Return* UNVR 3 Komponen

Dengan demikian dapat diperoleh distribusi plot *return* saham UNVR 3 komponen seperti yang disajikan dalam Gambar 4.26.

4.2.4 Pemilihan Model Terbaik

Setelah diperoleh beberapa model yang layak untuk mewakili data *return* saham, langkah selanjutnya yaitu melakukan pemilihan model terbaik. Dalam penelitian, pemilihan model terbaik dilakukan berdasarkan dengan nilai *DIC* (*Deviance Information Criteria*) yang disajikan pada Tabel 4.18.

Tabel 4.18 memberikan informasi bahwa pemodelan *return* saham ASII, TLKM dan UNVR menggunakan metode univariat yaitu ARIMA diperoleh nilai DIC yang lebih besar dibandingkan dengan menggunakan metode MNAR. Dengan demikian dapat dikatakan bahwa metode MNAR dapat digunakan untuk memodelkan *return* saham ASII, TLKM dan UNVR dengan lebih baik.

Tabel 4.18 Perbandingan Nilai DIC Antara Model ARIMA dengan MNAR

Saham	Metode	Model ARIMA	DIC
ASII	Bayesian ARIMA	ARIMA([3],0,0)	-7.757,78
		ARIMA([3,6],0,0)	-7.743,97
	Bayesian MNAR	MNAR(2;[3],[3,6])	-11.103,20
		MNAR(3;[3],[3,6]),0)	-12.807,90
TLKM	Bayesian ARIMA	ARIMA([2],0,0)	-8.271,54
		ARIMA([3],0,0)	-8.256,44
		ARIMA([4],0,0)	-8.250,15
		ARIMA([2,3],0,0)	-8.275,24
		ARIMA([3,4],0,0)	-8.259,21
		ARIMA([2,3,4],0,0)	-8282.64
	Bayesian MNAR	MNAR(2;[2,3],[3,4])	-12.178,80
		MNAR(2;[2],[3])	-12.168,60
		MNAR(2;[2],[4])	-12.165,20
		MNAR(2;[3],[4])	-12.151,50
UNVR	Bayesian ARIMA	MNAR(2;[2],[3],[4])	-14.419,00
		MNAR(3;[2,3],[3,4],[2,3,4])	-14.461,90
		ARIMA(2,0,0)	-7.043,92
	Bayesian ARIMA	ARIMA([11],0,0)	-6.889,91
		ARIMA([1,2,11],0,0)	-7.000,17
Bayesian MNAR	Bayesian MNAR	MNAR(2;2,[11])	-9.586,14
		MNAR(3;1,2,[11])	-10.622,00

Dalam penelitian ini akan digunakan model MNAR dengan 3 komponen karena pada ketiga saham tersebut diperoleh nilai DIC terkecil ketika menggabungkan model AR(p) menjadi 3 komponen *mixture*. Saham ASII akan diwakili oleh model MNAR(3;[3],[3,6],0), saham TLKM oleh model MNAR (3;[2,3], [3,4],[2,3,4]) dan saham UNVR oleh model MNAR(3; 1,2,[11]). Model terbaik yang terpilih pada masing-masing saham akan digunakan untuk menghitung besarnya risiko investasi menggunakan metode *Value at Risk* (*VaR*).

4.2.5 Perhitungan *Value at Risk* berdasarkan Model MNAR Terbaik

Untuk menghitung besarnya risiko yang akan ditanggung oleh investor apabila investor tersebut menanamkan asetnya pada saham ASII, TLKM dan UNVR digunakan metode *Value at Risk*

dengan pendekatan MNAR dan diperoleh hasil seperti yang ditampilkan dalam Tabel 4.19.

Tabel 4.19 Perhitungan *Value at Risk* (VaR)

Saham	Lama Investasi	Quantile 5%	Quantile 1%
ASII	1 Hari	-0.0346	-0.04889
	5 Hari	-0.0773	-0.10925
	20 hari	-0.1545	-0.21844
TLKM	1 Hari	-0.04306	-0.06086
	5 Hari	-0.09616	-0.13595
	20 Hari	-0.19223	-0.2718
UNVR	1 Hari	-0.14573	-0.16352
	5 Hari	-0.19882	-0.23859
	20 Hari	-0.29486	-0.37441

Tabel 4.19 memberikan informasi mengenai hasil estimasi *VaR* dengan berbagai lamanya investasi tersebut dilakukan. Nilai *VaR* untuk saham ASII sebesar -0,0346, TLKM sebesar -0,04306 dan UNVR sebesar -0,14573. ASII adalah terendah dari ketiga saham tersebut yaitu sebesar -0,0346, yang menunjukkan bahwa dengan tingkat kepercayaan 95%, kemungkinan kerugian maksimum yang dapat ditolerir oleh investor adalah 0,0346 rupiah dari aset yang telah diinvestasikan. Misalkan seorang investor menanamkan asetnya pada saham PT Astra International Tbk yaitu sebesar Rp 100.000.000,-. Maka kemungkinan kerugian maksimum yang dapat ditolerir oleh investor sebesar Rp 3.460.000,-. Hal ini berarti bahwa 5% peluang investor tersebut akan mengalami kerugian yang melebihi Rp 3.460.000,- dalam 1 hari ke depan. Sedangkan untuk *VaR* sebesar -0,0773 menunjukkan bahwa 5% peluang investor tersebut akan mengalami kerugian yang melebihi 0,0773 rupiah dari aset yang telah diinvestasikan dalam 5 hari ke depan atau dengan tingkat kepercayaan 95%, dalam kurun 5 hari ke depan investor akan mengalami kerugian maksimal sebesar 0,0773 dari aset yang diinvestasikan. Tabel 4.19 juga menunjukkan bahwa semakin lama seorang in-

vestor menanamkan assetnya, maka semakin besar pula risiko yang akan ditanggung oleh investor tersebut. Semakin tinggi tingkat kepercayaan yang digunakan, maka semakin besar pula nilai *VaR* yang dihasilkan atau dengan kata lain kemungkinan kerugian yang didapat akan semakin besar.

Dari ketiga saham JII yang diteliti, nilai *VaR* tertinggi terjadi pada saham TLMK dan terendah pada saham ASII. Jika dilihat dari tingkat risiko yang diterima terdapat 3 tipe investor yaitu *risk averter*, *risk neutral* dan *risk seeker*. Seorang *risk seeker*, akan cenderung memilih berinvestasi pada saham UNVR yang memiliki risiko tertinggi, karena *return* yang tinggi akan diikuti dengan tingkat risiko yang tinggi pula. Sedangkan untuk *risk averter*, akan cenderung memilih berinvestasi pada saham ASII, karena investor jenis ini tidak senang terhadap risiko, dengan konsekuensi tidak dapat mengharapkan tingkat *return* yang terlalu tinggi. Untuk *risk averter* yang tidak menyukai adanya risiko, akan cenderung berinvestasi pada saham ASII, karena saham ASII memiliki *mean return* positif terbesar dengan risiko paling kecil.

(Halaman ini sengaja dikosongkan)

Lampiran 1. Data

- a. Data *Close Price* Dan *Return Saham* PT Astra International Tbk

Date	Close price	Return Saham
1/4/2010	35300	-
1/5/2010	35500	0,005666
1/6/2010	35300	-0,00563
1/7/2010	34200	-0,03116
1/8/2010	34400	0,005848
1/11/2010	34950	0,015988
1/12/2010	35400	0,012876
1/13/2010	35100	-0,00847
1/14/2010	35550	0,012821
1/15/2010	36200	0,018284
1/18/2010	36000	-0,00552
1/19/2010	36250	0,006944
1/20/2010	35800	-0,01241
1/21/2010	35250	-0,01536
1/22/2010	33800	-0,04113
1/25/2010	33400	-0,01183
1/26/2010	33850	0,013473
:	:	:
2/19/2016	6900	-0,02128
2/22/2016	6750	-0,02174
2/23/2016	6525	-0,03333
2/24/2016	6400	-0,01916
2/25/2016	6425	0,003906
2/26/2016	6800	0,058366
2/29/2016	6800	0

Lampiran 1 (Lanjutan)

b. Data *Close Price* Dan *Return Saham* PT Telekomunikasi Indonesia Tbk

Date	Close price	Return Saham
1/4/2010	9550	-
1/5/2010	9600	0,005236
1/6/2010	9500	-0,01042
1/7/2010	9250	-0,02632
1/8/2010	9350	0,010811
1/11/2010	9450	0,010695
1/12/2010	9500	0,005291
1/13/2010	9400	-0,01053
1/14/2010	9350	-0,00532
1/15/2010	9500	0,016043
1/18/2010	9400	-0,01053
1/19/2010	9450	0,005319
1/20/2010	9500	0,005291
1/21/2010	9450	-0,00526
1/22/2010	9300	-0,01587
1/25/2010	9250	-0,00538
:	:	:
2/18/2016	3315	-0,006
2/19/2016	3195	-0,0362
2/22/2016	3180	-0,00469
2/23/2016	3220	0,012579
2/24/2016	3230	0,003106
2/25/2016	3300	0,021672
2/26/2016	3310	0,00303
2/29/2016	3250	-0,01813

Lampiran 1 (Lanjutan)

- c. Data *Close Price* Dan *Return Saham* PT Unilever Indonesia Tbk

Date	Close	Return Saham
1/4/2010	11050	-
1/5/2010	11400	0,031674
1/6/2010	11300	-0,00877
1/7/2010	11100	-0,0177
1/8/2010	11150	0,004505
1/11/2010	11250	0,008969
1/12/2010	11100	-0,01333
1/13/2010	11050	-0,0045
1/14/2010	11000	-0,00452
1/15/2010	11000	0
1/18/2010	11000	0
1/19/2010	11300	0,027273
1/20/2010	11650	0,030973
1/21/2010	11550	-0,00858
1/22/2010	11550	0
1/25/2010	11450	-0,00866
:	:	:
2/18/2016	41675	0,00786
2/19/2016	42750	0,025795
2/22/2016	43375	0,01462
2/23/2016	42450	-0,02133
2/24/2016	42000	-0,0106
2/25/2016	42725	0,017262
2/26/2016	43900	0,027501
2/29/2016	44525	0,014237

Lampiran 2. Program Code Model ARIMA Untuk *Return* Saham ASII

a. Model AR[3]

```

model;
{
  for( t in 1 : 1585 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  for( t in 1 : 1585 ) {
    mu[t] <- a[1] * z1[t]
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1585){
    error[t]<-z[t]-mu[t]
  }
}
INITIAL
list(a=c(1), tau=1)

DATA
list(z=c(0.005848, 0.015988, 0.012876, -0.008475, 0.012821, 0.018284, -
0.005525, 0.006944, -0.012414, -0.015363, -0.041135, -0.011834,...),
z1=c(0.005666, -0.005634, -0.031161, 0.005848, 0.015988, 0.012876, -
0.008475. 0.012821. 0.018284. -0.005525. 0.006944. -0.012414....))

```

b. Model AR[6]

```

model;
{
  for( t in 1 : 1582 ) {
    mu[t] <- a[1] * z2[t]
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)
  for( t in 1 : 1582 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
}
INITIAL
list(a=c(1), tau=1)

DATA
list(z=c(-0.008475, 0.012821, 0.018284, -0.005525, 0.006944, -0.012414, -
0.015363, -0.041135, -0.011834, 0.013473, 0.014771,...),
z2=c(0.005666, -0.005634, -0.031161, 0.005848, 0.015988, 0.012876, -
0.008475, 0.012821, 0.018284, -0.005525, 0.006944, -0.012414,...))

```

Lampiran 2 (Lanjutan)

c. Model AR[3,6]

```

model;
{
  for( t in 1 : 1582 ) {
    mu[t] <- a[1] * z1[t] + a[2] * z2[t]
  }
  for( t in 1 : 1582 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)
  a[2] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1582){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(a=c(1,1), tau=1)

DATA
list(z=c(-0.008475, 0.012821, 0.018284, -0.005525, 0.006944, -0.012414, -
0.015363, -0.041135, -0.011834, 0.013473, 0.014771,...),
z1=c(0.005848, 0.015988, 0.012876, -0.008475, 0.012821, 0.018284, -0.005525,
0.006944, -0.012414, -0.015363, -0.041135, -0.011834,...),
z2=c(0.005666, -0.005634, -0.031161, 0.005848, 0.015988, 0.012876, -0.008475,
0.012821, 0.018284, -0.005525, 0.006944, -0.012414,...))

