



TESIS-SS142501

**ANALISIS RISIKO INVESTASI SAHAM SYARIAH
MENGGUNAKAN METODE VALUE AT RISK DENGAN
PENDEKATAN BAYESIAN MIXTURE LAPLACE
AUTOREGRESSIVE (MLAR)**

BRINA MIFTAHURROHMAH

NRP. 1315 201 025

DOSEN

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

Dr. Kartika Fithriasari, M.Si.

PROGRAM MAGISTER

JURUSAN STATISTIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

INSTITUT TEKNOLOGI SEPULUH NOPEMBER

SURABAYA

2017



THESIS-SS142501

***ISLAMIC STOCK INVESTMENT RISK ANALYSIS
USING VALUE AT RISK BY APPROACH OF
MIXTURE LAPLACE AUTOREGRESSIVE (MLAR)***

BRINA MIFTAHURROHMAH

NRP. 1315 201 025

SUPERVISOR

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

Dr. Kartika Fithriasari, M.Si.

MAGISTER PROGRAM

DEPARTMENT OF STATISTICS

FACULTY OF MATHEMATICS AND NATURAL SCIENCE

SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY

SURABAYA

2017

ANALISIS RISIKO INVESTASI SAHAM SYARIAH MENGGUNAKAN METODE *VALUE AT RISK* DENGAN PENDEKATAN BAYESIAN MIXTURE LAPLACE *AUTOREGRESSIVE (MLAR)*

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

d)

Institut Teknologi Sepuluh Nopember
Oleh:

**BRINA MIFTAHURROHMAH
NRP. 1315 201 025**

Tanggal Ujian 13 Januari 2017
Periode Wisuda Maret 2017

Disediakan oleh

1. Prof. Drs. Nur Iriawan, M.Ikom., Ph.D.
NIP. 19621015 198803 1 002 (Pembimbing I)


2. Dr. Kartika Fithriasari, M.Si.
NIP. 19691212 199303 2 002 (Pembimbing II)


3. Dr. Brodjol Sutijo Suprijah Ulama, M.Si.
NIP. 19660125 199002 1 001 (Penguji)


4. Dr. rer. pol. Heri Kuswanto, M.Si.
NIP. 19820326 200312 1 004 (Penguji)




Direktur Program Pascasarjana

Prof. Ir. Djauhar Manfaat, M.Sc., Ph.D.
NIP. 19601202 198701 1 001

**ANALISIS RISIKO INVESTASI SAHAM SYARIAH
MENGGUNAKAN METODE *VALUE AT RISK*
DENGAN PENDEKATAN BAYESIAN *MIXTURE LAPLACE
AUTOREGRESSIVE (MLAR)***

Nama Mahasiswa	:	Brina Miftahurrohmah
NRP	:	13 15 201 025
Pembimbing	:	Prof. Drs. Nur Iriawan, M.Ikom., Ph.D.
Ko-Pembimbing	:	Dr. Kartika Fithriasari, M.Si.

ABSTRAK

Investasi saham merupakan salah satu hal yang sangat menarik di bidang bisnis. Hal itu dikarenakan dengan melakukan investasi, banyak keuntungan yang akan didapatkan. Namun, investasi saham juga rawan terhadap risiko terjadinya kerugian. Oleh sebab itu, sebelum melakukan investasi, investor perlu mengetahui kemungkinan risiko yang akan terjadi. *Value at Risk* (VaR) sebagai metode pengukuran risiko yang paling populer, sering mengabaikan pola data yang tidak Normal uni-modal. Perhitungan risiko menggunakan metode VaR dengan *Mixture Normal Autoregressive* (MNAR) telah dilakukan. Laporan ini mengusulkan VaR dengan *Mixture Laplace Autoregressive* (MLAR) yang akan dilakukan untuk menganalisis data *return* saham syariah tiga perusahaan yang tergabung dalam JII dengan kapitalisasi terbesar, yaitu PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLKM) dan PT. Unilever Indonesia Tbk (UNVR). Estimasi parameter dilakukan dengan menggunakan pendekatan Bayesian *Markov Chain Monte Carlo* (MCMC). Hasil analisis menunjukkan bahwa Risiko tertinggi hingga terendah secara berturut-turut dalam investasi akan dialami saham ASII, UNVR, dan TLKM.

Kata Kunci: *Mixture Normal Autoregressive* (MNAR), *Mixture Laplace Autoregressive* (MLAR), Bayesian, *Markov Chain Monte Carlo* (MCMC).

Halaman ini sengaja dikosongkan

***ISLAMIC STOCK INVESTMENT RISK ANALYSIS
USING VALUE AT RISK BY APPROACH OF MIXTURE
LAPLACE AUTOREGRESSIVE (MLAR)***

Name	:	Brina Miftahurrohmah
NRP	:	1315 201 025
Supervisor	:	Prof. Drs. Nur Iriawan, M.Ikom., Ph.D.
Co-Supervisor	:	Dr. Kartika Fithriasari, M.Si.

ABSTRACT

Investment in stocks is something very interesting in the field of business. It is because by investing, a lot of profit to be obtained. However, investments in stocks are also vulnerable to the risk of loss. Therefore, before investing, investors need to be aware of the possibility that the risk will occur. Value at Risk (VaR) as the most popular risk measurement method, is frequently ignore when the pattern of return is not uni-modal Normal. The calculation of the risks using VaR method with the Normal Mixture Autoregressive (MNAR) approach has been considered. This paper proposes VaR method couple with the Mixture Laplace Autoregressive (MLAR) that would be implemented for analyzing the first three biggest capitalization Islamic stock return in JII, namely PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLKM), and PT. Unilever Indonesia Tbk (UNVR). Parameter estimation is performed by employing Bayesian Markov Chain Monte Carlo (MCMC) approaches. Results of analysis showed that the highest risk to the lowest level of investment will be experienced by ASII, TLKM, and UNVR stocks.

Keywords: *Mixture Normal Autoregressive (MNAR), Mixture Laplace Autoregressive (MLAR), Bayesian, Markov Chain Monte Carlo (MCMC).*

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Assalamu'alaikum Warahmatullah Wabarakatuh.

Puji syukur penulis panjatkan atas kehadiran Allah SWT atas segala rahmat, nikmat, ridho serta hidayah yang telah diberikan. Sholawat serta salam tetap tercurahkan kepada Nabi Muhammad SAW atas suri tauladan yang telah diberikan, sehingga Tesis yang berjudul **“Analisis Risiko Investasi Saham Syariah Menggunakan Metode Value At Risk Dengan Pendekatan Bayesian Mixture Laplace Autoregressive (MLAR) ”** dapat terselesaikan. Ucapan terima kasih yang tak terhingga penulis sampaikan kepada pihak-pihak yang telah membantu dalam menyelesaikan Tesis ini, diantaranya:

1. Bapak Dr. Suhartono, M.Sc. selaku Ketua Jurusan Statistika ITS yang selalu memberikan dukungan dan motivasi selama menjalani perkuliahan di Program Studi Magister Jurusan Statistika ITS.
2. Bapak Prof. Drs. Nur Iriawan, M.Ikom., Ph.D dan Ibu Dr. Dra. Kartika Fithriasari, M.Si. selaku dosen pembimbing Tesis yang telah bersedia memberikan bimbingan, motivasi, arahan serta dukungan kepada penulis dari awal hingga akhir penyusunan Tesis ini.
3. Bapak Dr.rer.pol. Heri Kuswanto, M.Si. selaku Ketua Program Studi Magister Jurusan Statistika ITS Surabaya dan dosen penguji yang telah memberikan motivasi, arahan, dukungan, kritik dan saran yang sangat bermanfaat dalam penyusunan Tesis.
4. Bapak Dr. Brodjol Sutijo Suprih Ulama, M.Si. selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga laporan Tesis ini menjadi lebih baik.
5. Ibu Irhamah, M.Si., Ph.D selaku dosen wali penulis selama kuliah di Program Studi Magister Jurusan Statistika ITS.
6. Bapak dan Ibu dosen serta seluruh tenaga kependidikan Jurusan Statistika ITS atas bantuan dan ilmu yang bermanfaat.

7. Kedua orang tua yang telah memberikan banyak do'a serta dukungan, sehingga penulis dapat menjalani kuliah sampai sekarang dan dapat menyelesaikan Tesis ini.
8. Almarhumah Bu Dhe Sumantri dan Almarhum Pak Dhe Tokol yang telah merawat penulis dari bayi dan secara tidak langsung telah memotivasi dan memberi semangat untuk menuntut ilmu setinggi-tingginya.
9. Teman-teman seperjuangan selama kuliah di Program Studi Magister Jurusan Statistika ITS atas dukungan, pengalaman dan seluruh kebaikan yang tidak dapat diungkapkan satu per satu.
10. Semua pihak yang tidak dapat disebutkan satu per satu atas seluruh bantuan yang telah diberikan kepada penulis.

Dalam Penulisan laporan ini penulis merasa masih banyak kekurangan baik dalam teknis penulisan maupun materi, mengingat akan kemampuan yang dimiliki penulis. Untuk itu kritik dan saran dari semua pihak sangat penulis harapkan demi penyempurnaan pembuatan Tesis ini. Semoga laporan Tesis ini bermanfaat bagi pembaca dan memberikan sumbangsih kepada semua pihak yang membutuhkan.

Wassalamu'alaikum Warahmatullah Wabarakatuh.

Surabaya, Januari 2017

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL.....	i
LEMBAR PENGESAHAN	v
ABSTRAK	vii
ABSTRAK	ix
KATA PENGANTAR	xi
DAFTAR ISI.....	xiii
DAFTAR TABEL.....	xv
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN.....	xix
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan.....	4
1.4 Manfaat.....	5
1.5 Batasan Masalah.....	5
BAB 2 TINJAUAN PUSTAKA	7
2.1 Kemiringan dan Kurtosis.....	7
2.2 Model <i>Autoregressive</i> (AR)	8
2.3 Stasioneritas <i>Time Series</i>	9
2.3.1 Uji Levene.....	9
2.3.2 <i>Autocorrelation Function</i> (ACF).....	10
2.3.3 <i>Partial Autocorrelation Function</i> (PACF).....	11
2.4 Proses Non Stationeritas	11
2.4.1 <i>Differencing</i>	11
2.4.2 Transformasi Box-Cox.....	12
2.5 <i>Diagnostic Check</i>	13
2.6 Distribusi Laplace.....	14
2.7 Model <i>Mixture Autoregressive</i>	16

2.8	<i>Model Mixture Laplace Autoregressive</i>	17
2.9	Stationeritas Model MLAR	19
2.10	Penaksiran Parameter.....	20
2.10.1	Metode Bayesian	21
2.10.2	Distribusi Prior	21
2.10.3	<i>Markov Chain Monte Carlo</i> (MCMC) dengan <i>Gibbs Sampler</i>	23
2.11	Uji Signifikansi Parameter.....	25
2.12	Kriteria Pemilihan Model Terbaik.....	25
2.13	<i>Value at Risk</i> (VaR)	27
2.14	<i>Return</i> Saham.....	29
2.15	<i>Backtesting</i>	31
	BAB 3 METODOLOGI PENELITIAN	33
3.1	Sumber Data dan Variabel Penelitian	33
3.2	Langkah Penelitian	33
3.3	Penelitian sebelumnya	38
	BAB 4 ANALISIS DAN PEMBAHASAN	41
4.1	Penentuan Distribusi prior	41
4.2	Pemodelan <i>Mixture Laplace Autoregressive</i> (MLAR)	44
4.3	Pemilihan Model Terbaik	59
4.4	Perhitungan <i>Value at Risk</i> (VaR).....	60
4.5	<i>Backtesting</i> saham ASII, TLKM dan UNVR	63
	BAB 5 KESIMPULAN DAN SARAN	65
5.1	Kesimpulan	65
5.2	Saran	65
	DAFTAR PUSTAKA.....	67
	LAMPIRAN	71

DAFTAR TABEL

	Halaman
Tabel 2. 1 Transformasi Box-Cox.....	12
Tabel 4.1 Estimasi Parameter Saham ASII	42
Tabel 4.2 Estimasi Parameter Saham TLKM	43
Tabel 4.3 Estimasi Parameter Saham UNVR	44
Tabel 4.4 Estimasi Parameter Model MLAR(2;[3],[3,6]).....	48
Tabel 4.5 Estimasi Parameter Model MLAR(3;[3],[3,6], 0).....	49
Tabel 4.6 Estimasi Parameter Model MLAR(2;[2],[3]).....	51
Tabel 4.7 Estimasi Parameter Model MLAR(2;[2],[4]).....	51
Tabel 4.8 Estimasi Parameter Model MLAR(2;[3],[4]).....	52
Tabel 4.9 Estimasi Parameter Model MLAR(2;[2,3],[3,4]).....	53
Tabel 4.10 Estimasi Parameter Model MLAR(3;[2,3],[3,4],[2,3,4]).....	54
Tabel 4.11 Estimasi Parameter Model MLAR(3;[2],[3],[4]).....	56
Tabel 4.12 Estimasi Parameter Model MLAR(2;2,[11])	57
Tabel 4.13 Estimasi Parameter Model MLAR(3;2,[11],(2,[11])).....	58
Tabel 4.14 Perbandingan Model MNAR dan MLAR berdasarkan DIC.....	59
Tabel 4.15 Hasil Perhitungan VaR	63
Tabel 4.16 Uji Kupiec	63

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

	Halaman
Gambar 2. 1 Kurtosis	8
Gambar 2. 2 Perbedaan distribusi Laplace klasik dan standar.....	16
Gambar 3.1 Kapitalisasi pasar saham JII	34
Gambar 3. 2 Diagram alir penelitian.....	36
Gambar 3. 3 Diagram alir penelitian ARIMA	37
Gambar 3. 4 Diagram alir penelitian MLAR	38
Gambar 3.5 Marginal Plot dari Return Saham (a)ASII, (b)TLKM dan (c)UNVR	39
Gambar 4.1 Doodle untuk Model MLAR(2;[3],[3,6]).....	46

Halaman sengaja dikosongkan

DAFTAR LAMPIRAN

	Halaman
Lampiran A Data Return Saham ASII	71
Lampiran B Data <i>Return</i> Saham TLKM.....	72
Lampiran C Data <i>Return</i> Saham UNVR.....	73
Lampiran D ASII MLAR(2;[3],[3,6]).....	74
Lampiran E ASII MLAR(3;[3],[3,6],0)	78
Lampiran F TLKM MLAR(2;[2,3],[3,4])	85
Lampiran G TLKM MLAR(2;[2],[3])	90
Lampiran H TLKM MLAR(2;[2],[4])	94
Lampiran I TLKM MLAR(2;[3],[4]).....	98
Lampiran J TLKM MLAR(3;[2,3],[3,4],[2,3,4])	102
Lampiran K TLKM MLAR(3;[2],[3],[4]).....	110
Lampiran L UNVR MLAR(2;2,[11])	115
Lampiran M UNVR MLAR(3;2,[11],(2,[11]))	119

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

Dalam bab ini akan dijelaskan lima subbab, yaitu mengenai latar belakang, rumusan masalah, tujuan, manfaat yang ingin dicapai dan batasan masalah dari penelitian ini. Masing-masing subbab akan dijelaskan sebagai berikut.

1.1 Latar Belakang

Salah satu instrumen-instrumen keuangan yang diperjualbelikan di pasar modal adalah saham. Saham merupakan salah satu sekuritas yang memiliki tingkat risiko yang tinggi. Risiko tinggi ditunjukkan oleh ketidakpastian *return* yang akan diterima investor di masa datang. Semakin tinggi *return* yang diinginkan, maka semakin besar pula risiko yang ditimbulkan. Oleh sebab itu pengukuran risiko sangat penting pada bidang investasi. Dengan diketahuinya risiko, maka kebijakan investasi dapat dilakukan dengan lebih terukur. Hal utama yang harus dilakukan dalam pengelolaan risiko adalah mengidentifikasi penyebab risiko itu.

Metode yang digunakan dalam mengukur risiko sangat banyak sekali. Metode-metode tersebut diantaranya *Value at Risk* (VaR) dan *Expected-Shortfall* (ES) atau *return-level* (Gilli & Kellezi, 2006). Namun, metode yang banyak digunakan dan sangat popular saat ini adalah VaR. Hasil perhitungan VaR yang akurat sangat diperlukan dalam menentukan modal yang akan dikeluarkan oleh perusahaan. Dengan demikian, risiko yang dihadapi perusahaan semakin kecil dan kerugian yang mungkin terjadi dapat ditanggulangi. Risiko merupakan kemungkinan dampak yang akan terjadi di masa depan, oleh sebab itu perlu dilakukan peramalan.

Peramalan merupakan suatu kegiatan yang bertujuan untuk memperkirakan kejadian yang akan terjadi pada masa yang akan datang, berdasarkan kejadian-kejadian di masa lampau. Metode peramalan telah banyak dikembangkan dalam analisis *time series* linier. Metode-metode tersebut sebagian besar dikembangkan berdasarkan asumsi residual berdistribusi Normal. Dengan demikian, *marginal* dan *conditional* distribusinya harus berdistribusi Normal. Salah satu

metode peramalan yang menerapkan asumsi tersebut adalah ARIMA Box's Jenkins. ARIMA Box's Jenkins adalah suatu metode yang sangat tepat untuk menangani atau mengatasi kerumitan deret waktu dan situasi peramalan lainnya. Metode Box Jenkins (ARIMA) akan tepat guna jika observasi dari data runtun waktu bersifat dependen atau berhubungan satu sama lain secara statistik. Salah satu model ARIMA yang sering menggambarkan kondisi *return* saham adalah model *Autoregressive*. Model *Autoregressive* merupakan model yang menggambarkan bahwa variabel dependen dipengaruhi oleh variabel dependen itu sendiri pada periode-periode dan waktu-waktu sebelumnya. Model ini mengharuskan residual berdistribusi Normal dengan *mean* nol dan varians tertentu.

Wong dan Li (2000) menyatakan bahwa dalam kenyataannya, banyak data *time series* yang tidak stasioner terhadap *mean* dan cenderung bersifat multimodal. Selain itu, banyak juga data *time series* yang bersifat heteroskedastisitas yang memberikan pola marjinal dan membawa sifat leptokurtik, sehingga asumsi Normal dilanggar (Wong & Li, 2000).

Model *Gaussian Mixture Transition Distribution* (GMTD) diperkenalkan oleh Le, Martin dan Raftery (1996) untuk menangkap adanya ketidaknormalan dan ketidaklinieran suatu data *time series*. Model telah terbukti berguna dalam pemodelan beberapa kasus non-linier. Namun, model ini tidak mampu memodelkan data Canadian lynx (Wong & Li, 2000) karena ada pola siklus. Dengan demikian, Wong dan Li (2000) menggeneralisir model GMTD menjadi model *Mixture Autoregressive* (MAR).

Model MAR terdiri dari gabungan komponen K Gaussian AR. Sifat stasioner dan *Autocorrelation Function* (ACF) sangat mudah diturunkan. Wong dan Li (2000) menggunakan algoritma *Expectation-Maximization* (EM) untuk mengestimasi parameter. Perubahan fitur *conditional distributions* membuat model ini mampu memodelkan *time series* dengan distribusi bersyarat multimodal dan dengan heteroskedastisitas. Model yang diterapkan untuk dua set data riil dan dibandingkan dengan model alternatif lainnya. Model MAR mampu menangkap fitur data yang lebih baik model alternatif lainnya.

Nguyen dan McLachan (2016) telah mampu membuktikan pada penelitian yang telah dilakukan dengan metode *Mixture of Linear Experts* bahwa dengan

menggunakan distribusi Laplace hasil yang didapatkan akan lebih robust daripada menggunakan distribusi Normal. Berdasarkan pernyataan tersebut, Nguyen, dkk (2016) memperkenalkan model *Mixture Laplace Autoregressive* (MLAR) yang menggunakan model gabungan *conditional Laplace*, sebagai alternatif model MAR. Hasil analisis yang dilakukan oleh Nguyen, dkk (2016) pada data *calcium imaging of zebrafish brain* menunjukkan bahwa hasil bahwa model yang dibentuk dengan MLAR telah mampu menangkap pola data yang menggambarkan kondisi yang sebenarnya.

Penelitian mengenai risiko saham syariah menggunakan metode VaR dengan pendekatan *Mixture Normal Autoregressive* (MNAR) pernah dilakukan oleh Putri (2016). Analisis tersebut diimplementasikan pada 3 perusahaan yang tergabung dalam JII dengan kapitalisasi terbesar, diantaranya PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLKM) dan PT. Unilever Indonesia Tbk (UNVR). Analisis tersebut dilakukan oleh Putri (2006) karena *return* saham ketiga perusahaan memiliki variabilitas yang berbeda karena adanya nilai ekstrim pada ujung kanan dan kiri. Selain itu ketiga *return* saham juga tidak Normal, yang ditunjukkan dengan distribusi *return* yang lebih runcing daripada distribusi normal atau biasa disebut leptokurtik. Hasil dari analisis tersebut menunjukkan bahwa model MNAR belum lebih baik dalam menangkap pola data *return* saham yang tidak homogen yang menyebabkan ketidaknormalan data sehingga untuk menangani hal tersebut dilakukan analisis menggunakan metode yang lebih sesuai.

Berdasarkan uraian di atas, pada penelitian tugas akhir ini akan dilakukan analisis risiko dengan MLAR akan diimplementasikan pada data *return* saham yang sama seperti yang digunakan oleh Putri (2016). Metode MLAR digunakan karena distribusi *return* dari saham syariah lebih runcing daripada distribusi Normal (leptokurtik) yang menyerupai sifat distribusi Laplace dan terindikasi adanya multimodal.

Estimasi parameter akan dilakukan dengan menggunakan pendekatan Bayesian *Markov Chain Monte Carlo* (MCMC). Bayesian MCMC dapat mengatasi kesulitan tinggi dalam proses estimasi parameter jika dibandingkan dengan menggunakan metode estimasi lain misalkan MPLE (*Maximum Partial Likelihood*

Estimation), karena masing-masing fungsi distribusi harus dilikelihodkan dan akan menghasilkan persamaan yang rumit.

1.2 Rumusan Masalah

Saham merupakan salah satu sekuritas yang memiliki tingkat risiko yang tinggi. Oleh sebab itu pengukuran risiko sangat penting pada bidang investasi. Dengan diketahuinya risiko, maka kebijakan investasi dapat dilakukan dengan lebih terukur. Salah satu metode yang digunakan untuk mengukur risiko adalah *Value at Risk* (VaR). Risiko merupakan kemungkinan dampak yang akan terjadi di masa depan, oleh sebab itu perlu dilakukan peramalan. Banyak metode yang telah dikembangkan untuk peramalan. Nguyen, dkk (2016) memperkenalkan model *Mixture Laplace Autoregressive* (MLAR) yang menyatakan bahwa dengan MLAR, masalah-masalah yang terjadi pada saat diterapkan asumsi Normal untuk residual akan teratasi. Dengan demikian maka dalam penelitian ini ingin didapatkan model MLAR dengan pendekatan Bayesian MCMC yang terbentuk dan hasil pengukuran risiko saham syariah pada data *return* PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLKM) dan PT. Unilever Indonesia Tbk (UNVR).

1.3 Tujuan

Berdasarkan permasalahan yang telah diuraikan di atas, tujuan yang ingin dicapai dalam penelitian ini adalah.

1. Menentukan model MLAR dengan pendekatan Bayesian MCMC yang terbentuk pada data *return* PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLKM) dan PT. Unilever Indonesia Tbk (UNVR).
2. Menghasilkan pengukuran risiko investasi saham pada PT. Astra International Tbk (ASII), PT. Telekomunikasi Indonesia Tbk (TLKM) dan PT. Unilever Indonesia Tbk (UNVR) menggunakan metode VaR dengan pendekatan MLAR.

1.4 Manfaat

Hasil penelitian ini diharapkan dapat menambah khasanah keilmuan, khususnya dalam pengembangan metode untuk menyelesaikan masalah yang berkaitan dengan model MLAR. Selain itu, penelitian ini juga bermanfaat bagi investor yang ingin melakukan investasi dengan mempertimbangkan VaR pada saham-saham emiten yang tercatat di *Jakarta Islamic Index* (JII) khususnya perusahaan yang digunakan sebagai sampel.

1.5 Batasan Masalah

Analisis yang dilakukan dalam penelitian ini memiliki batasan masalah yaitu estimasi parameter model MLAR menggunakan analisis Bayesian MCMC dengan *Gibbs Sampler*. Jumlah *mixture* yang digunakan maksimal 3 komponen yang didapatkan dengan mengkombinasikan komponen *autoregressive* yang mungkin terbentuk. Selain itu, distribusi prior yang digunakan adalah *pseudo prior* dan *conjugate prior*.

Halaman sengaja dikosongkan

BAB 2

TINJAUAN PUSTAKA

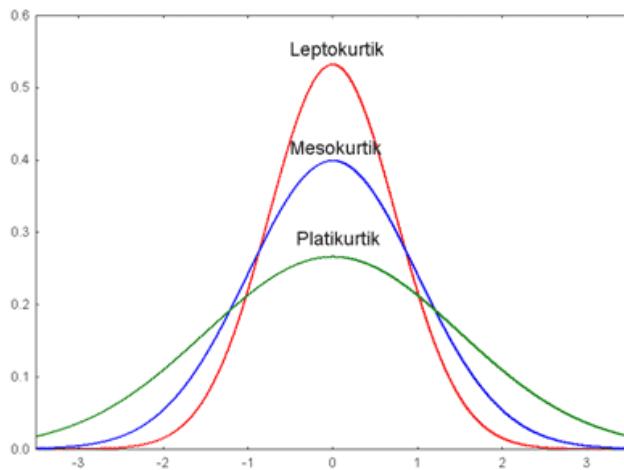
Bab ini akan membahas mengenai landasan teori yang digunakan dalam penelitian ini. Teori-teori tersebut meliputi konsep kemiringan dan kurtosis, ARIMA, *Mixture Autoregressive*, *Mixture Laplace Autoregressive* (MLAR), analisis Bayesian, Uji Signifikansi, *Deviance In Criterion* (DIC) untuk pemilihan model terbaik, *Value at Risk* (VaR) dan *Return* saham. Dalam paparan teori tersebut terdapat subbab yang membahas hal-hal yang berkaitan dengan teori-teori yang telah disebutkan. Penjelasan teori-teori tersebut lebih detail adalah sebagai berikut.

2.1 Kemiringan dan Kurtosis

Sebelum dilakukan pemodelan, sebaiknya terlebih dulu dilakukan identifikasi distribusi data, sehingga pemodelan yang dilakukan lebih valid. Identifikasi distribusi data dapat dilakukan secara deskriptif maupun inferensi. Salah satu cara identifikasi data yang bersifat deskriptif adalah dengan melihat bentuk kurva pendekatan distribusi empirisnya, yaitu dengan menghitung nilai kemiringan (*skewness*) dan keruncingan (*kurtosis*).

Kemiringan (*skewness*) merupakan derajat ketidaksimetrian, atau dapat juga didefinisikan sebagai penyimpangan dari kesimetrian, dari suatu distribusi. Jika suatu kurva frekuensi dari suatu distribusi memiliki ekor kurva yang lebih panjang ke arah sisi kanan dibandingkan ke arah sisi kiri dari nilai maksimum tengah, maka distribusi seperti ini dikenal dengan distribusi miring kanan, atau memiliki kemiringan positif. Sebaliknya, jika ekor kurva yang lebih panjang ke arah sisi kiri dibandingkan ke arah sisi kanan dari nilai maksimum tengah, maka distribusi seperti ini dikenal dengan distribusi miring kiri, atau memiliki kemiringan negatif (Spiegel & Stephens, 1999). Jika nilai dari kemiringan adalah nol maka distribusi datanya adalah simetris.

Kurtosis adalah derajat ketinggian puncak atau keruncingan suatu distribusi. Nilai kurtosis biasanya merupakan nilai relatif distribusi Normal. Sebuah distribusi yang mempunyai puncak yang relatif tinggi (Spiegel & Stephens, 1999).



Gambar 2. 1 Kurtosis

Gambar 2.1 menunjukkan visualisasi kurtosis yaitu leptokurtik, mesokurtik dan platikurtik. Distribusi leptokurtik memiliki ekor tebal (*fat tail*) yang menunjukkan peluang adanya nilai ekstrim yang lebih tinggi dan memiliki bentuk yang lancip, dimana nilai-nilai observasi terkonsentrasi dalam rentang nilai yang sempit. Distribusi yang memiliki sifat leptokurtik adalah distribusi Laplace dan Logistik. Distribusi mesokurtik memiliki bentuk yang tidak datar dan tidak lancip dan biasa disebut distribusi Normal. Distribusi platikurtik memiliki ekor tipis (*thin tail*) dan berbentuk datar, dimana nilai-nilai observasi didistribusikan secara merata di semua kelas. Kurtosis distribusi mesokurtik (Normal) adalah tiga, untuk distribusi leptokurtik adalah lebih dari tiga. Sedangkan untuk distribusi yang platikurtik nilai kurtosismnya adalah kurang dari tiga.

2.2 Model Autoregressive (AR)

Model Autoregressive atau AR(p) menyatakan bahwa situasi yang diamati pada masa sekarang bergantung pada pengamatan pada masa lalu. Persamaan model AR (p) dapat dituliskan dengan persamaan.

$$\phi_p(B) \dot{y}_t = a_t, \quad (2.1)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \cdots - \phi_p B^p), \quad (2.2)$$

maka persamaan matematis dari AR(p) adalah

$$\begin{aligned} (1 - \phi_1 B - \cdots - \phi_p B^p) \dot{y}_t &= a_t \\ \dot{y}_t - \phi_1 \dot{y}_{t-1} - \cdots - \phi_p \dot{y}_{t-p} &= a_t \\ \dot{y}_t &= \phi_1 \dot{y}_{t-1} + \cdots + \phi_p \dot{y}_{t-p} + a_t; \quad \dot{y}_t = y_t - \mu, \end{aligned} \quad (2.3)$$

keterangan:

ϕ_p = parameter Autoregressive lag ke- p

a_t = residual observasi ke- t

2.3 Stasioneritas Time Series

Suatu series dinyatakan stasioner dalam *mean* jika proses pembangkitan yang mendasari suatu *time series* didasarkan pada *mean* atau penyebaran *series* yang konstan. Begitu pula untuk stasioner dalam varians, *series* dinyatakan stasioner dalam varians jika proses pembangkitan yang mendasari suatu *time series* didasarkan pada varians atau penyebaran *series* yang konstan. Untuk mengetahui data sudah stasioner atau tidak, dilakukan uji Levene untuk menguji apakah data sudah stasioner terhadap varians atau tidak serta melihat *time series plot*, ACF dan PACF untuk mengetahui apakah data sudah stasioner terhadap *mean* atau tidak.

2.3.1 Uji Levene

Uji Levene digunakan untuk menguji apakah m sampel memiliki varians yang sama (Levene, 1960). Varians yang sama di seluruh sampel disebut homogenitas varians. Uji Levene dapat digunakan untuk memverifikasi asumsi homogenitas varians. Uji Levene kurang sensitif dibandingkan uji Bartlett untuk data yang berdistribusi Normal. Jadi, jika data tidak berdistribusi Normal atau tidak

diketahui distribusi dari data, uji Levene cocok untuk menguji homogenitas varians.

Hipotesis uji Levene adalah.

Hipotesis:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_m^2$$

$$H_1: \sigma_i^2 \neq \sigma_j^2 \text{ untuk paling sedikit satu pasangan } (i, j)$$

statistik uji:

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

dimana N adalah jumlah observasi, y_{ij} adalah $|Y_{ij} - \bar{Y}_{i\cdot}|$, $\bar{Y}_{i\cdot}$ adalah *mean* dari subgrup ke- i , $\bar{y}_{i\cdot}$ adalah *mean* dari $y_{i\cdot}$ dan $\bar{y}_{..}$ adalah *mean* keseluruhan dari y_{ij} .

2.3.2 Autocorrelation Function (ACF)

Autocorrelation Function (ACF) merupakan analisis *time series* yang menunjukkan kovarians dan korelasi antara y_t dan y_{t+k} dari proses yang sama, yang hanya dipisah oleh lag ke- k (Wei, 2006).

$$\rho_k = \frac{\text{Cov}(y_t, y_{t+k})}{\sqrt{\text{Var}(y_t)} \sqrt{\text{Var}(y_{t+k})}} \quad (2.5)$$

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} = \frac{\gamma_k}{\gamma_0}, k = 0, 1, \dots \quad (2.6)$$

dengan $\gamma_0 = \text{Var}(y_t) = \text{Var}(y_{t+k})$, γ_k disebut fungsi *autocovariace*, ρ_k disebut *autocorrelation function (ACF)* populasi dan $\hat{\rho}_k$ disebut ACF sampel. *Mean* sampel dari data (\bar{y}) diperoleh dari perhitungan dengan menggunakan rumus $\bar{y} = \sum_{t=1}^n y_t / n$ (Wei, 2006).

2.3.3 Partial Autocorrelation Function (PACF)

PACF ($\hat{\phi}_{kk}$) merupakan analisis *time series* yang menunjukkan varians dan korelasi antara y_t dan y_{t+k} setelah mutual linier dependensi pada variabel intervensi y_{t+1}, y_{t+2}, \dots , dan y_{t+k-1} telah dihilangkan (Wei, 2006).

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

dengan $\hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - \hat{\phi}_{kk} \hat{\phi}_{k-1,k-j}$, untuk $j = 1, 2, \dots, k-1$ dan $\hat{\phi}_{11} = \hat{\rho}_1$.