```

Lampiran 3. Program Code Model ARIMA Untuk Return Saham TLKM

a. Model AR[2]

```

model;
{
  for( t in 1 : 1572 ) {
    mu[t] <- a[1] * z2[t]
  }
  for( t in 1 : 1572 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1572){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(a=c(1), tau=1)

DATA
list(z=c(-0.026315789, 0.010810811, 0.010695187, 0.005291005, -,...),
z2=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, 0.010695187,
0.005291005, -0.010526316, -0.005319149, 0.016042781,...))

```

b. Model AR[3]

```

model;
{
  for( t in 1 : 1571 ) {
    mu[t] <- a[1] * z3[t]
  }
  for( t in 1 : 1571 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1571){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(a=c(1), tau=1)

DATA
list(z=c(0.010810811, 0.010695187, 0.005291005, -0.010526316, -,...),
z3=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, 0.010695187,...))

```

Lampiran 3 (Lanjutan)

c. Model AR[4]

```

model;
{
  for( t in 1 : 1570) {
    mu[t] <- a[1] * z4[t]
  }
  for( t in 1 : 1570) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1570){
    error[t]<-z[t]-mu[t]
  }
}

NITIAL
list(a=c(1), tau=1)

DATA
list(z=c(0.010695187, 0.005291005, -0.010526316, -0.005319149, 0.016042781,...),
z4=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, 0.010695187,...))

```

d. Model AR[2,3]

```

model;
{
  a[2] ~ dnorm( 0.0,1.0E-6)
  for( t in 1 : 1571 ) {
    mu[t] <- a[1] * z2[t] + a[2] * z3[t]
  }
  for( t in 1 : 1571 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1571){
    error[t]<-z[t]-mu[t]
  }
}

NITIAL
list(a=c(1,1), tau=1)

DATA
list(z=c(0.010810811, 0.010695187, 0.005291005, -0.010526316, -0.005319149,...),
z2=c(-0.010416667, -0.026315789, 0.010810811, 0.010695187, 0.005291005,...),
z3=c(0.005235602 -0.010416667 -0.026315789 0.010810811 0.010695187 ))
```

Lampiran 3 (Lanjutan)**e. Model AR[3,4]**

```

model;
{
  a[2] ~ dnorm( 0.0,1.0E-6)
  for( t in 1 : 1570 ) {
    mu[t] <- a[1] * z2[t] + a[2] * z3[t]
  }
  for( t in 1 : 1570 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1570){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(a=c(1,1), tau=1)

DATA
list(z=c(0.010695187, 0.005291005, -0.010526316, -0.005319149, 0.016042781,...),
z2=c(-0.026315789, 0.010810811, 0.010695187, 0.005291005,...),
z4=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, 0.010695187,...))

```

f. Model AR[3,4]

```

model;
{
  for( t in 1 : 1570 ) {
    mu[t] <- a[1] * z3[t] + a[2] * z4[t]
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  for( t in 1 : 1570 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  a[2] ~ dnorm( 0.0,1.0E-6)
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1570){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(a=c(1,1), tau=1)

DATA
list(z=c(0.010695187, 0.005291005, -0.010526316, -0.005319149, 0.016042781,...),
z3=c(-0.010416667, -0.026315789, 0.010810811, 0.010695187, 0.005291005,...),
z4=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, 0.010695187,...))

```

Lampiran 3 (Lanjutan)

g. Model AR[2,3,4]

```

model;
{
  for( t in 1 : 1570 ) {
    mu[t] <- a[1] * z2[t] + a[2] * z3[t] + a[3] * z4[t]
  }
  for( t in 1 : 1570 ) {
    z[t] ~ dnorm(mu[t], tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  a[1] ~ dnorm( 0.0,1.0E-6)
  a[2] ~ dnorm( 0.0,1.0E-6)
  a[3] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1570){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(a=c(1,1,1), tau=1)

DATA
list(z=c(0.010695187, 0.005291005, -0.010526316, -0.005319149, 0.016042781,...),
      z2=c(-0.026315789, 0.010810811, 0.010695187, 0.005291005, -0.010526316,...),
      z3=c(-0.010416667, -0.026315789, 0.010810811, 0.010695187, 0.005291005,...),
      z4=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, 0.010695187,...))

```

Lampiran 4. Program Code Model ARIMA Untuk Return Saham UNVR

a. Model AR(2)

```

model;
{
  for( t in 1 : 1572 ) {
    mu[t] <- a[1] * z1[t] + a[2] * z2[t]
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  for( t in 1 : 1572 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  a[1] ~ dnorm( 0.0,1.0E-6)
  a[2] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1572){
    error[t]<-z[t]-mu[t]
  }
}
INITIAL
list(a=c(1,1), tau=1)

DATA
list(z=c(-0.017699115, 0.004504505, 0.00896861, -0.013333333, -0.004504505,...),
z1=c(-0.00877193, -0.017699115, 0.004504505, 0.00896861, -0.013333333,...),
z2=c(0.031674208, -0.00877193, -0.017699115, 0.004504505, 0.00896861,...))

```

b. Model AR[11]

```

model;
{
  for( t in 1 : 1563 ) {
    mu[t] <- a[1] * z11[t]
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  for( t in 1 : 1563 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  a[1] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1563){
    error[t]<-z[t]-mu[t]
  }
}
INITIAL
list(a=c(1), tau=1)

DATA
list(z=c(0.030973451, -0.008583691, 0, -0.008658009, 0, 0, -0.004366812,...),
z11=c(0.031674208, -0.00877193, -0.017699115, 0.004504505, 0.00896861,...))

```

Lampiran 4 (Lanjutan)

c. Model AR[1,2,11]

```

model;
{
  for( t in 1 : 1563 ) {
    z[t] ~ dnorm(mu[t],tau)
  }
  tau ~ dgamma(0.001,0.001)
  sigma <- 1 / sqrt(tau)
  for( t in 1 : 1563 ) {
    mu[t] <- a[1] * z1[t] + a[2] * z2[t] + a[3] * z11[t]
  }
  a[2] ~ dnorm( 0.0,1.0E-6)
  a[1] ~ dnorm( 0.0,1.0E-6)
  a[3] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:1563){
    error[t]<-z[t]-mu[t]
  }
}
INITIAL
list(a=c(1,1,1), tau=1)

DATA
list(z=c(0.030973451, -0.008583691, 0, -0.008658009, 0, 0, -0.004366812,...),
      z1=c(0.027272727, 0.030973451, -0.008583691, 0, -0.008658009, 0, 0, -
            0.004366812, -0.00877193, 0.013274336, 0, 0.013100437, ...),
      z2=c(0, 0.027272727, 0.030973451, -0.008583691, 0, -0.008658009, 0, 0, -
            0.004366812, -0.00877193, 0.013274336, 0, 0.013100437, ...),
      z11=c(0.031674208, -0.00877193, -0.017699115, 0.004504505, 0.00896861, -
            0.013333333, -0.004504505, -0.004524887, 0, 0,...))

```

Lampiran 5 Hasil Output Pengujian Residuala. *Run Test****Return Saham ASII*****Runs test for E1 (Model AR[3])**

Runs above and below K = 0.000699214
The observed number of runs = 674
The expected number of runs = 680.930
654 observations above K, 708 below
P-value = 0.707

Runs test for E2 (Model AR[3,6])

Runs above and below K = 0.000856950
The observed number of runs = 769
The expected number of runs = 772.229
736 observations above K, 810 below
P-value = 0.869

Return Saham TLKM

Runs test for E1_tel (Model AR[2])
Runs above and below K = 0.000885093
The observed number of runs = 649
The expected number of runs = 647.975
651 observations above K, 643 below
P-value = 0.955

Runs test for E2_tel (Model AR[3])

Runs above and below K = 0.000699278
The observed number of runs = 686
The expected number of runs = 647.360
637 observations above K, 656 below
P-value = 0.032

Runs test for E3_tel (Model AR[4])

Runs above and below K = 0.000377969
The observed number of runs = 686
The expected number of runs = 646.813
657 observations above K, 635 below
P-value = 0.029

Lampiran 5 (Lanjutan)

```
Runs test for E4_tel (Model AR[2,3,4])
Runs above and below K = 0.000632086
The observed number of runs = 804
The expected number of runs = 774.228
788 observations above K, 759 below
P-value = 0.130
```

```
Runs test for e5_tel (Model AR[2,3])
Runs above and below K = 0.000615528
The observed number of runs = 758
The expected number of runs = 748.403
739 observations above K, 756 below
P-value = 0.619
```

```
Runs test for e6_tel (Model AR[3,4])
Runs above and below K = 0.000631787
The observed number of runs = 766
The expected number of runs = 747.738
733 observations above K, 761 below
P-value = 0.344
```

Return Saham UNVR

```
Runs test for E1_unv (Model AR(2))
Runs above and below K = 0.00168713
The observed number of runs = 652
The expected number of runs = 766.665
735 observations above K, 799 below
P-value = 0.000
```

```
Runs test for E2_unv (Model AR[11])
Runs above and below K = 0.00113904
The observed number of runs = 747
The expected number of runs = 686.455
634 observations above K, 746 below
P-value = 0.001
```

```
Runs test for E3_unv (Model AR[1,2,11])
Runs above and below K = 0.00160576
The observed number of runs = 663
The expected number of runs = 779.851
757 observations above K, 802 below
P-value = 0.000
```

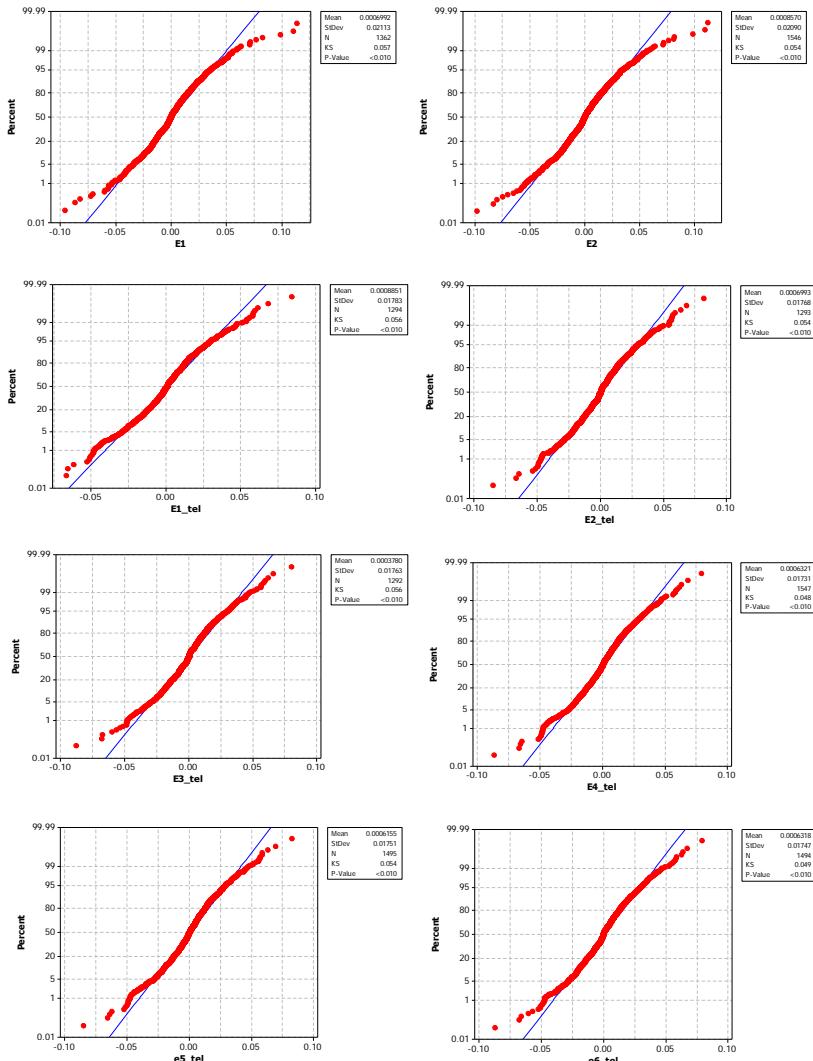
Lampiran 5 (Lanjutan)

b. Pengujian Lagrange Multiplier (LM)

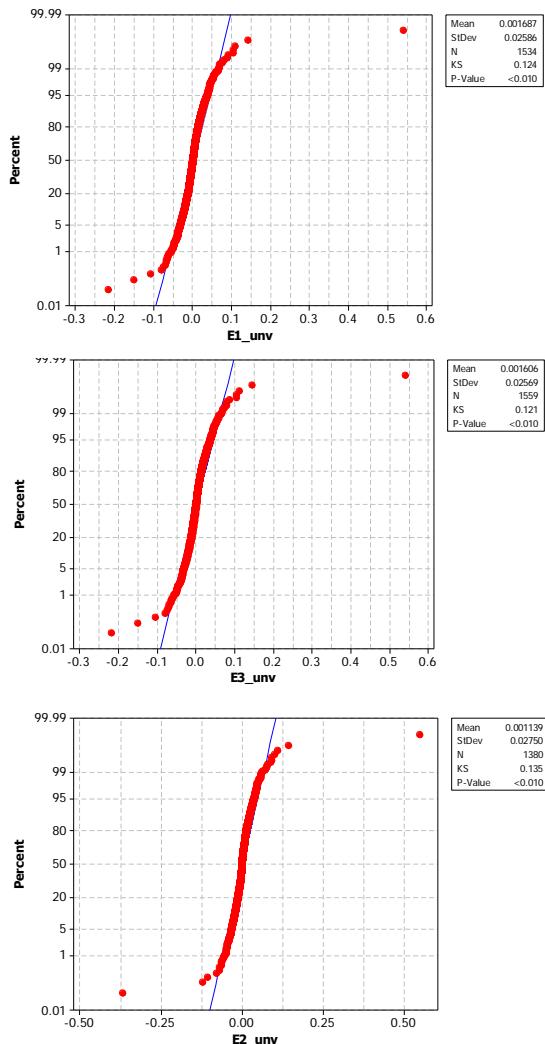
<i>Return Saham ASII</i>					
AR[3]	chi-square	p-value	AR[3,6]	chi-square	p-value
[1,]	6.620871	1.01E-02	[1,]	12.88057	3.32E-04
[2,]	10.185668	6.14E-03	[2,]	18.72739	8.58E-05
[3,]	32.933576	3.33E-07	[3,]	82.489	0.00E+00
[4,]	39.235569	6.23E-08	[4,]	99.44376	0.00E+00
[5,]	73.855478	1.61E-14	[5,]	121.00172	0.00E+00
[6,]	75.036775	3.77E-14	[6,]	123.93098	0.00E+00
[7,]	78.476209	2.82E-14	[7,]	145.38292	0.00E+00
[8,]	79.657871	5.73E-14	[8,]	149.49119	0.00E+00
[9,]	80.021704	1.60E-13	[9,]	152.9642	0.00E+00
[10,]	81.470172	2.58E-13	[10,]	163.62103	0.00E+00
[11,]	81.967032	6.14E-13	[11,]	163.89396	0.00E+00
[12,]	83.457144	9.00E-13	[12,]	164.76885	0.00E+00
<i>Return Saham TLKM</i>					
AR[2]	chi-square	p-value	AR[3]	chi-square	p-value
[1,]	84.75072	0	[1,]	23.3082	1.38E-06
[2,]	93.09096	0	[2,]	29.67715	3.59E-07
[3,]	130.34269	0	[3,]	34.00081	1.98E-07
[4,]	159.7193	0	[4,]	43.41562	8.48E-09
[5,]	176.97019	0	[5,]	45.78633	1.00E-08
[6,]	181.06388	0	[6,]	48.08095	1.14E-08
[7,]	181.98964	0	[7,]	51.86436	6.21E-09
[8,]	184.42577	0	[8,]	51.78788	1.85E-08
[9,]	184.50483	0	[9,]	53.15487	2.73E-08
[10,]	189.32876	0	[10,]	54.22208	4.41E-08
[11,]	196.92626	0	[11,]	54.22291	1.07E-07
[12,]	199.71675	0	[12,]	58.32691	4.55E-08
AR[4]	chi-square	p-value	AR[2,3,4]	chi-square	p-value
[1,]	39.05809	4.11E-10	[1,]	51.45104	7.34E-13
[2,]	43.82102	3.05E-10	[2,]	53.85839	2.02E-12
[3,]	47.1016	3.31E-10	[3,]	61.66127	2.60E-13
[4,]	59.66688	3.41E-12	[4,]	67.76888	6.71E-14
[5,]	59.93538	1.25E-11	[5,]	72.70578	2.80E-14
[6,]	60.47512	3.60E-11	[6,]	74.22634	5.54E-14
[7,]	65.28276	1.32E-11	[7,]	77.41278	4.64E-14
[8,]	65.29572	4.22E-11	[8,]	77.85676	1.32E-13
[9,]	69.36294	2.03E-11	[9,]	78.78228	2.82E-13
[10,]	71.36306	2.42E-11	[10,]	81.63144	2.40E-13
[11,]	71.20688	7.20E-11	[11,]	85.59894	1.21E-13
[12,]	71.5015	1.68E-10	[12,]	85.72873	3.30E-13

Lampiran 5 (Lanjutan)

Return Saham TLKM			Return Saham UNVR		
AR[2,3]	chi-square	p-value	AR[3,4]	chi-square	p-value
[1,]	96.26504	0	[1,]	44.85803	2.12E-11
[2,]	102.74852	0	[2,]	51.66673	6.04E-12
[3,]	115.63173	0	[3,]	55.11233	6.50E-12
[4,]	134.26728	0	[4,]	62.38895	9.12E-13
[5,]	143.42729	0	[5,]	65.03897	1.10E-12
[6,]	148.22327	0	[6,]	66.53168	2.10E-12
[7,]	159.58388	0	[7,]	68.96087	2.40E-12
[8,]	159.60876	0	[8,]	69.02574	7.68E-12
[9,]	160.36457	0	[9,]	69.25134	2.13E-11
[10,]	174.19135	0	[10,]	73.80666	8.12E-12
[11,]	178.08399	0	[11,]	74.79284	1.49E-11
[12,]	178.2081	0	[12,]	74.88284	3.87E-11
Return Saham UNVR			Return Saham UNVR		
AR(2)	chi-square	p-value	AR[11]	chi-square	p-value
[1,]	37.48863	9.19E-10	[1,]	191.7885	0
[2,]	37.69561	6.52E-09	[2,]	214.7705	0
[3,]	37.79462	3.12E-08	[3,]	219.067	0
[4,]	39.37727	5.82E-08	[4,]	219.9598	0
[5,]	39.35121	2.02E-07	[5,]	220.0528	0
[6,]	39.32345	6.19E-07	[6,]	219.9095	0
[7,]	39.31444	1.70E-06	[7,]	219.7487	0
[8,]	39.30146	4.32E-06	[8,]	219.7789	0
[9,]	39.29135	1.02E-05	[9,]	219.6286	0
[10,]	39.32997	2.22E-05	[10,]	219.5105	0
[11,]	40.25447	3.24E-05	[11,]	219.382	0
[12,]	40.36258	6.26E-05	[12,]	219.2231	0
AR[1,2,11]	chi-square	p-value	Return Saham UNVR		
[1,]	40.03773	2.49E-10	Return Saham UNVR		
[2,]	40.28932	1.78E-09	Return Saham UNVR		
[3,]	40.39135	8.80E-09	Return Saham UNVR		
[4,]	42.0091	1.66E-08	Return Saham UNVR		
[5,]	41.98214	5.94E-08	Return Saham UNVR		
[6,]	41.95368	1.88E-07	Return Saham UNVR		
[7,]	41.96841	5.27E-07	Return Saham UNVR		
[8,]	41.95875	1.38E-06	Return Saham UNVR		
[9,]	41.95522	3.35E-06	Return Saham UNVR		
[10,]	41.9482	7.66E-06	Return Saham UNVR		
[11,]	42.08597	1.57E-05	Return Saham UNVR		
[12,]	42.11368	3.19E-05	Return Saham UNVR		

Lampiran 5 (Lanjutan)c. Pengujian *Kolmogorov-Smirnov*

Lampiran 5 (Lanjutan)



Lampiran 6 Uji Kesesuaian Distribusi

a. *Return Saham ASII*

Goodness of Fit Test		
Distribution	AD	P
Normal	11.362	<0.005
3-Parameter Lognormal	11.045	*
2-Parameter Exponential	462.070	<0.010
3-Parameter Weibull	26.790	<0.005
Smallest Extreme Value	73.283	<0.010
Largest Extreme Value	50.352	<0.010
3-Parameter Gamma	11.417	*
Logistic	3.623	<0.005
3-Parameter Loglogistic	3.533	*

b. *Return Saham TLMK*

Goodness of Fit Test		
Distribution	AD	P
Normal	11.848	<0.005
3-Parameter Lognormal	11.810	*
2-Parameter Exponential	476.437	<0.010
3-Parameter Weibull	22.959	<0.005
Smallest Extreme Value	53.553	<0.010
Largest Extreme Value	54.964	<0.010
3-Parameter Gamma	13.053	*
Logistic	4.975	<0.005
3-Parameter Loglogistic	4.975	*

c. *Return Saham UNVR*

Goodness of Fit Test		
Distribution	AD	P
Normal	11.848	<0.005
3-Parameter Lognormal	11.810	*
2-Parameter Exponential	476.437	<0.010
3-Parameter Weibull	22.959	<0.005
Smallest Extreme Value	53.553	<0.010
Largest Extreme Value	54.964	<0.010
3-Parameter Gamma	13.053	*
Logistic	4.975	<0.005
3-Parameter Loglogistic	4.975	*