2.4 Proses Non Stationeritas

Dalam menarik kesimpulan mengenai struktur dari proses stokastik berdasarkan jumlah pengamatan yang terbatas, harus dilakukan penyederhanaan asumsi dari struktur tersebut. Asumsi penting yang digunakan adalah stasioneritas data. Untuk memenuhi asumsi stasioneritas, pada suatu *time series* yang non stasioner perlu dilakukan transformasi untuk nonstasioner pada varians dan *difference* untuk kasus non stasioner terhadap *mean* (Wei, 2006).

2.4.1 Differencing

Suatu *series* dikatakan stasioner dalam *mean* jika proses pembangkitan yang mendasari suatu *time series* didasarkan pada *mean* yang konstan. Pada proses nonstasioner dalam *mean* ini dapat dilakukan *difference* dimana tujuannya untuk mencapai stasioneritas. Notasi yang sangat bermanfaat adalah *backward shift* (B). Operator tersebut mempunyai pengaruh menggeser data satu periode kebelakang. Operasi pembeda orde ke- d menghasilkan *series* baru yaitu W_t (Makridakris, Wheelwright, & McGee, 1999).

$$W_t = (1 - B)^d y_t \quad (2.8)$$

Untuk memeriksa ke stasionetitas, dapat digunakan *time series plot* dari data. Jika plot berfiktuasi di sekitar garis yang sejajar sumbu waktu, dapat dikatakan *series* telah stasioner terhadap *mean*.

2.4.2 Transformasi Box-Cox

Differencing belum tentu akan mengubah data yang tidak stasioner menjadi stasioner. Banyak data yang stasioner terhadap *mean* tetapi tidak stasioner terhadap varians. Oleh karena itu, perlu dilakukan transformasi yang bertujuan untuk menstabilkan varians yaitu dengan transformasi Box-Cox (Wei, 2006).

$$T(y_t) = \frac{y_t^\Lambda - 1}{\Lambda} \quad (2.9)$$

Tabel 2. 1 Transformasi Box-Cox

Λ	Transformasi
-1	$\frac{1}{y_t}$
-0,5	$\frac{1}{\sqrt{y_t}}$
0	$\ln y_t$
0,5	$\sqrt{y_t}$
1	y_t

Sumber: Wei, 2006

Tabel 2.1 merupakan tabel transformasi Box-Cox yang digunakan dalam menstabilkan varians.

Adapun syarat untuk melakukan transformasi adalah sebagai berikut.

- Transformasi dilakukan hanya untuk deret y_t yang positif.
- Transformasi dilakukan sebelum melakukan *differencing*.
- Selain menstabilkan varians, transformasi juga bertujuan untuk menormalkan residual.

2.5 Diagnostic Check

Time series dimulai dengan identifikasi model dan estimasi parameter. Setelah estimasi parameter, langkah selanjutnya adalah menaksir kecukupan model. *Diagnostic check* dilakukan dengan menguji apakah residual sudah identik, independen dan berdistribusi Normal atau tidak. Hal itu dilakukan untuk mendapatkan hasil peramalan yang baik. Uji yang digunakan untuk asumsi independen adalah uji Ljung-Box (Wei, 2006).

Hipotesis:

$$H_0: \rho_1 = \rho_2 = \dots = \rho_\kappa = 0$$

$$H_1: \text{minimal ada satu } \rho_k \neq 0 \quad (k = 1, 2, \dots, \kappa)$$

statistik uji:

$$Q^* = n(n+2) \sum_{k=1}^{\kappa} \frac{\rho_k^2}{n-k}, \quad (2.10)$$

daerah penolakan:

tolak H_0 jika $Q^* > x_{\alpha, df}^2$, dengan derajat bebas $(df) = \kappa - p - q$.

Uji homogenitas residual dapat dilakukan dengan uji *Lagrange Multiplier* (LM).

Hipotesis:

$$H_0: \xi_1 = \xi_2 = \dots = \xi_p = 0$$

$$H_1: \text{minimal ada satu } \xi_i \neq 0 \quad (i = 1, 2, \dots, p)$$

statistik uji:

$$LM = T \times R^2. \quad (2.11)$$

daerah penolakan:

tolak H_0 jika $LM > x_{\alpha, df}^2$, dengan derajat bebas $(df) = p$ (banyaknya periode waktu sebelumnya yang mempengaruhi data sekarang).

T adalah ukuran sampel ($n - s$) dan R^2 adalah koefisien determinasi yang dihitung dari regresi menggunakan estimasi dari residual $(a_t^2 = \zeta_0 + \zeta_1 a_{t-1}^2 + \dots + \zeta_p a_{t-p}^2 + u_t)$ (Andersen, Davis, K., & Mikhosch, 2009).

Diagnostic Check lainnya adalah menguji asumsi distribusi residual. Pengujian asumsi distribusi residual yang digunakan adalah uji *Kolmogorov smirnov* (Daniel, 1989).

Hipotesis:

$$H_0: F(x) = F_0(x)$$

$$H_1: F(x) \neq F_0(x)$$

statistik uji:

$$D = \text{Sup}|S(x) - F_0(x)|, \quad (2.12)$$

keterangan:

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

$F_0(x)$: fungsi peluang kumulatif distribusi tertentu

$F(x)$: fungsi distribusi yang belum diketahui

Sup : nilai supremum semua x dari $|S(x) - F_0(x)|$

daerah penolakan:

tolak H_0 jika $D > D_{1-\alpha,n}$ dengan derajat n adalah jumlah sampel dan $D_{1-\alpha,n}$ adalah nilai D dari tabel *Kolmogorov smirnov*.

2.6 Distribusi Laplace

Distribusi Laplace klasik adalah sebuah distribusi peluang dengan *probability distribution function* (pdf)

$$f(y; \mu, s) = \frac{1}{2s} e^{-|y-\mu|/\sigma}, -\infty < y < \infty, \quad (2.13)$$

dimana $\mu \in (-\infty, \infty)$ dan $s > 0$ adalah parameter *location* dan *scale*. Distribusi Laplace juga dikenal sebagai perbedaan antara dua variable *random* eksponensial

sehingga disebut distribusi *double exponential*, distribusi *two-tailed exponential* dan *the bilateral exponential law*.

Persamaan (2.13) sama dengan $2s^2$. Dengan demikian varians dari distribusi Laplace klasik standar, yang memiliki kepadatan

$$g(y; 0, 1) = \frac{1}{2} e^{-|y|}, -\infty < y < \infty, \quad (2.14)$$

sama dengan 2. Untuk berbagai derivasi tampaknya lebih baik memasukkan kembali parameter dari kepadatan distribusi Laplace

$$g(y; \mu, \sigma) = \frac{1}{\sqrt{2}\sigma} e^{-\sqrt{2}|y-\mu|/\sigma}, -\infty < y < \infty. \quad (2.15)$$

Dalam kasus ini distribusi Laplace standar ditentukan nilai $\mu = 0$ dan $\sigma = 1$. Dengan *location* sama dengan 1, bentuk kepadatan peluang dapat ditulis

$$g(y; 0, 1) = \frac{1}{\sqrt{2}} e^{-\sqrt{2}|y|}, -\infty < y < \infty, \quad (2.16)$$

Perbedaan distribusi Laplace klasik dan standar divisualisasikan pada Gambar 2.2

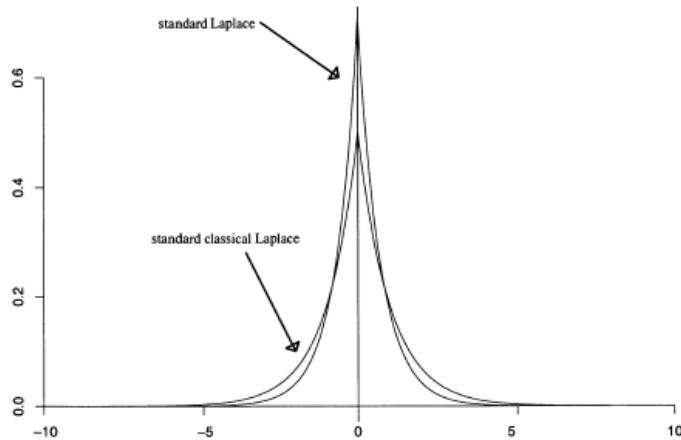
Cumulative distribution function (Cdf) untuk persamaan (2.13) adalah

$$F(y; \mu, s) = \begin{cases} \frac{1}{2} e^{-|y-\mu|/s} & ; y \leq \mu, \\ 1 - \frac{1}{2} e^{-|y-\mu|/s} & ; y \geq \mu. \end{cases} \quad (2.17)$$

Distribusi ini simetris terhadap μ , untuk sembarang y , maka

$$f(\mu - y; \mu, s) = f(\mu + y; \mu, s) \text{ dan } F(\mu - y; \mu, s) = 1 - F(\mu + y; \mu, s). \quad (2.18)$$

Konsekuensi yang didapat adalah *mean*, median dan modus dari distribusi ini semua sama dengan μ (Kotz, Kozubowski, & Podgorski, 2001).



Gambar 2. 2 Perbedaan distribusi Laplace klasik dan standar

2.7 Model *Mixture Autoregressive*

Jika diketahui data yang apabila dilakukan terhadap distribusi (*goodness of fit*) secara univariate unimodal selalu menolak hipotesis nol, meskipun sudah dilakukan terhadap distribusi Exponential Power, Normal miring dan MSNBurn, maka layak data tersebut untuk diduga mempunyai pola yang akan mengikuti distribusi campuran atau bahkan layak untuk diduga berdistribusi univariate multimodal. Pendekatan rumus pola distribusi campuran dan univariate multi modal sebagai berikut (Iriawan, 2012).

$$f_{mix}(y|\boldsymbol{\theta}, \mathbf{w}) = \sum_{j=1}^K w_j g_j(y|\boldsymbol{\theta}_j) \quad (2.19)$$

dengan $f_{mix}(y|\boldsymbol{\theta}, \mathbf{w})$ adalah fungsi densitas distribusi *mixture*, $g_j(y|\boldsymbol{\theta}_j)$ adalah fungsi densitas ke- j sebanyak K komponen penyusun model distribusi campuran, $\boldsymbol{\theta}_j$ adalah vektor parameter setiap distribusi komponen penyusun distribusi campuran $(\theta_1, \theta_2, \dots, \theta_j)$, $j = 1, 2, \dots, K$, \mathbf{w} adalah vektor parameter proporsi

dengan elemen-elemen (w_1, w_2, \dots, w_i) . w_j adalah parameter proporsi komponen distribusi campuran dengan $\sum_{j=1}^K w_j = 1$ serta $0 \leq w_j \leq 1, j = 1, 2, \dots, K$ dan K adalah banyaknya distribusi sebagai komponen penyusun distribusi campuran.

Model distribusi campuran yang dinyatakan pada persamaan (2.19) berlaku untuk pemodelan distribusi campuran dengan banyaknya komponen tertentu (*finite mixture model*). Jika data berdistribusi Normal dengan *mean* μ_j dan varians σ_j^2 sebanyak K komponen, maka persamaan (2.19) dapat dituliskan dalam persamaan berikut.

$$f_{mix}(y | \mathbf{w}, \boldsymbol{\mu}, \boldsymbol{\sigma}^2) = w_1 N(y | \mu_1, \sigma_1^2) + \dots + w_K N(y | \mu_K, \sigma_K^2) \quad (2.20)$$

2.8 Model *Mixture Laplace Autoregressive*

Wong dan Li (2000) telah memperkenalkan metode *Mixture Autoregressive* (MAR) dengan menggunakan model gabungan K komponen conditional Gaussian dengan persamaan

$$F(y_t | \mathcal{F}_{t-1}; \boldsymbol{\vartheta}) = \sum_{j=1}^K \pi_j \Phi\left(y_t; \boldsymbol{\phi}_{j,0} + \sum_{i=1}^p \boldsymbol{\phi}_{j,i} y_{t-i}, \sigma_j\right), \quad (2.21)$$

Φ adalah fungsi kepadatan Normal, $\pi_j > 0, \sum_{j=1}^K \pi_j = 1, \boldsymbol{\phi} = (\phi_{j,0}, \phi_{j,1}, \dots, \phi_{j,p})^T \in \mathbb{R}^{p+1}$, serta $\sigma_j > 0$ untuk semua $j = 1, 2, \dots, K$.

Mixture Laplace Autoregressive (MLAR) merupakan model yang dikenalkan oleh Nguyen, dkk (2016) dengan menggunakan model gabungan *conditional Laplace*, sebagai alternatif model MAR. Model MLAR mensyaratkan kondisi yang stasioner. Nguyen dan McLachan (2016) juga mengatakan bahwa asumsi Normal yang diterapkan pada residual sensitif terhadap *outlier*. Dengan MLAR, masalah-masalah yang terjadi pada saat diterapkan asumsi Normal untuk

residual akan teratasi. Y_t dinyatakan berasal dari sebuah K komponen model MLAR order p (model MLAR (K, p)) $Y_t | \mathcal{F}_{t-1}; \boldsymbol{\vartheta}$ jika mempunyai bentuk kepadatan

$$F(y_t | \mathcal{F}_{t-1}; \boldsymbol{\vartheta}) = \sum_{j=1}^K \pi_j \lambda\left(y_t; \phi_{j,i0} + \sum_{i=1}^p \phi_{j,i} y_{t-i}, \sigma_j\right), \quad (2.22)$$

dimana

$$\lambda(y; \mu, \sigma) = (\sigma\sqrt{2})^{-1} \exp(-\sqrt{2}|x - \mu|/\sigma) \quad (2.23)$$

adalah fungsi kepadatan Laplace dengan *mean* μ , varians σ^2 dan

$$\boldsymbol{\vartheta} = (\pi_1, \pi_2, \dots, \pi_K, \boldsymbol{\phi}_1^T, \boldsymbol{\phi}_2^T, \dots, \boldsymbol{\phi}_K^T, \sigma_1, \sigma_2, \dots, \sigma_K)^T \quad (2.24)$$

adalah model vektor parameter. Residual dari model MLAR juga dianggap memiliki distribusi Laplace (Nguyen & McLachlan, Laplace mixture of linear experts, 2016).

Model MLAR mempunyai *conditional mean* dan *conditional* varians berturut-turut adalah

$$E(Y_t | \mathcal{F}_{t-1}) = \sum_{j=1}^K \pi_j \boldsymbol{\phi}_j^T \mathbf{y}_{(t-1)} \quad (2.25)$$

dan

$$Var(Y_t | \mathcal{F}_{t-1}) = \sum_{j=1}^K \pi_j \sigma_j^2 + \sum_{j=1}^K \pi_j \left[\boldsymbol{\phi}_j^T \mathbf{y}_{(t-1)} \right]^2 + \left[\sum_{j=1}^K \pi_j \boldsymbol{\phi}_j^T \mathbf{y}_{(t-1)} \right]^2. \quad (2.26)$$

dimana $\mathbf{y}_{t-1} = (1, y_{t-1}, \dots, y_{t-p})^T$. Jika vektor parameter diketahui atau diestimasi, Persamaan (2.25) dan (2.26) dapat digunakan untuk melakukan prediksi dari y_t , berdasarkan \mathcal{F}_{t-1} .

2.9 Stationeritas Model MLAR

Analog dengan Teorema 1 dalam Wong dan Li (2000), stasioneritas order pertama dari model MLAR (K, p) , menggunakan persamaan (2.25) dan ketentuan total harapan sebagai berikut.

Teorema 1 (Nguyen, Geoffrey, Ullmann, & Janke, 2016). Syarat perlu dan cukup agar Y_t stasioner dalam *mean* (orde pertama) adalah akar-akar persamaan

$$1 - \sum_{i=1}^p \left(\sum_{j=1}^K \pi_j \phi_{j,i}^T \right) z^{-i} = 0, \quad (2.27)$$

semuanya berada di dalam unit *circle*.

Asumsikan bahwa Y_t mempunyai *mean* nol. Dengan menggunakan ketentuan total harapan, memungkinkan untuk menunjukkan bahwa Y_t adalah stasioner orde kedua. Maka untuk setiap $k = 1, 2, \dots, p$

$$\begin{aligned} E(Y_t Y_{t-k}) &= E[E(Y_t Y_{t-k} | \mathcal{F}_{t-1})] \\ &= E[Y_{t-k} E(Y_t | \mathcal{F}_{t-1})] \\ &= \sum_{i=1}^p \left(\sum_{j=1}^K \pi_j \phi_{j,i} \right) E(Y_{t-j} Y_{t-k}). \end{aligned} \quad (2.28)$$

Ini berarti bahwa jika Y_t dibentuk dari MLAR (K, p) stasioner orde kedua, kemudian autokorelasi Y_t bisa dihasilkan menggunakan persamaan (2.29)

$$\rho_k = \sum_{i=1}^p \left(\sum_{j=1}^K \pi_j \phi_{j,i} \right) \rho_{|k-i|}, \quad (2.29)$$

dimana $k = 1, 2, \dots, p$.

Seperti Wong dan Li (2000), stasioneritas order kedua dari model MLAR $(K,1)$ dan MLAR $(K,2)$, menggunakan persamaan (2.27) sampai (2.29) dan ketentuan total harapan sebagai berikut.

Teorema 2 (Nguyen, Geoffrey, Ullmann, & Janke, 2016). Y_t diambil dari model MLAR $(K,1)$ yang telah stasioner orde pertama. Syarat perlu dan cukup agar Y_t stasioner orde kedua adalah $\left| \sum_{j=1}^K \pi_j \phi_{j,1}^2 \right| < 1$.

Teorema 3 (Nguyen, Geoffrey, Ullmann, & Janke, 2016). Y_t diambil dari model MLAR $(K,2)$ yang telah stasioner orde pertama. Syarat perlu dan cukup agar Y_t stasioner orde kedua adalah $\alpha_2 + \alpha_1 < 1, \alpha_2 - \alpha_1 < 1$ dan $\alpha_2 < 1$, dimana

$$\alpha_1 = \sum_{j=1}^K \pi_j \phi_{j,1}^2 + \frac{2 \left(\sum_{j=1}^K \pi_j \phi_{j,1} \phi_{j,2} \right) \left(\sum_{j=1}^K \pi_j \phi_{j,1} \right)}{1 - \sum_{j=1}^K \pi_j \phi_{j,2}} \quad (2.30)$$

dan

$$\alpha_2 = \sum_{j=1}^K \pi_j \phi_{j,2}^2. \quad (2.31)$$

2.10 Penaksiran Parameter

Penaksiran parameter untuk MLAR dilakukan dengan menggunakan Bayesian *Markov Chain Monte Carlo* (MCMC). Berikut ini akan dipaparkan mengenai metode bayes dan MCMC.

2.10.1 Metode Bayesian

Model bayesian dikembangkan dari metode bayes. Metode yang digunakan untuk model bayesian dinamakan metode bayes. Dasar dari metode ini adalah teorema bayes. Dalam teorema bayes klasik, teori probabilitas dapat dituliskan dengan persamaan (2.32).

$$p(\theta|y) = \frac{p(y|\theta)p(\theta)}{p(y)} \quad (2.32)$$

dimana θ yang menunjukkan parameter yang akan diestimasi.

Dalam Teorema Bayes terdapat pembaruan informasi prior dengan menggunakan informasi sampel yang terdapat dalam data melalui fungsi likelihood yang dituliskan sebagai berikut.

$$p(\theta|y) = \frac{f(y|\theta)p(\theta)}{p(y)} \quad (2.33)$$

dengan $p(\theta|y)$ adalah distribusi posterior, $p(\theta)$ adalah distribusi prior, $f(y|\theta)$ adalah nilai likelihood dari sampel dan $p(y)$ adalah *normalized constant* yang dapat diabaikan, sehingga distribusi posterior dapat dituliskan

$$p(\theta|y) \propto f(y|\theta)p(\theta). \quad (2.34)$$

2.10.2 Distribusi Prior

Distribusi prior adalah bagian penting dari inferensi Bayesian dan mewakili informasi tentang parameter yang tidak pasti yang dikombinasikan dengan distribusi probabilitas data baru untuk menghasilkan distribusi posterior, yang pada akhirnya digunakan untuk kesimpulan dan keputusan masa depan melibatkan distribusi prior. Masalah-masalah utama dalam mendirikan sebuah distribusi prior adalah informasi apa yang masuk ke dalam distribusi prior dan sifat distribusi posterior yang dihasilkan. Dengan parameter yang diidentifikasi dan

sampel yang berukuran besar, pilihan yang sesuai dari distribusi sebelumnya akan memiliki efek kecil pada kesimpulan posterior (Gelman, 2002). Adapun jenis-jenis distribusi prior sebagai berikut.

1. Prior informatif (*informative prior*)

Prior informatif (*informative prior*) mengacuh pada pemberian nilai parameter yang berdasarkan informasi-informasi permasalahan yang ada. Prior informatif (*informative prior*) dikelompokkan menjadi tiga, yaitu prior tidak informatif (*noninformative prior*), prior informatif tinggi (*highly informative prior*) dan prior informatif menengah/cukup (*moderately informative hierarchical prior*). Prior tidak informatif (*noninformative prior*) mempertimbangkan parameter varians σ_1^2 dan σ_2^2 , yang sebenarnya cukup baik diidentifikasi dalam distribusi posterior. Prior informatif tinggi (*highly informative prior*) cukup tepat digunakan pada kondisi ekstrim yaitu saat informasi ilmiah menyediakan beberapa parameter Θ dalam model. Prior informatif menengah/ cukup (*moderately informative hierarchical prior*) digunakan jika beberapa parameter fisiologis Θ yang tidak baik diperkirakan oleh data tetapi informasi ilmiah yang dimiliki terbatas (Gelman, 2002).

2. *Conjugate* dan *Non-conjugate prior*

Conjugate prior merupakan metode estimasi parameter yang banyak digunakan yang memungkinkan semua hasil yang akan diturunkan dalam bentuk tertutup. *Conjugate prior* selalu mempertimbangkan pemilihan distribusi prior dalam bentuk sekawan dengan distribusi pembentuk fungsi likelihoodnya (Murphy, 2007). Sebuah konjugat sebelumnya dibangun dengan memfaktorkan fungsi likelihood menjadi dua bagian. Faktor pertama harus independen dari parameter yang menarik tetapi mungkin tergantung pada data. Faktor kedua adalah fungsi tergantung pada parameter yang menarik dan tergantung pada data hanya melalui statistik yang cukup. *Conjugate prior* diharuskan proporsional pada faktor kedua ini (Fink, 1997). Sebaliknya, *non-conjugate prior* merupakan penentuan distribusi *prior* yang tidak didasarkan pada pola fungsi *likelihood* (Box & Tiao, 1973).

3. *Proper* dan *Non-proper prior*

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 & Tiao, 1973).

4. *Pseudo prior*

Pseudo prior, yaitu prior yang berhubungan yang penentuan nilainya didasarkan pada estimasi secara *frequentist* (Charlin dan Chib, 1995).

2.10.3 *Markov Chain Monte Carlo* (MCMC) dengan *Gibbs Sampler*

Markov Chain Monte Carlo (MCMC) adalah metode umum yang dilakukan dengan menentukan nilai-nilai θ dari pendekatan distribusi dan kemudian nilai-nilai θ tersebut diperbaiki untuk lebih mendekati target distribusi posterior $p(\theta|y)$. Sampel diambil secara berurutan, dengan distribusi sampel yang diambil tergantung pada nilai terakhir yang diambil, dengan demikian sampel yang diambil membentuk rantai *markov* Chain. Sebuah rantai *markov* merupakan rangkaian variabel random $\theta^1, \theta^2, \dots, \theta^b$. Distribusi dari θ^b yang diberikan hanya bergantung pada semua θ sebelumnya pada nilai yang baru saja muncul yaitu θ^{b-1} . Kunci kesuksesan metode terletak pada pendekatan distribusi yang diperbaiki pada setiap tahap simulasi, dalam hal ini adalah kondisi konvergen.

Dalam aplikasi MCMC, beberapa rangkaian pengambilan simulasi independen dibentuk. Setiap rangkaian $\theta^b, b = 1, 2, 3, \dots$ dibuat dengan menentukan titik θ^0 sebagai langkah awal, selanjutnya untuk setiap t dilakukan pengambilan θ^b dari sebuah distribusi transisi yaitu $T_b(\theta^b | \theta^{b-1})$ yang tergantung pada pengambilan sebelumnya, θ^{b-1} . Distribusi peluang transisi harus dibuat sehingga rantai *Markov* konvergen untuk sebuah distribusi stationer yang unik yaitu distribusi posterior.

MCMC digunakan ketika rantai *Markov* tidak mungkin untuk menghitung sampel θ langsung dari $p(\theta|y)$; sebaliknya dengan menggunakan sampel iteratif sedemikian rupa bahwa setiap langkah dari proses yang diharapkan untuk

mengambil sampel dari distribusi yang mendekati $p(\theta | y)$. Pendekatan ini tampaknya menjadi cara termudah untuk mendapatkan hasil yang reliabel, setidaknya ketika digunakan dengan hati-hati (Gelman, 2002).

Algoritma rantai Markov tertentu yang telah ditemukan dan berguna dalam banyak masalah multidimensi adalah *Gibbs sampler* atau disebut juga *alternating conditional sampling*, yang didefinisikan dalam subvektor dari θ . Misalkan parameter θ telah dibagi menjadi d komponen atau subvektor, $(\theta_1, \theta_2, \dots, \theta_d)$. Setiap iterasi dari siklus *Gibbs sampler* melalui subvektor θ , menggambarkan setiap bagian tergantung pada nilai lain. Pada setiap iterasi b , sebuah urutan dari d subvektor θ dipilih dan, pada gilirannya, setiap θ_j^b adalah sampel dari distribusi bersyarat diberikan semua komponen lain dari θ :

$$p(\theta_j | \theta_{-j}^{b-1}, y), \quad (2.35)$$

dimana θ_{-j}^{b-1} merepresentasikan semua komponen dari θ , kecuali untuk θ_j pada nilai sebenarnya:

$$\theta_{-j}^{b-1} = (\theta_1^b, \theta_2^b, \dots, \theta_{j+1}^{b-1}, \dots, \theta_d^{b-1}). \quad (2.36)$$

kemudian, setiap subvektor θ_j di-*update* secara kondisional pada nilai terakhir dari komponen lain dari θ , dimana iterasi b nilai dari komponen-komponen siap di-*update* dan iterasi $b-1$ nilai-nilai dari komponen yang lain.

Dalam kasus Normal, berarti $\theta = (\mu, \sigma, w)$ sehingga bentuk posterior jointnya adalah $p(\mu, \sigma, w | y)$. *Gibss Sampler* akan membantu menaksir parameter μ, σ dan w secara iteratif dengan mengikuti skema sampling sebagai berikut.

1. Diberikan state: $\theta^b = (\mu, \sigma, w)^b$ pada iterasi ke $b = 0$
2. Membangkitkan parameter komponen setiap *mixture*.
 - a. Membangkitkan $\mu^{(b+1)}$ dari $p(\mu | y, \sigma^{(b)}, w^{(b)})$.

- b. Membangkitkan $\sigma^{(b+1)}$ dari $p(\sigma | y, \mu^{(b+1)}, w^{(b)})$.
 - c. Membangkitkan $w^{(b+1)}$ dari $p(w | y, \mu^{(b)}, \sigma^{(b+1)})$.
3. Mengulangi langkah 2 sebanyak T kali, dimana $T \rightarrow \infty$

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

2.11 Uji Signifikansi Parameter

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 kepercayaan 95% dari distribusi *posterior*, yaitu dengan melihat *credible interval*, jika *credible interval* tidak memuat 0 (nol).

2.12 Kriteria Pemilihan Model Terbaik

Pada umumnya, asumsi distribusi suatu data, $y = (y_1, y_2, \dots, y_n)$, tergantung pada banyaknya parameter (p -dimensi parameter) Θ . Dari sudut pandang frekuatif, model taksiran didasarkan pada *deviance*, selisih dalam log-likelihood antara model *fit* dan *saturated*. Model *saturated* merujuk pada model pada model dengan jumlah parameter sebanyak jumlah observasi, dimana hasil yang diperoleh sesuai dengan data. Berdasarkan analogi, Dempster (1974) menyarankan untuk memeriksa distribusi posterior dari penyimpangan klasik yang didefinisikan

$$D(\Theta) = -2 \ln p(y | \Theta) + 2 \ln g(y) \quad (2.37)$$

untuk pemilihan model Bayesian. $p(\mathbf{y}|\boldsymbol{\theta})$ adalah fungsi likelihood yang merupakan *conditional joint probability density function* dari observasi yang diberikan parameter yang tidak diketahui, dan $\ln g(\mathbf{y})$ menunjukkan syarat standarisasi penuh. Dempster (1974) mengusulkan untuk membandingkan plot dan *mean posterior* dari $D(\boldsymbol{\theta})$ dan Spiegelhalter, dkk. (2002) menyarankan agar menggunakan pengembangan dari *DIC* sebagai kriteria pemilihan model terbaik. Berdasarkan distribusi posterior dari $D(\boldsymbol{\theta})$, *DIC* terdiri dari dua komponen yaitu mengukur *goodness of fit* dan sebuah kondisi *penalty* untuk meningkatkan kompleksitas model:

$$DIC = \bar{D} + 2p_D, \quad (2.38)$$

1. Syarat pertama, sebuah ukuran Bayesian dari model yang sesuai didefinisikan sebagai ekspektasi posterior dari penyimpangan

$$\bar{D} = E_{\boldsymbol{\theta}|\mathbf{y}}[D(\boldsymbol{\theta})] = E_{\boldsymbol{\theta}|\mathbf{y}}[-2\ln f(\mathbf{y}|\boldsymbol{\theta})] \quad (2.39)$$

Model paling sesuai dari data dan lebih baik adalah nilai untuk *log-likelihood*. \bar{D} didefinisikan sebagai -2 kali *log-likelihood*, meskipun memperoleh nilai lebih kecil untuk model yang lebih baik.

2. Komponen kedua mengukur kompleksitas model dengan jumlah parameter yang efektif, p_D didefinisikan sebagai perbedaan antara *mean posterior* dari penyimpangan tersebut dan penyimpangan yang dievaluasi pada posterior *mean* $\bar{\boldsymbol{\theta}}$ dari parameter:

$$\begin{aligned} p_D &= \bar{D} - D(\bar{\boldsymbol{\theta}}) \\ &= E_{\boldsymbol{\theta}|\mathbf{y}}[D(\boldsymbol{\theta})] - D(E_{\boldsymbol{\theta}|\mathbf{y}}[\boldsymbol{\theta}]) \\ &= E_{\boldsymbol{\theta}|\mathbf{y}}[-2\ln L(\mathbf{y}|\boldsymbol{\theta})] + 2\ln f(\mathbf{y}|\bar{\boldsymbol{\theta}}) \end{aligned} \quad (2.40)$$

Dengan mendefinisikan $-2\ln p(\mathbf{y}|\boldsymbol{\theta})$ sebagai informasi residual dalam data \mathbf{y} bersyarat $\boldsymbol{\theta}$ dan menginterpretasikan itu sebagai ukuran ketidakpastian, persamaan (2.40) menunjukkan bahwa p_D dapat dianggap sebagai ekspektasi berlebih dari kebenaran atas informasi residual estimasi data \mathbf{y} bersyarat $\boldsymbol{\theta}$. Dengan demikian p_D dapat ditafsirkan sebagai pengurangan yang diharapkan dalam ketidakpastian karena estimasi.

Model dikatakan baik, jika model tersebut mempunyai *DIC* yang lebih kecil dibandingkan model alternatif lainnya (Berg, Meyer, & Yu, 2004).

2.13 *Value at Risk (VaR)*

Value at Risk (VaR) atau disebut juga *Quantile Risk Metrics* menggambarkan estimasi dari kerugian maksimum yang mungkin terjadi pada portofolio bank akibat risiko pasar dalam periode waktu tertentu dan dalam tingkat keyakinan statistik tertentu. Menurut Butler (1999), VaR merupakan metodologi yang dominan untuk memperkirakan secara tepat berapa banyak uang yang berisiko setiap hari di pasar keuangan. Berdasarkan definisi VaR, jika berbicara tentang VaR pasti tidak lepas dengan istilah risiko. Risiko merupakan kombinasi peluang suatu kejadian dengan konsekuensinya atau akibatnya. Risiko juga dapat didefinisikan sebagai risiko murni (*pure risk*) dan risiko spekulasi (*speculative risk*). Risiko murni (*pure risk*) adalah kemungkinan terjadinya sesuatu yang jika terjadi pasti menyebabkan kerugian, sedangkan risiko spekulasi juga merupakan kemungkinan terjadinya sesuatu, tetapi jika terjadi akibatnya mungkin rugi tetapi juga mungkin untung (Siahaan, 2009). Vaughan (1978) dalam Suswinarno (2013) mengemukakan beberapa definisi risiko, diantaranya risiko didefinisikan sebagai kemungkinan terjadinya kerugian, risiko adalah ketidakpastian, risiko merupakan penyebaran hasil aktual dari hasil yang diharapkan dan risiko sebagai peluang suatu *outcome* berbeda dengan *outcome* yang diharapkan. Ahli statistik mendefinisikan risiko sebagai derajat penyimpangan suatu nilai sekitar suatu posisi sentral atau di sekitar titik *mean* (Suswinarno, 2013).

Dari berbagai definisi di atas, risiko dihubungkan dengan kemungkinan terjadinya akibat buruk (kerugian) yang tidak diinginkan atau tidak terduga. Dengan

kata lain kemungkinan itu sudah menunjukkan adanya ketidakpastian. Oleh sebab itu, untuk menghindari risiko yang tidak diinginkan dilakukan perhitungan VaR.

VaR dapat dihitung secara analitis, pada dasar Normal linier, simulasi historis atau simulasi monte carlo. VaR dapat dirumuskan secara matematis sebagai nilai kerugian pada tingkat kepercayaan tertentu $(1 - \alpha)$ dan hal itu sama dengan menurunkan kuantil dari distribusi probabilitas dari variabel random, sehingga

$$P(X < x_\alpha) = \alpha \quad (2.41)$$

dimana x_α adalah -VaR

Jika fungsi distribusi $F(x)$ dari X diketahui maka kuantil yang sesuai untuk setiap nilai yang diberikan dari α dapat dihitung sebagai

$$x_\alpha = F^{-1}(\alpha) \quad (2.42)$$

sehingga

$$\text{VaR} = -x_\alpha = -F^{-1}(\alpha). \quad (2.43)$$

Metode perhitungan VaR Normal linier merupakan metode yang mengasumsikan bahwa distribusi dari *return* adalah Normal dan portofolio harus linier. Dengan demikian

$$P(X < x_\alpha) = P\left(\frac{X - \mu}{\sigma} < \frac{x_\alpha - \mu}{\sigma}\right) = P\left(Z < \frac{x_\alpha - \mu}{\sigma}\right) = \alpha, \quad (2.44)$$

dimana Z adalah sebuah variable Normal standard. Jadi

$$\frac{x_\alpha - \mu}{\sigma} = \Phi^{-1}(\alpha), \quad (2.45)$$

dengan fungsi distribusi Normal yang simetri,

$$\Phi^{-1}(\alpha) = -\Phi^{-1}(1-\alpha). \quad (2.46)$$

Oleh karena itu, dengan mensubtitusikan $\text{VaR}_\alpha = -x_\alpha$ ke persamaan (2.46) maka

$$\text{VaR} = \Phi^{-1}(1-\alpha)\sigma - \mu. \quad (2.47)$$

Dengan demikian, persamaan yang digunakan untuk menghitung VaR pada horison h adalah dapat dituliskan

$$\text{VaR}_{h,\alpha} = \Phi^{-1}(1-\alpha)\sigma_h - \mu_h. \quad (2.48)$$

Dalam kondisi riil, rezim pasar antara pasar yang satu dengan yang lainnya tidak selalu sama. Metode *mixture* dirancang untuk menangkap rezim pasar yang berbeda. Persamaan yang digunakan untuk menghitung *mixture* VaR pada horison h adalah

$$\sum_{i=1}^n \pi_i P(X < x_{h,\alpha}) = \alpha \quad (2.49)$$

sehingga

$$\text{Var}_{h,\alpha} = \sum_{j=1}^K \pi_j (\Phi^{-1}(1-\alpha)\sigma_{jh} - \mu_{jh}). \quad (2.50)$$

dengan K adalah banyaknya *mixture*.

2.14 *Return* Saham

Saham adalah surat berharga yang menunjukkan kepemilikan perusahaan sehingga pemegang saham memiliki hak klaim atas dividen atau distribusi lain yang

dilakukan perusahaan kepada pemegang sahamnya, termasuk hak klaim atas aset perusahaan, dengan prioritas setelah hak klaim pemegang surat berharga lain dipenuhi jika terjadi likuiditas. Menurut Husnan (2002) sekuritas (saham) merupakan secerik kertas yang menunjukkan hak pemodal (yaitu pihak yang memiliki kertas tersebut) untuk memperoleh bagian dari prospek atau kekayaan organisasi yang menerbitkan sekuritas tersebut dan berbagai kondisi yang memungkinkan pemodal tersebut menjalankan haknya, sedangkan menurut Tandelilin (2001), saham merupakan surat bukti bahwa kepemilikan atas aset-aset perusahaan yang menerbitkan saham. Jadi, saham adalah surat berharga yang diperdagangkan di pasar modal yang dikeluarkan oleh sebuah perusahaan yang berbentuk Perseroan Terbatas (PT), dimana saham tersebut menyatakan bahwa pemilik saham tersebut adalah juga pemilik sebagian dari perusahaan tersebut (Sani, 2013).

Motivasi investor untuk melakukan investasi salah satunya adalah dengan membeli saham perusahaan dengan harapan untuk mendapatkan kembalian (*return*) investasi yang sesuai dengan apa yang telah diinvestasikannya. Return saham menurut Jogiyanto (2000) merupakan hasil yang diperoleh dari investasi. Return dapat berupa return realisasi yang sudah terjadi maupun return ekspektasi yang belum terjadi namun diharapkan akan terjadi di masa mendatang. Return realisasi merupakan return yang sudah terjadi. Return realisasi dihitung berdasarkan data historis. Return ini penting karena digunakan sebagai salah satu pengukur kinerja perusahaan dan juga berguna sebagai dasar penentuan return ekspektasi dan resiko di masa datang. Rumus yang digunakan untuk menentukan *return* adalah

$$X_t = \frac{d_t - d_{t-1}}{d_{t-1}}, \quad (2.51)$$

dimana X_t adalah *return* harga saham pada hari ke- t , d_t adalah harga saham pada hari ke- t , dan d_{t-1} adalah harga saham pada hari ke- $t-1$.

2.15 Backtesting

Backtesting adalah prosedur statistik di mana keuntungan dan kerugian aktual secara sistematis dibandingkan dengan VaR yang sesuai perkiraan. Pengujian *Backtesting* yang paling banyak digunakan adalah uji kupiec. Uji kupiec, juga dikenal sebagai uji POF (*Proportion Of Failure*), mengukur apakah jumlah *exception* konsisten dengan kuantil ke- α (Dowd, 2006). Jumlah *exception* mengikuti distribusi binomial:

$$f(x) = \binom{T}{x} p^x (1-p)^{T-x}. \quad (2.52)$$

Oleh karena itu, satu-satunya informasi yang diperlukan untuk melaksanakan uji kupiec adalah jumlah observasi (T), jumlah *exception* (x) dan kuantil ke- α . (Kansantaloustiede, Tutkielma, & Nieppola, 2009)

Hipotesis untuk uji kupiec adalah

$$H_0 : p = \hat{p}$$

$$H_1 : p \neq \hat{p}$$

Tingkat kegagalan \hat{p} berbeda dengan p yaitu tingkat kegagalan yang mengacu pada kuantil ke- α . Statistik uji yang digunakan adalah *likelihood ratio* (LR) (Kupiec, 1995).

$$LR = -2 \ln \left(\frac{\left(1-p\right)^{T-x} p^x}{\left(1-\frac{x}{T}\right)^{T-x} \left(\frac{x}{T}\right)^x} \right) \quad (2.53)$$

dimana p adalah probabilitas kegagalan pada kuantil tertentu. LR asimtotik dengan distribusi chi-square (χ^2) dengan derajat bebas 1, sehingga jika nilai LR lebih besar dari *critical value* distribusi chi-square (χ^2) maka H_0 akan ditolak.

Dengan demikian model dapat dikatakan valid atau akurat.

Halaman ini sengaja dikosongkan

BAB 3

METODOLOGI PENELITIAN

Dalam bab ini akan dijelaskan mengenai sumber data, variabel-variabel yang akan diteliti serta metodologi penelitian berisi penjelasan mengenai langkah-langkah yang dilakukan dalam analisis. Selain itu, dalam bab ini juga disajikan diagram alir proses analisis data yang merupakan versi ringkas dari langkah-langkah yang dilakukan dalam proses analisis data. Berikut ini adalah pemaparan secara detail mengenai bab 3.

3.1 Sumber Data dan Variabel Penelitian

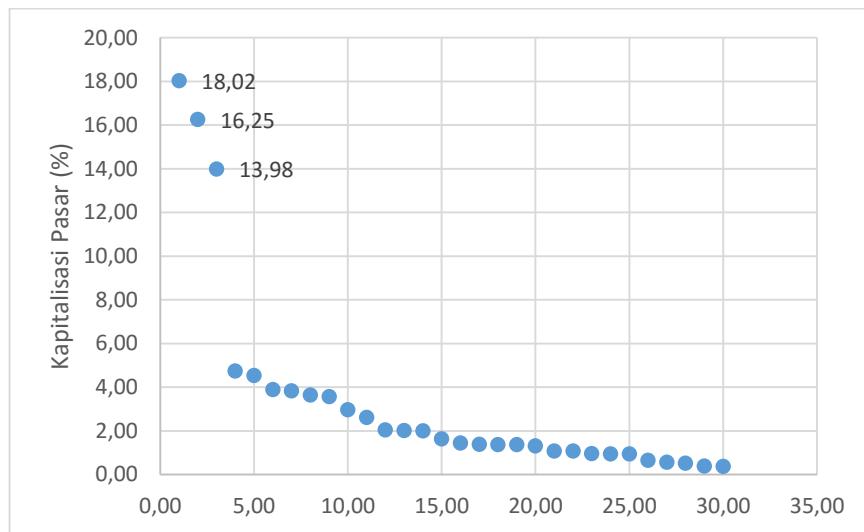
Data yang digunakan dalam penelitian ini merupakan data sekunder yaitu data harian *return* saham syariah dari tiga perusahaan yang tergabung di *Jakarta Islamic Index* (JII) yaitu PT Astra Internasional Tbk (ASII), PT Telekomunikasi Indonesia Tbk (TLKM) dan PT Unilever Indonesia Tbk (UNVR). Data diperoleh dari situs resmi yahoo finance berupa data harian penutupan harga saham (*close price*) mulai Januari 2010 hingga Juli 2016. Saham ketiga perusahaan tersebut dipilih karena perusahaan memiliki kapitalisasi pasar terbesar, sehingga dapat mewakili perdagangan pasar harian, bahkan mampu menjadi indeks *mover* dalam pembentukan JII maupun IHSG (Indeks Harga Saham Gabungan) di Bursa Efek Indonesia (BEI). Selain itu, Saham-saham tersebut merupakan saham-saham aktif dan likuid memenuhi kriteria JII selama 6 tahun terakhir dan salah satu *market leader* pada sektor industrinya, sehingga dapat dijadikan *benchmark*. Alasan lain dipilih tiga perusahaan tersebut diteliti karena berdasarkan Gambar 3.1, dengan menggunakan tiga perusahaan tersebut telah mewakili 48,43% kapitalisasi saham JII.

3.2 Langkah Penelitian

Berdasarkan sumber data dan variable penelitian yang telah dipaparkan, langkah penelitian yang dilakukan sebagai berikut.

1. Mengumpulkan data saham yang akan digunakan dalam pelitian.

2. Mendeskripsikan karakteristik masing-masing saham.
3. Menghitung *return* saham dengan Persamaan (2.51).



Gambar 3.1 Kapitalisasi pasar saham JII

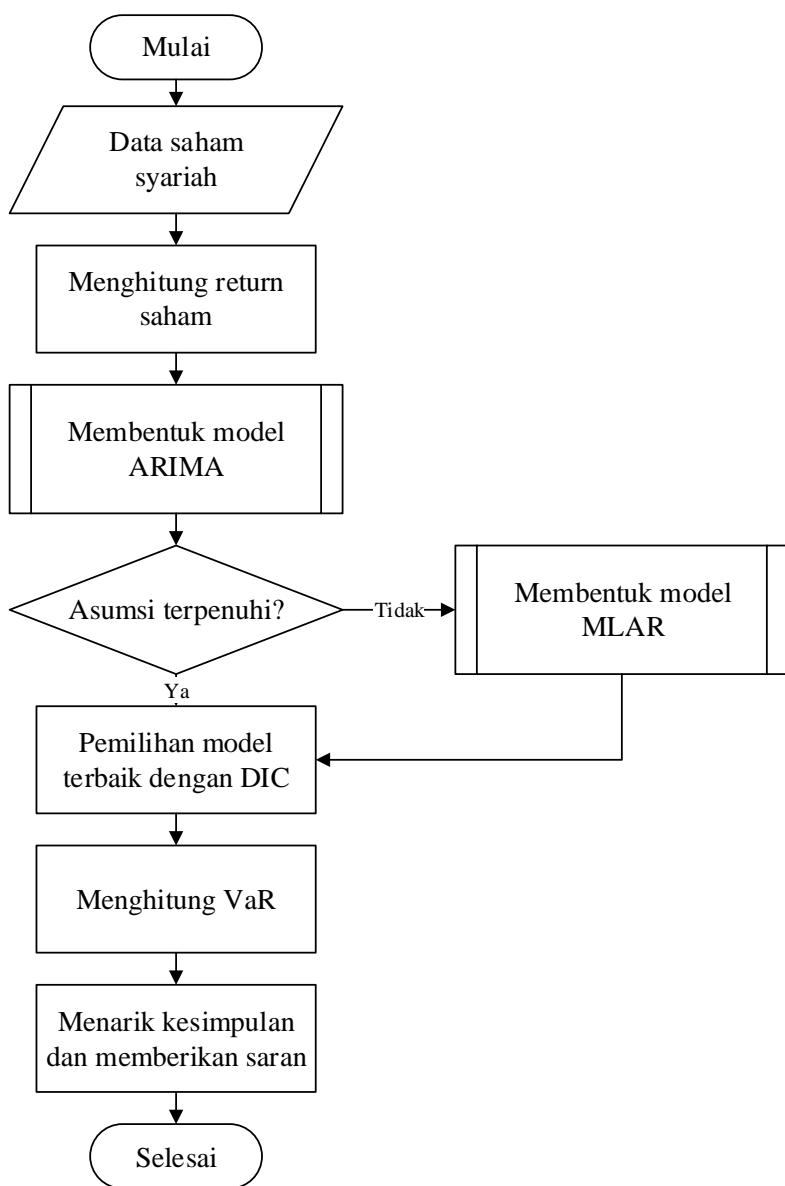
4. Membentuk model ARIMA dari masing-masing *return* saham dengan langkah-langkah sebagai berikut.
 - a. Mengidentifikasi kestasioneran data terhadap *mean* dan varians dengan menggunakan *time series plot*, ACF dan PACF.
 - b. Melakukan transformasi terhadap *mean* dan/atau varians jika data tidak stasioner. Jika data tidak stasioner terhadap *mean* dan varians, maka data ditransformasi Box-Cox terlebih dahulu kemudian dilakukan *differencing*.
 - c. Menduga model ARIMA yang terbentuk berdasarkan plot ACF dan PACF.
 - d. Melakukan estimasi dan pengujian signifikansi parameter model ARIMA dengan pendekatan Bayesian.
 - e. *Diagnostic check* dengan melakukan pengujian *white Noise* menggunakan Persamaan (2.10) dan (2.11) serta distribusi Normal pada residual.
5. Pembentukan model MLAR dengan pendekatan Bayesian dapat dilakukan dengan langkah sebagai berikut.

- a. Identifikasi *mixture* pada data *return* yang telah stasioner dengan menggunakan histogram dan *marginal plot* serta melakukan uji distribusi.
 - b. Menentukan orde AR berdasarkan orde ARIMA yang signifikan dan jumlah komponen *mixture* yang terbentuk untuk model MLAR.
 - c. Melakukan estimasi dan pengujian signifikansi parameter model MLAR dengan pendekatan Bayesian.
 - d. Pemilihan model terbaik dengan kriteria DIC.
6. Menghitung besar risiko investasi saham dengan model VaR Normal Linier dengan cara:
- a. Menentukan lama investasi (h) yang akan dianalisis.
 - b. Menentukan besaran α yang akan digunakan.
 - c. Menentukan π , μ dan σ dari hasil estimasi parameter model MLAR yang terbaik.
 - d. Menghitung VaR menggunakan persamaan (2.50) berdasarkan informasi pada bagian 6a hingga 6c.
7. Menarik kesimpulan dan memberikan saran.

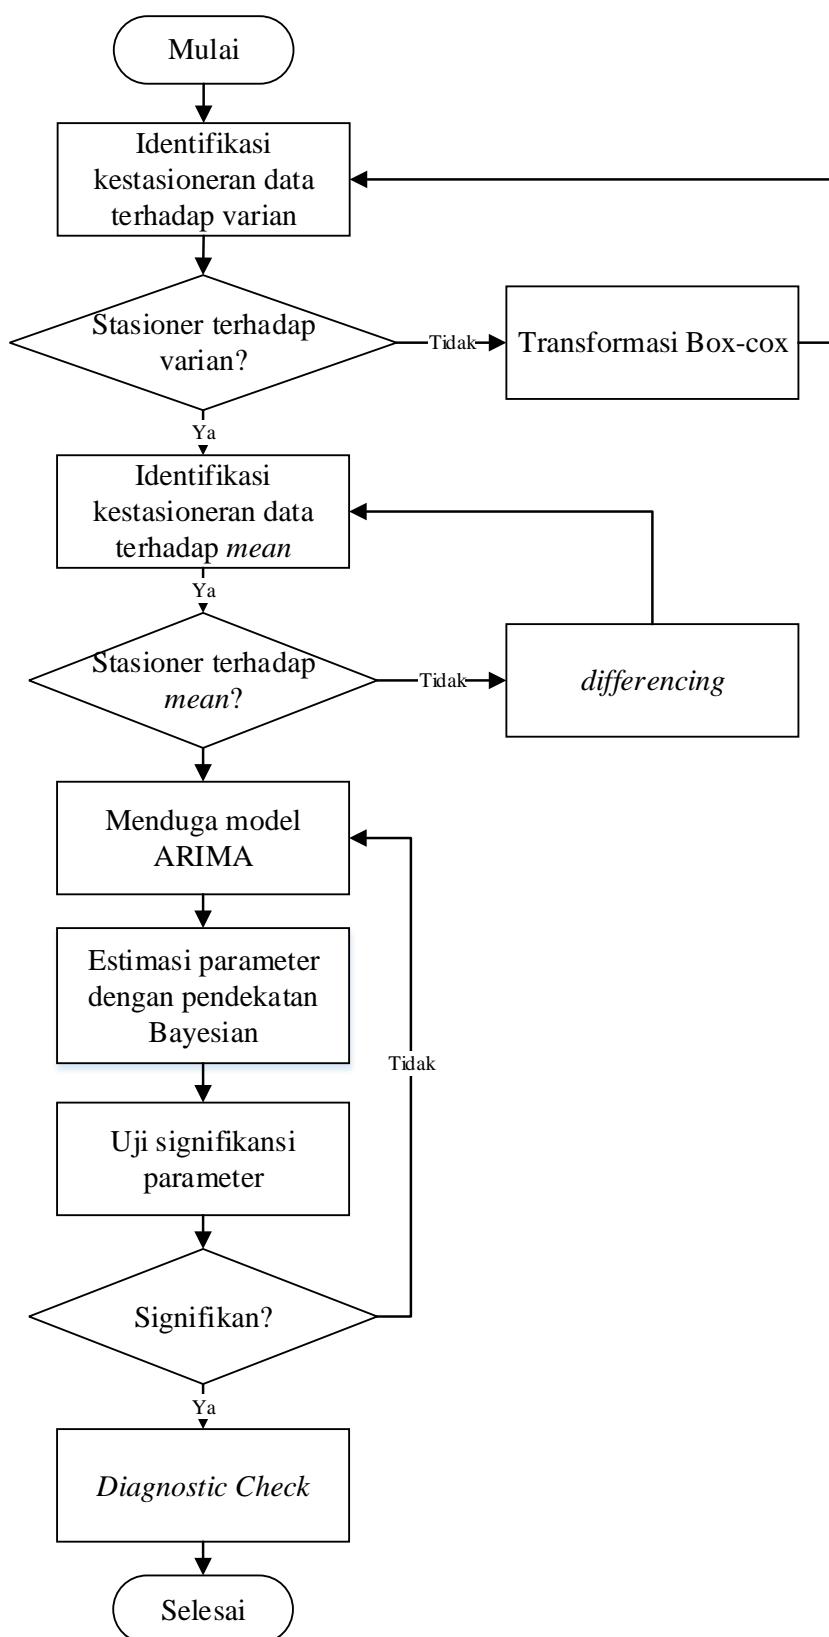
Estimasi parameter model ARIMA dan MLAR dengan pendekatan Bayesian dilakukan dengan tahapan sebagai berikut.

- 1) Menentukan *distribusi prior* yang sesuai untuk pemodelan ARIMA dan MLAR.
- 2) Membangun struktur ARIMA dan MLAR dengan Bayesian *full conditional distribution* secara iteratif dengan metode *Gibbs Sampler* untuk menaksir parameter.
- 3) Membuat *doodle* untuk mengimplementasikan model ARIMA dan MLAR menggunakan WinBUGS.
- 4) Mengestimasi parameter dengan metode MCMC dalam program WinBUGS.

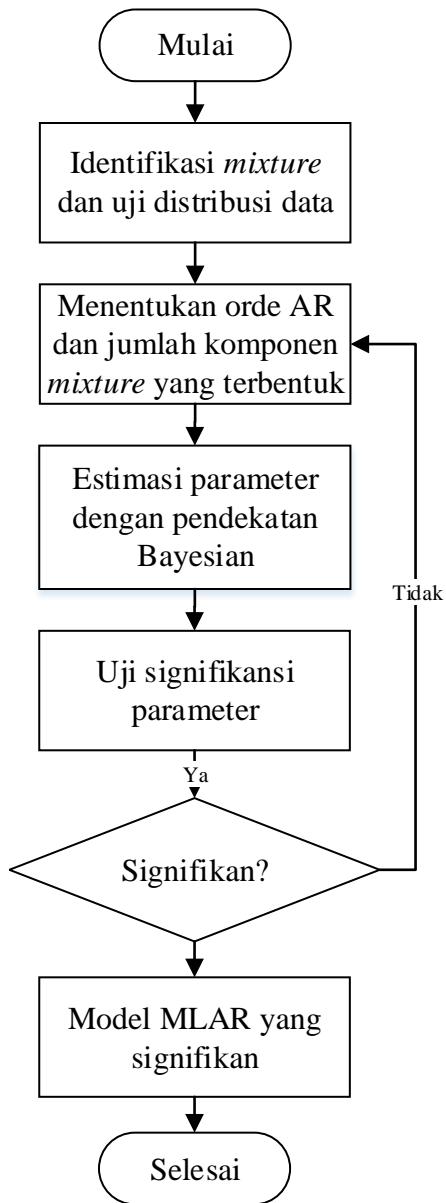
Langkah-langkah di atas dapat digambarkan dengan alur seperti pada Gambar (3.2), (3.2) dan (3.3).



Gambar 3. 2 Diagram alir penelitian



Gambar 3. 3 Diagram alir penelitian ARIMA

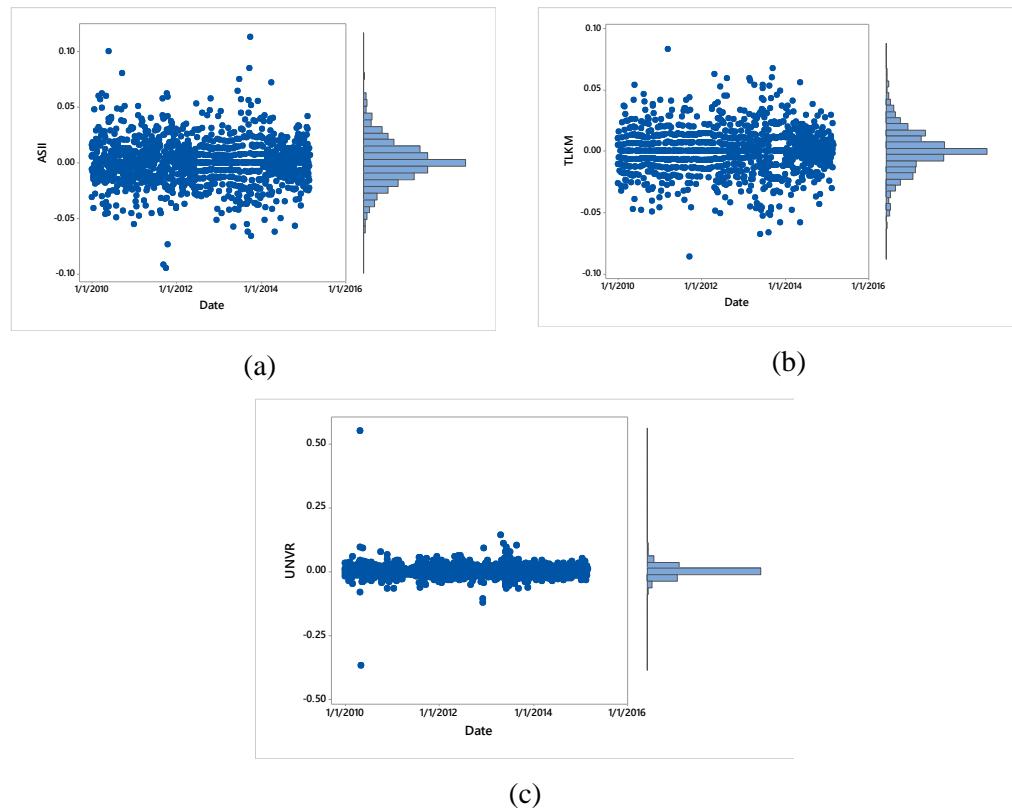


Gambar 3. 4 Diagram alir penelitian MLAR

3.3 Penelitian sebelumnya

Penelitian mengenai analisis *Value at Risk* (VaR) menggunakan data 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) pernah dilakukan oleh (Putri, 2016). Analisis tersebut dilakukan dengan pendekatan

Mixture Normal Autoregressive (MNAR). Dalam analisis tersebut dijelaskan bahwa *return* sudah stasioner terhadap *mean* dan varians. Selain itu, didapatkan pula model ARIMA yang signifikan akan tetapi tidak memenuhi asumsi distribusi Normal dan *white noise*. Model tersebut adalah AR([3]) dan AR([3,6]) untuk saham ASII, AR([2]), AR([3]), AR([4]), AR([2,3]), AR([2,4]), AR([3,4]), dan AR([2,3,4]) serta AR(2), AR([11]), dan AR(2,[11]). 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.



Gambar 3.5 Marginal Plot dari *Return* Saham (a)ASII, (b)TLKM dan (c)UNVR

Gambar 3.5 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.

BAB 4

ANALISIS DAN PEMBAHASAN

Bab 4 akan membahas mengenai pemodelan *return* saham ASII, TLKM dan UNVR beserta perhitungan *Value at Risk* (VaR). Subbab pertama dimulai dengan penentuan distribusi prior. Dalam penentuan distribusi prior inilah estimasi model ARIMA diterapkan untuk mendapatkan parameter prior yang akan digunakan untuk analisis Bayesian MLAR. Orde ARIMA yang digunakan diperoleh dari penelitian sebelumnya. Subbab kedua akan menjelaskan mengenai pemodelan MLAR pada PT Astra International Tbk (ASII), PT Telekomunikasi Indonesia Tbk (TLKM) dan PT Unilever Indonesia Tbk (UNVR). Subbab ketiga akan membahas mengenai pemilihan model terbaik berdasarkan DIC. Model yang dipilih merupakan model yang didapatkan dari subbab kedua. Subbab terakhir berisi penjelasan mengenai VaR yang telah dihitung.

4.1 Penentuan Distribusi prior

Analisis Bayesian dinyatakan sebagai kombinasi dari fungsi likelihood yang dikombinasikan dengan distribusi prior sehingga membentuk distribusi posterior. Penggunaan prior yang tepat sangat diperlukan dalam analisis Bayesian. Hal itu disebabkan jika salah dalam memilih prior, hasil yang didapatkan akan salah.

Dalam mengestimasi parameter model MLAR menggunakan Bayesian, distribusi prior untuk parameter standar deviasi adalah *conjugate prior* berupa invers Gamma, sedangkan untuk parameter *Autoregressive* menggunakan *pseudo prior*. *Pseudo prior* yang digunakan dalam analisis ini adalah distribusi Laplace dengan parameter *scale* dan *location*. Nilai parameter untuk distribusi tersebut didapatkan dari mengestimasi parameter *Autoregressive* untuk tiap komponen pada saham tertentu dengan analisis Bayesian. Analisis Bayesian untuk analisis parameter *Autoregressive* tiap komponen menggunakan *conjugate prior* distribusi Normal.

Hasil estimasi parameter *Autoregressive* tiap komponen untuk saham ASII ditunjukkan pada Tabel 4.1.

Tabel 4.1 Estimasi Parameter Saham ASII

Model	Parameter	Mean	Standar Deviasi	2,50%	97,50%
AR([3])	ϕ_3	-0,09153	0,02397	-0,13820	-0,04450
	ϕ_3	-0,09661	0,02405	-0,14330	-0,04914
AR([3,6])	ϕ_6	-0,05732	0,02901	-0,10510	-0,00993

Tabel 4.1 menunjukkan bahwa semua parameter pada model AR([3]) dan AR([3,6]) telah signifikan. Hal itu ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Dengan demikian, komponen *mixture* pada saham ASII yang memuat model AR([3]) akan memiliki distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,09153 dan *scale* sebesar 0,02397 untuk parameter ϕ_3 . Sedangkan untuk komponen *mixture* yang memuat model AR([3,6]) akan memiliki distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,09661 dan *scale* sebesar 0,02405 untuk parameter ϕ_3 serta distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,05732 dan *scale* sebesar 0,02901 untuk parameter ϕ_6 .

Hasil estimasi parameter *Autoregressive* tiap komponen untuk saham TLKM ditunjukkan pada Tabel 4.2.

Tabel 4.2 memberikan informasi bahwa semua parameter pada model AR([2]), AR([3]), AR([4]), AR([2,3]), AR([2,4]), AR([3,4]) dan AR([2,3,4]) diperoleh *credible interval* yang tidak memuat 0 (nol), sehingga semua parameter untuk masing-masing model telah signifikan. Dengan demikian, komponen *mixture* pada saham TLKM yang memuat model AR([2]) akan memiliki distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,09308 dan *scale* sebesar 0,02415 untuk parameter ϕ_2 . Hal tersebut berlaku pula untuk model AR([3]) dan AR([4]) secara berturut-turut memiliki parameter *location* sebesar -0,08148 dan *scale* 0,02417 untuk parameter ϕ_3 serta parameter *location* sebesar -0,08269 dan *scale* 0,02517 untuk parameter ϕ_4 . Sedangkan untuk komponen *mixture* yang memuat model AR([2,3]) akan memiliki distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,09518 dan *scale* sebesar

0,02411 untuk parameter ϕ_2 serta distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,08414 dan *scale* sebesar 0,03157 untuk parameter ϕ_3 . Distribusi prior untuk masing-masing parameter *Autoregressive* pada model AR([2,4]), AR([3,4]) dan AR([2,3,4]) berupa distribusi Laplace dengan parameter *location* ditunjukkan oleh *mean* dan *scale* ditunjukkan oleh standar deviasi pada parameter yang bersesuaian.

Tabel 4.2 Estimasi Parameter Saham TLKM

Model	Parameter	Mean	Standar Deviasi	2,50%	97,50%
AR([2])	ϕ_2	-0,09308	0,02415	-0,13940	-0,04577
AR([3])	ϕ_3	-0,08148	0,02417	-0,12790	-0,03412
AR([4])	ϕ_4	-0,08269	0,02517	-0,13140	-0,03277
AR([2,3])	ϕ_2	-0,09518	0,02411	-0,14180	-0,04778
	ϕ_3	-0,08414	0,03157	-0,13170	-0,03681
AR([2,4])	ϕ_2	-0,10080	0,12500	-0,14790	-0,05310
	ϕ_4	-0,07732	0,64040	-0,13120	-0,03593
AR([3,4])	ϕ_3	-0,08415	0,02415	-0,13090	-0,03666
	ϕ_4	-0,07649	0,03160	-0,12410	-0,02907
AR([2,3,4])	ϕ_2	-0,10310	0,02397	-0,14990	-0,05654
	ϕ_3	-0,08723	0,03175	-0,13470	-0,04081
	ϕ_4	-0,08644	0,02622	-0,13280	-0,03872

Hasil estimasi parameter *Autoregressive* tiap komponen untuk saham UNVR ditunjukkan pada Tabel 4.3.

Tabel 4.3 memperlihatkan bahwa *credible interval* tidak memuat 0 (nol) yang artinya semua parameter pada model AR(2), AR([11]) dan AR([2,11]) telah signifikan. Oleh karena itu, komponen *mixture* pada saham UNVR yang memuat model AR(2) akan memiliki distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar -0,26540 dan *scale* sebesar 0,02425 untuk parameter ϕ_1 serta parameter *location* sebesar -0,09637 dan *scale* sebesar 0,02757 untuk parameter ϕ_2 . Parameter ϕ_{11} pada model AR([11]) akan memiliki distribusi prior berupa distribusi Laplace dengan parameter *location* sebesar 0,05798 dan *scale*

sebesar 0,02415. Pada model AR([2,11]) terdapat tiga parameter yaitu ϕ_1 , ϕ_2 dan ϕ_{11} yang masing-masing berdistribusi Laplace dengan parameter *location* sebesar -0,09661 untuk ϕ_1 , -0,09651 untuk ϕ_2 dan 0,05874 untuk ϕ_{11} serta *scale* sebesar 0,02397 untuk ϕ_1 , 0,02789 untuk ϕ_2 dan 0,02453 untuk ϕ_{11} .