Lampiran 7 Model MNAR(2;[3],[3,6]) Untuk *Return* Saham ASII

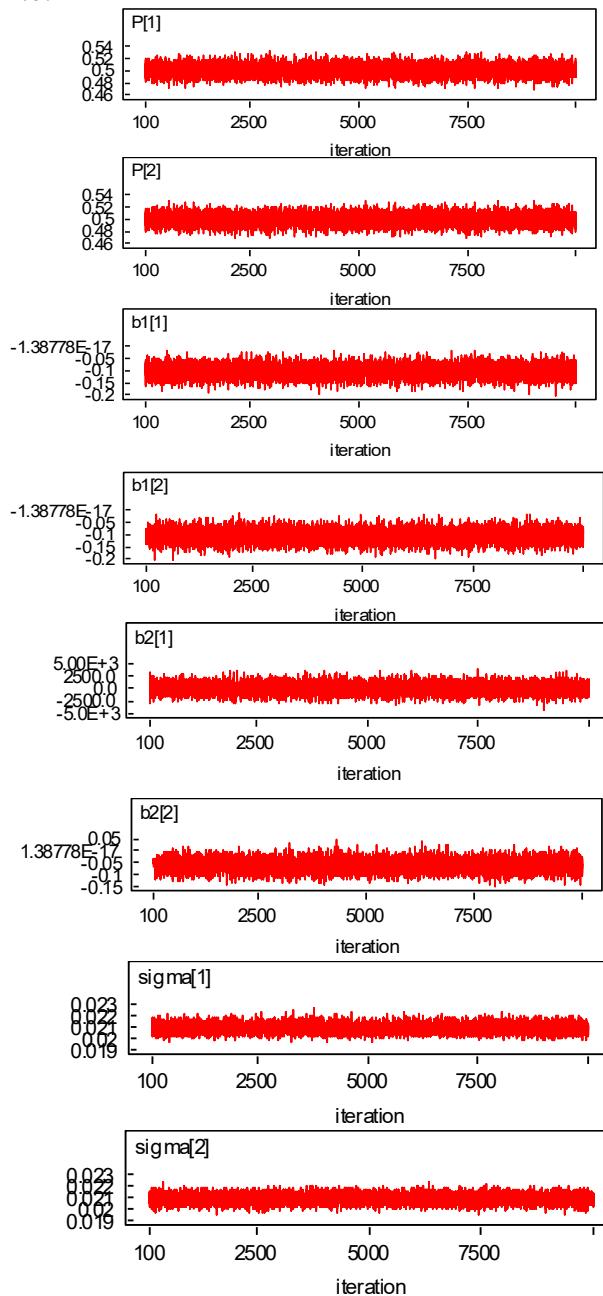
a. *Program Code, Struktur data dan Initial Value*

```

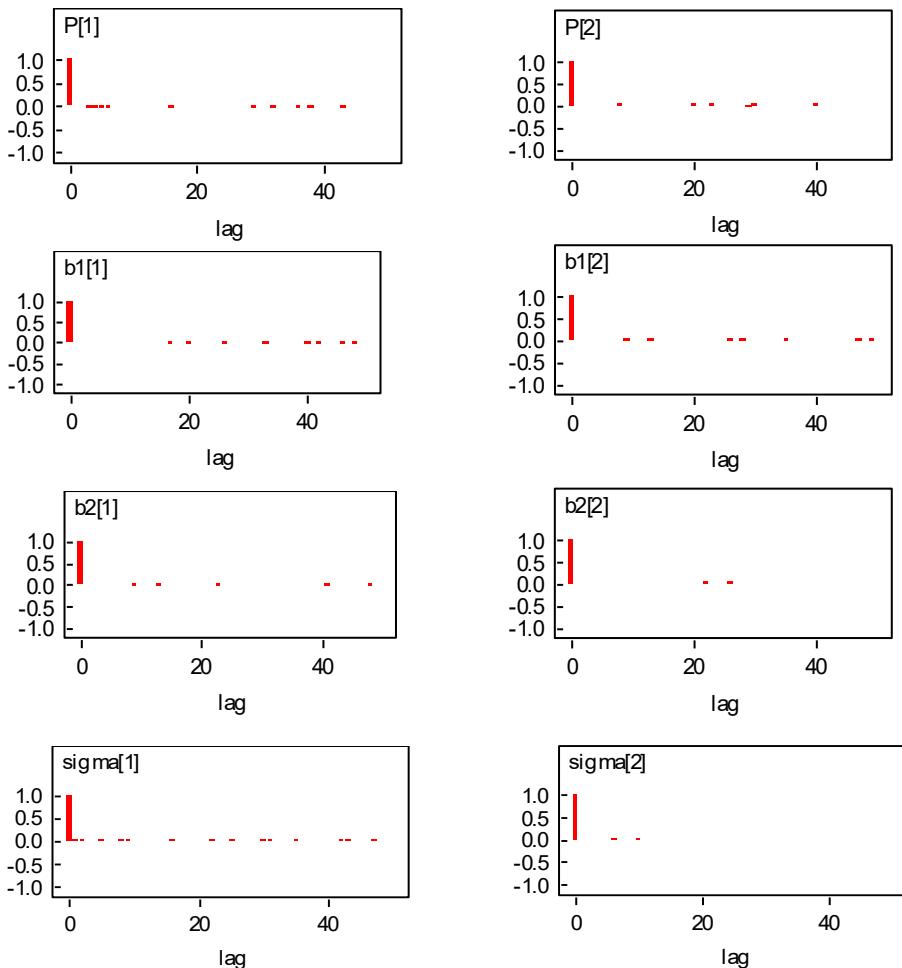
model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i] + b2[T[i]] * z2[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
}
NITIAL
list(b1=c(1,1), b2=c(1,1), tau=c(1,1))

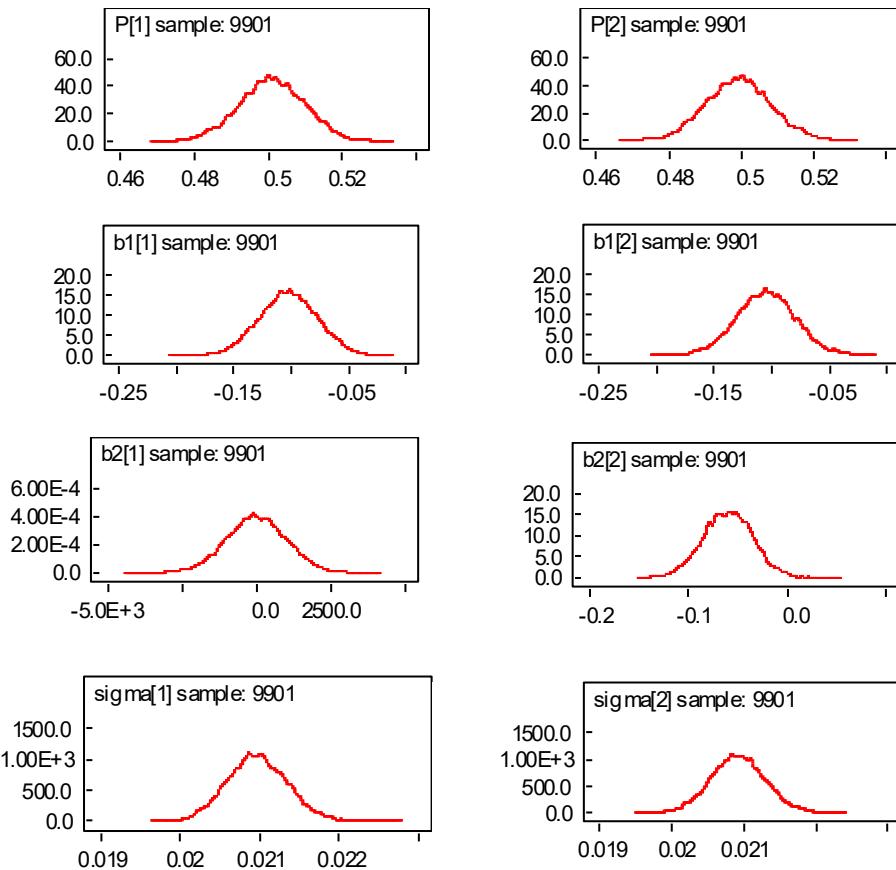
DATA
list(z=c(0.005848, 0.015988, 0.012876,..., -0.008475, 0.012821, 0.018284, -0.005525...),
z1=c(0.005666, -0.005634, -0.031161, 0.005848,..., 0.005848, 0.015988,
0.012876, -0.008475,...),
z2=c(0, 0, 0, 0, 0, 0, 0, 0, 0, 0,..., 0.005666, -0.005634, -0.031161,
0.005848,...),
T=c(1, 1, 1, 1...,2, 2, 2, 2, 2, 2,...,), N=3164, alpha=c(1,1))

```

Lampiran 7 (Lanjutan)b. *History Plot*

Lampiran 7 (Lanjutan)
c. Autocorrelation Plot



Lampiran 7 (Lanjutan)d. *Kernel Density*

Lampiran 8 Model MNAR(3;[3],[3,6],0) Untuk *Return* Saham ASII

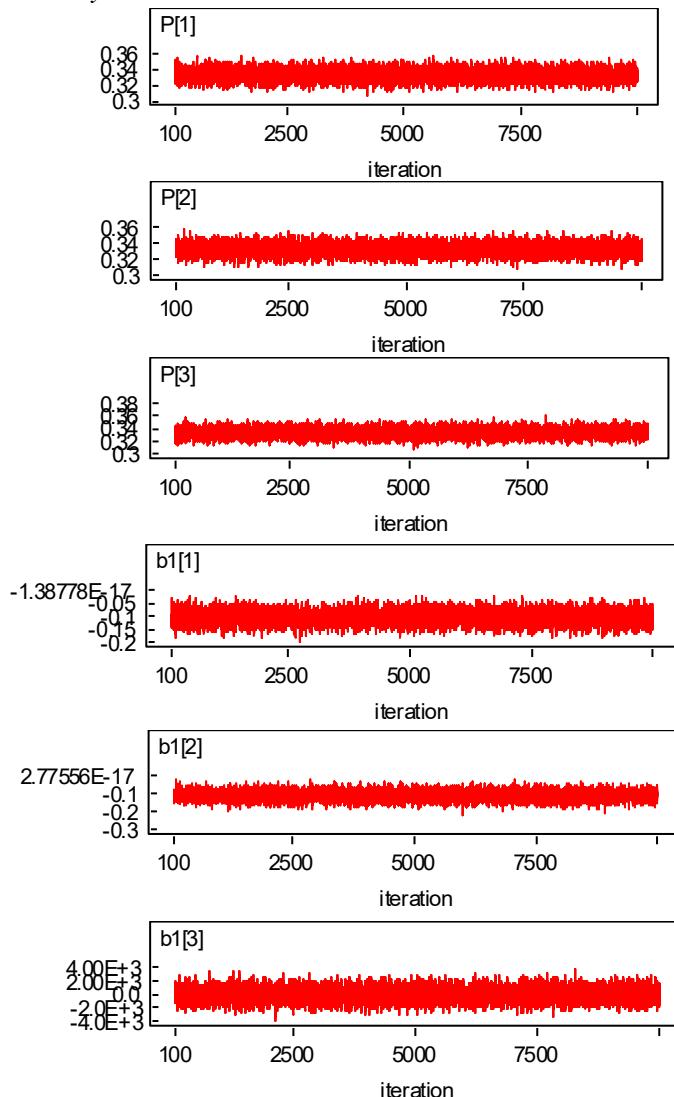
a. *Program Code, Struktur Data dan Initial Value*