Tabel 4.3 Estimasi Parameter Saham UNVR

Model	Parameter	Mean	Standar Deviasi	2,50%	97,50%
AR(2)	ϕ_1	-0,26540	0,02425	-0,31220	-0,21790
	ϕ_2	-0,09637	0,02757	-0,14360	-0,04933
AR([11])	ϕ_{11}	0,05798	0,02415	0,01149	0,10550
	ϕ_1	-0,26500	0,02397	-0,31220	-0,21830
AR(2,[11])	ϕ_2	-0,09651	0,02789	-0,14460	-0,04898
	ϕ_{11}	0,05874	0,02453	0,01326	0,10510

4.2 Pemodelan *Mixture Laplace Autoregressive* (MLAR)

Pada penelitian sebelumnya yang telah dilakukan oleh Putri (2016) menunjukkan bahwa dalam pemodelan ARIMA *return* saham ASII, TLKM dan UNVR menunjukkan hasil yang kurang baik. Hal itu disebabkan karena asumsi dalam pemodelan ARIMA tidak terpenuhi. Oleh sebab itu (Putri, 2016) melakukan pemodelan *Mixture Normal Autoregressive* (MNAR), yaitu dengan menggabungkan komponen *Autoregressive*. Dalam penelitian tersebut diimplementasikan komponen *mixture* yang telah ditentukan yaitu sebanyak 2 dan 3 komponen. Dalam hal ini, komponen *mixture* merupakan kombinasi model ARIMA yang telah terbentuk , Tabel 4.1 sampai Tabel 4.3, untuk masing-masing saham. 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

leptokutrik, 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.

Dengan tujuan sama dengan Putri (2016), dalam penelitian ini akan dilakukan analisis menggunakan pemodelan *Mixture Laplace Autoregressive* (MLAR). Pemodelan ini merupakan alternative dari model MNAR. Dengan melakukan analisis menggunakan MLAR diharapkan mendapatkan model yang lebih baik dibandingkan MNAR. Sama halnya dengan MNAR, analisis ini juga dilakukan terhadap data *return* saham ASII, TLKM dan UNVR dengan komponen *mixture* sebanyak 2 dan 3 komponen untuk masing-masing saham. Hipotesis yang digunakan untuk parameter adalah sebagai berikut.

$H_0 : \pi_j = 0$ yang artinya parameter pada komponen *mixture* ke- j tidak signifikan,

$$j = 1, 2, \dots, K.$$

$H_1 : \pi_j \neq 0$ yang artinya parameter pada komponen *mixture* ke- j signifikan, $j = 1, 2, \dots, K$.

$H_0 : \phi_{i,j} = 0$ yang artinya parameter model *Autoregressive* ke- i , dan komponen *mixture* ke- j tidak signifikan, $i = 1, 2, \dots, p; j = 1, 2, \dots, K$.

$H_1 : \phi_{i,j} \neq 0$ yang artinya parameter model *Autoregressive* ke- i , dan komponen *mixture* ke- j signifikan, $i = 1, 2, \dots, p; j = 1, 2, \dots, K$.

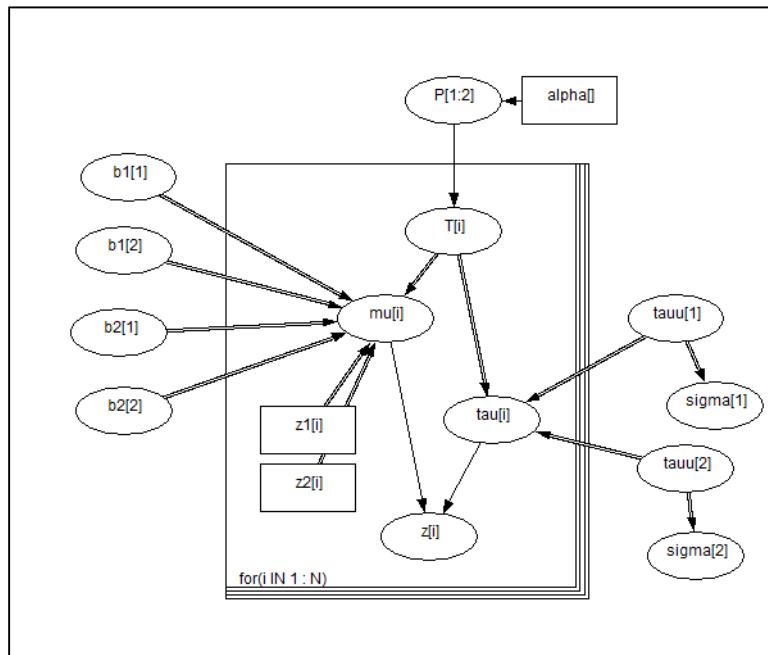
$H_0 : \sigma_j = 0$ yang artinya parameter pada komponen *mixture* ke- j tidak signifikan, $j = 1, 2, \dots, K$.

$H_1 : \sigma_j \neq 0$ yang artinya parameter pada komponen *mixture* ke- j signifikan, $j = 1, 2, \dots, K$.

Estimasi parameter MLAR dimulai dengan membangun struktur *Directed Acyclic Graph* (DAG) seperti yang ditunjukkan oleh Gambar 4.1.

Gambar 4.1 memperlihatkan kotak DAG yang terdiri dari empat node, $z[i]$, $mu[i]$, $tau[i]$, dan $T[i]$, dengan $i = 1, 2, \dots, N$ dan N adalah banyaknya data. $z[i]$ merupakan *return* saham ASII yang terdiri dari gabungan 2 komponen distribusi Laplace dengan parameter $mu[i]$ dan $tau[i]$. $mu[i]$ bertipe *logical* membentuk

persamaan model *Autoregressive*, $\mu[i] = b1[T[i]] * z1[i] + b2[T[i]] * z2[i]$, dengan $b1$ dan $b2$ sebagai parameter *Autoregressive* beristribusi Laplace dengan *scale* dan *location* berturut-turut adalah nilai *mean* dan presisi sesuai hasil yang telah didapatkan dari tahap penentuan distribusi prior subbab 4.1 sesuai model *Autoregressive* pembentuk masing-masing komponen. $z1$ dan $z2$ merupakan data *return* saham ASII yang telah dimodifikasi sesuai order *Autoregressive* pembentuk model MLAR(2;[3],[3,6]) yang memiliki tipe konstan. $\tauau[i]$ digunakan untuk menerjemahkan σ_j , $j = 1, 2$ yang bertipe konstan dengan nilai $\sqrt{2}/\tauau[j]$. $\tauau[j]$ berdistribusi Gamma dengan *shape* dan *scale* masing-masing sebesar 0,001. $\mu[i]$ dan σ_j diidentifikasi oleh nilai $T[i]$ dengan $T[i]$ yang berubah sesuai distribusi Dirichlet, $P[1:2]$ yang diatur untuk dapat mempunyai nilai 1 dan 2 saja. *Hyperparameter* terdalam adalah $T[i]$ ini, yaitu dua level dengan $P[1:2]$ di level pertama dan $\alpha[j]$ di level kedua yang konstan. Dalam penelitian ini variabel z dinotasikan dengan y , $b1[j]$ dinotasikan sebagai $\phi_{j,1}$, σ_j dinotasikan sebagai parameter σ_j .



Gambar 4.1 Doodle untuk Model MLAR(2;[3],[3,6])

Proses MCMC untuk estimasi model MLAR(3;[3],[3,6]) dilakukan sebanyak 10.000 kali iterasi dengan sampel yang digunakan untuk mengestimasi parameter sebanyak 9999 sampel karena hanya terjadi proses *burn-in* sebanyak 1 iterasi. Hasil iterasi tersebut telah menunjukkan bahwa hasil estimasi parameter telah konvergen. Pemantauan konvergensi dapat dilihat pada rantai markov yang telah memenuhi sifat *ergodic*. Sifat *ergodic* diindikasikan proses yang telah *irreducible*, *aperiodic* dan *recurrent*. *Irreducible* yaitu selama iterasi estimasi parameter sampel diambil secara acak yang ditunjukkan oleh *history plot* pada Lampiran D.2 yang memperlihatkan sifat stationer dan acak. *Aperiodic* ditunjukkan oleh *history plot* yang tidak membentuk pola tertentu. *Recurrent* yaitu parameter yang dibangkitkan pada *state i* berpeluang untuk kembali ke *state i*. Selain itu, konvergensi juga dapat dilihat pada plot autokorelasi pada Lampiran D.2 menunjukkan bahwa lag nol bernilai satu kemudian lag selanjutnya bernilai mendekati nol serta plot *density* pada Lampiran D.2 menunjukkan distribusi pada masing-masing parameter cenderung memiliki pusat di tengah.

Doodle yang digunakan untuk estimasi model MLAR(3;[3],[3,6], 0) seperti yang telah ditunjukkan oleh Lampiran E.1 hampir sama seperti MLAR(3;[3],[3,6]) akan tetapi komponen pembentuk *mixture* sebanyak 3 sehingga $\mu[i]$ dan $\sigma[j]$, $i = 1, 2, 3; j = 1, 2, 3$, diidentifikasi oleh nilai $T[i]$ dengan $T[i]$ yang berubah sesuai distribusi Dirichlet, $P[1:3]$ yang diatur untuk dapat mempunyai nilai 1, 2 dan 3 saja. Proses MCMC untuk estimasi model MLAR(3;[3],[3,6],0) ditunjukkan oleh Lampiran E.2 dengan penjelasan yang sama seperti MLAR(3;[3],[3,6]).

Hasil estimasi parameter MLAR untuk saham ASII ditunjukkan pada Tabel 4.4 dan 4.5.

Berdasarkan Tabel 4.4 diketahui bahwa parameter π_1 dan π_2 yang merepresentasikan pembobot komponen pertama dan kedua dari model MLAR(2;[3],[3,6]) sudah signifikan. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Komponen *Autoregressive* juga menunjukkan hal yang sama yaitu parameter $\phi_{1,3}$ yang merupakan parameter untuk

komponen pertama yang dibentuk dari model AR([3]) dan parameter $\phi_{2,3}$ serta $\phi_{2,6}$ yang merupakan parameter untuk komponen kedua yang dibentuk dari model AR([3,6]) sudah signifikan. Hal itu ditunjukkan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Dengan demikian *return* saham ASII dipengaruhi oleh *return* saham 3 hari dan 6 hari sebelumnya. *Credible interval* dari parameter σ_1 dan σ_2 , dalam doodle ditunjukkan oleh node sigma[1] dan sigma [2], yang merepresentasikan parameter standar deviasi komponen pertama dan kedua tidak memuat 0 (nol) yang artinya kedua parameter tersebut sudah signifikan. Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(2;[3],[3,6]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,50040 \left(\left(0,02149\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09141\dot{y}_{t-3}|}{0,02149} \right) \right) \\ & + 0,049960 \left(\left(0,02151\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09651\dot{y}_{t-3} + 0,05724\dot{y}_{t-6}|}{0,02151} \right) \right). \end{aligned}$$

Tabel 4.4 Estimasi Parameter Model MLAR(2;[3],[3,6])

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,50040	0,00839	0,48390	0,51680
π_2	0,49960	0,00839	0,48320	0,51610
$\phi_{1,3}$	-0,09141	$8,17 \times 10^{-4}$	-0,09303	-0,08957
$\phi_{2,3}$	-0,09651	$8,30 \times 10^{-4}$	-0,09814	-0,09461
$\phi_{2,6}$	-0,05724	0,00120	-0,05970	-0,05461
σ_1	0,02149	$5,13 \times 10^{-4}$	0,02052	0,02252
σ_2	0,02151	$5,14 \times 10^{-4}$	0,02051	0,02254

Tabel 4.5 menunjukkan bahwa parameter π_1 , π_2 dan π_3 yang secara berurutan merepresentasikan pembobot untuk komponen pertama, kedua dan ketiga telah signifikan, sehingga layak digunakan dalam model *mixture*. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). *Return* saham ASII terbukti dipengaruhi oleh *return* saham 3 hari dan 6 hari sebelumnya, dimana parameter $\phi_{1,3}$ yang merupakan parameter komponen pertama berupa model

AR([3]) dan parameter $\phi_{2,3}$, $\phi_{2,6}$ yang merupakan parameter komponen kedua berupa model AR([3,6]) telah signifikan. Signifikansi tersebut ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Selain parameter pembobot dan *Autoregressive*, ketiga komponen *mixture* juga menginformasikan bahwa standar deviasi masing-masing komponen telah signifikan, dimana *credible interval* yang tidak memuat 0 (nol). Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(3;[3],[3,6],0) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,33320 \left(\left(0,02149\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09142\dot{y}_{t-3}|}{0,02149} \right) \right) \\ & + 0,33280 \left(\left(0,02151\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09649\dot{y}_{t-3} + 0,05720\dot{y}_{t-6}|}{0,02151} \right) \right) \\ & + 0,33400 \left(\left(0,02133\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t|}{0,02133} \right) \right). \end{aligned}$$

Tabel 4.5 Estimasi Parameter Model MLAR(3;[3],[3,6], 0)

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,33320	0,00655	0,32060	0,34610
π_2	0,33280	0,00658	0,31970	0,34570
π_3	0,33400	0,00658	0,32130	0,34690
$\phi_{1,3}$	-0,09142	$8,17 \times 10^{-4}$	-0,09308	-0,08962
$\phi_{2,3}$	-0,09649	$8,34 \times 10^{-4}$	-0,09813	-0,09453
$\phi_{2,6}$	-0,05720	0,00121	-0,05965	-0,05454
σ_1	0,02149	$5,09 \times 10^{-4}$	0,02054	0,02251
σ_2	0,02151	$5,05 \times 10^{-4}$	0,02053	0,02253
σ_3	0,02133	$5,09 \times 10^{-4}$	0,02034	0,02234

Doodle yang digunakan untuk estimasi parameter MLAR pada *return saham TLKM* hampir sama seperti MLAR(2;[3],[3,6]). Perbedaannya terletak pada data yang digunakan yaitu data *return saham TLKM*. Selain itu, pada model MLAR(2;[2],[3]) dalam Lampiran G.1 parameter *autoregressive* yang digunakan hanya *b1[1]* yang merupakan parameter dari komponen pertama yaitu AR[2] dan *b1[2]* yang merupakan parameter dari komponen kedua yaitu AR[3]. Untuk

MLAR(2;[2],[4]) dalam Lampiran I.1, parameter *autoregressive* yang digunakan hanya $b1[1]$ yang merupakan parameter dari komponen pertama yaitu AR[3] dan $b1[2]$ yang merupakan parameter dari komponen kedua yaitu AR[4]. Begitu pula untuk MLAR(2;[2,3],[3,4]) dalam Lampiran F.1, parameter *autoregressive* yang digunakan adalah $b1[1]$ dan $b2[1]$ yang merupakan parameter dari komponen pertama yaitu AR([2,3]) serta $b1[2]$ dan $b2[2]$ yang merupakan parameter dari komponen kedua yaitu AR([3,4]). Doodle untuk model MLAR(3;[2,3],[3,4],-[2,3,4]) dalam Lampiran J.1, bentuk doodle akan mirip dengan MLAR-(3;[3],[3,6],0), tetapi parameter *autoregressive* yang digunakan adalah $b1[1]$, $b2[1]$ dan $b3[1]$ yang merupakan parameter dari komponen pertama yaitu AR([2,3]) serta $b1[2]$ dan $b2[2]$ dan $b3[2]$ yang merupakan parameter dari komponen kedua yaitu AR([3,4]) serta $b1[3]$ dan $b2[3]$ dan $b3[3]$ yang merupakan parameter dari komponen kedua yaitu AR([2,3,4]). Parameter $b3[1]$ dan $b1[2]$ hanya digunakan untuk memenuhi aturan pembentukan doodle di WinBUGS. Untuk MLAR(3;[2],[3],[4]) doodle yang terbentuk akan mirip dengan MLAR(2;[2],[3]), akan tetapi ada penambahan parameter $b1[3]$ yang merupakan parameter dari komponen ketiga yaitu AR[4] seperti yang ditunjukkan oleh Lampiran K.1. Proses MCMC untuk estimasi model MLAR(3;[3],[3,6],0) ditunjukkan oleh Lampiran F.2 untuk MLAR(2;[2,3],[3,4]), Lampiran G.2 untuk MLAR(2;[2],[3]), Lampiran H.2 untuk MLAR(2;[2],[4]), Lampiran I.2 untuk MLAR(2;[3],[4]), Lampiran J.2 untuk MLAR(3;[2,3],[3,4],([2,3,4])), dan Lampiran K.2 untuk MLAR(2;[2],[3],[4]), dengan penjelasan yang sama seperti MLAR(3;[3],[3,6]).

Hasil estimasi parameter MLAR untuk saham TLKM dapat dilihat pada Tabel 4.6 sampai Tabel 4.11.

Tabel 4.6 menunjukkan bahwa parameter yang merepresentasikan pembobot untuk komponen pertama dan kedua yaitu π_1 dan π_2 telah signifikan, sehingga layak digunakan dalam model *mixture*. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). *Return* saham TLKM terbukti dipengaruhi oleh *return* saham 2 hari dan 3 hari sebelumnya, dimana parameter $\phi_{1,2}$ yang merupakan parameter komponen pertama berupa model

AR([2]) dan parameter $\phi_{2,3}$ yang merupakan parameter komponen kedua berupa model AR([3]) telah signifikan. Signifikansi tersebut ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Selain parameter pembobot dan *Autoregressive*, ketiga komponen *mixture* juga menginformasikan bahwa standar deviasi masing-masing komponen telah signifikan, dimana *credible interval* yang tidak memuat 0 (nol). Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(2;[2],[3]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,5 \left((0,01789\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09297\dot{y}_{t-2}|}{0,01789} \right) \right) \\ & + 0,5 \left((0,01788\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08135\dot{y}_{t-3}|}{0,01788} \right) \right). \end{aligned}$$

Tabel 4.6 Estimasi Parameter Model MLAR(2;[2],[3])

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,5	0,008470	0,48340	0,51650
π_2	0,5	0,008470	0,48350	0,51660
$\phi_{1,2}$	-0,09297	$8,33 \times 10^{-4}$	-0,09462	-0,09116
$\phi_{2,3}$	-0,08135	$8,45 \times 10^{-4}$	-0,08297	-0,07945
σ_1	0,01789	$4,31 \times 10^{-4}$	0,01708	0,01877
σ_2	0,01788	$4,32 \times 10^{-4}$	0,01705	0,01874

Tabel 4.7 Estimasi Parameter Model MLAR(2;[2],[4])

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,50020	0,008476	0,48360	0,51660
π_2	0,49980	0,008476	0,48340	0,51640
$\phi_{1,2}$	-0,09296	$8,21 \times 10^{-4}$	-0,09458	-0,09116
$\phi_{2,4}$	-0,08254	$9,14 \times 10^{-4}$	-0,08429	-0,0805
σ_1	0,01789	$4,31 \times 10^{-4}$	0,01707	0,01877
σ_2	0,01787	$4,29 \times 10^{-4}$	0,01704	0,01873

Dari Tabel 4.7 diketahui bahwa parameter π_1 dan π_2 yang merepresentasikan pembobot komponen pertama dan kedua dari model

MLAR(2;[2],[4]) sudah signifikan. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Komponen *Autoregressive* juga menunjukkan hal yang sama yaitu parameter $\phi_{1,2}$ yang merupakan parameter untuk komponen pertama yang dibentuk dari model AR([2]) dan parameter $\phi_{2,4}$ yang merupakan parameter untuk komponen kedua yang dibentuk dari model AR([4]) sudah signifikan. Hal itu ditunjukkan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Dengan demikian *return* saham ASII dipengaruhi oleh *return* saham 2 hari dan 4 hari sebelumnya. *Credible interval* dari parameter σ_1 dan σ_2 yang merepresentasikan parameter standar deviasi komponen pertama dan kedua tidak memuat 0 (nol) yang artinya kedua parameter tersebut sudah signifikan. Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(2;[2],[4]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,50020 \left((0,01789\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09296\dot{y}_{t-2}|}{0,01789} \right) \right) \\ & + 0,49980 \left((0,01787\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08254\dot{y}_{t-4}|}{0,01787} \right) \right). \end{aligned}$$

Tabel 4.8 Estimasi Parameter Model MLAR(2;[3],[4])

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,50020	0,008516	0,48340	0,51670
π_2	0,49980	0,008516	0,48340	0,51660
$\phi_{1,3}$	-0,08134	$8,37 \times 10^{-4}$	-0,08295	-0,07947
$\phi_{2,4}$	-0,08254	$9,10 \times 10^{-4}$	-0,08428	-0,08046
σ_1	0,01789	$4,31 \times 10^{-4}$	0,01707	0,01876
σ_2	0,01787	$4,29 \times 10^{-4}$	0,01704	0,01874

Berdasarkan Tabel 4.8 diketahui bahwa parameter π_1 dan π_2 yang merepresentasikan pembobot komponen pertama dan kedua dari model MLAR(2;[3],[4]) sudah signifikan. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior yang tidak memuat 0 (nol). Komponen *Autoregressive* juga menunjukkan hal yang sama yaitu parameter $\phi_{1,3}$ yang merupakan parameter untuk

komponen pertama yang dibentuk dari model AR([3]) dan parameter $\phi_{2,4}$ yang merupakan parameter untuk komponen kedua yang dibentuk dari model AR([4]) sudah signifikan. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Dengan demikian *return* saham TLKM pada hari ke- t dipengaruhi oleh *return* saham 3 hari dan 4 hari sebelumnya. *Credible interval* dari parameter σ_1 dan σ_2 yang merepresentasikan parameter standar deviasi komponen pertama dan kedua tidak memuat 0 (nol) yang artinya kedua parameter tersebut sudah signifikan. Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(2;[3],[4]) dapat ditulis

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,50020 \left((0,01789\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08134\dot{y}_{t-3}|}{0,01789} \right) \right) \\ & + 0,49980 \left((0,01787\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08254\dot{y}_{t-4}|}{0,01787} \right) \right) \end{aligned}$$

Tabel 4.9 Estimasi Parameter Model MLAR(2;[2,3],[3,4])

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,50010	0,008538	0,48340	0,5165
π_2	0,49990	0,008538	0,48350	0,5166
$\phi_{1,2}$	-0,09512	$8,30 \times 10^{-4}$	-0,09687	-0,09334
$\phi_{2,3}$	-0,08406	$8,32 \times 10^{-4}$	-0,08577	-0,08222
$\phi_{1,3}$	-0,08391	0,001439	-0,08672	-0,08069
$\phi_{2,4}$	-0,07629	0,001417	-0,07911	-0,07312
σ_1	0,01789	$4,33 \times 10^{-4}$	0,01707	0,01876
σ_2	0,01787	$4,33 \times 10^{-4}$	0,01704	0,01875

Tabel 4.9 memberikan informasi bahwa semua parameter model MLAR(2;[2,3],[3,4]) telah signifikan, dimana *credible interval* dari distribusi prior untuk masing-masing parameter tidak memuat 0 (nol). Informasi lain yang didapat adalah proporsi pembobot untuk komponen pertama lebih besar dibanding komponen kedua. Selain itu *return* saham TLKM pada hari ke- t terlihat dipengaruhi oleh *return* pada 2, 3 dan 4 hari sebelumnya. Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(2;[2,3],[3,4]) dapat ditulis

$$\begin{aligned}
(\dot{y}_t | \mathcal{F}_{t-1}) = & 0,50010 \left(\left(0,01789\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09512\dot{y}_{t-2} + 0,08391\dot{y}_{t-3}|}{0,01789} \right) \right) \\
& + 0,49990 \left(\left(0,01787\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08406\dot{y}_{t-3} + 0,07629\dot{y}_{t-4}|}{0,01787} \right) \right)
\end{aligned}$$

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

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,33350	0,006557	0,32060	0,34640
π_2	0,33330	0,006634	0,32030	0,34600
π_3	0,33320	0,006586	0,32020	0,34640
$\phi_{1,2}$	-0,09508	$8,20 \times 10^{-4}$	-0,09671	-0,09326
$\phi_{3,2}$	-0,01041	$8,20 \times 10^{-4}$	-0,01227	-0,00880
$\phi_{1,3}$	-0,03814	0,017750	-0,07478	-0,00376
$\phi_{2,3}$	-0,08405	$8,27 \times 10^{-4}$	-0,08566	-0,08220
$\phi_{3,3}$	-0,08699	0,001441	-0,08986	-0,08377
$\phi_{2,4}$	-0,07648	0,001435	-0,07950	-0,07339
$\phi_{3,4}$	-0,08622	0,001428	-0,08899	-0,08298
σ_1	0,01786	$4,33 \times 10^{-4}$	0,01703	0,01872
σ_2	0,01786	$4,32 \times 10^{-4}$	0,01702	0,01871
σ_3	0,01788	$4,27 \times 10^{-4}$	0,01706	0,01873

Tabel 4.10 menjelaskan bahwa parameter π_1 , π_2 dan π_3 yang secara berurutan merepresentasikan pembobot untuk komponen pertama, kedua dan ketiga telah signifikan, sehingga layak digunakan dalam model *mixture*. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Parameter $\phi_{1,2}$, $\phi_{1,3}$ yang merupakan parameter komponen pertama berupa model AR([2,3]), parameter $\phi_{2,3}$, $\phi_{2,4}$ yang merupakan parameter komponen kedua berupa model AR([3,4]) serta parameter $\phi_{3,2}$, $\phi_{3,3}$, $\phi_{3,4}$ yang merupakan parameter komponen kedua berupa model AR([2,3,4]) telah signifikan. Signifikansi tersebut ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Dengan demikian *return* saham TLKM pada hari ke- t dipengaruhi oleh *return* saham 2, 3 dan 4 hari sebelumnya. Selain itu, ketiga komponen *mixture* juga menginformasikan bahwa standar deviasi

masing-masing komponen telah signifikan, dimana *credible interval* yang tidak memuat 0 (nol). Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(3;[2,3],[3,4],[2,3,4]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,33350 \left(\left(0,01786\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09508\dot{y}_{t-2} + 0,03814\dot{y}_{t-3}|}{0,01786} \right) \right) \\ & + 33330 \left(\left(0,01786\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08405\dot{y}_{t-3} + 0,07648\dot{y}_{t-4}|}{0,01786} \right) \right) \\ & + 33320 \left(\left(0,01788\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,01041\dot{y}_{t-2} + 0,08699\dot{y}_{t-3} + 0,08622\dot{y}_{t-4}|}{0,01788} \right) \right). \end{aligned}$$

Doodle yang digunakan untuk estimasi parameter MLAR pada *return saham UNVR* hampir sama seperti MLAR(2;[3],[3,6]). Perbedaannya terletak pada data yang digunakan yaitu data *return saham UNVR*. Selain itu, pada model MLAR(2;2,[11]), Lampiran L.1, $b1[1]$ dan $b2[1]$ yang merupakan parameter dari komponen pertama yaitu AR(2) serta $b1[2]$ yang merupakan parameter dari komponen kedua yaitu AR([11]) dan $b2[2]$ diatur untuk memenuhi aturan pembentukan doodle di WinBUGS. Doodle untuk model MLAR(3;(2),[11],-(2,[11])) akan mirip dengan MLAR(3;[2,3],[3,4],[2,3,4]), tetapi parameter *autoregressive* yang digunakan adalah $b1[1]$, $b2[1]$ dan $b3[1]$ yang merupakan parameter dari komponen pertama yaitu AR(2); $b1[2]$, $b2[2]$ dan $b3[2]$ yang merupakan parameter dari komponen kedua yaitu AR[11] serta $b1[3]$ dan $b2[3]$ dan $b3[3]$ yang merupakan parameter dari komponen ketiga yaitu AR(2,[11]). Parameter $b3[1]$ dan $b1[2]$ hanya digunakan untuk memenuhi aturan pembentukan doodle di WinBUGS seperti yang ditunjukkan oleh Lampiran M.1. Proses MCMC untuk estimasi model MLAR(2;(2),[11]) ditunjukkan oleh Lampiran L.2 dan model MLAR(3;(2),[11],(2,[11])) pada Lampiran M.2 dengan penjelasan yang sama seperti MLAR(3;[3],[3,6],0).

Tabel 4.11 menjelaskan bahwa parameter π_1 , π_2 dan π_3 yang secara berurutan merepresentasikan pembobot untuk komponen pertama, kedua dan ketiga telah signifikan, sehingga layak digunakan dalam model *mixture*. Hal itu dibuktikan

oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). Parameter $\phi_{1,2}$ yang merupakan parameter komponen pertama berupa model AR([2]), parameter $\phi_{2,3}$ yang merupakan parameter komponen kedua berupa model AR([3]) serta parameter $\phi_{3,4}$ yang merupakan parameter komponen ketiga berupa model AR([4]) telah signifikan. Signifikansi tersebut ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Dengan demikian *return* saham TLKM pada hari ke- t dipengaruhi oleh *return* saham 2, 3 dan 4 hari sebelumnya. Selain itu, ketiga komponen *mixture* juga menginformasikan bahwa standar deviasi masing-masing komponen telah signifikan, dimana *credible interval* yang tidak memuat 0 (nol). Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(3;[2],[3],[4]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,33350 \left(\left(0,01789\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,09297\dot{y}_{t-2}|}{0,01789} \right) \right) \\ & + 33340 \left(\left(0,01789\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08134\dot{y}_{t-3}|}{0,01789} \right) \right) \\ & + 33310 \left(\left(0,01788\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,08252\dot{y}_{t-4}|}{0,01788} \right) \right). \end{aligned}$$

Tabel 4.11 Estimasi Parameter Model MLAR(3;[2],[3],[4])

Parameter	Mean	Standar deviasi	2.50%	97.50%
π_1	0,33350	0,00653	0,32100	0,34650
π_2	0,33340	0,00664	0,32050	0,34630
π_3	0,33310	0,00660	0,32030	0,34610
$\phi_{1,2}$	-0,09297	$8,23 \times 10^{-4}$	-0,09458	-0,09113
$\phi_{2,3}$	-0,08134	$8,31 \times 10^{-4}$	-0,08295	-0,07948
$\phi_{3,4}$	-0,08252	$9,23 \times 10^{-4}$	-0,08426	-0,08040
σ_1	0,01789	$4,32 \times 10^{-4}$	0,01707	0,01876
σ_2	0,01789	$4,30 \times 10^{-4}$	0,01706	0,01875
σ_3	0,01788	$4,35 \times 10^{-4}$	0,01703	0,01876

Hasil estimasi parameter MLAR untuk saham UNVR ditunjukkan pada Tabel 4.12 dan Tabel 4.13.

Tabel 4.12 memperlihatkan bahwa parameter yang merepresentasi-kan pembobot untuk komponen pertama dan kedua yaitu π_1 dan π_2 telah signifikan, sehingga layak digunakan dalam model *mixture*. Hal itu dibuktikan oleh *credible interval* dari distribusi posterior tidak memuat 0 (nol). *Return* saham UNVR terbukti dipengaruhi oleh *return* saham 1, 2 dan 11 hari sebelumnya, dimana parameter $\phi_{1,1}$, $\phi_{1,2}$ yang merupakan parameter komponen pertama berupa model AR(2) dan parameter $\phi_{2,11}$ yang merupakan parameter komponen kedua berupa model AR([11]) telah signifikan. Signifikansi tersebut ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Selain parameter pembobot dan *Autoregressive*, ketiga komponen *mixture* juga menginformasikan bahwa standar deviasi masing-masing komponen telah signifikan, dimana *credible interval* yang tidak memuat 0 (nol). Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(2;2,[11]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,50140 \left((0,02052\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,26520\dot{y}_{t-1} + 0,09621\dot{y}_{t-2}|}{0,02052} \right) \right) \\ & + 0,49860 \left((0,02039\sqrt{2})^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t - 0,05787\dot{y}_{t-11}|}{0,02039} \right) \right). \end{aligned}$$

Tabel 4.12 Estimasi Parameter Model MLAR(2;2,[11])

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,50140	0,00855	0,48480	0,51800
π_2	0,49860	0,00855	0,48210	0,51520
$\phi_{1,1}$	-0,26520	$8,67 \times 10^{-4}$	-0,26680	-0,26310
$\phi_{2,11}$	0,05787	$8,41 \times 10^{-4}$	0,05600	0,05955
$\phi_{1,2}$	-0,09621	0,00106	-0,09828	-0,09382
σ_1	0,02052	$4,95 \times 10^{-4}$	0,01957	0,02151
σ_2	0,02039	$4,90 \times 10^{-4}$	0,01945	0,02137

Tabel 4.13 menjelaskan bahwa parameter π_1 , π_2 dan π_3 yang secara berurutan merepresentasikan pembobot untuk komponen pertama, kedua dan ketiga telah signifikan, sehingga layak digunakan dalam model *mixture*. Hal itu dibuktikan

oleh *credible interval* dari distribusi posterior yang tidak memuat 0 (nol). Parameter $\phi_{1,1}$, $\phi_{1,2}$ yang merupakan parameter komponen pertama berupa model AR(2), parameter $\phi_{2,11}$ yang merupakan parameter komponen kedua berupa model AR([11]) serta parameter $\phi_{3,1}$, $\phi_{3,2}$, $\phi_{3,11}$ yang merupakan parameter komponen kedua berupa model AR(2,[11]) telah signifikan. Signifikansi tersebut ditunjukkan oleh *credible interval* yang tidak memuat 0 (nol). Dengan demikian *return* saham UNVR pada hari ke- t dipengaruhi oleh *return* saham 1, 2 dan 11 hari sebelumnya. Selain itu, ketiga komponen *mixture* juga menginformasikan bahwa standar deviasi masing-masing komponen telah signifikan, dimana *credible interval* tidak memuat 0 (nol). Berdasarkan hasil estimasi parameter tersebut, persamaan matematis model MLAR(3;2,[11],[2,[11]]) dapat dituliskan

$$\begin{aligned} (\dot{y}_t | \mathcal{F}_{t-1}) = & 0,33450 \left(\left(0,02053\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,26520\dot{y}_{t-1} + 0,09634\dot{y}_{t-2}|}{0,02053} \right) \right) \\ & + 33280 \left(\left(0,02032\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t - 0,05798\dot{y}_{t-11}|}{0,02032} \right) \right) \\ & + 33280 \left(\left(0,02058\sqrt{2} \right)^{-1} \exp \left(-\sqrt{2} \frac{|\dot{y}_t + 0,26480\dot{y}_{t-1} + 0,09634\dot{y}_{t-2} - 0,05125\dot{y}_{t-11}|}{0,02058} \right) \right). \end{aligned}$$

Tabel 4.13 Estimasi Parameter Model MLAR(3;2,[11],(2,[11]))

Parameter	Mean	Standar deviasi	2,50%	97,50%
π_1	0,33450	0,00658	0,32180	0,34750
π_2	0,33280	0,00659	0,31960	0,34580
π_3	0,33280	0,00654	0,32000	0,34550
$\phi_{1,1}$	-0,26520	$8,84 \times 10^{-4}$	-0,26680	-0,26310
$\phi_{3,1}$	-0,26480	$8,24 \times 10^{-4}$	-0,26640	-0,26290
$\phi_{1,2}$	-0,09637	$1,24 \times 10^{-4}$	-0,09664	-0,09611
$\phi_{3,2}$	-0,09634	0,00111	-0,09855	-0,09386
$\phi_{2,11}$	0,05798	$8,23 \times 10^{-4}$	0,05620	0,05973
$\phi_{3,11}$	0,05125	0,00897	0,02927	0,06481
σ_1	0,02053	$4,95 \times 10^{-4}$	0,01957	0,02153
σ_2	0,02032	$4,90 \times 10^{-4}$	0,01939	0,02132
σ_3	0,02058	$4,93 \times 10^{-4}$	0,01963	0,02155

4.3 Pemilihan Model Terbaik

Dalam penelitian ini, pemilihan model terbaik dilakukan berdasarkan nilai *Deviance Information Criterion* (DIC). Model yang akan dibandingkan adalah model yang didapat dari pemodelan Bayesian MNAR dan Bayesian MLAR. Hasil perhitungan DIC direpresentasikan pada Tabel 4.14.