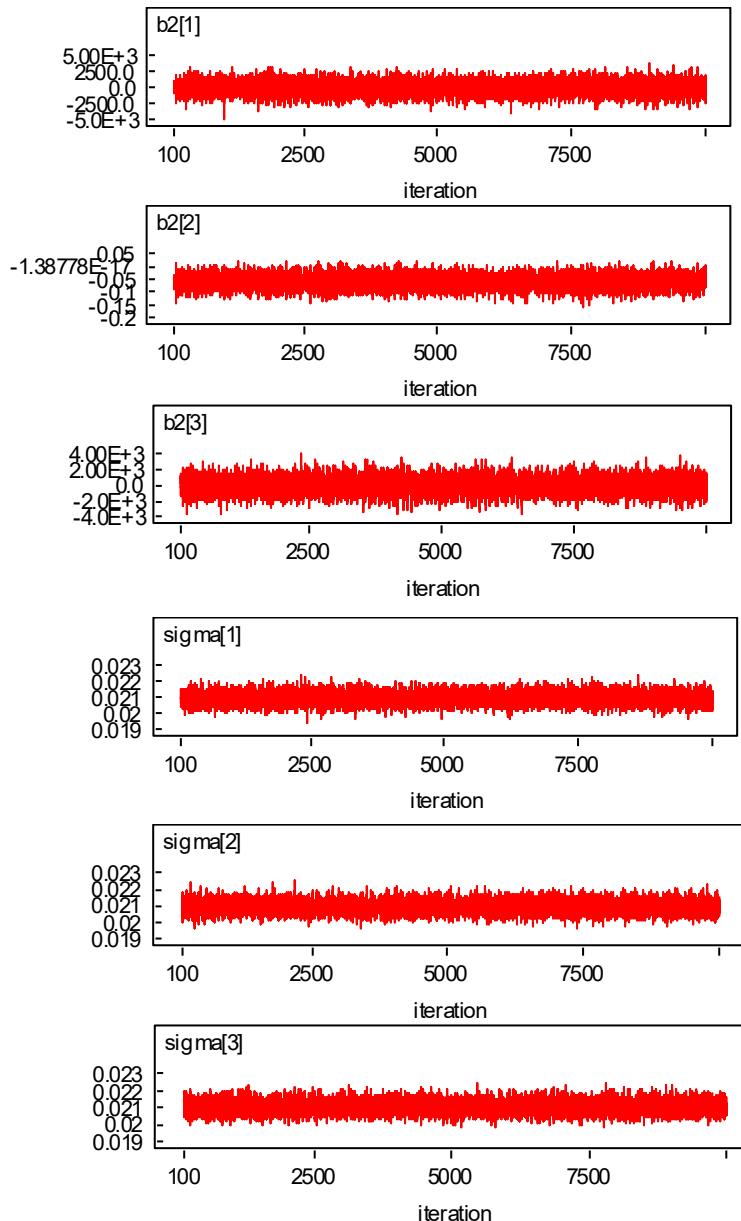
```

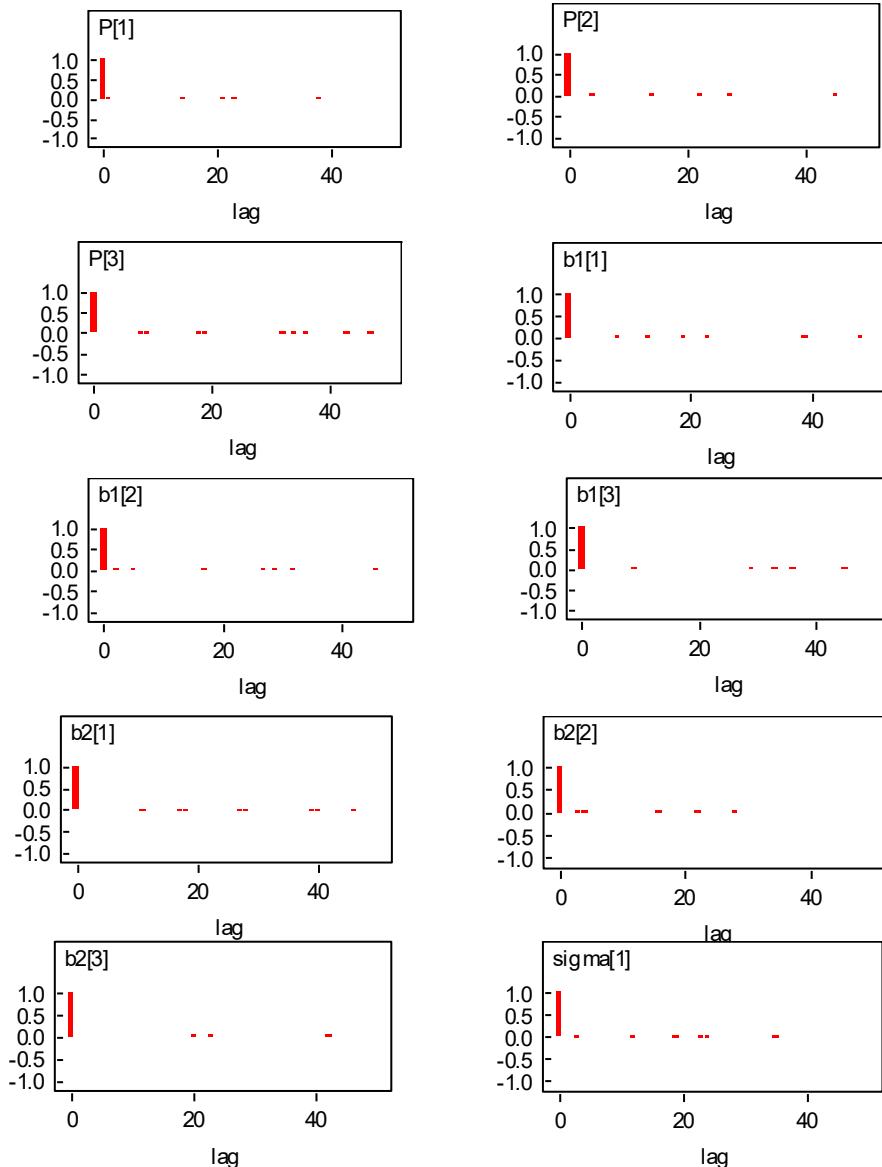
model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i]+b2[T[i]]*z2[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:3])
  }
  P[1:3] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  b1[3] ~ dnorm( 0.0,1.0E-6)
  b2[3] ~ dnorm( 0.0,1.0E-6)
  tau[3] ~ dgamma(0.001,0.001)
  sigma[3] <- 1 / sqrt(tau[3])
}
INITIAL
list(b1=c(1,1,1), b2=c(1,1,1), tau=c(1,1,1))

DATA
list(z=c0.005848, 0.015988, 0.012876, -0.008475,..., -0.008475,
.012821, 0.018284, -0.005525,..., 0.005666, -0.005634, 0.031161,
0.005848,...),
z1=c(0.005666, -0.005634, -0.031161, 0.005848,..., 0.005848,
0.015988, 0.012876, -0.008475,...,0, 0, 0, 0, ...),
z2=c(0, 0, 0, 0, ..., 0.005666, -0.005634, -0.031161, 0.005848,...,0, 0, 0,
0,...),
T=(1, 1, 1, 1, 1,...,2, 2, 2,...,3, 3, 3, 3,...), N=4755, alpha=c(1,1,1))

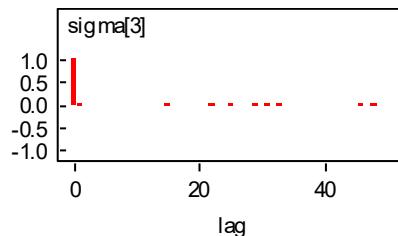
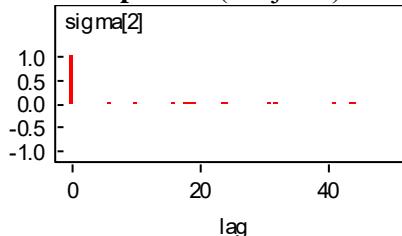
```

Lampiran 8 (Lanjutan)a. *History Plot*

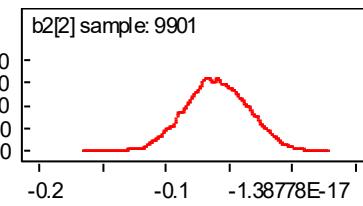
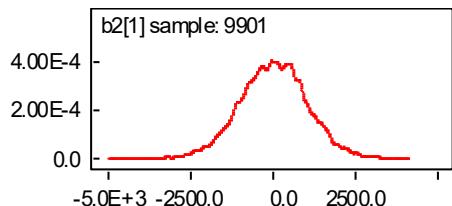
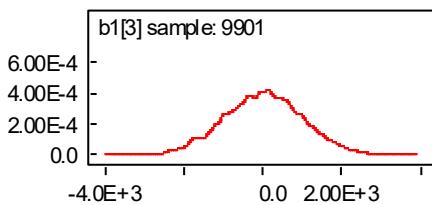
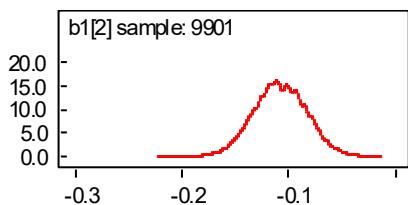
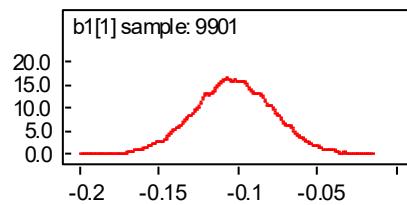
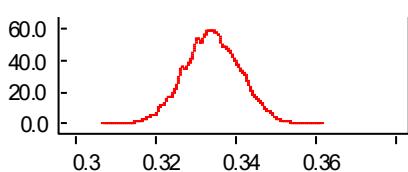
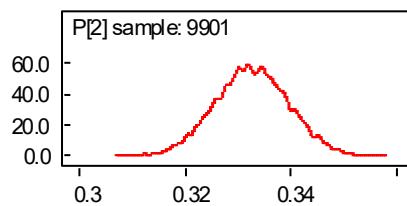
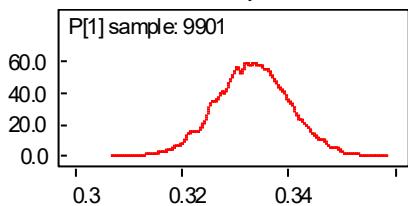
Lampiran 8 (Lanjutan)

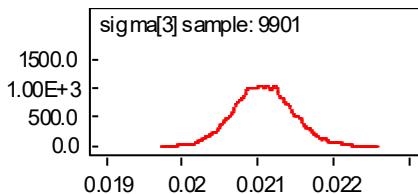
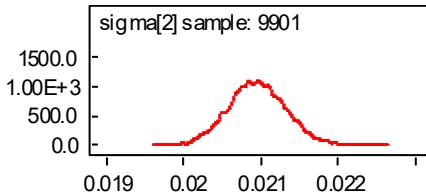
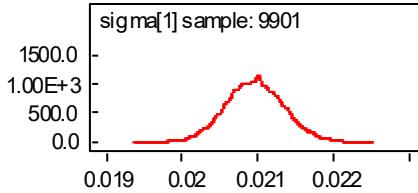
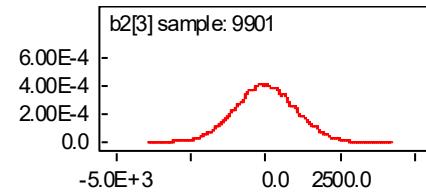
Lampiran 8 (Lanjutan)**b. Autocorrelation Plot**

Lampiran 8 (Lanjutan)



c. Kernel Density



Lampiran 8 (Lanjutan)

Lampiran 9 Program Code, Struktur Data dan Initial Value Untuk Return Saham TLKM

a. Model MNAR(2;[2],[3])

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 /sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
}

NITIAL
list(b1=c(1,1), tau=c(1,1))

DATA
list(z=c(-0.026315789, 0.010810811, 0.010695187, 0.005291005, -
0.010526316,...,0.010810811, 0.010695187, 0.005291005, -
0.010526316,...),
z1=c(0.005235602, -0.010416667, -0.026315789,
0.010810811,...,0.005235602, -0.010416667, -0.026315789,
0.010810811,...),
T=c(1, 1, 1, 1,...,2, 2, 2, 2,...), N=3143, alpha=c(1,1))

```

Lampiran 9 (Lanjutan)

b. Model MNAR (2;[2],[4])

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
}

INITIAL
list(b1=c(1,1), tau=c(1,1))

DATA
list(z=c(-0.026315789, 0.010810811, 0.010695187,.., 0.005235602, -0.010416667, -0.026315789, 0.010810811,...),
      z1=c(0.005235602, -0.010416667, -0.026315789, 0.010810811,...,0.005235602, -0.010416667, -0.026315789, 0.010810811,...),
      T=(1, 1, 1, 1,1,...,2, 2, 2, 2,...), N=3142, alpha=c(1,1))

```

Lampiran 9 (Lanjutan)

c. Model MNAR (2;[3],[4])

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
}

INITIAL
list(b1=c(1,1), tau=c(1,1))

DATA
list(z=c(0.010810811, 0.010695187, 0.005291005,..., 0.010695187,
0.005291005, -0.010526316, -0.005319149...),
z1=c(0.005235602, -0.010416667, -0.026315789,
0.010810811,...,0.005235602, -0.010416667, -0.026315789,
0.010810811,...),
T=c(1, 1, 1, 1,...,2, 2, 2, 2, 2,...), N=3141, alpha=c(1,1))

```

Lampiran 9 (Lanjutan)

d. Model MNAR(2;[2,3],[3,4])

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i] + b2[T[i]] * z2[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirich(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)

  for (t in 1:N){
    error[t]<-z[t]-mu[t]
  }
}

INITIAL
list(b1=c(1,1), b2=c(1,1), tau=c(1,1))

DATA
list(z=c(0.010810811,0.010695187,0.005291005,..., 0.010695187,
0.005291005, -0.010526316, -0.005319149,...),
z1=C(-0.010416667, -0.026315789, 0.010810811, 0.010695187,...,-
0.010416667, -0.026315789, 0.010810811, 0.010695187,...),
z2=c(0.005235602, -0.010416667, -0.026315789, 0.010810811,
0.005235602, -0.010416667, -0.026315789, 0.010810811,..),
T=c(1, 1, 1, 1, ...,2, 2, 2, 2,..), N=3141, alpha=c(1,1))

```

Lampiran 9 (Lanjutan)

e. Model MNAR(3;[2],[3],[4])

```

model;
{
  for( i in 1 : N ){
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:3])
  }
  P[1:3] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 /sqrt(tau[2])
  for( i in 1 : N ){
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b1[3] ~ dnorm( 0.0,1.0E-6)
  tau[3] ~ dgamma(0.001,0.001)
  sigma[3] <- 1 / sqrt(tau[3])
}
NITIAL
list(b1=c(1,1,1), tau=c(1,1,1))

DATA
list(z=c(-0.026315789, 0.010810811, 0.010695187,..., 0.010810811,
0.010695187, 0.005291005, -0.010526316,..., 0.010695187,
0.005291005, -0.010526316, -0.005319149,...),
z1=c(0.005235602, -0.010416667, -0.026315789, 0.010810811,...,
0.005235602, -0.010416667, -0.026315789,
0.010810811,...,0.005235602, -0.010416667, -0.026315789,
0.010810811...),
T=c(1, 1, 1, 1,..., 2, 2, 2, 2, ....,3, 3, 3, 3, 3,...), N=4713,
alpha=c(1,1,1))

```

Lampiran 9 (Lanjutan)

f. Model MNAR(3;[2,3],[3,4],[2,3,4])

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i] + b2[T[i]] * z2[i] + b3[T[i]] * z3[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:3])
  }
  P[1:3] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  b1[3] ~ dnorm( 0.0,1.0E-6)
  b2[3] ~ dnorm( 0.0,1.0E-6)
  tau[3] ~ dgamma(0.001,0.001)
  sigma[3] <- 1 / sqrt(tau[3])
  b3[1] ~ dnorm( 0.0,1.0E-6)
  b3[2] ~ dnorm( 0.0,1.0E-6)
  b3[3] ~ dnorm( 0.0,1.0E-6)
  }
}

INITIAL
list(b1=c(1,1,1), b2=c(1,1,1), b3=c(1,1,1), tau=c(1,1,1))

DATA
list(z=c(0.010810811, 0.010695187, 0.005291005, -0.010526316,...,
0.010695187, 0.005291005, -0.010526316, -0.005319149, ..., 0.010695187,
0.005291005, -0.010526316, -0.005319149,...),
z1=c(-0.010416667, -0.026315789, 0.010810811, 0.010695187,...,-0.010416667,
-0.026315789, 0.010810811, 0.010695187,..., -0.026315789,
0.010810811,0.010695187, 0.005291005,...),
z2=c(0.005235602, -0.010416667, -0.026315789, 0.010810811, ...,0.005235602,
-0.010416667,-0.026315789, 0.010810811,...,-0.010416667, -0.026315789,
0.010810811, 0.010695187,...),
z3=c(0, 0, 0, ...,0, 0, 0,..., 0.005235602, -0.010416667, -0.026315789,
0.010810811,...),
T=c(1, 1, 1,1, 1,...,2, 2, 2, ...,3, 3, 3,3,...), N=4711, alpha=c(1,1,1))

```

Lampiran 10 Model MNAR(2;2,[11]) Untuk *Return* Saham UNVR

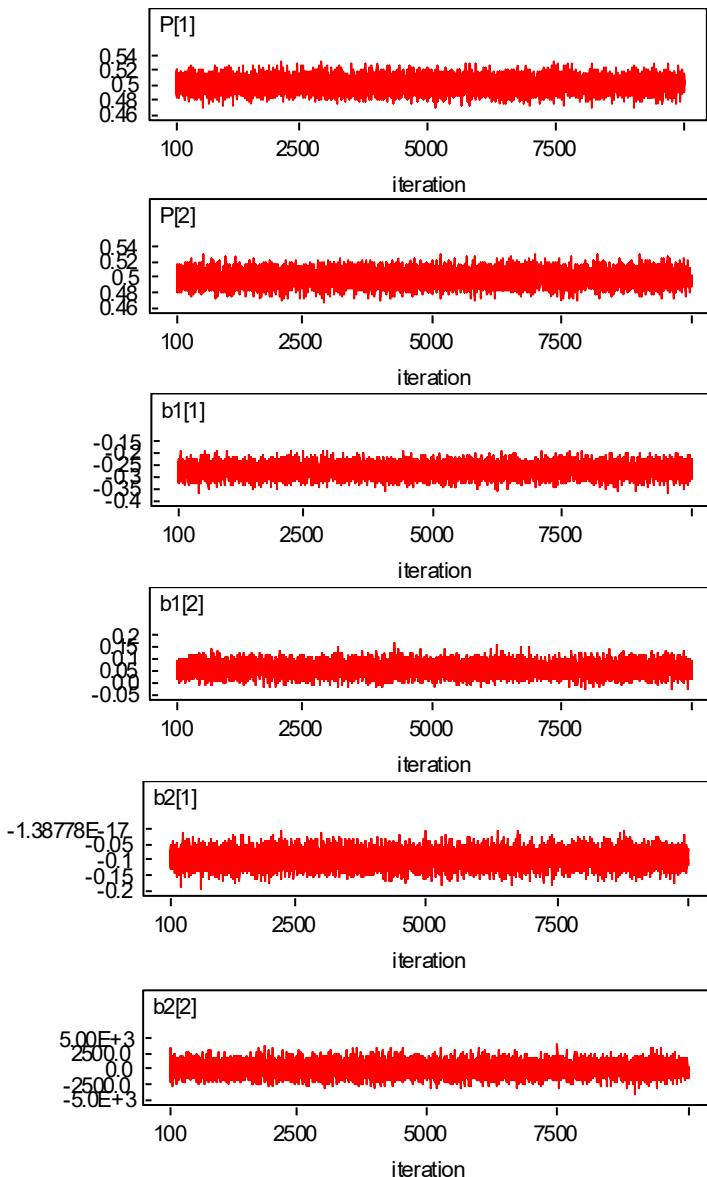
a. *Program Code, Struktur Data dan Initial Value*

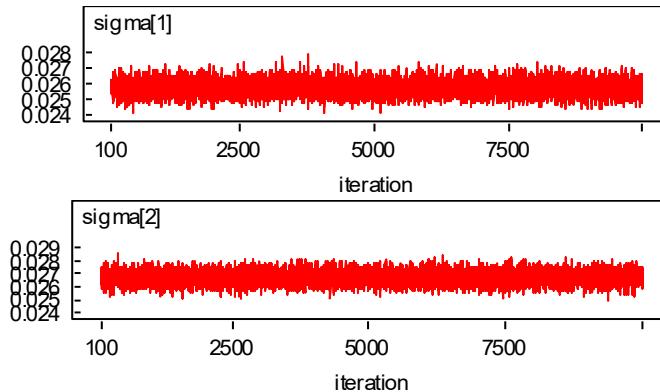
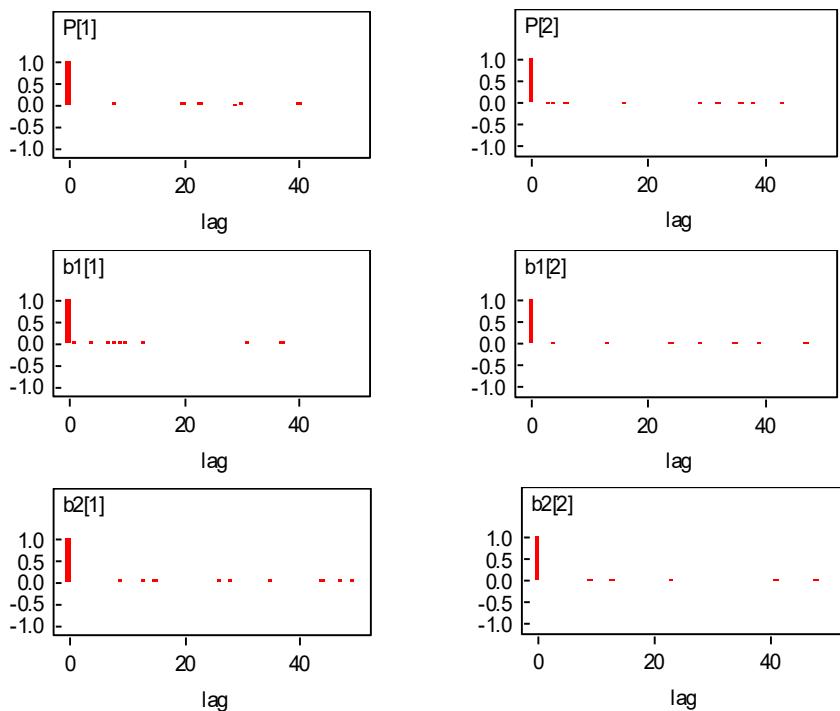
```

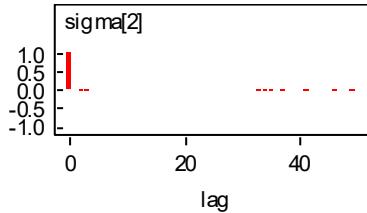
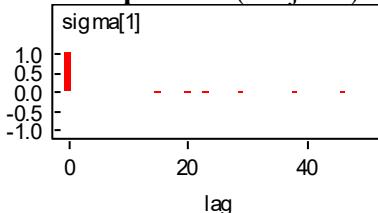
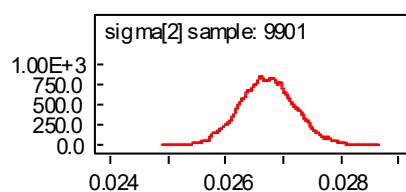
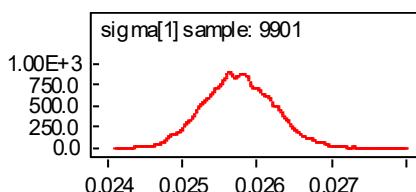
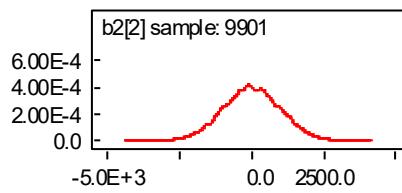
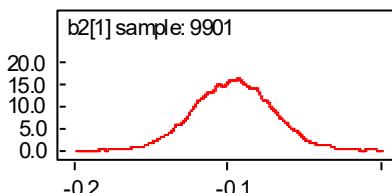
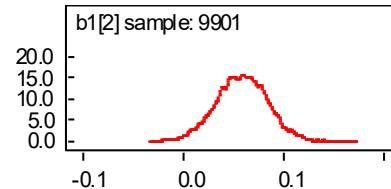
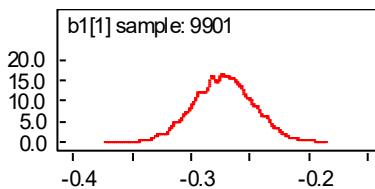
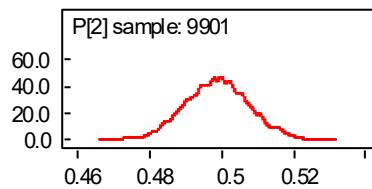
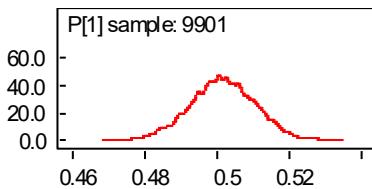
model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i] + b2[T[i]] * z2[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
}
INITIAL
list(b1=c(1,1), b2=c(1,1), tau=c(1,1))