Tabel 4.14 Perbandingan Model MNAR dan MLAR berdasarkan DIC

Saham	Metode	Model	DIC
ASII	Bayesian	MLAR(2;[3],[3,6])	-12.572,1
	MLAR	MLAR(3;[3],[3,6],0)	-14.648,1
	Bayesian	MNAR(2;[3],[3,6])	-12.266,5
	MNAR	MNAR(3;[3],[3,6],0)	-14.149,1
TLKM		MLAR(2;[2,3],[3,4])	-13.725,4
		MLAR(2;[2],[3])	-13.731,2
	Bayesian	MLAR(2;[2],[4])	-13.729,9
	MLAR	MLAR(2;[3],[4])	-13.725,8
		MLAR(3;[2,3],[3,4],[2,3,4])	-16.385,7
		MLAR(3;[2],[3],[4])	-16.383,6
		MNAR(2;[2,3],[3,4])	-13.423,6
		MNAR(2;[2],[3])	-13.411,8
	Bayesian	MNAR(2;[2],[4])	-13.405,3
	MNAR	MNAR(2;[3],[4])	-12.151,5
UNVR		MNAR(3;[2,3],[3,4],[2,3,4])	-14.461,9
		MNAR(3;[2],[3],[4])	-15.897,5
	Bayesian	MLAR(2;2,[11])	-12.772,7
	MLAR	MLAR(3;1,2,[11],0)	-14.934,4
	Bayesian	MNAR(2;2,[11])	-10.777,8
	MNAR	MNAR(3;1,2,[11],0)	-12.002,9

Tabel 4.14 memberikan informasi bahwa dalam kasus ini model yang dihasilkan oleh metode Bayesian MLAR selalu lebih baik dibandingkan model yang dihasilkan oleh Bayesian MNAR. Hal tersebut ditunjukkan oleh nilai DIC setiap model Bayesian MLAR yang lebih kecil dibandingkan dengan model Bayesian MNAR untuk orde yang sama. Hasil analisis menunjukkan bahwa model terbaik untuk saham ASII adalah model MLAR(3;[3],[3,6],0) dengan nilai DIC sebesar -14.648,1. Untuk saham TLKM. model terbaik ditunjukkan oleh model MLAR(3;[2,3],[3,4],[2,3,4]) dengan nilai DIC sebesar -16.385,7. Saham UNVR

menunjukkan bahwa model terbaik adalah model MLAR(3;(2),[11],(2,[11])) dengan nilai DIC sebesar -14.934,4.

4.4 Perhitungan *Value at Risk (VaR)*

Perhitungan VaR dilakukan mengasumsikan bahwa faktor risiko *return* berdistribusi Laplace dengan parameter μ dan σ . Oleh sebab itu, perlu ditentukan rumus untuk menghitung VaR dengan asumsi *return* berdistribusi Laplace. Berikut ini proses penentuan rumus VaR dengan asumsi *return* berdistribusi Laplace.

$$P(X \leq x) = F(x | \mu, \sigma) = \begin{cases} 1 - \frac{1}{2} \exp\left(-\frac{(x-\mu)}{\sigma}\right), & \text{untuk } x \geq \mu \\ \frac{1}{2} \exp\left(\frac{(x-\mu)}{\sigma}\right), & \text{untuk } x < \mu \end{cases}$$

untuk $x \geq \mu$ dapat dibentuk rumus kuantil ke α sebagai berikut

$$\begin{aligned} P(X \leq x_\alpha) &= \alpha \\ 1 - \frac{1}{2} \exp\left(-\left(\frac{(x_\alpha-\mu)}{\sigma}\right)\right) &= \alpha \\ -\frac{1}{2} \exp\left(-\left(\frac{(x_\alpha-\mu)}{\sigma}\right)\right) &= \alpha - 1 \\ \exp\left(-\left(\frac{(x_\alpha-\mu)}{\sigma}\right)\right) &= -2\alpha + 2 \\ -\left(\frac{(x_\alpha-\mu)}{\sigma}\right) &= \ln(-2\alpha + 2) \\ \frac{(x_\alpha-\mu)}{\sigma} &= -\ln(-2\alpha + 2) \\ x_\alpha - \mu &= -\sigma \ln(-2\alpha + 2) \\ x_\alpha &= -\sigma \ln(-2\alpha + 2) + \mu. \end{aligned}$$

Setelah didapatkan rumus kuantil ke α (x_α), selanjutnya menentukan rumus VaR sebagai berikut

$$\text{VaR} = -x_\alpha$$

$$\begin{aligned}
&= -(-\sigma \ln(-2\alpha + 2) + \mu) \\
&= \sigma \ln(-2\alpha + 2) - \mu.
\end{aligned}$$

Kemudian untuk $x < \mu$ dapat dibentuk rumus kuantil ke α sebagai berikut

$$P(X \leq x_\alpha) = \alpha$$

$$\frac{1}{2} \exp\left(\frac{(x_\alpha - \mu)}{\sigma}\right) = \alpha$$

$$\exp\left(\frac{(x_\alpha - \mu)}{\sigma}\right) = 2\alpha$$

$$\frac{(x_\alpha - \mu)}{\sigma} = \ln(2\alpha)$$

$$x_\alpha - \mu = \sigma \ln(2\alpha)$$

$$x_\alpha = \sigma \ln(2\alpha) + \mu$$

Setelah didapatkan rumus kuantil ke α (x_α), selanjutnya menentukan rumus VaR sebagai berikut

$$\begin{aligned}
\text{VaR} &= -x_\alpha \\
&= -(\sigma \ln(2\alpha) + \mu) \\
&= \sigma \ln(2\alpha) - \mu.
\end{aligned}$$

Dari perhitungan di atas dapat disimpulkan bahwa

$$\text{VaR} = \sigma \ln(-2\alpha + 2) - \mu, \quad \text{untuk } x \geq \mu$$

dan

$$\text{VaR} = \sigma \ln(2\alpha) - \mu, \quad \text{untuk } x < \mu.$$

Karena *return* diharapkan bebas risiko, nilai μ yang merupakan parameter nilai sekarang dari *return* yang diharapkan adalah 0 (nol), sehingga

$$\text{VaR} = \sigma \ln(-2\alpha + 2), \quad \text{untuk } x \geq 0$$

dan

$$\text{VaR} = \sigma \ln(2\alpha) - 0, \quad \text{untuk } x < 0.$$

Dengan demikian

$$\begin{aligned}
\text{VaR} &= \sigma \ln(-2\alpha + 2) + \sigma \ln(2\alpha) \\
&= \sigma(\ln(-2\alpha + 2) + \ln(2\alpha)) \\
&= \sigma(\ln((-2\alpha + 2) \times (2\alpha))) \\
&= \sigma(\ln(-4\alpha^2 + 4\alpha)) \\
&= \sigma(\ln(4(-\alpha^2 + \alpha))).
\end{aligned}$$

Dengan fungsi distribusi Laplace yang simetri,

$$\text{VaR} = -\left(\sigma(\ln(4(-\alpha^2 + \alpha)))\right).$$

Nilai VaR dibawah asumsi *return* identik, independen dan berdistribusi Laplace pada *horizon* waktu h adalah

$$\text{VaR}_{h,\alpha} = \sqrt{h} \times \text{VaR}_{1,\alpha}$$

Dalam kondisi *mixture*, VaR dapat dihitung dengan persamaan

$$\text{VaR}_{\text{mix}} = \pi_1 \sqrt{h} \times \text{VaR}_{1,\alpha} + \pi_2 \sqrt{h} \times \text{VaR}_{1,\alpha} + \dots + \pi_3 \sqrt{h} \times \text{VaR}_{1,\alpha}$$

sehingga secara umum dapat ditulis

$$\text{VaR}_{\text{mix}} = \sum_{j=1}^K \pi_j \sqrt{h} \times \text{VaR}_{1,\alpha}$$

Perhitungan VaR dilakukan menggunakan hasil estimasi dari model terbaik yang telah didapat dari tahapan sebelumnya. Hasil perhitungan VaR dapat dilihat pada Tabel 4.15.

Tabel 4.15 menunjukkan bahwa semakin lama investor menanamkan sahamnya, semakin besar pula resiko yang akan dihadapi. Selain itu semakin besar *confidence level* yang digunakan, semakin besar pula risiko yang harus dihadapi. Risiko terbesar yang akan ditanggung oleh investor adalah ketika investor melakukan investasi saham ke ASII. Hal itu disebabkan karena saham ASII mempunyai nilai VaR yang lebih tinggi dibanding saham lain sebesar 0,03561 untuk investasi selam 1 hari. Risiko terbesar selanjutnya adalah investasi saham UNVR dengan VaR sebesar 0,03401 disusul oleh TLKM sebesar 0,02788. Hasil perhitungan VaR untuk saham ASII menunjukkan bahwa pada kuantil 5% dengan lama investasi satu hari menghasilkan VaR sebesar 0,02908 yang artinya seorang

investor menginvestasikan dana sebesar Rp.100.000.000,00, dia tidak akan kehilangan dana lebih dari Rp. 3.561.142,00 dari investasi ini selama satu hari ke depan atau resiko kerugian maksimal yang dihadapai investor sebesar Rp. 3.561.142,00.

Tabel 4.15 Hasil Perhitungan VaR

Saham	Lama Investasi	Kuantil		Investasi (100 juta Rupiah)	
		5%	1%	5%	1%
ASII	1 hari	0,03561	0,06924	3.561.142	6.923.856
	5 hari	0,07963	0,15482	7.962.955	15.482.213
	20 hari	0,15926	0,30964	15.925.910	30.964.426
TLKM	1 hari	0,02908	0,05769	2.907.547	5.769.014
	5 hari	0,06501	0,12900	6.501.472	12.899.907
	20 hari	0,13003	0,25800	13.002.944	25.799.814
UNVR	1 hari	0,03401	0,06612	3.400.979	6.612.455
	5 hari	0,07605	0,14786	7.604.820	14.785.899
	20 hari	0,15210	0,68878	15.209.641	68.878.329

4.5 Backtesting saham ASII, TLKM dan UNVR

Hasil perhitungan VaR pada subbab 4.4 perlu diuji untuk mengetahui apakah model perhitungan sudah valid atau belum. Oleh sebab itu dilakukan pengujian *Backtesting* dengan menggunakan uji kupiec sebagai berikut.

Hipotesis:

$$H_0 : p = \hat{p}$$

$$H_1 : p \neq \hat{p}$$

Tabel 4.16 Uji Kupiec

Saham	Kuantil	Likelihood Ratio (LR)	Keputusan
ASII	5%	0,09	Gagal Tolak H_0
	1%	2,83	Gagal Tolak H_0
TLKM	5%	0,09	Gagal Tolak H_0
	1%	3,69	Gagal Tolak H_0
UNVR	5%	0,07	Gagal Tolak H_0
	1%	0,69	Gagal Tolak H_0

Tabel 4.16 memperlihatkan bahwa dengan menggunakan persamaan 2.54 didapatkan nilai LR untuk masing-masing saham di setiap kuantil. Dengan daerah kritis Tolak H_0 jika nilai LR lebih kecil dari $\chi^2_{0,05;1}$ yaitu 3,84, dapat diambil keputusan Gagal Tolak H_0 . Keputusan tersebut mengartikan bahwa semua model yang terbentuk telah akurat.

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dipaparkan dalam bab 4, dapat disimpulkan bahwa

- 1 Model yang dihasilkan oleh metode Bayesian MLAR selalu lebih baik dibandingkan model yang dihasilkan oleh Bayesian MNAR. Selain itu, analisis menunjukkan bahwa model terbaik untuk saham ASII adalah model $MLAR(3;[3],[3,6],0)$. Untuk saham TLKM, model terbaik ditunjukkan oleh model $MLAR(3;[2,3],[3,4],[2,3,4])$. Saham UNVR menunjukkan bahwa model terbaik adalah model $MLAR(3;(2),[11],(2,[11]))$.
- 2 Perhitungan VaR dengan mengasumsikan *return* berdistribusi Laplace menunjukkan bahwa semakin lama investor menanamkan sahamnya, semakin besar pula resiko yang akan dihadapi. Semakin besar *confidence level* yang digunakan, semakin besar pula risiko yang harus dihadapi. Risiko tertinggi hingga terendah secara berturut-turut dalam investasi akan dialami saham ASII, UNVR, dan TLKM. Selain itu, model VaR yang digunakan telah akurat.

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. 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*).

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- Andersen, T. G., Davis, R. A., K., J.-P., & Mikhosch, T. (2009). *Handbook of Financial Time Series*. Berlin: Springer.
- Berg, A., Meyer, R., & Yu, J. (2004). Deviance Information Criterion for Comparing Stochastic Volatility Models. *Journal of Business & Economic Statistics*, 107-120.
- Box, G. E., & Tiao, G. C. (1973). *Bayesian Inference in Statistical Analysis*. Massachusetts: Adison Wesley.
- Butler, C. (1999). *Mastering Value at Risk*. New York: Prentice Hall.
- Charlin, B., & Chip, S. (1995). Bayesian Model Choice via Markov Chain Monte Carlo Methods. *Journal of the Royal Statistical Society, Series B (Methodological)*, 57(3), 473-484.
- Daniel, W. W. (1989). *Statistik Non Parametrik Terapan*. Jakarta: PT.Gramedia.
- Dempster, A. P. (1974). The Direct Use of Likelihood for Significance Testing. *Proceedings of Conference on Foundational Questions in Statistical*, 335-352.
- Dowd, K. (2006). Retrospective Assessment of Value-at-Risk. *Risk Management: A Modern Perspective*, 183-202.
- Fink, D. (1997). A Compendium of Conjugate Priors. *Environmental Statistics Group*.
- Gelman, A. (2002). Prior Distribution. *Encyclopedia of Environmetrics*, 3, 1634-1637.
- Gilli, M., & Kellezi, E. (2006). An Application of Extreme Value Theory for Measuring Financial Risk. *Computational Economics*, 27, 207-228.
- Husnan, S. (2002). *Dasar-dasar Teori Portofolio dan Analisis Sekuritas*. Edisi ke. Yogyakarta: AMP YKPN.
- Iriawan, N. (2012). *Pemodelan dan Analisis Data-Driven*. Surabaya: ITS Press.
- Jogiyanto. (2000). *Analisis dan Desain Sistem Informasi : Pendekatan terstruktur teori dan praktis aplikasi bisnis*. Yogyakarta: Andi.

- Kansantaloustiede, Tutkielma, M. T., & Nieppola, O. (2009). *Backtesting Value-at-Risk Models*. Helsinki: Helsinki School Of Economics.
- Kotz, S., Kozubowski, T. J., & Podgorski, K. (2001). *The Laplace Distribution and Generalizations: A Revisit with Applications to Communications, Economics, Engineering, and Finance*. New York: Springer Science+Business Media, LLC.
- Kupiec, P. H. (1995). Techniques for verifying the accuracy of risk measurement models. *The Journal of Derivatives*, 3, 73-84.
- Le, N. D., Martin, R. D., & Raftery, A. E. (1996). Modelling Flat Stretches, Burst, and Outlier Time Series In Exponential Variable. *J. Am. Statist. Ass.*, 1504-1514.
- Levene, H. (1960). In *Contributions to Probability and Statistics: Essays in Honor of Harold Hotelling*, edited by Olkin, I. dkk. Stanford, CA: Stanford University Press.
- Makridakis, Wheelwright, & McGee. (1999). *Metode dan Aplikasi Peramalan*. Jakarta: Binarupa Aksara.
- Miftahurrohmah, B., Iriawan, N., & Fithriasari, K. (2016). On The Value at Risk Using Bayesian Mixture Laplace Autoregressive Modeling Approach for the Islamic Stock Investment Risk. *telah diseminarkan di The 1st International Conference on Mathematics: Education, Theory, and Application (ICMETA)*.
- Murphy, K. P. (2007). Conjugate Bayesian analysis of the Gaussian distribution. *Science Journal*.
- Nguyen, H. D., & McLachlan, G. J. (2016). Laplace mixture of linear experts. *Computational Statistics and Data Analysis* 93, 177-191.
- Nguyen, H. D., Geoffrey, M. J., Ullmann, J. F., & Janke, A. L. (2016). Laplace mixture autoregressive models. *Statistics and Probability Letters* 110, 18-24.
- Putri, U. M. (2016). *Analisis Risiko Investasi Saham Syariah Menggunakan Metode Value at Risk dengan Pendekatan Mixture Normal Autoregressive*. Surabaya: Institut Teknologi Sepuluh Nopember.

- Sani, L. W. (2013). *Residual Income Model, Operational Cash Flow And Share Value Book As Alternatives To Predict Stock Prices (A Study at Corporations Listed in LQ45 Index in 2009-2011)*. Other thesis. Lampung: Universitas Lampung.
- Siahaan, H. (2009). *Manajemen Risiko Pada Perusahaan dan Birokrasi*. Jakarta: PT. Elex Media Komputindo.
- Spiegel, M. R., & Stephens, L. J. (1999). *Schaum's Outlines of Theory and Problems of Statistics*. New York: McGraw-Hill Company.
- Spiegelhalter, D. J., Best, N. G., Carlin, B. P., & van der Linde, A. (2002). Bayesian Measures of Model Complexity and Fit" (with discussion). *Journal of the Royal Statistical Society, 64*, 583-639.
- Suswinarno. (2013). *Mengantisipasi Risiko dalam Pengadaan Barang/ Jasa Pemerintah*. Jakarta: Visimedia.
- Tandelilin, E. (2001). *Analisis Investasi dan Manajemen Portofolio Edisi Pertama*. Yogyakarta: BPFE Yogyakarta.
- Vaughan, E. J., & Elliot, C. M. (1978). *Fundamentals of Risk and Insurance (2nd ed)*. Santa Barbara: John Wiley & Son, Inc.
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods Second Edition*. New York: Pearson Education.
- Wong, C. S., & Li, W. K. (2000). On a Mixture Autoregressive. *Journal of the Royal Statistical Society Series B*, 95-115.

Halaman ini sengaja dikosongkan

LAMPIRAN

Lampiran A Data Return Saham ASII

Tanggal	<i>Close</i>	<i>Return</i>
1/4/2010	35300,00	
1/5/2010	35500,00	0,0056657
1/6/2010	35300,00	-0,0056338
1/7/2010	34200,00	-0,0311615
1/8/2010	34400,00	0,0058480
1/11/2010	34950,00	0,0159884
1/12/2010	35400,00	0,0128755
1/13/2010	35100,00	-0,0084746
1/14/2010	35550,00	0,0128205
1/15/2010	36200,00	0,0182841
1/18/2010	36000,00	-0,0055249
1/19/2010	36250,00	0,0069444
1/20/2010	35800,00	-0,0124138
1/21/2010	35250,00	-0,0153631
1/22/2010	33800,00	-0,0411348
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
10/3/2016	8475,00	0,0272727
10/4/2016	8600,00	0,0147493
10/5/2016	8425,00	-0,0203488
10/6/2016	8350,00	-0,0089021
10/7/2016	8200,00	-0,0179641
10/10/2016	8275,00	0,0091463
10/11/2016	8325,00	0,0060423
10/12/2016	8300,00	-0,0030030
10/13/2016	8200,00	-0,0120482
10/14/2016	8325,00	0,0152439
10/17/2016	8225,00	-0,0120120
10/18/2016	8475,00	0,0303951
10/19/2016	8375,00	-0,0117994
10/20/2016	8375,00	0,0000000
10/21/2016	8375,00	0,0000000

Lampiran B Data *Return* Saham TLKM

Tanggal	<i>Close</i>	<i>Return</i>
1/4/2010	9550.00	
1/5/2010	9600.00	0.0052356
1/6/2010	9500.00	-0.0104167
1/7/2010	9250.00	-0.0263158
1/8/2010	9350.00	0.0108108
1/11/2010	9450.00	0.0106952
1/12/2010	9500.00	0.0052910
1/13/2010	9400.00	-0.0105263
1/14/2010	9350.00	-0.0053191
1/15/2010	9500.00	0.0160428
1/18/2010	9400.00	-0.0105263
1/19/2010	9450.00	0.0053191
1/20/2010	9500.00	0.0052910
1/21/2010	9450.00	-0.0052632
1/22/2010	9300.00	-0.0158730
1/25/2010	9250.00	-0.0053763
1/26/2010	9300.00	0.0054054
1/27/2010	9250.00	-0.0053763
1/28/2010	9300.00	0.0054054
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
10/3/2016	4380.00	0.0162413
10/4/2016	4360.00	-0.0045662
10/5/2016	4300.00	-0.0137615
10/6/2016	4210.00	-0.0209302
10/7/2016	4200.00	-0.0023753
10/10/2016	4160.00	-0.0095238
10/11/2016	4160.00	0.0000000
10/12/2016	4140.00	-0.0048077
10/13/2016	4180.00	0.0096618
10/14/2016	4210.00	0.0071770
10/17/2016	4240.00	0.0071259
10/18/2016	4230.00	-0.0023585
10/19/2016	4200.00	-0.0070922
10/20/2016	4200.00	0.0000000

Lampiran C Data *Return* Saham UNVR

Tanggal	<i>Close</i>	<i>Return</i>
1/4/2010	11050	
1/5/2010	11400	0.031674
1/6/2010	11300	-0.008772
1/7/2010	11100	-0.017699
1/8/2010	11150	0.004505
1/11/2010	11250	0.008969
1/12/2010	11100	-0.013333
1/13/2010	11050	-0.004505
1/14/2010	11000	-0.004525
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	-0.008584
1/22/2010	11550	0
1/25/2010	11450	-0.008658
1/26/2010	11450	0
1/27/2010	11450	0
1/28/2010	11400	-0.004367
.	.	.
.	.	.
.	.	.
.	.	.
.	.	.
10/3/2016	45200	0.01459
10/4/2016	45050	-0.003319
10/5/2016	44825	-0.004994
10/6/2016	45175	0.007808
10/7/2016	44500	-0.014942
10/10/2016	44600	0.002247
10/11/2016	45250	0.014574
10/12/2016	45000	-0.005525
10/13/2016	44500	-0.011111
10/14/2016	45000	0.011236
10/17/2016	44725	-0.006111
10/18/2016	44475	-0.00559
10/19/2016	44325	-0.003373
10/20/2016	44300	-0.000564

Lampiran D ASII MLAR(2;[3],[3,6])

1. Code WinBUGS

```

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)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- 1 / sqrt(tao[2])
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- 1 / sqrt(tao[1])
  b2[1] ~ dnorm( 0.0,1.0E-6)
  b2[2] ~ dnorm( 0.0,1.0E-6)
}

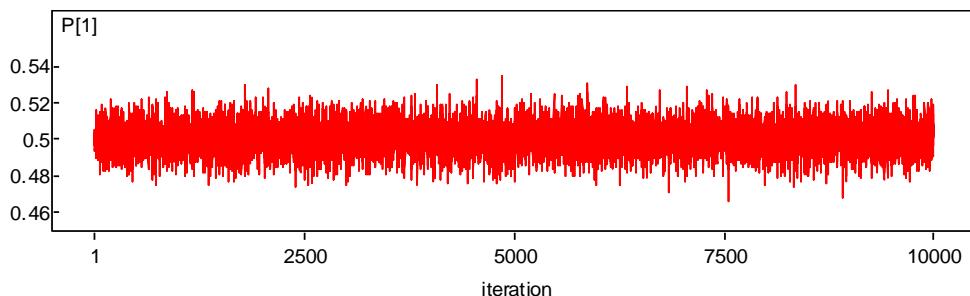
```

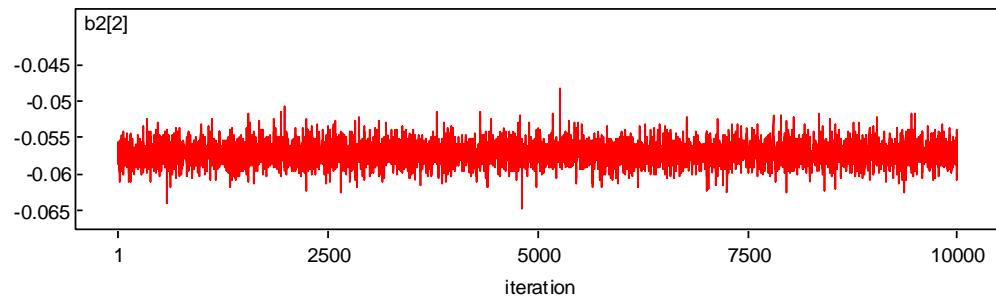
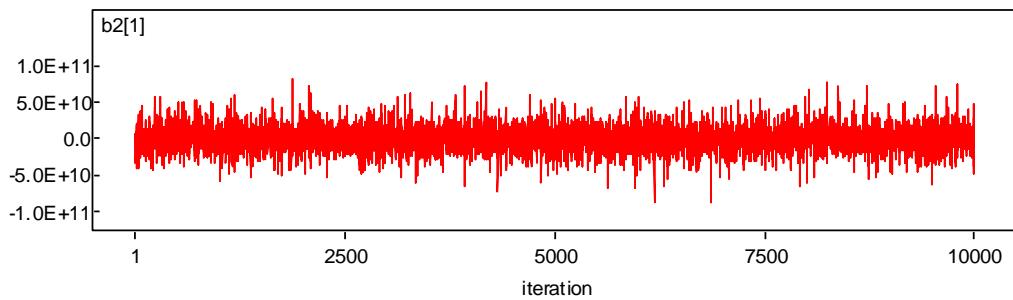
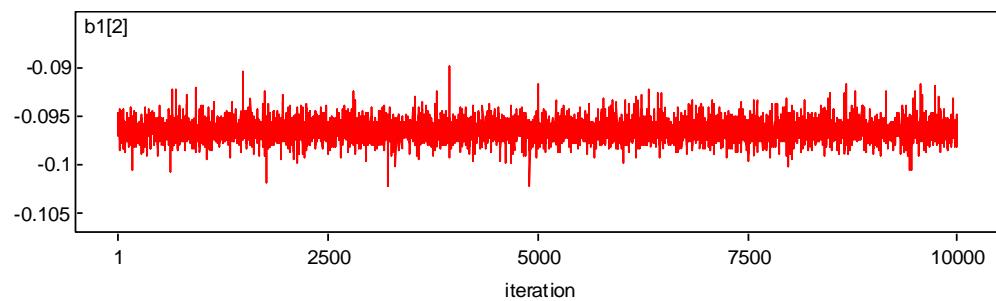
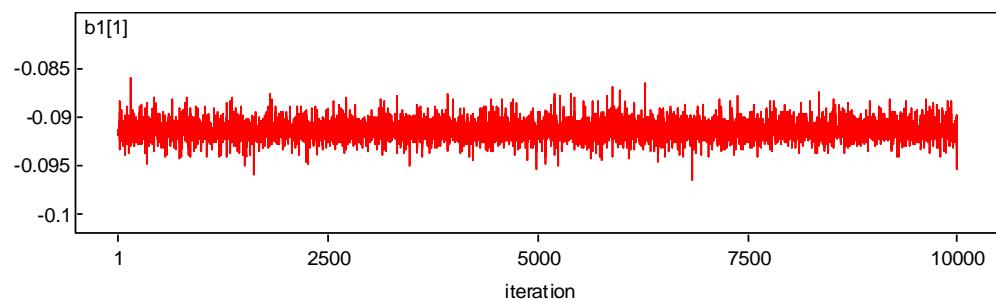
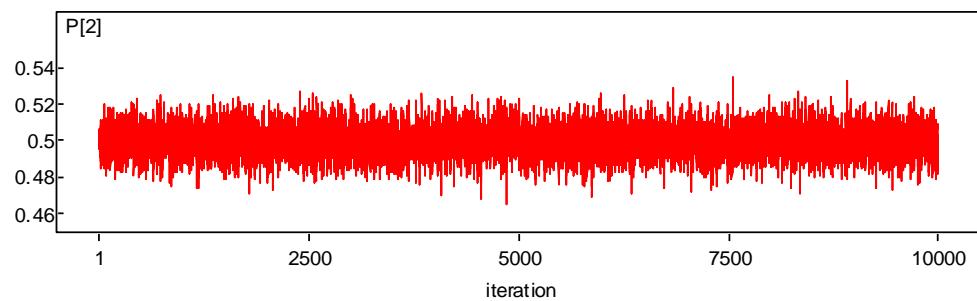
2. Output WinBUGS

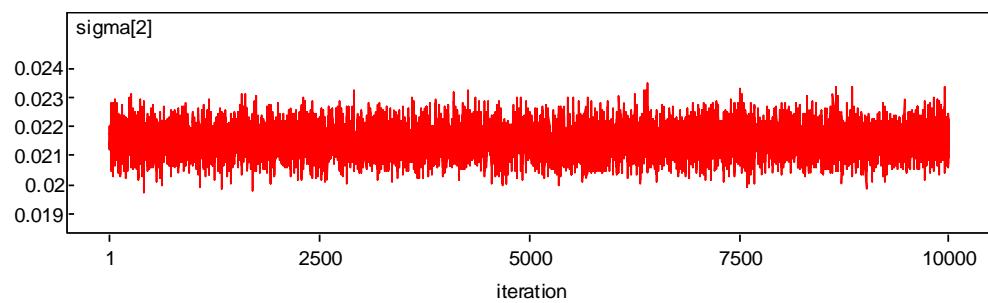
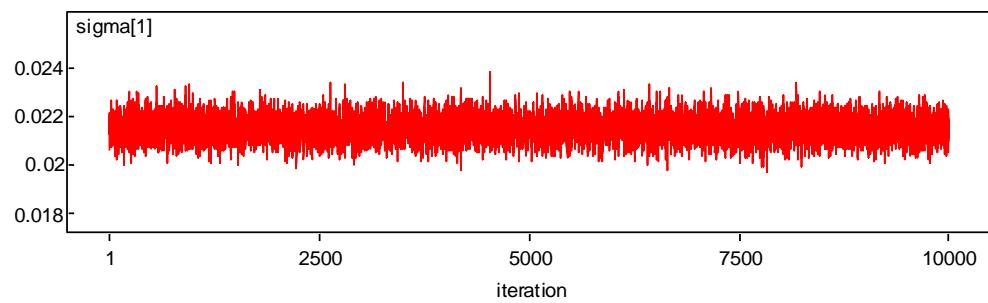
Statistik:

node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5004	0.008388	9.553E-5	0.4839	0.5005	0.5168	1	10000
P[2]	0.4996	0.008388	9.553E-5	0.4832	0.4995	0.5161	1	10000
b1[1]	-0.09141	8.172E-4	8.001E-6	-0.09303	-0.09147	-0.08957	1	10000
b1[2]	-0.09651	8.299E-4	8.188E-6	-0.09814	-0.09656	-0.09461	1	10000
b2[1]	1.479E+8	1.408E+10	1.381E+8	-2.893E+10	-2.427E+7	2.985E+10	1	10000
b2[2]	-0.05724	0.001195	1.168E-5	-0.0597	-0.05728	-0.05461	1	10000
sigma[1]	0.02149	5.128E-4	4.56E-6	0.02052	0.02149	0.02252	1	10000
sigma[2]	0.02151	5.142E-4	5.168E-6	0.02051	0.02149	0.02254	1	10000