DATA
list(z=c(-0.017699115, 0.004504505, 0.00896861, -0.013333333,...,
0.030973451, -0.008583691, 0, -0.008658009, 0, 0,...),
z1=c(-0.00877193, -0.017699115, 0.004504505, 0.00896861,...,
0.031674208, -0.00877193, -0.017699115, 0.004504505,...),
z2=c(0.031674208, -0.00877193, -0.017699115, 0.004504505,..., 0, 0,
0, 0,...)
T=(1, 1, 1, 1,...,2, 2, 2,...,3, 3, 3,...), N=3135, alpha=c(1,1))

```

Lampiran 10 (Lanjutan)b. *History Plot*

Lampiran 10 (Lanjutan)**c. Autocorrelation Plot**

Lampiran 10 (Lanjutan)**d. Kernel Density**

Lampiran 11 Model MNAR(3,1,2,[11]) Untuk *Return Saham UNVR*

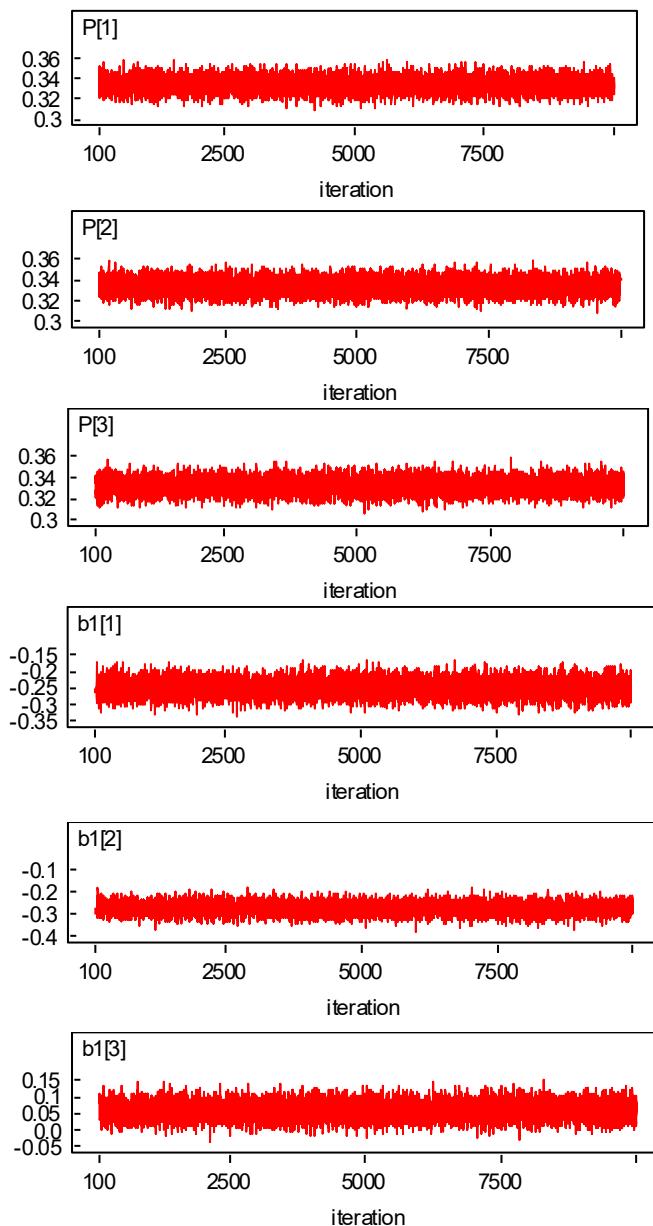
a. *Program Code, Struktur Data dan Initial Value*

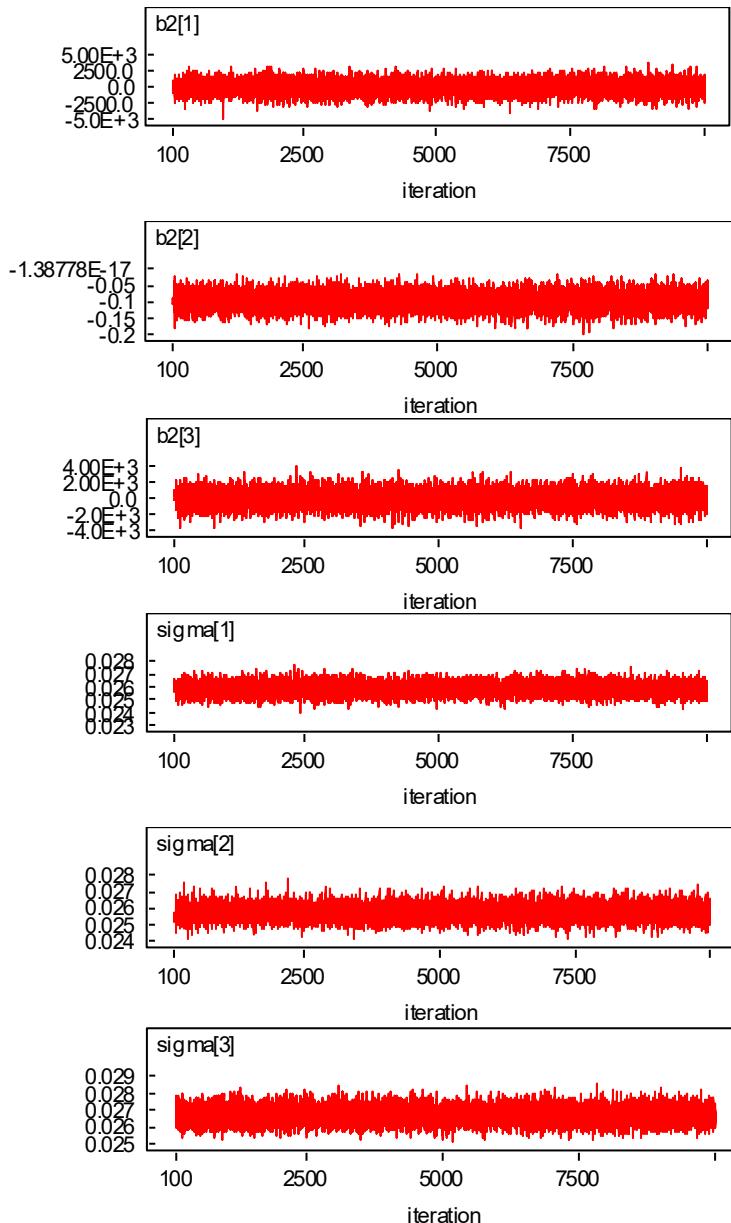
```

model;
{
  for( i in 1 : N ) {
    z[i] ~ dnorm(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i] + b2[T[i]] * z2[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:3])
  }
  P[1:3] ~ ddirch(alpha[])
  b1[1] ~ dnorm( 0.0,1.0E-6)
  b1[2] ~ dnorm( 0.0,1.0E-6)
  tau[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tau[2])
  for( i in 1 : N ) {
    tau[i] <- tau[T[i]]
  }
  tau[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tau[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
  b1[3] ~ dnorm( 0.0,1.0E-6)
  b2[3] ~ dnorm( 0.0,1.0E-6)
  tau[3] ~ dgamma(0.001,0.001)
  sigma[3] <- 1 / sqrt(tau[3])
}
INITIAL
list(b1=c(1,1,1), b2=c(1,1,1), tau=c(1,1,1))

DATA
list(z=c(-0.00877193, -0.017699115, 0.004504505, 0.00896861,..., -
0.017699115, 0.004504505, 0.00896861, -0.013333333,...,0.030973451, -
0.008583691, 0, -0.008658009, 0,...),
z1=c(0.031674208, -0.00877193, -0.017699115, 0.004504505,
0.00896861,..., -0.00877193, -0.017699115, 0.004504505, 0.00896861, -
0.013333333,..., 0.031674208, -0.00877193, -0.017699115, 0.004504505,
0.00896861,...),
z2=0, 0, 0 ,0,..., 0.031674208, -0.00877193, -0.017699115,
0.004504505, 0.00896861,...,0, 0, 0, 0, 0,...),
T=c(1, 1 ,1, 1, 1,...,2, 2, 2, 2,...,3, 3, 3, 3,...), N=4708, alpha=c(1,1,1))

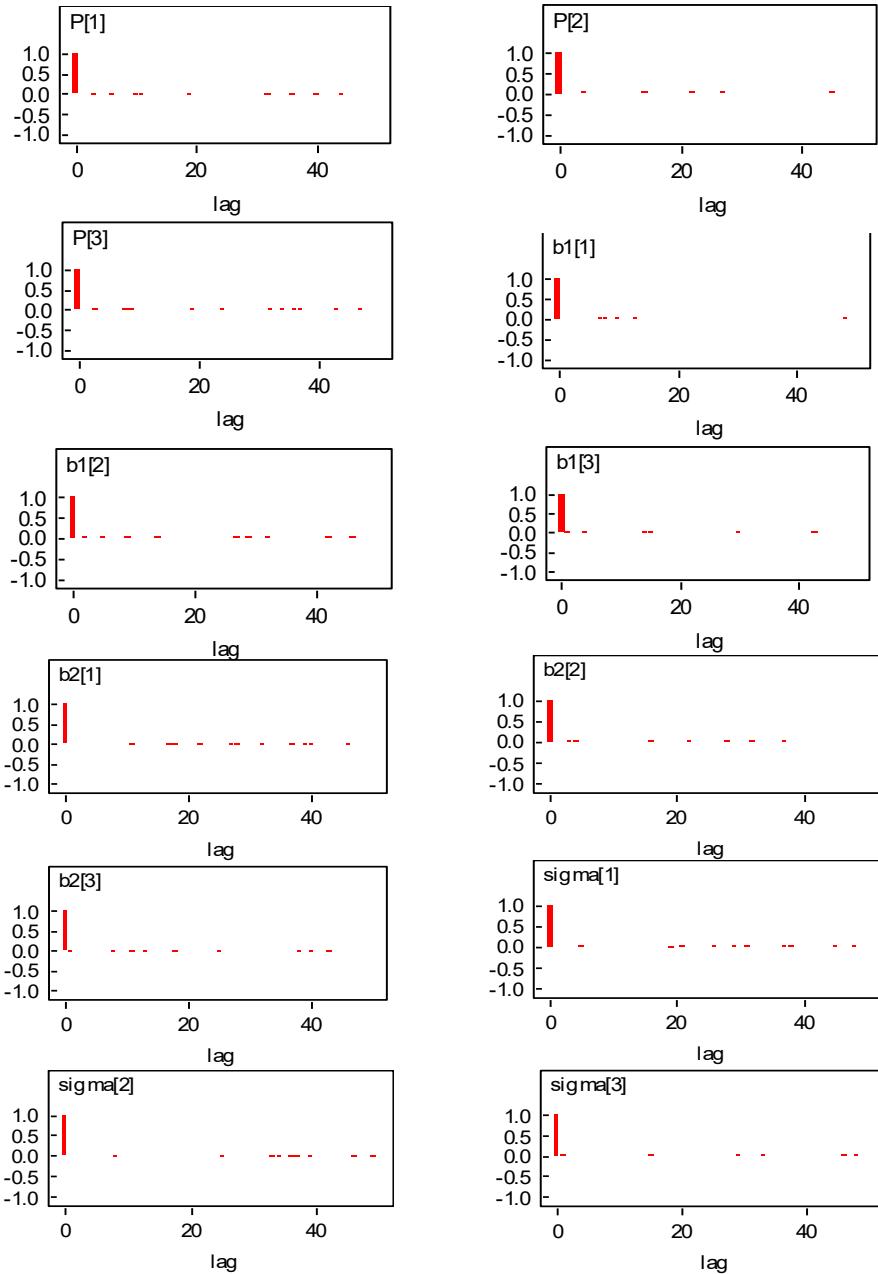
```

Lampiran 11 (Lanjutan)b. *History Plot*

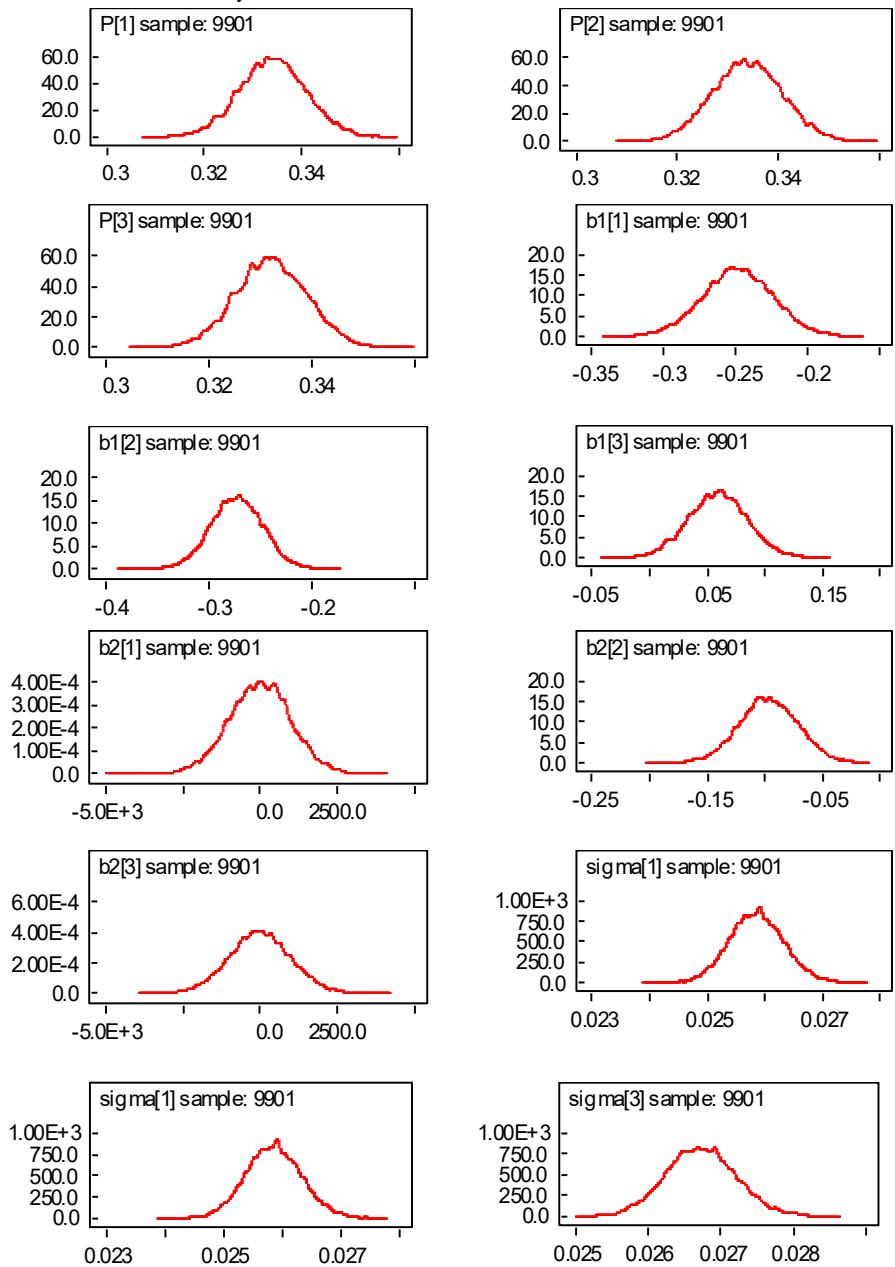
Lampiran 11 (Lanjutan)

Lampiran 11 (Lanjutan)

c. Autocorrelation Plot



d. Kernel Density



Lampiran 12 Surat Pernyataan**SURAT PERNYATAAN**

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

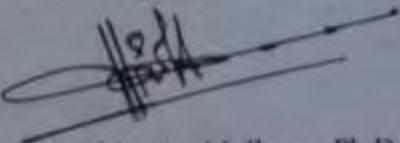
Nama : Ulfa Meilinda Putri
NRP : 1312100047

menyatakan bahwa data yang digunakan dalam Tugas Akhir/Thesis ini merupakan data sekunder yang diambil dari penelitian/buku/ Tugas-Akhir/Thesis/publikasi lainnya yaitu:

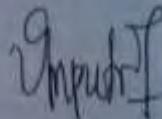
Sumber : www.finance.yahoo.com
Keterangan : Data Close Price Saham di yahoo finance mulai tanggal 1 Januari 2010 sampai dengan 29 Februari 2016

Surat pernyataan ini dibuat dengan sebenar-benarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui,
Pembimbing Tugas Akhir


Prof. Drs. Nur Sriawan, M. Ikom., Ph.D.
NIP. 19621015 198803 1 002

Surabaya, Juli 2016



Ulfa Meilinda Putri
NRP. 1312100047

*(coret yang tidak perlu)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan pada penelitian mengenai analisis risiko investasi saham syariah menggunakan *Var* dengan pendekatan Bayesian MNAR didapatkan kesimpulan sebagai berikut.

1. Saham ASII, TLKM dan UNVR memiliki *mean return* positif, artinya bahwa ketiga saham tersebut relatif konstan memberikan keuntungan dalam investasi. Selain itu berdasarkan nilai *skewness* dan kurtosis yang bernilai lebih besar atau lebih kecil dari 0 (nol), mengindikasi bahwa data *return* saham ASII, TLKM dan UNVR tidak mengikuti distribusi normal. Nilai kurtosis yang benilai positif menunjukkan bahwa distribusi *return* lebih runcing dari distribusi normal atau biasa disebut dengan leptokurtik.
2. Pendekatan univariat menggunakan model ARIMA menghasilkan nilai DIC yang lebih besar daripada pendekatan MNAR. Oleh sebab itu, digunakanlah pendekatan *mixture* dengan komponen sebanyak 3 untuk menghitung besarnya risiko yang akan ditanggung oleh investor apabila berinvestasi pada saham ASII, TLKM dan UNVR. Perhitungan risiko menggunakan VaR dengan pendekatan MNAR diperoleh hasil bahwa semakin tinggi tingkat kepercayaan yang digunakan, maka semakin besar pula nilai *VaR* yang dihasilkan dan semakin lama investasi yang dilakukan, maka semakin besar risiko yang akan ditanggung oleh investor. Dengan kata lain kemungkinan kerugian yang didapat akan semakin besar. Berdasarkan nilai VaR yang diperoleh, risiko tertinggi terjadi pada saham UNVR yaitu sebesar -0,14573, kemudian disusul dengan saham TLKM sebesar -0,04306 dan terendah saham ASII sebesar -0,0346.

5.2 Saran

Saran yang dapat menjadi pertimbangan dalam penelitian selanjutnya yaitu:

1. Dalam penelitian ini pemilihan saham hanya dibatasi pada saham syariah di JII dengan kapitalisasi terbesar. Oleh karena itu pemilihan saham dapat dilakukan dengan melihat kapitalisasi pasar terbesar dan juga kapitalisasi pasar terendah untuk mengetahui saham manakah yang lebih berisiko.
2. menambahkan banyaknya komponen AR (*Autoregressive*) agar model MNAR lebih baik dalam menangkap pola data *return* saham yang tidak homogen yang meyebabkan ketidaknormalan data.
3. perhitungan risiko juga dapat dilakukan dengan mempertimbangkan faktor lain seperti faktor makro ekonomi (tingkat suku bunga, nilai tukar/kurs, dsb), sehingga dapat digunakan metode CVaR (*Conditional Value at Risk*).

DAFTAR PUSTAKA

- Astra Internasional. (2015). *Profile About Astra* [On-line] <http://astra.co.id> (diakses pada 24 Januari 2016).
- Bodie, Z., Kane, A., dan Marcus, A.,J. (2002). *Investment* ed 5 th. New York: McGraw-Hill.
- Box, G., E., P., dan Tiao, G., C. (1973). *Bayesian Inference in Statistical Analysis*. Reading, Massachusetts: Adison Wesley.
- Casella, G., dan George, E., I. (1992). Explaining the Gibbs Sampler. *Journal of The American Statistician Association* 46(3), hal 167-174.
- Carlin, B.,P., dan Chib, S. (1995). “Bayesian Model Choice via Markov Chain Monte Carlo Methods”, *Journal of the Royal Statistical Society, Series B (Methodological)*, Vol. 57, Issue 3, 473-484.
- Dajan, A. (1991). *Pengantar Metode Statistik, jilid I*. Jakarta: Pustaka LP3ES.
- Daniel, W., W. (1989). *Applied Nonparametric Statistics Second Edition*. Dalam Alex Tri Kantjono W. Statistika Non Parametrik Terapan. Boston, MA: Houghton Mifflin.
- Darmadji, T., dan Fakhruddin, H., M. (2006). *Pasar Modal di Indonesia: Pendekatan Tanya Jawab*. Jakarta: Salemba Empat.
- Halim (2005). *Analisis Investasi*. Jakarta : Salemba Empat
- Hanggraeni, D. (2010). *Pengelolaan Risiko Usaha*. Jakarta: LPFE UI.
- Iriawan, N., (2001). Penaksiran Model Mixture Normal Univariabel: Suatu Pendekatan Mixture Bayesian dengan MCMC, *Prosiding Seminar Nasional dan Konferda VII Matematika Wilayan DIY & Jawa Tengah*, Yogyakarta, hal 105-110.
- Iriawan, N. (2012). *Pemodelan dan Analisis Data-Driven Volume 1*. Surabaya: ITSPress

- Jorion, P. (2007). *Value at Risk: The New Benchmark for Managing Finance Risk*. New York: McGraw-Hill.
- Koetin, E., A. (2002). *Analisa Pasar Modal*. Jakarta: Pustaka Sinar Harapan.
- Laila, F., R. (2010). *Perhitungan Value at Risk Indeks Harga Saham Syariah Menggunakan Model Volatilitas ARCH-GARCH Dalam Kelompok Jakarta Islamic Index*. Skripsi Program S1 Universitas Sains dan Teknologi Syarif Hidayatullah, Jakarta.
- Levene, H. (1960). *Contributions to Probability and Statistics*. Stanford University Press, CA.
- Nurharyanto. (2011). *Analisis Risiko Pasar Portofolio Investasi Saham dengan Metode Value at Risk*. Tesis Jurusan Manajemen Universitas Indonesia, Depok.
- Purwandi, L. (2008). *Pemodelan Indeks Han Seng Dengan Metode Mixture Autoregressive Dengan Jumlah Komponen Tertentu*. Skripsi Jurusan Statistika Institut Teknologi Sepuluh Nopember, Surabaya. (Tidak dipublikasikan)
- Rahman, F. (2008). *Penerapan Bayesian Mixture Autoregressive Pada Data Indeks NASDAQ*. Skripsi Jurusan Statistika Institut Teknologi Sepuluh Nopember, Surabaya. (Tidak dipublikasikan)
- Rozak, A. (2009). *Analisis Risiko dan Peramalan Harga Saham Dalam Keputusan Investasi Pada Perusahaan Perkebunan di PT Bursa Efek Indonesia*. Skripsi Departemen Agribisnis Institut Pertanian Bogor, Bogor.
- Samsul, M. (2006). *Pasar Modal dan Manajemen Portofolio*. Jakarta: Erlangga
- Spiegelhalter,D. J., Best,N.G., Carlin, B. P. and van der Linde, A. (2002) Bayesian measures of model complexity and fit. *J. R. Statist. Soc. B*, 64, 583–639.
- Tandelilin, dan Enduardus. (2010). *Analisis Investasi dan Manajemen Portofolio* Ed 1st. Yogyakarta: Kaninius.
- Telkom. (2015). *Riwayat Singkat Telkom* [On-line] <http://telkom.co.id> (diakses pada 15 Januari 2016).

- Unilever. (2016). *About Unilever* [On-line] <http://unilever.co.id> (diakses 25 Januari 2016).
- Valecky, J. (2012). Mixture Normal Value at Risk Models of Some European Market Portfolios. *International Scientific Conference Managing and Modelling of Financial Risks, Faculty of Economics, Finance Department, Ostrava.*
- Wei, W., W. (2006). *Time Series Analisis: Univariate and multivariate Methods*. USA: Pearson Educarion, Inc.
- Wijayanti, A. (2007). *Perbandingan Analisis Risiko Investasi Saham PT. Telkom dan Indosat Dengan Metode Value At Risk Pada Pendekatan Distribusi Uni-Modal Dan Mixture*. Skripsi Jurusan Statistika Institut Teknologi Sepuluh Nopember, Surabaya. (Tidak dipublikasikan)
- Wong, C., S., dan Li. W., K. (2000). On a Mixture Autoregressive Model. *Journal of the Royal Statistical Society Series B*, hal 95-115.

(Halaman ini sengaja dikosongkan)

BIODATA PENULIS



Penulis bernama lengkap Ulfameilinda Putri, merupakan anak pertama dari tiga bersaudara dengan dua adik laki-laki. Penulis dilahirkan di Bojonegoro pada tanggal 19 Mei 1994 dari pasangan Budi Utomo dan Puji Yunaeni. Pendidikan formal yang telah ditempuh penulis adalah SDN Kepatihan Bojonegoro (2000-2006), SMP Negeri 1 Bojonegoro (2006-2009), SMA Negeri 1 Bojonegoro (2009-2012). Pada tahun 2012, penulis melanjutkan pendidikannya di Jurusan Statistika ITS. Selama kuliah, penulis mendapatkan kepercayaan untuk menjadi asisten dosen mata kuliah Analisis Data II dan Metode Multivariat Terapan. Pada masa perkuliahan, penulis tertarik untuk menekuni dunia bisnis. Oleh karena itu, penulis menyalurkan keinginannya tersebut dengan aktif berorganisasi. Beberapa organisasi yang pernah diikuti oleh penulis, yaitu HIMASTA-ITS 2013/2014 sebagai Staff Departemen Kewirausahaan, FORSIS-ITS sebagai Tim Dana dan Usaha (Danus) serta UKM KOPMA-ITS 2015/2016 sebagai Direktur Administrasi Umum. Apabila pembaca memiliki kritik dan saran atau ingin berdiskusi lebih lanjut terkait Tugas Akhir ini, dapat disampaikan melalui *email*: ulfameilinda@gmail.com.