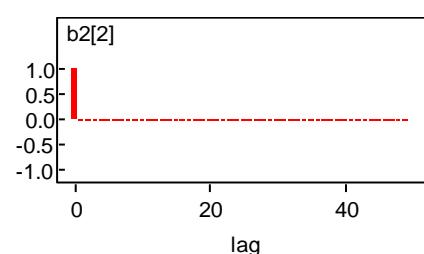
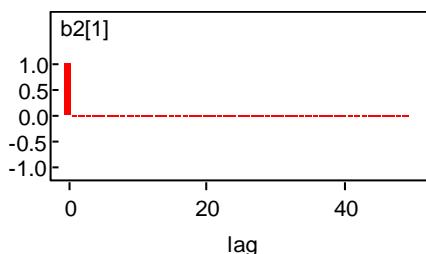
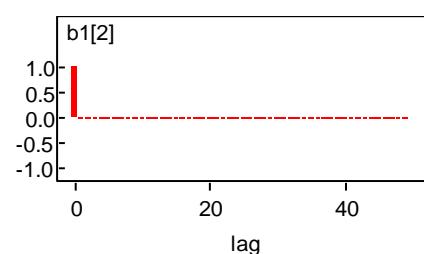
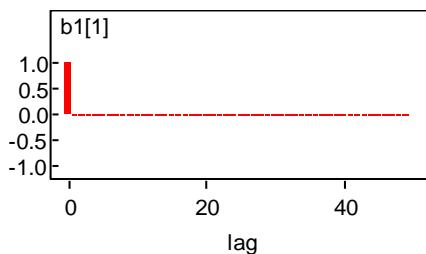
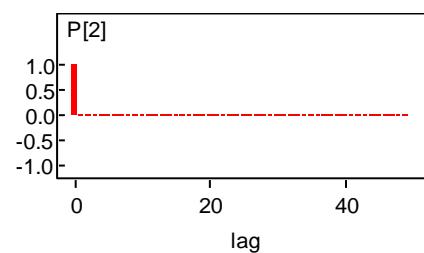
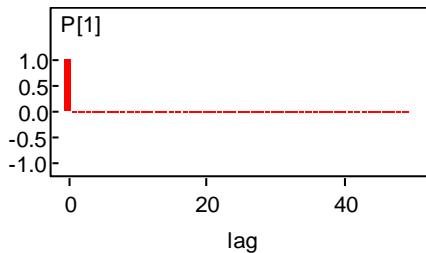
History:

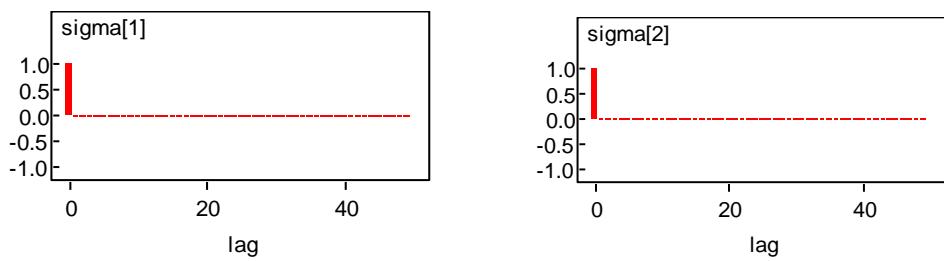




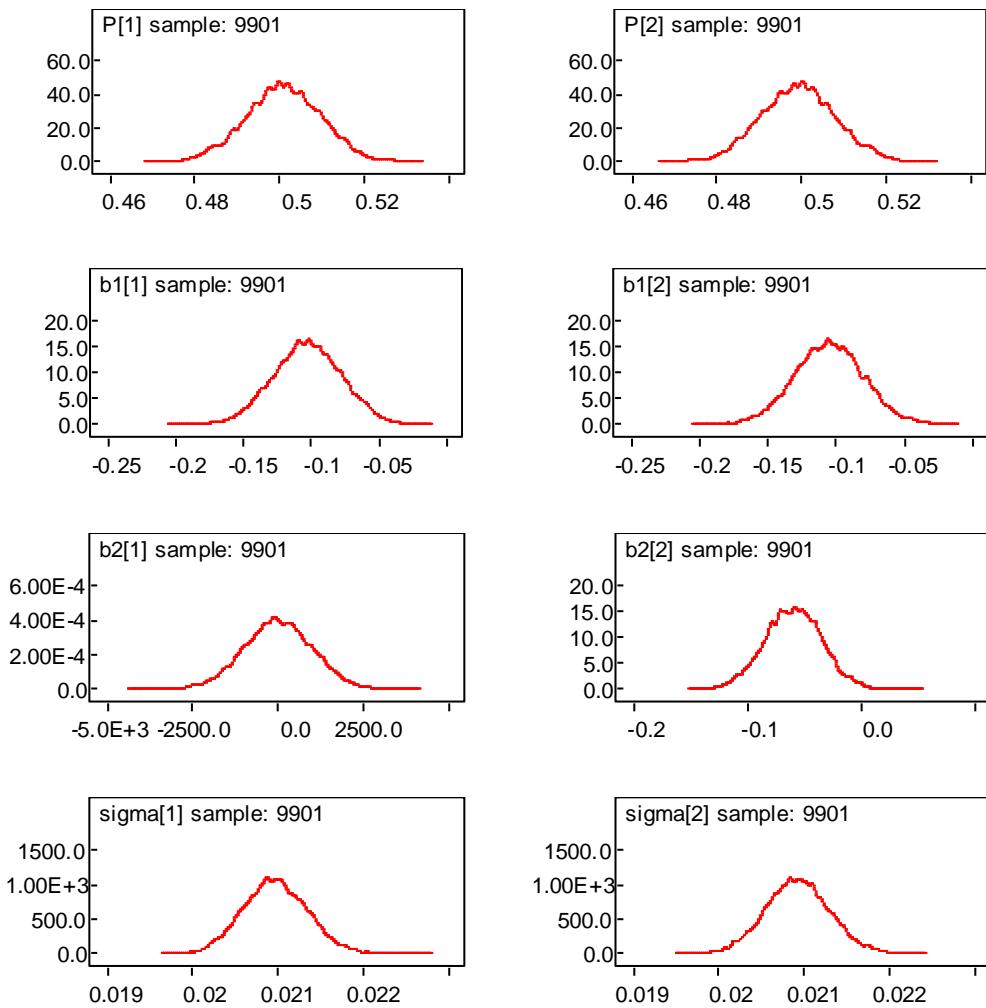


Autokorelasi:





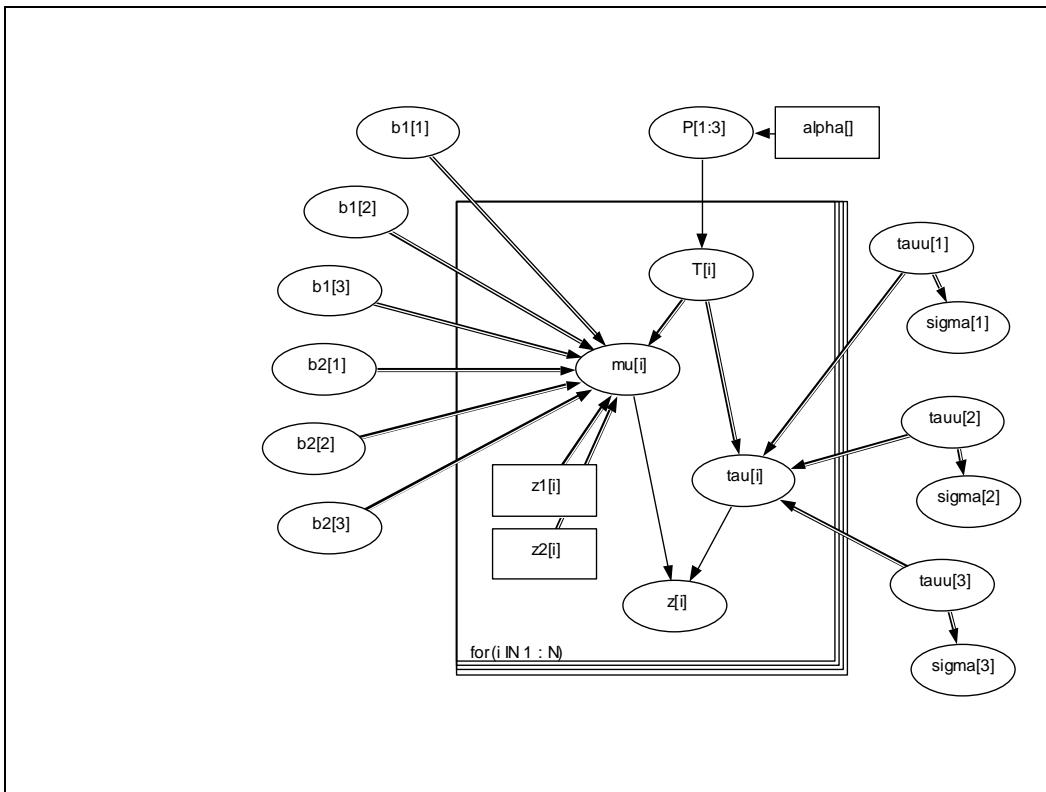
Density:



Lampiran E ASII MLAR(3;[3],[3,6],0)

1. Doodle dan code WinBUGS

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ ddexp(-0.09153,1740.0)
  b1[2] ~ ddexp(-0.09661,1729.0)
  tauu[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tauu[2]
  for( i in 1 : N ) {
    tau[i] <- tauu[T[i]]
  }
  tauu[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tauu[1]
  b2[1] ~ ddexp( 0.0, 0.1)
  b2[2] ~ ddexp(-0.05732,1188.0)
  b1[3] ~ ddexp( 0.0, 0.1)
  b2[3] ~ ddexp( 0.0, 0.1)
  tauu[3] ~ dgamma(0.001,0.001)
}

```

```

    sigma[3] <- sqrt(2) / tauu[3]
}

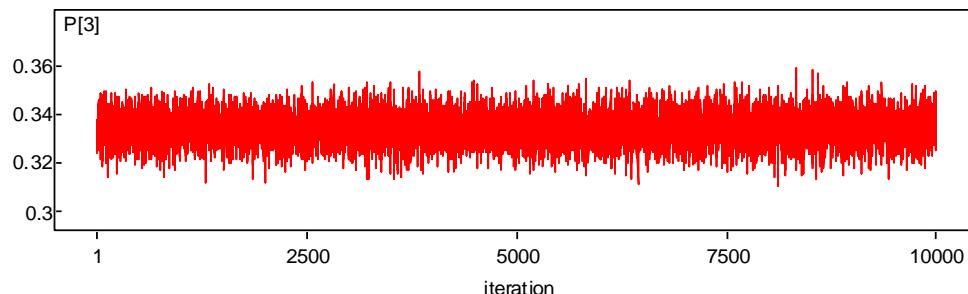
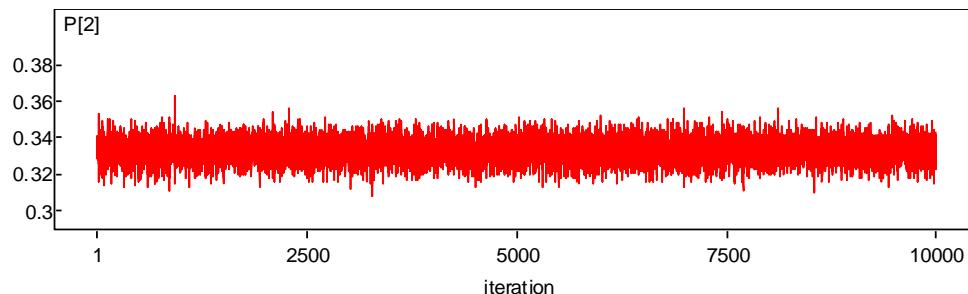
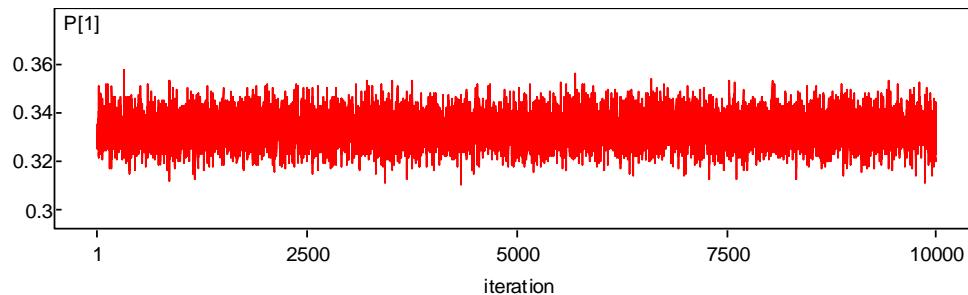
```

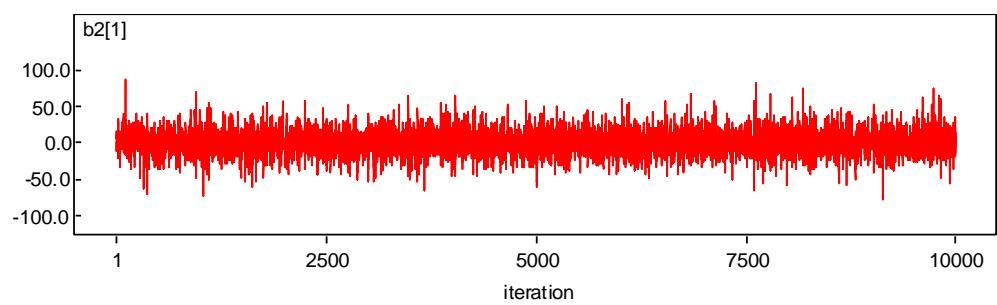
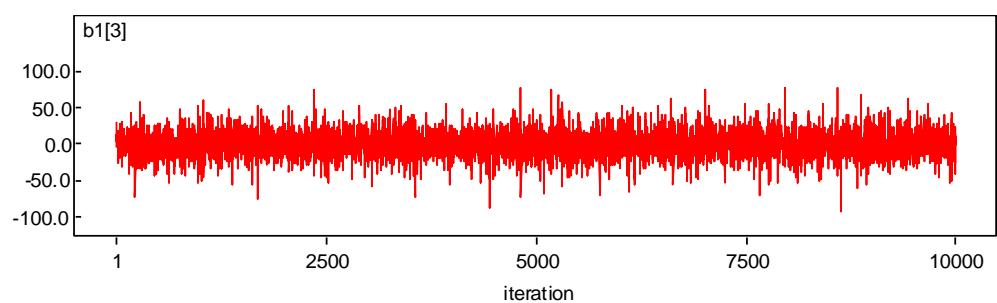
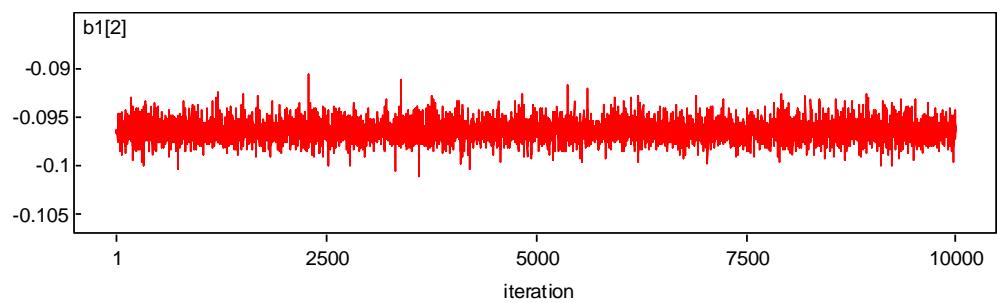
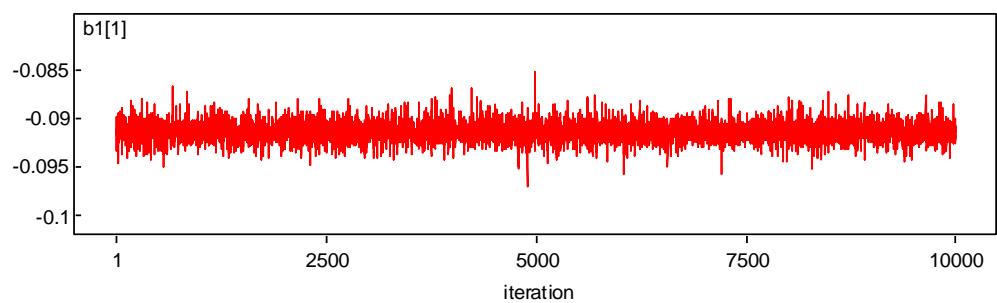
2. Output WinBUGS

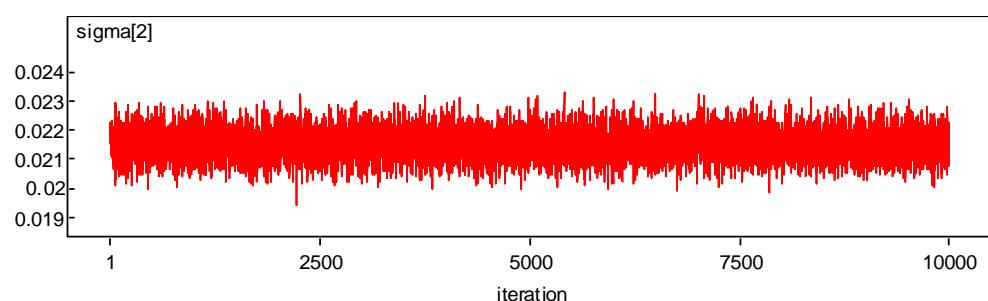
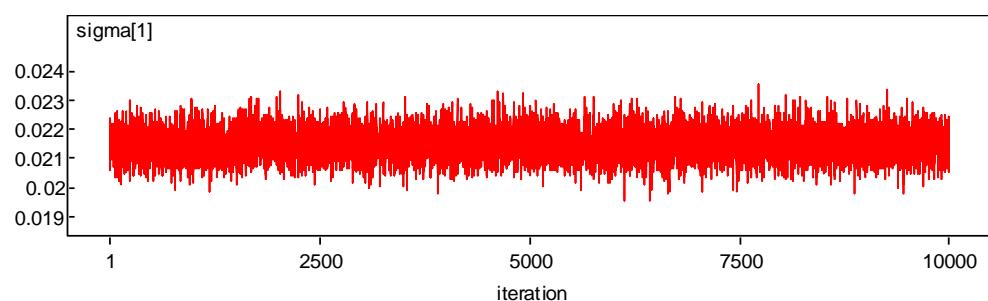
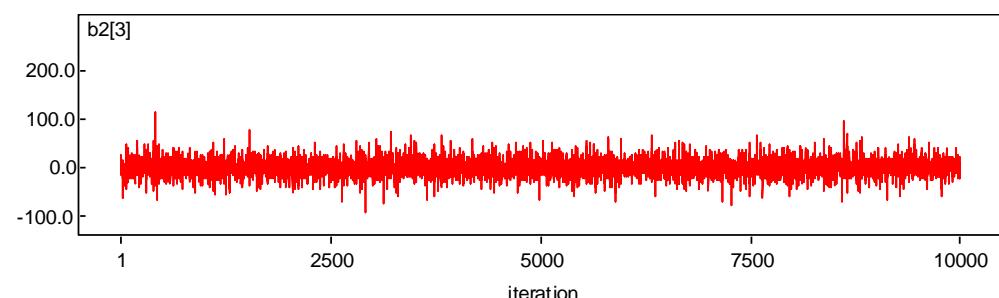
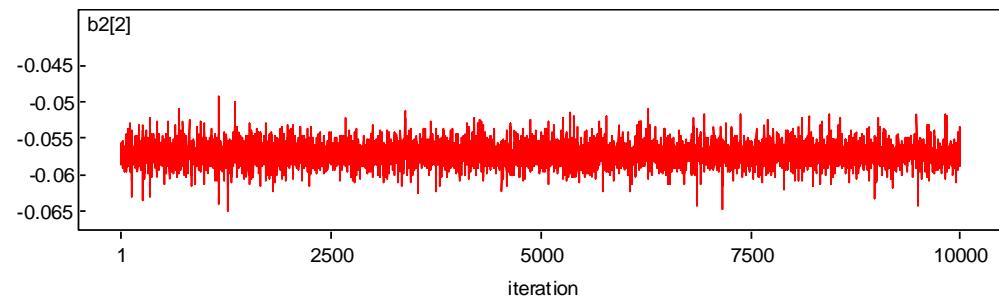
Statistik:

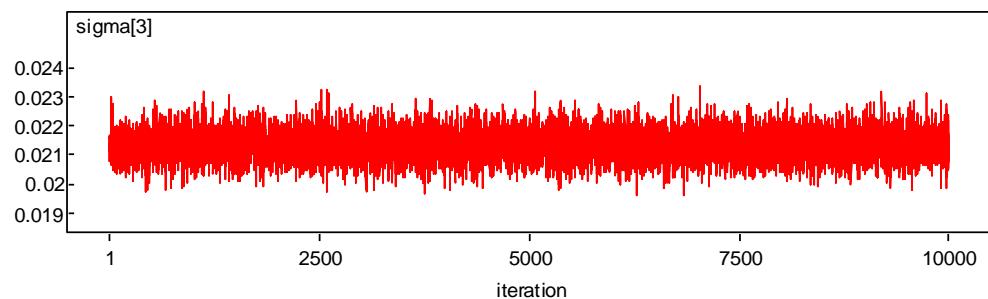
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.3332	0.00655	5.889E-5	0.3206	0.3332	0.3461	1	10000
P[2]	0.3328	0.00658	6.373E-5	0.3197	0.3327	0.3457	1	10000
P[3]	0.334	0.006576	6.358E-5	0.3213	0.3339	0.3469	1	10000
b1[1]	-0.09142	8.243E-4	9.381E-6	-0.09308	-0.09147	-0.08962	1	10000
b1[2]	-0.09649	8.335E-4	8.576E-6	-0.09813	-0.09655	-0.09453	1	10000
b1[3]	0.006134	14.0	0.1256	-29.86	0.03121	30.17	1	10000
b2[1]	0.07093	13.98	0.1313	-29.35	-0.09671	30.42	1	10000
b2[2]	-0.0572	0.00121	1.141E-5	-0.05965	-0.05726	-0.05454	1	10000
b2[3]	0.1078	14.11	0.1325	-29.64	0.1321	30.26	1	10000
sigma[1]	0.02149	5.087E-4	5.119E-6	0.02054	0.02149	0.02251	1	10000
sigma[2]	0.02151	5.052E-4	4.497E-6	0.02053	0.02151	0.02253	1	10000
sigma[3]	0.02133	5.089E-4	4.804E-6	0.02034	0.02132	0.02234	1	10000

History:

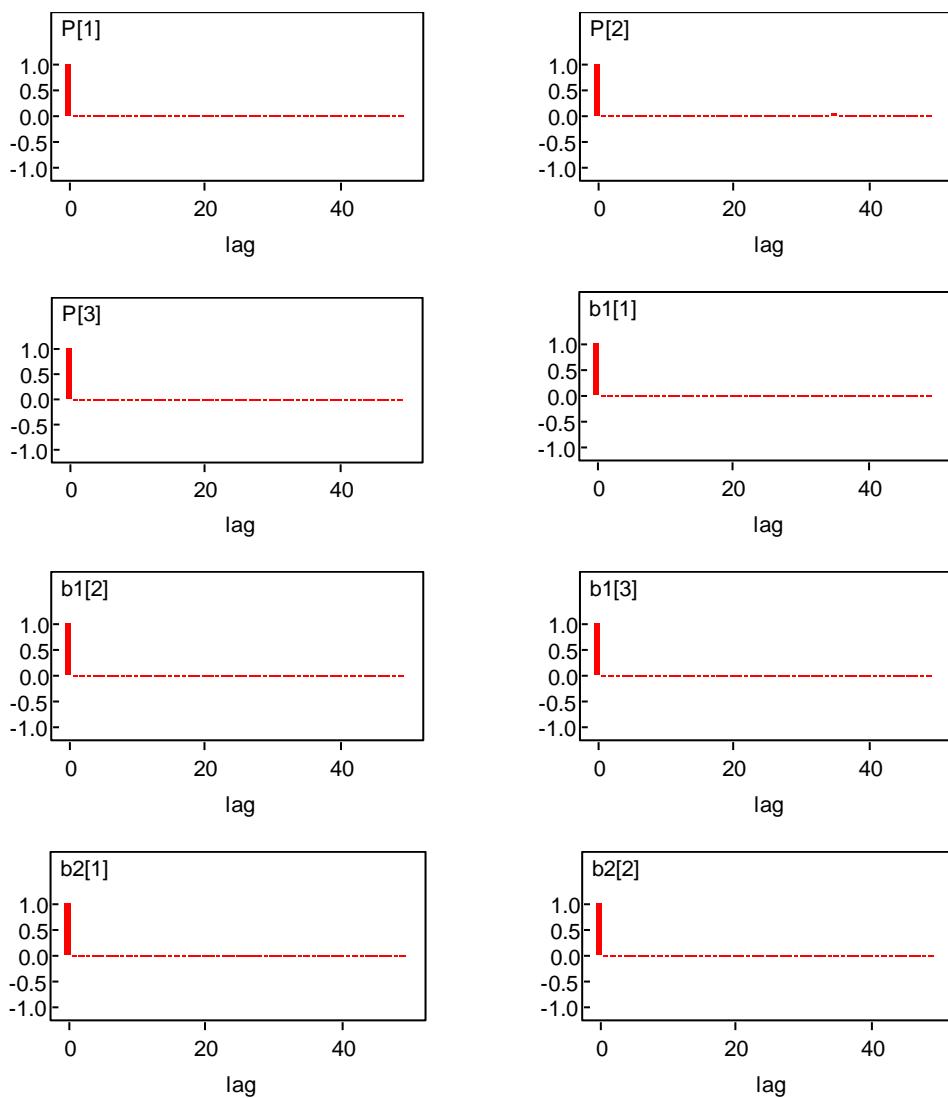


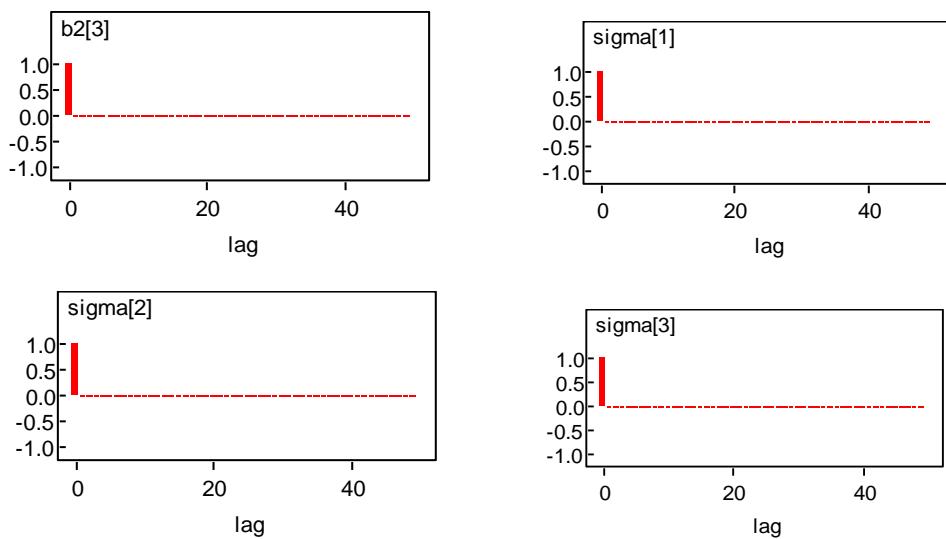




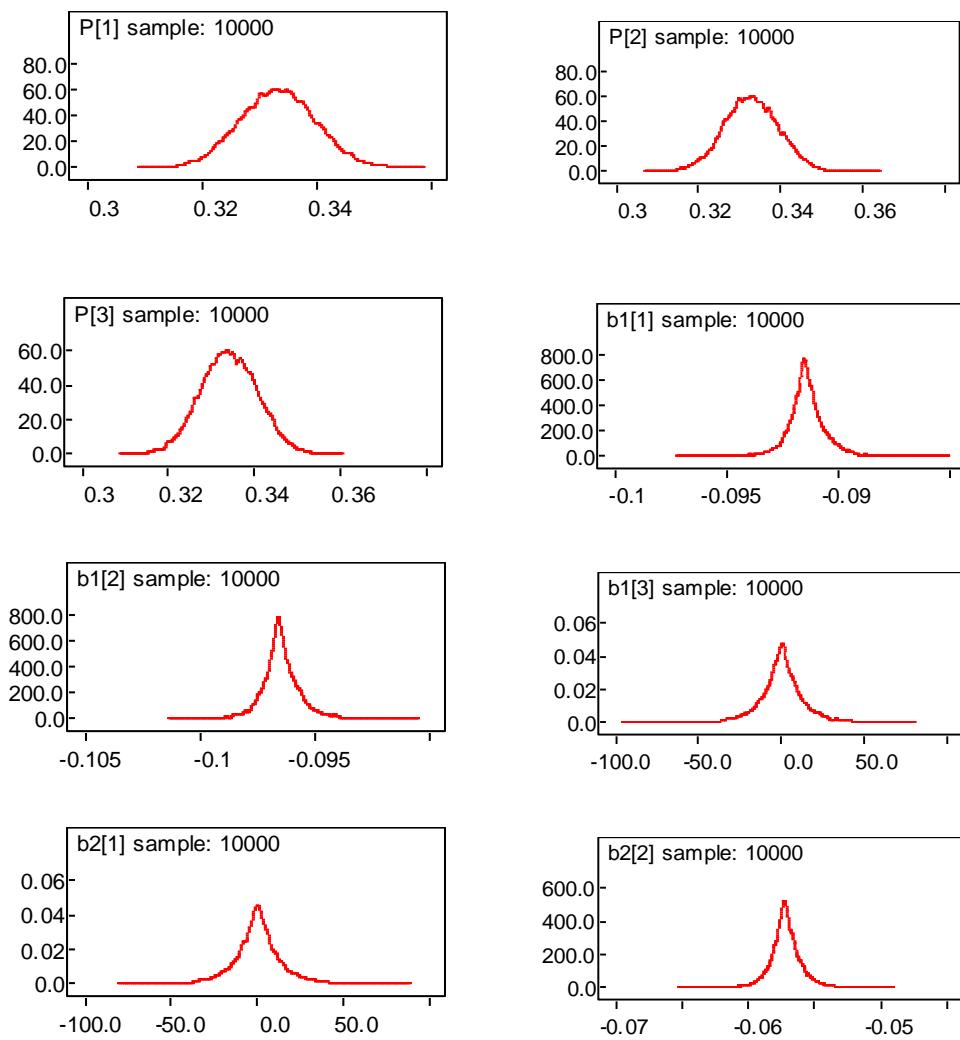


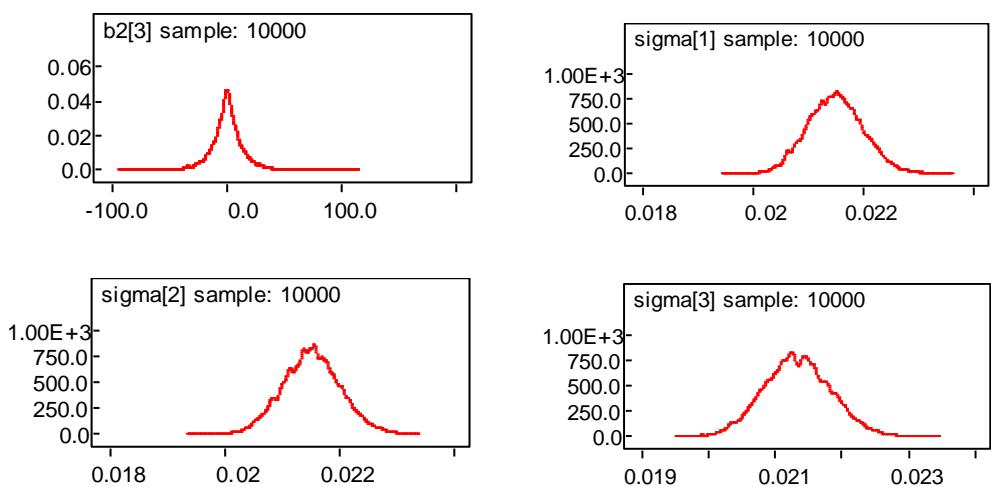
Autokorelasi:





Density:

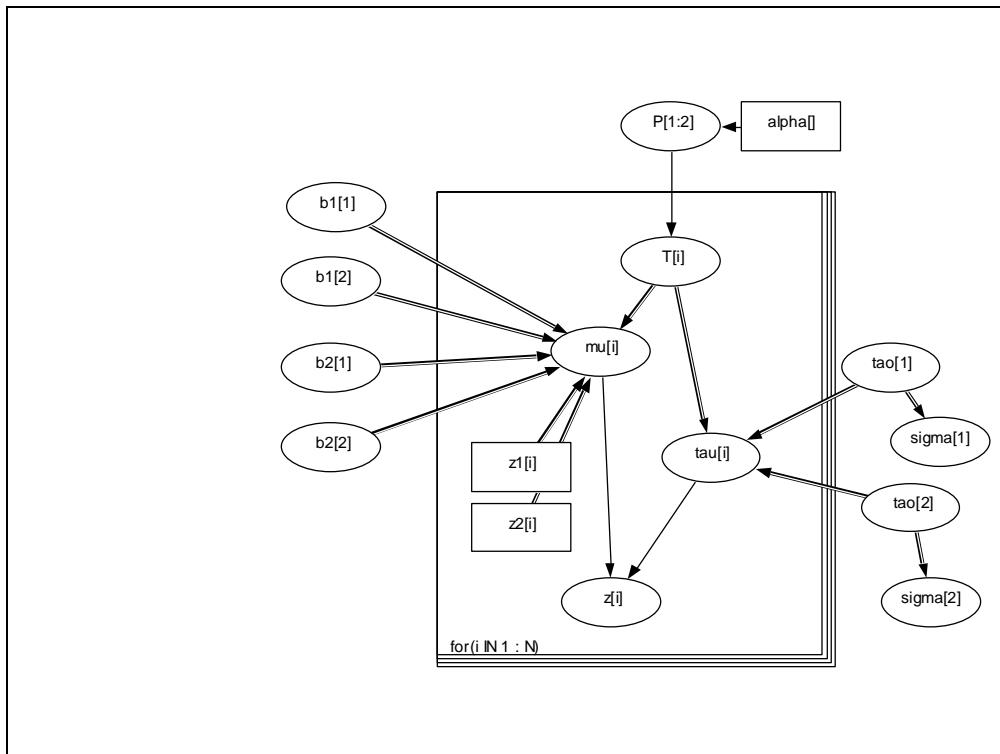




Lampiran F TLKM MLAR(2;[2,3],[3,4])

1. Doodle dan code WinBUGS

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ ddexp(-0.09518,1720.0)
  b1[2] ~ ddexp(-0.08415,1715.0)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
  b2[1] ~ ddexp(-0.08414,1003.0)
  b2[2] ~ ddexp(-0.07649,1001.0)
}

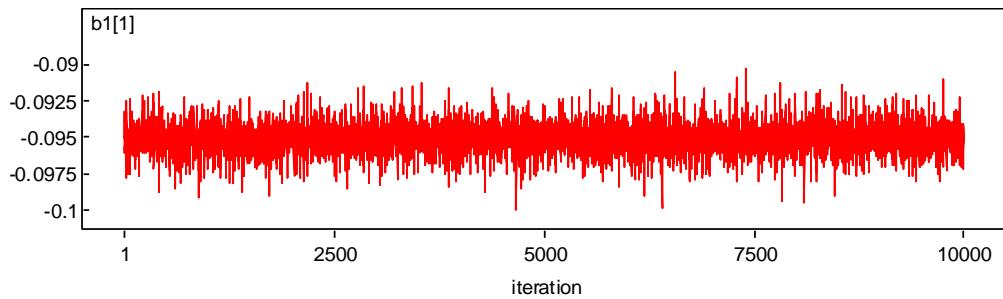
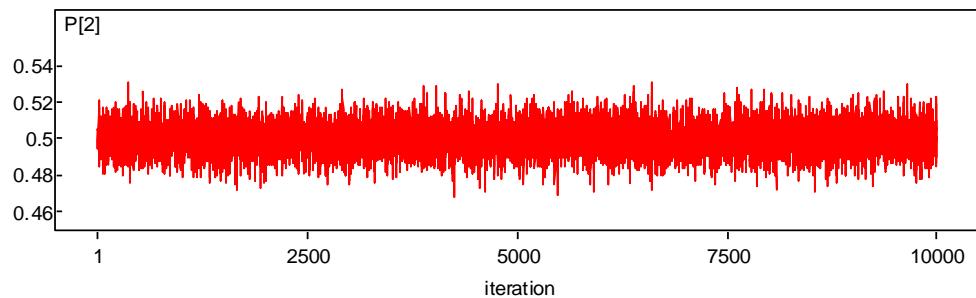
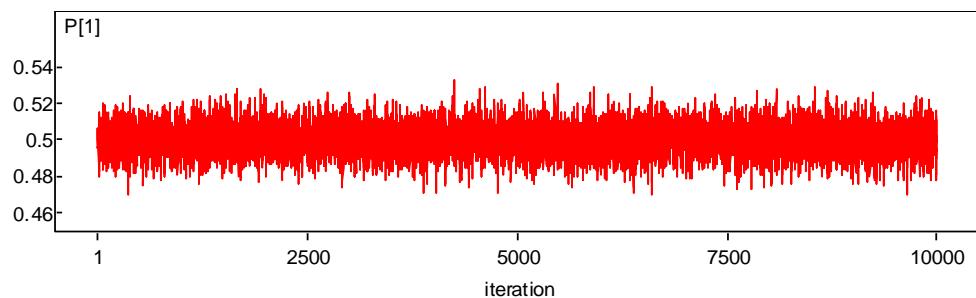
```

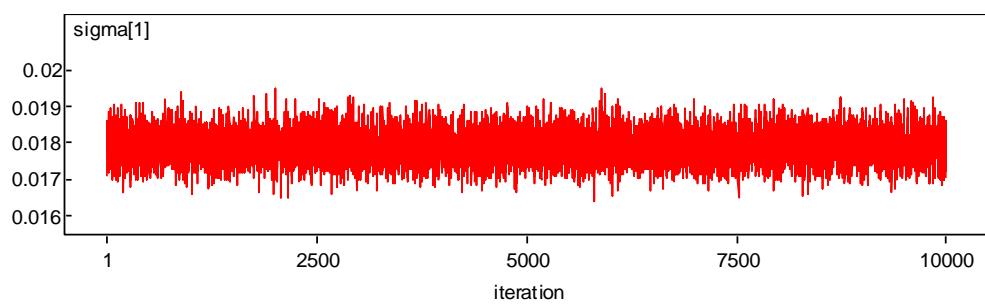
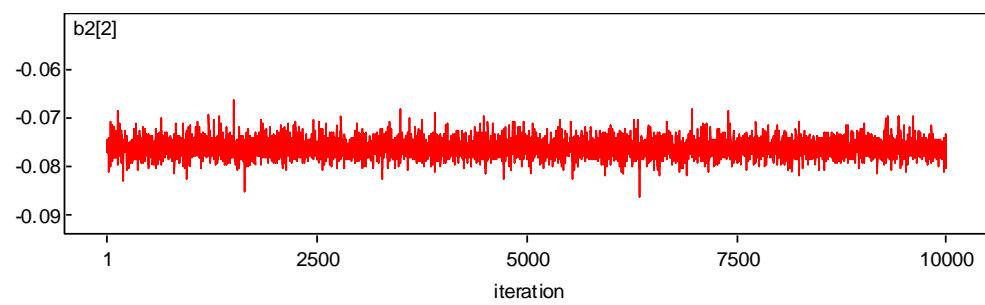
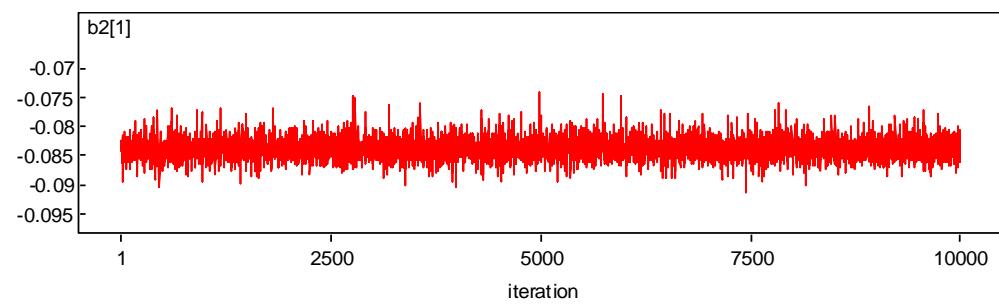
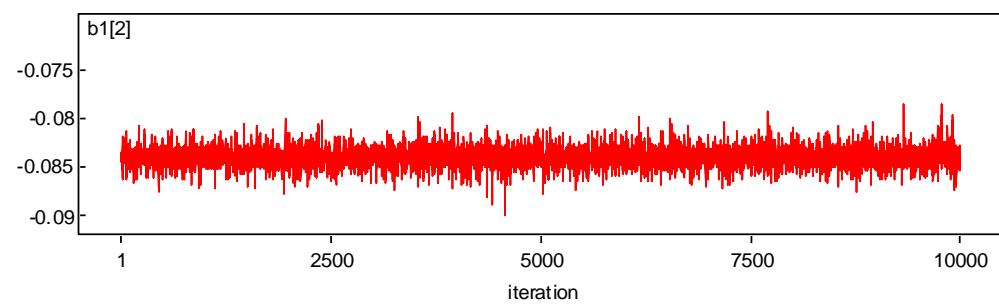
2. Output WinBUGS

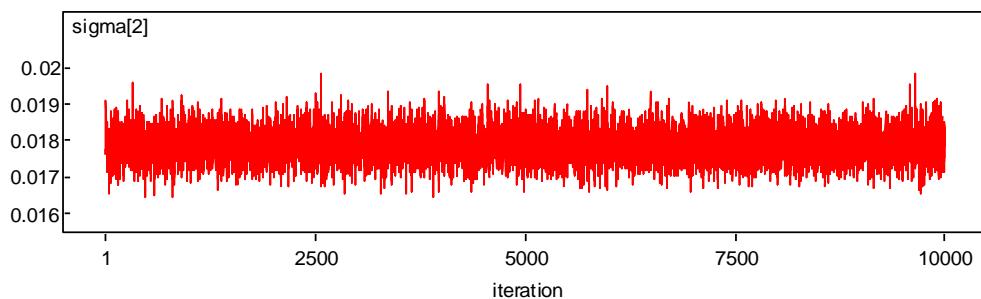
Statistik:

node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5001	0.008538	8.902E-5	0.4834	0.5001	0.5165	1	10000
P[2]	0.4999	0.008538	8.902E-5	0.4835	0.4999	0.5166	1	10000
b1[1]	-0.09512	8.304E-4	8.431E-6	-0.09687	-0.09514	-0.09334	1	10000
b1[2]	-0.08406	8.315E-4	8.985E-6	-0.08577	-0.08411	-0.08222	1	10000
b2[1]	-0.08391	0.001439	1.377E-5	-0.08672	-0.08402	-0.08069	1	10000
b2[2]	-0.07629	0.001417	1.534E-5	-0.07911	-0.0764	-0.07312	1	10000
sigma[1]	0.01789	4.334E-4	3.66E-6	0.01707	0.01788	0.01876	1	10000
sigma[2]	0.01787	4.327E-4	4.104E-6	0.01704	0.01786	0.01875	1	10000

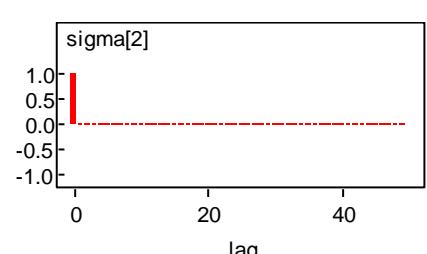
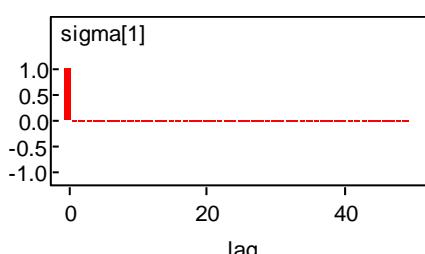
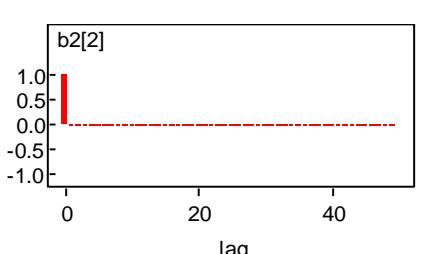
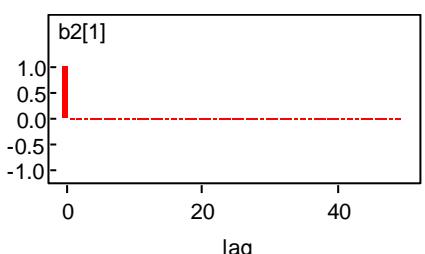
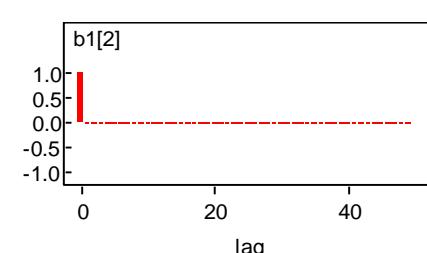
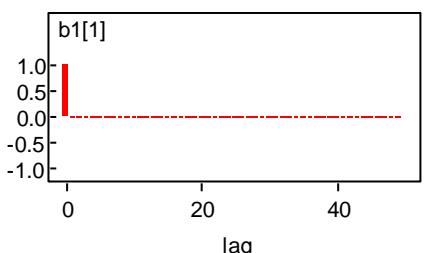
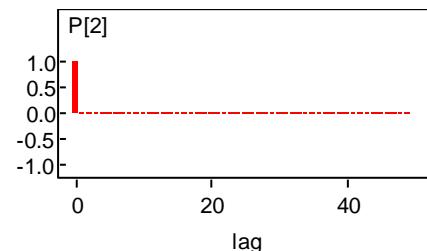
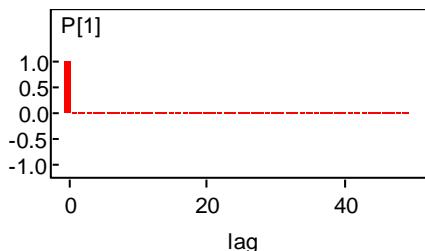
History:



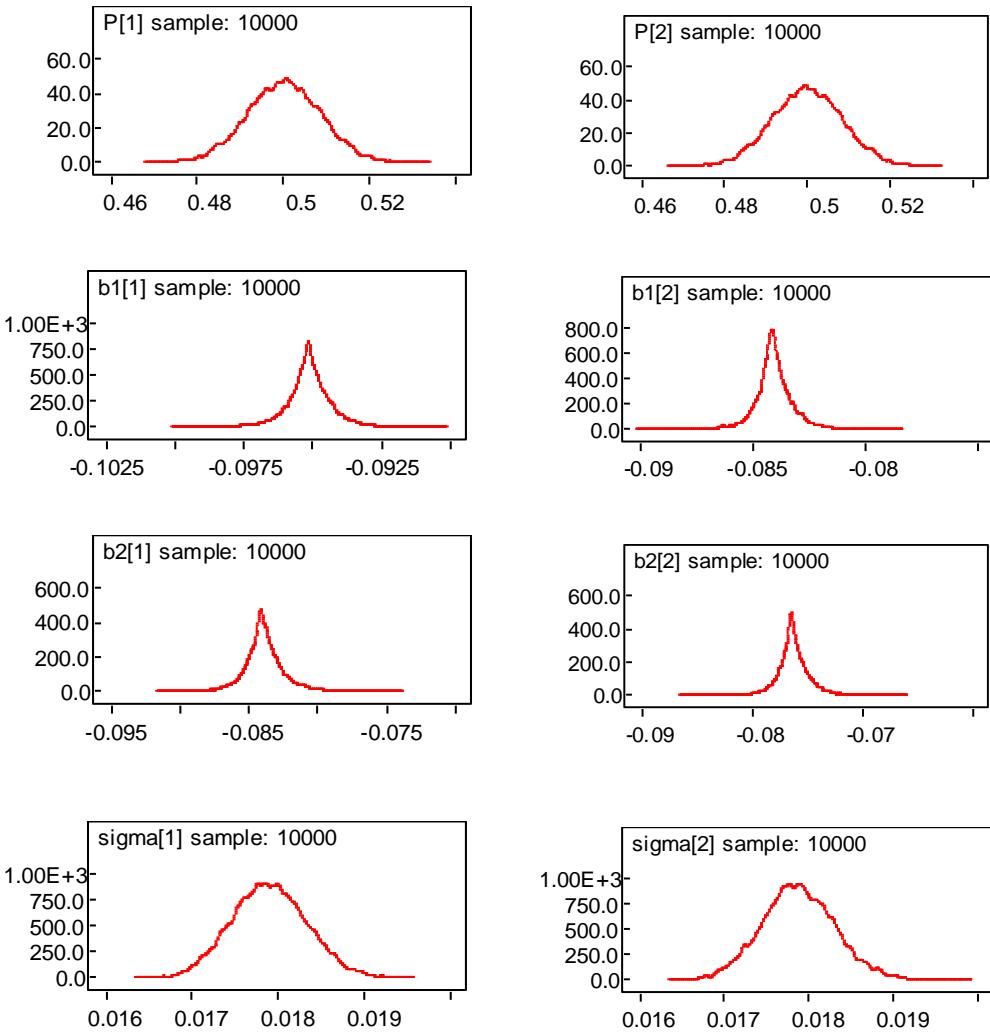




Autokorelasi:



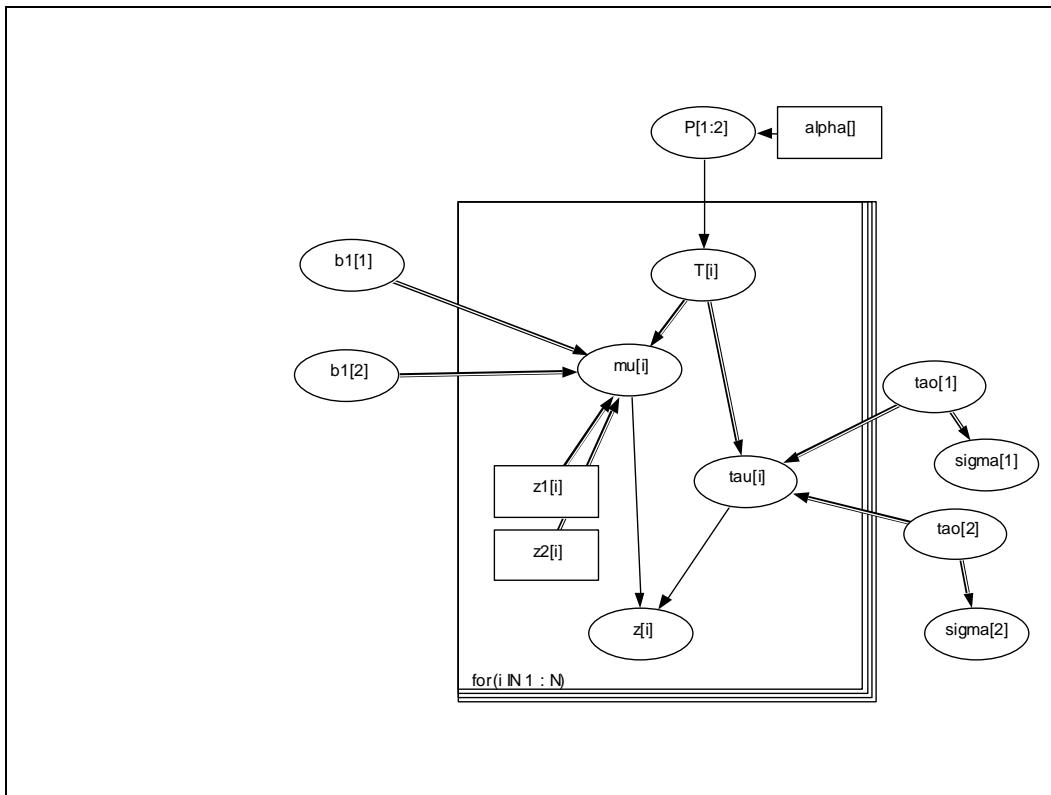
Density:



Lampiran G TLKM MLAR(2;[2],[3])

1. Doodle dan code WinBUGS

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ ddexp(-0.09308,1715.0)
  b1[2] ~ ddexp(-0.08148,1712.0)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
}

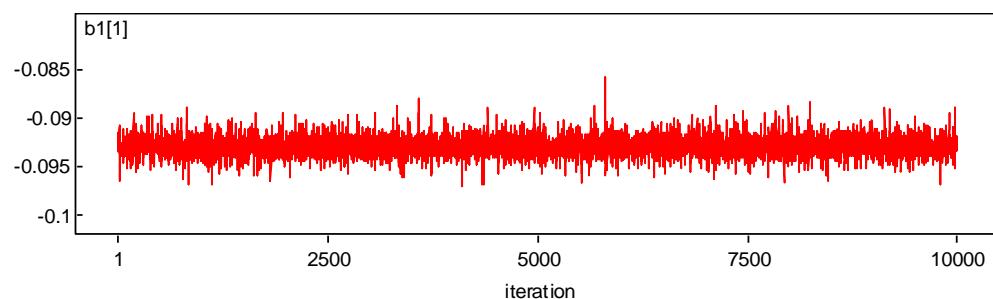
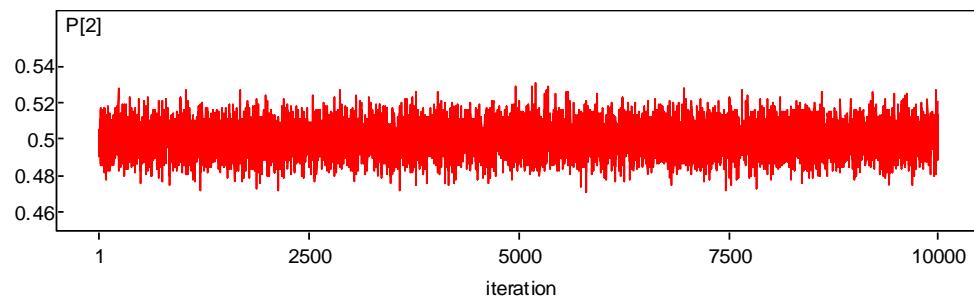
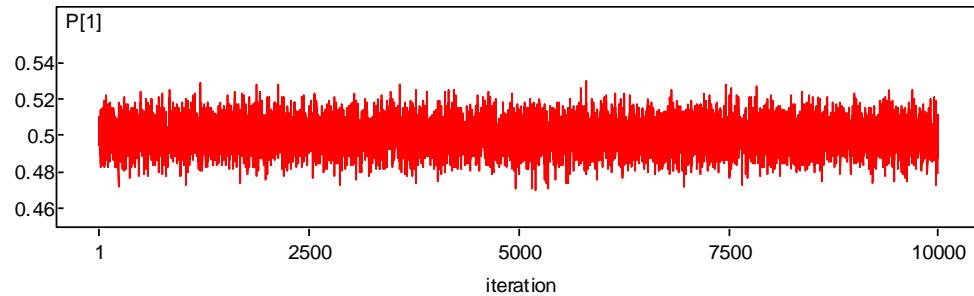
```

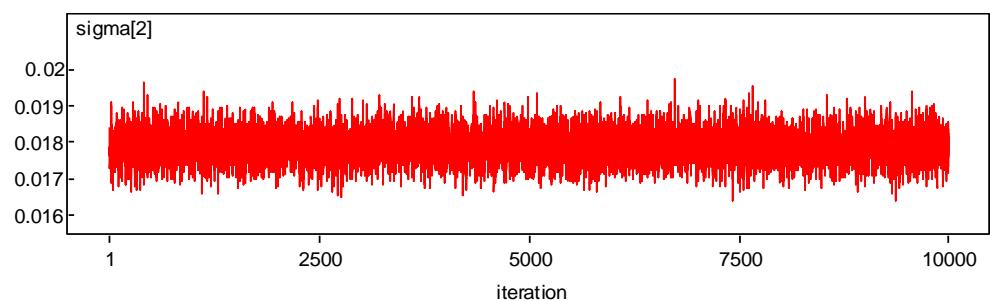
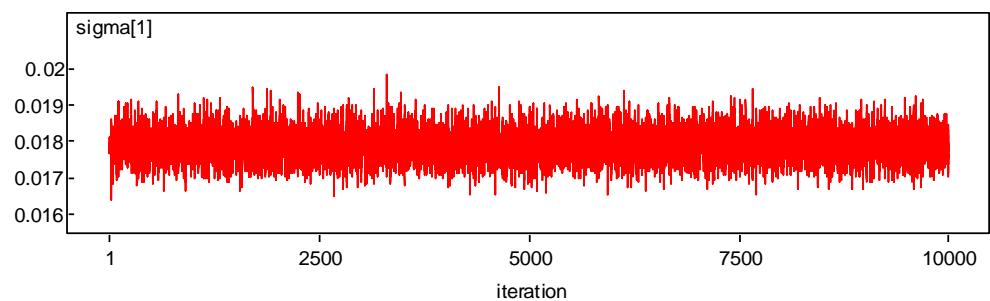
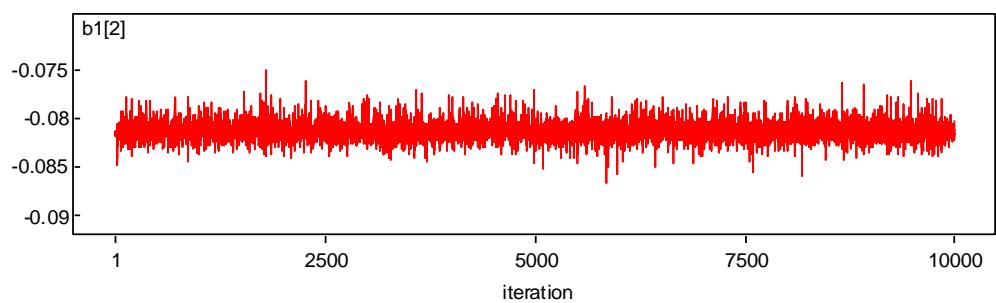
2. Output WinBUGS

Statistik:

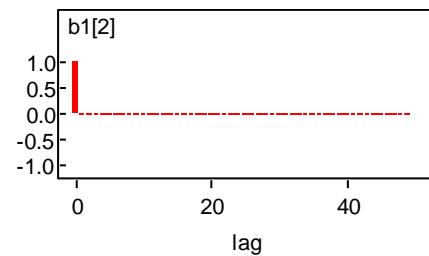
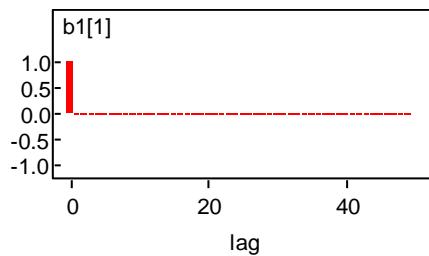
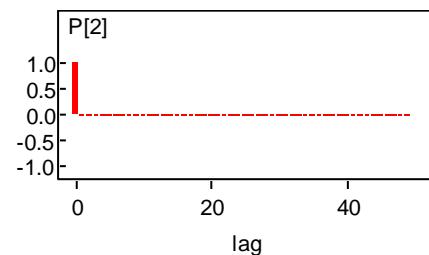
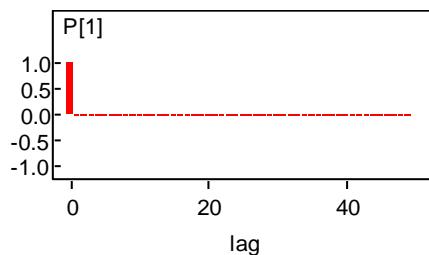
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5	0.00847	7.953E-5	0.4834	0.5001	0.5165	1	10000
P[2]	0.5	0.00847	7.953E-5	0.4835	0.4999	0.5166	1	10000
b1[1]	-0.09297	8.333E-4	7.697E-6	-0.09462	-0.09302	-0.09116	1	10000
b1[2]	-0.08135	8.446E-4	8.868E-6	-0.08297	-0.08141	-0.07945	1	10000
sigma[1]	0.01789	4.307E-4	3.923E-6	0.01708	0.01789	0.01877	1	10000
sigma[2]	0.01788	4.315E-4	4.219E-6	0.01705	0.01788	0.01874	1	10000

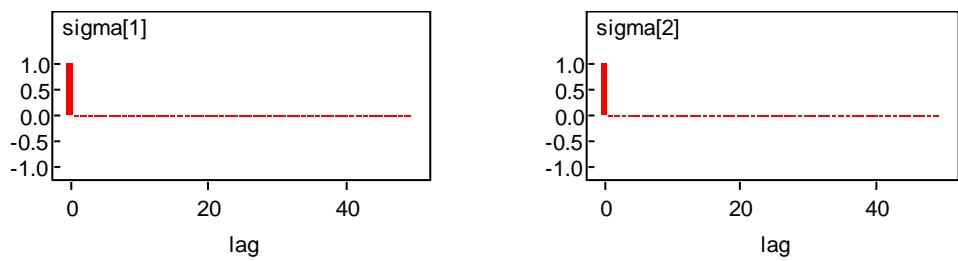
History:



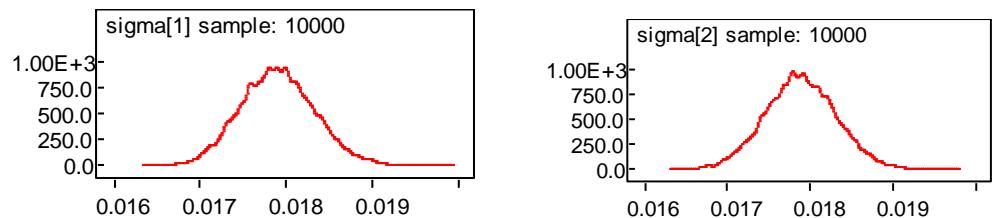
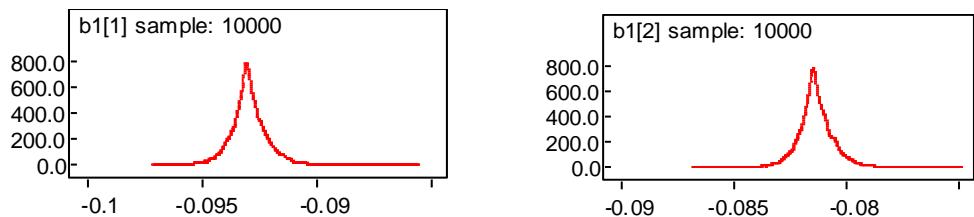
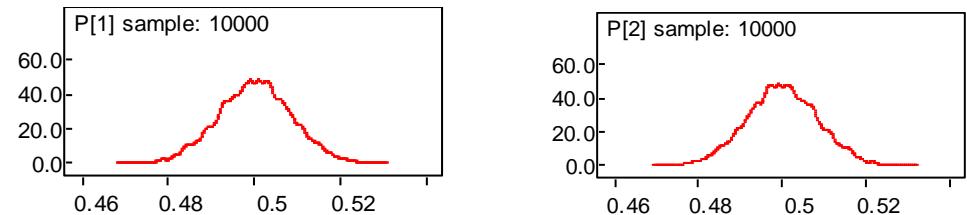


Autokorelasi:





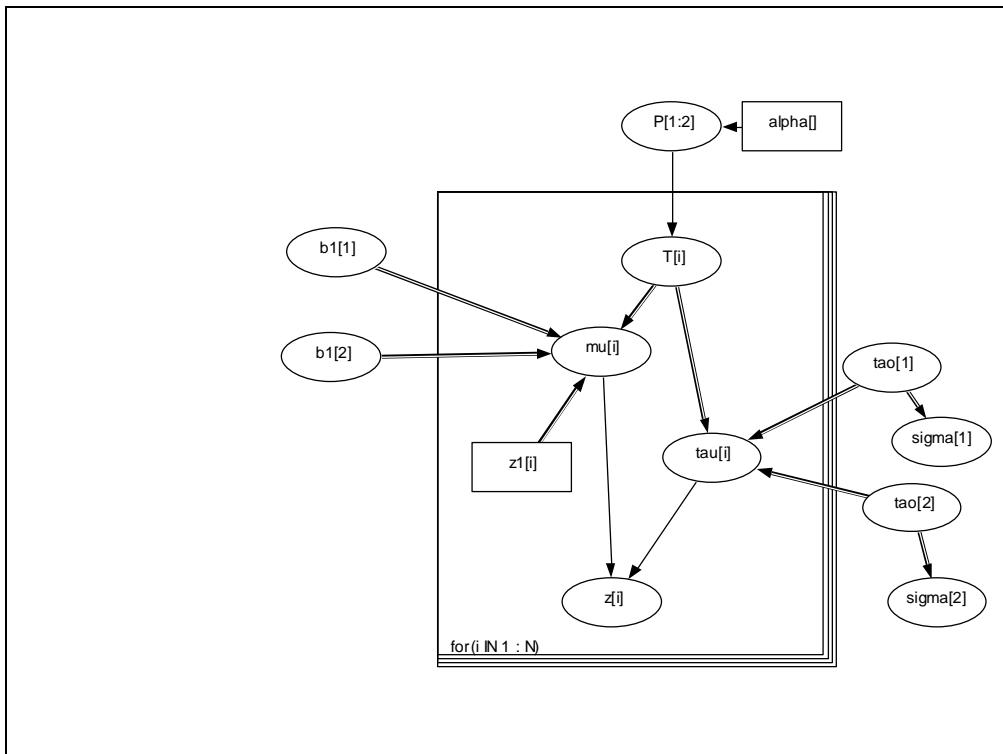
Density:



Lampiran H TLKM MLAR(2;[2],[4])

1. Doodle dan code WinBUGS

Doodle:



Code:

```

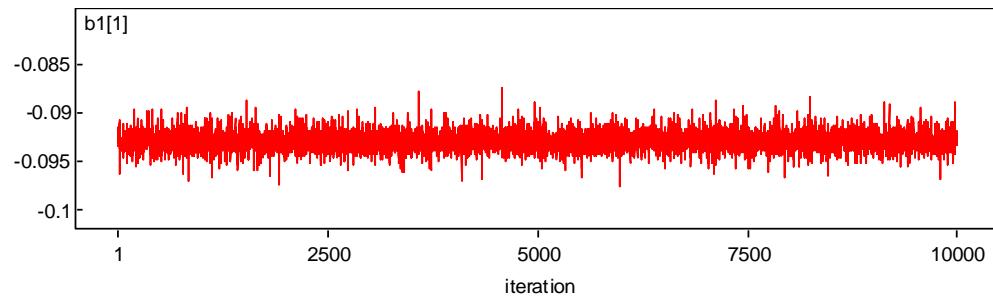
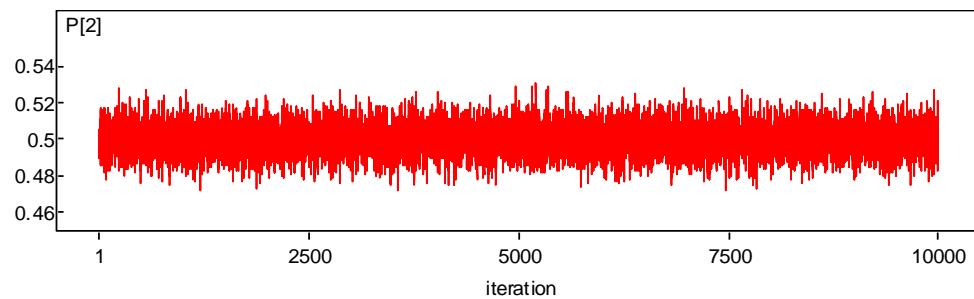
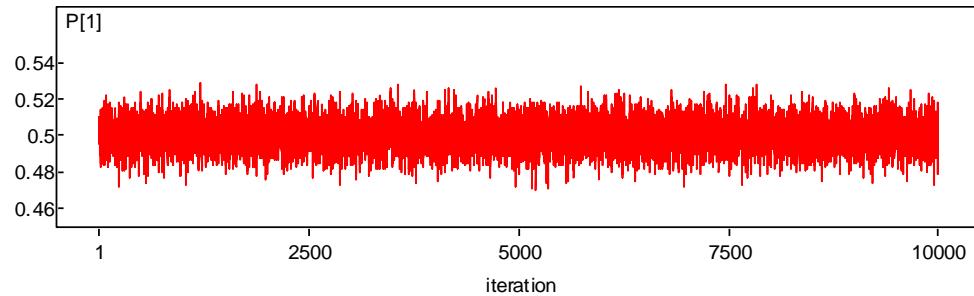
model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(mu[i],tau[i])
  }
  for( i in 1 : N ) {
    mu[i] <- b1[T[i]] * z1[i]
  }
  for( i in 1 : N ) {
    T[i] ~ dcat(P[1:2])
  }
  P[1:2] ~ ddirch(alpha[])
  b1[1] ~ ddexp(-0.09308,1715.0)
  b1[2] ~ ddexp(-0.08269,1578.0)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
}
  
```

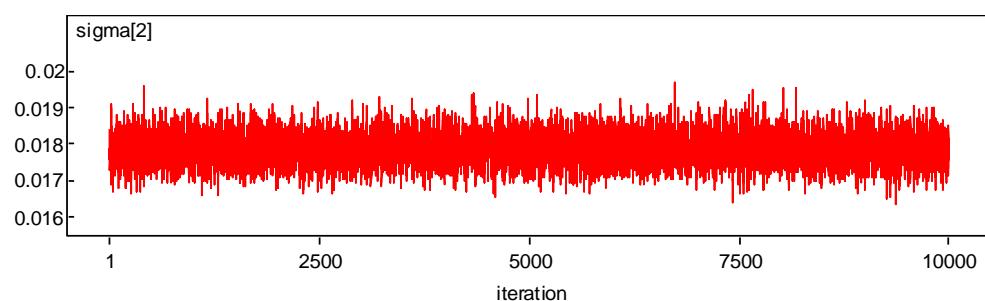
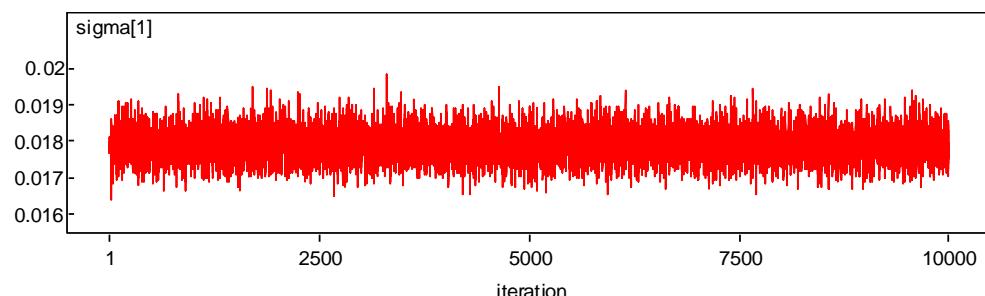
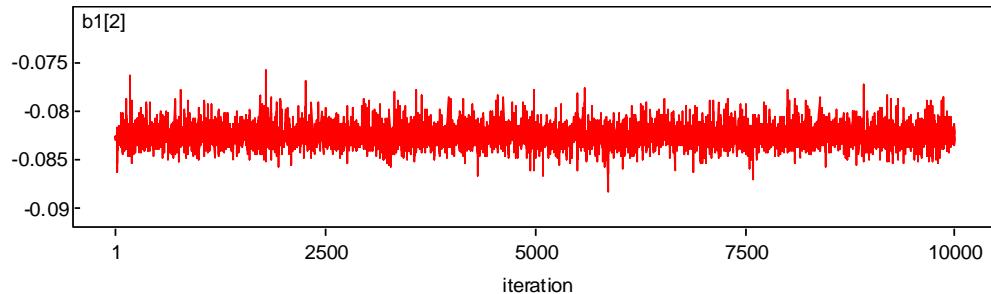
2. Output WinBUGS

Statistik:

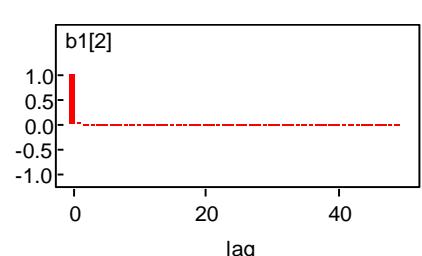
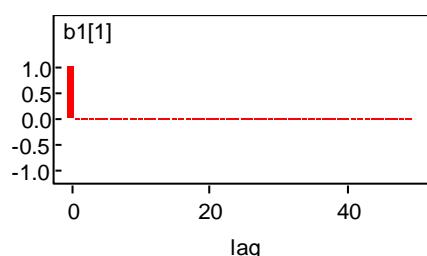
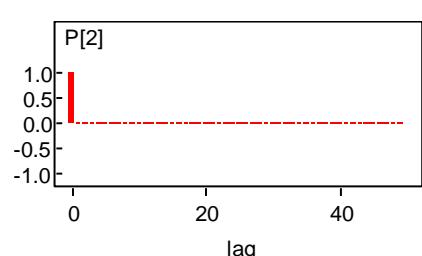
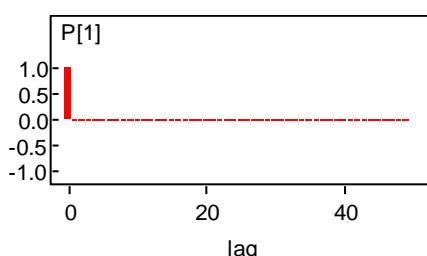
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5002	0.008476	7.521E-5	0.4836	0.5002	0.5166	1	10000
P[2]	0.4998	0.008476	7.521E-5	0.4834	0.4998	0.5164	1	10000
b1[1]	-0.09296	8.21E-4	7.657E-6	-0.09458	-0.09301	-0.09116	1	10000
b1[2]	-0.08254	9.137E-4	9.951E-6	-0.08429	-0.08261	-0.0805	1	10000
sigma[1]	0.01789	4.312E-4	4.318E-6	0.01707	0.01788	0.01877	1	10000
sigma[2]	0.01787	4.291E-4	3.788E-6	0.01704	0.01786	0.01873	1	10000

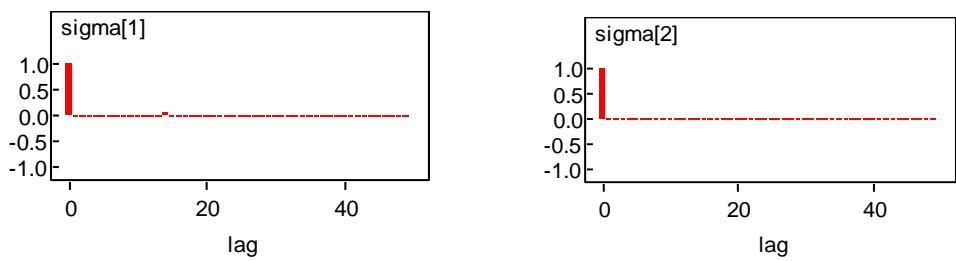
History:



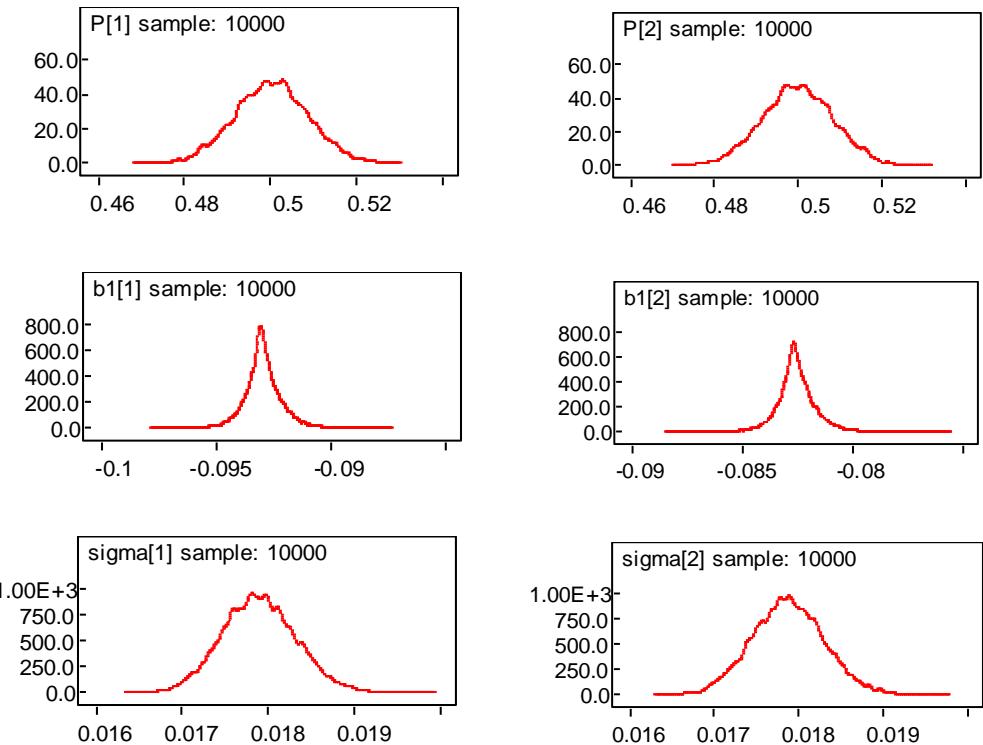


Autokorelasi:





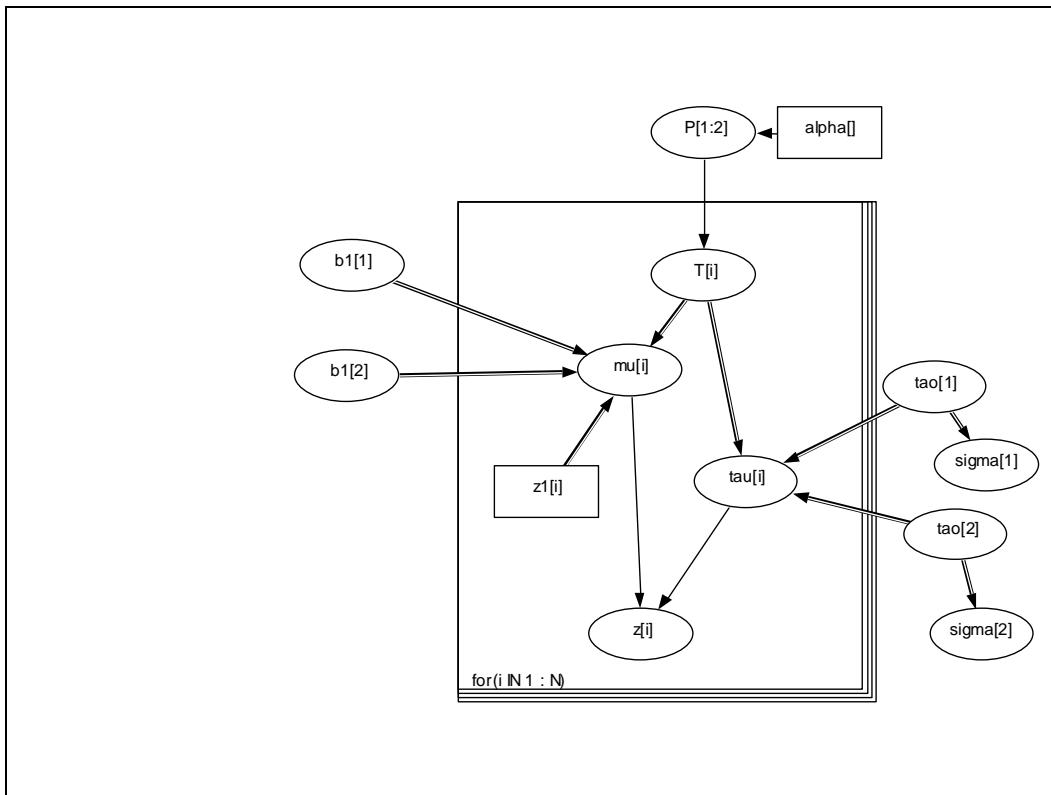
Density:



Lampiran I TLKM MLAR(2;[3],[4])

1. *Doodle* dan *code* WinBUGS

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ ddexp(-0.08148,1712.0)
  b1[2] ~ ddexp(-0.08269,1578.0)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
}

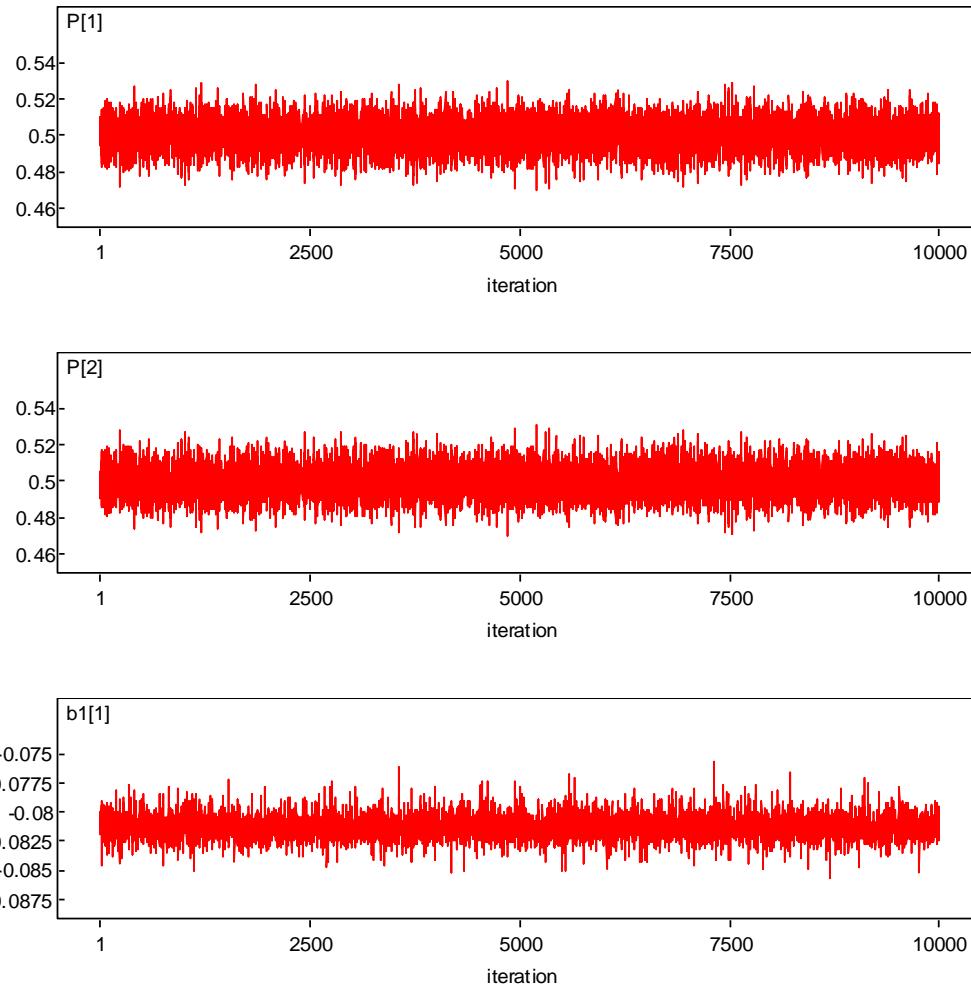
```

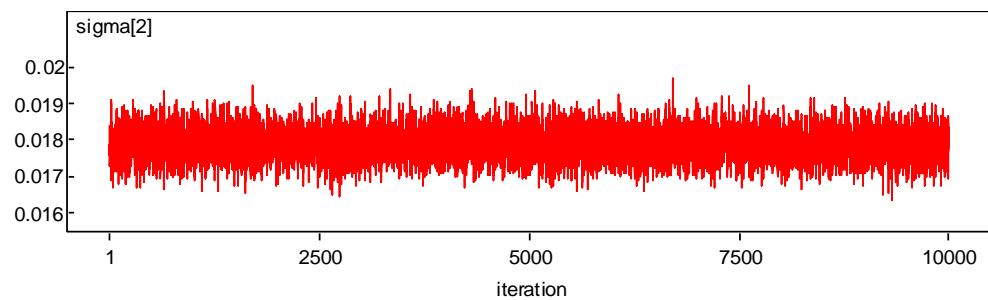
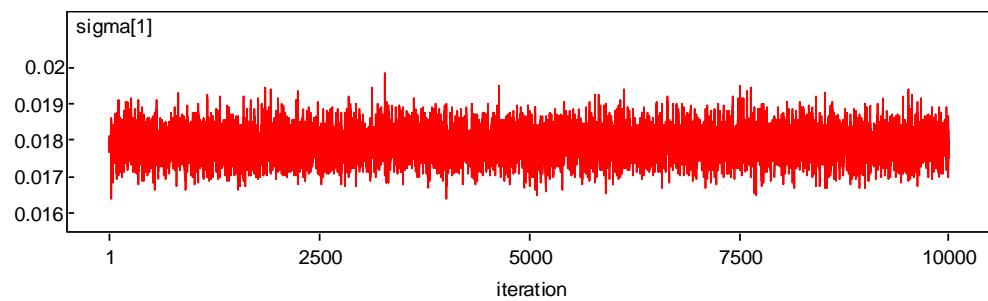
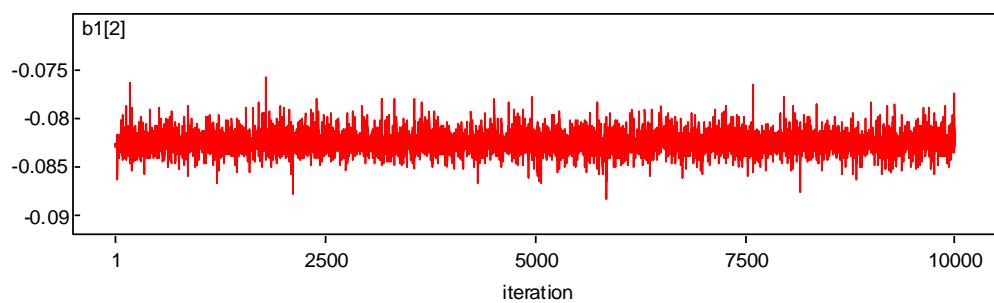
2. Output WinBUGS

Statistik:

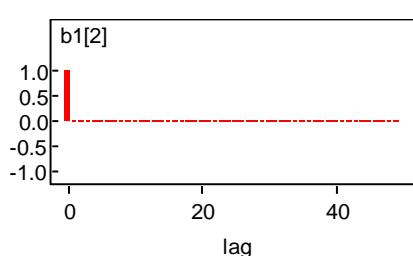
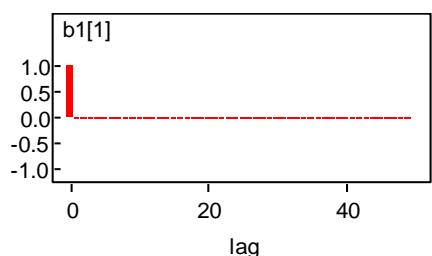
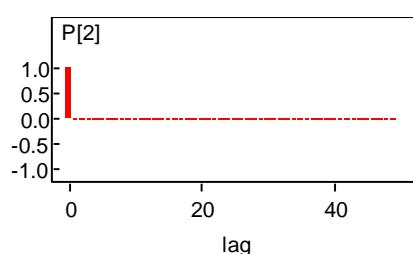
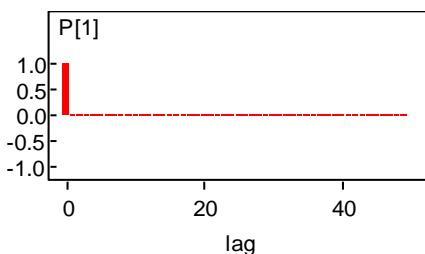
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5002	0.008516	8.922E-5	0.4834	0.5003	0.5167	1	10000
P[2]	0.4998	0.008516	8.922E-5	0.4834	0.4997	0.5166	1	10000
b1[1]	-0.08134	8.374E-4	8.258E-6	-0.08295	-0.0814	-0.07947	1	10000
b1[2]	-0.08254	9.103E-4	9.617E-6	-0.08428	-0.08261	-0.08046	1	10000
sigma[1]	0.01789	4.314E-4	4.406E-6	0.01707	0.01789	0.01876	1	10000
sigma[2]	0.01787	4.292E-4	3.791E-6	0.01704	0.01787	0.01874	1	10000

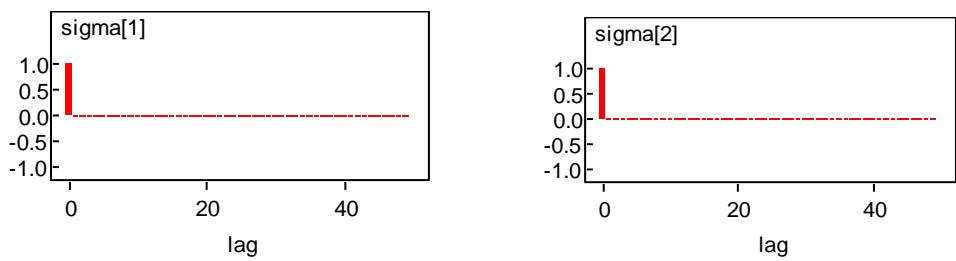
History:



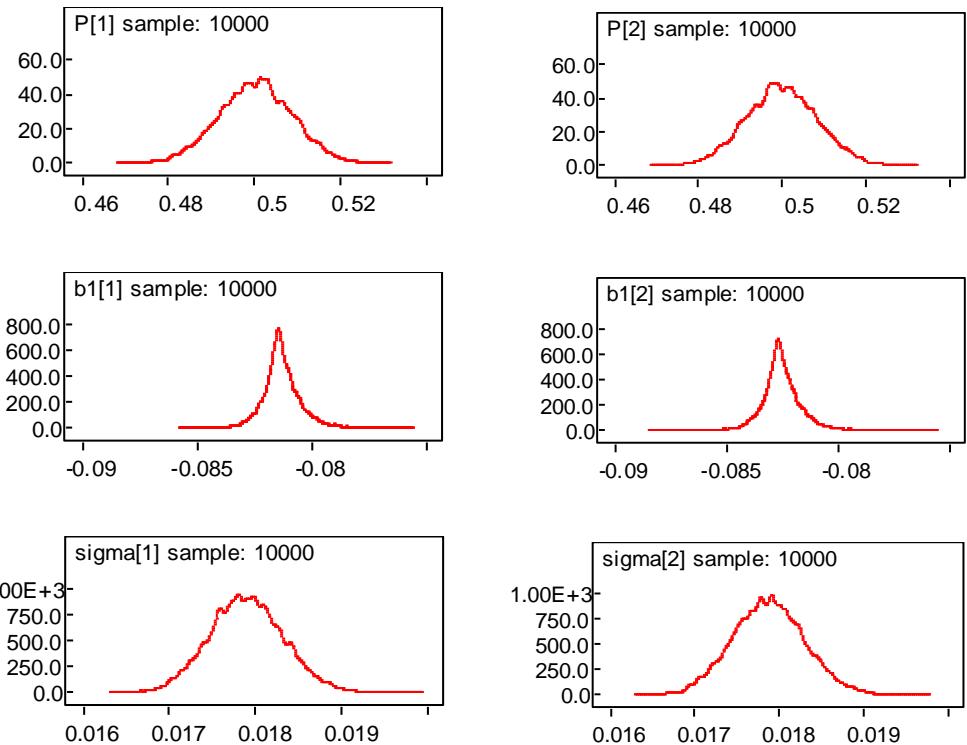


Autokorelasi:





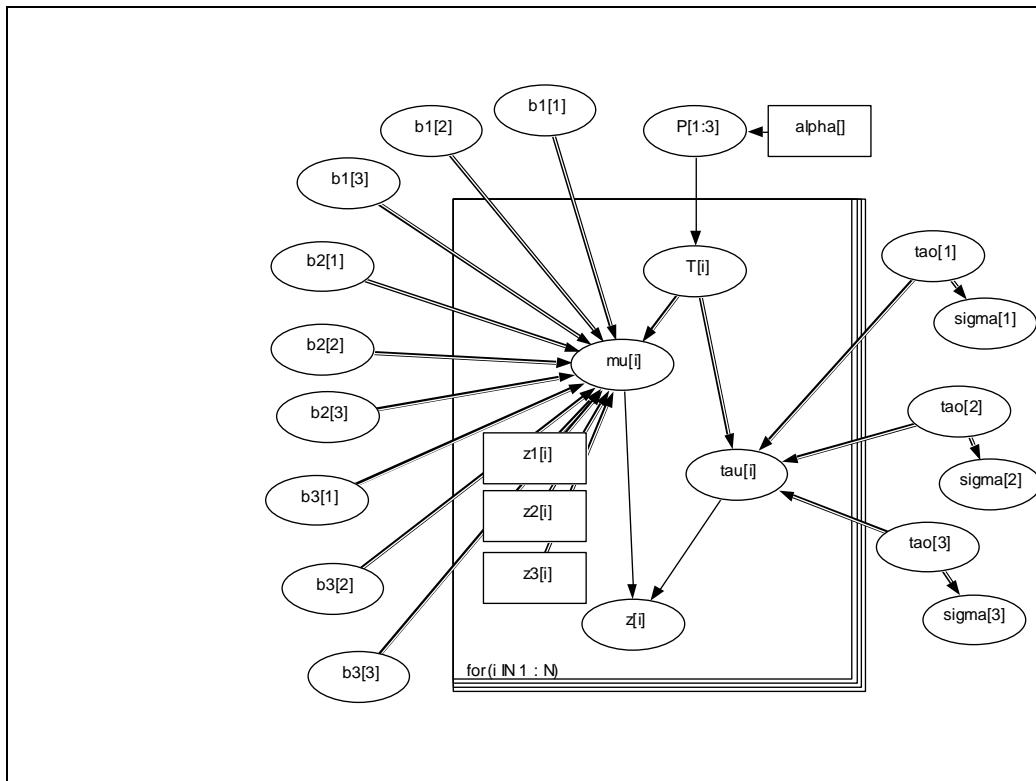
Density:



Lampiran J TLKM MLAR(3;[2,3],[3,4],[2,3,4])

1. Doodle dan code WinBUGS

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ dexp(-0.09518,1720.0)
  b1[2] ~ dexp( 0.0,1.0E-6)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
  b2[1] ~ dexp(-0.08414,0.03157)
  b2[2] ~ dexp(-0.08415,1715.0)
  b1[3] ~ dexp(-0.01031,1740.0)
  b2[3] ~ dexp(-0.08723,992)
  tao[3] ~ dgamma(0.001,0.001)
  sigma[3] <- sqrt(2) / tao[3]
}

```

```

b3[1] ~ ddexp( 0.0,1.0E-6)
b3[2] ~ ddexp(-0.07649,1001.0)
b3[3] ~ ddexp(-0.08644,1003.0)
}

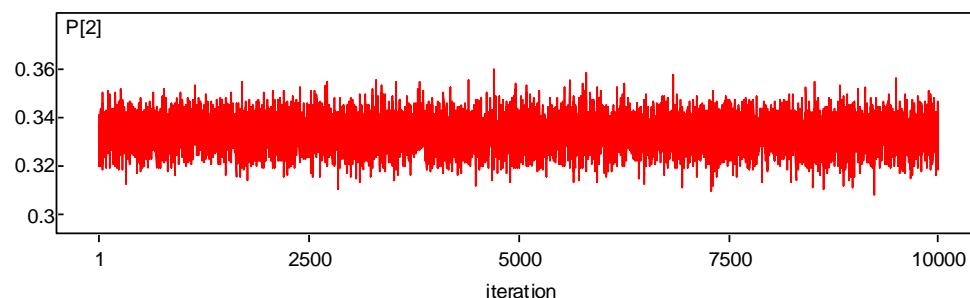
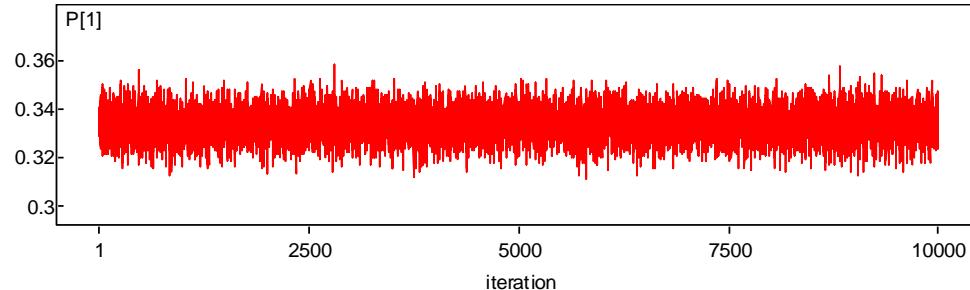
```

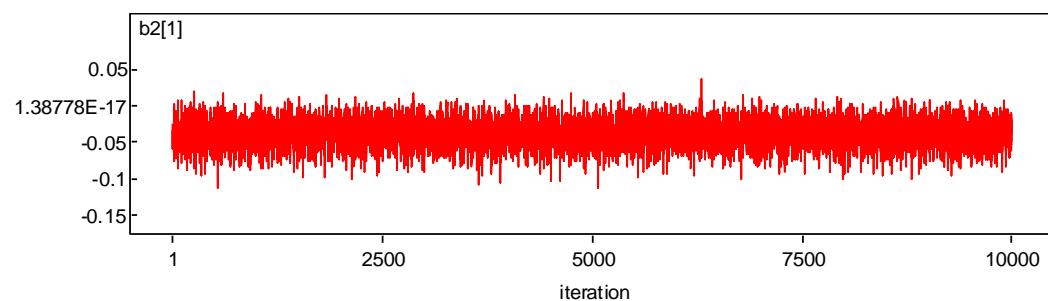
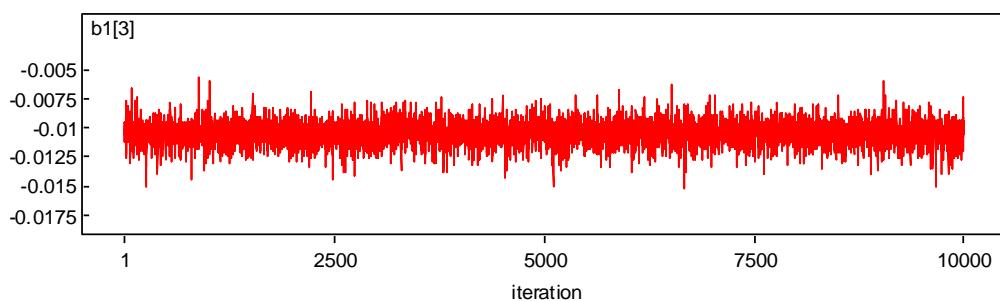
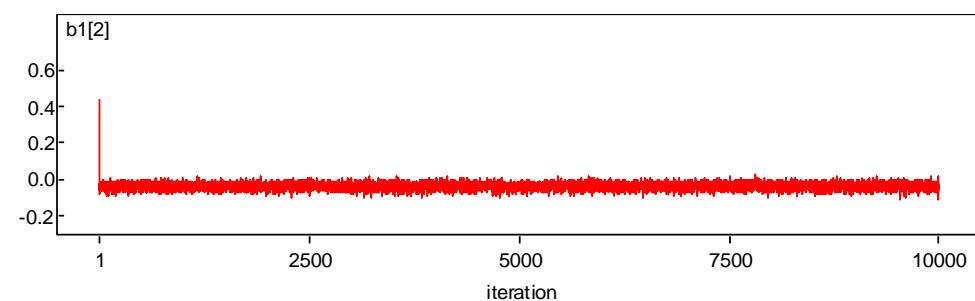
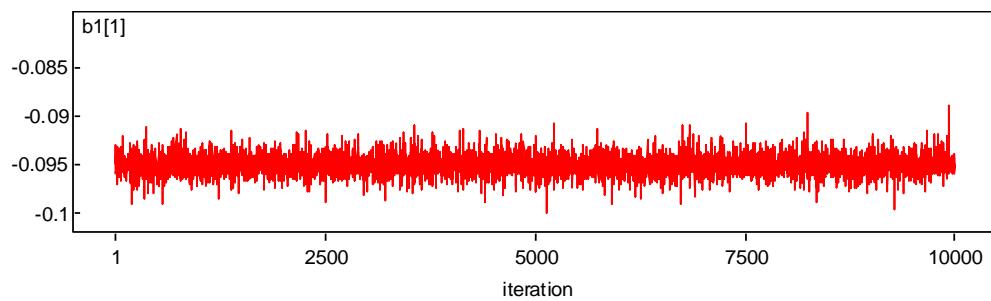
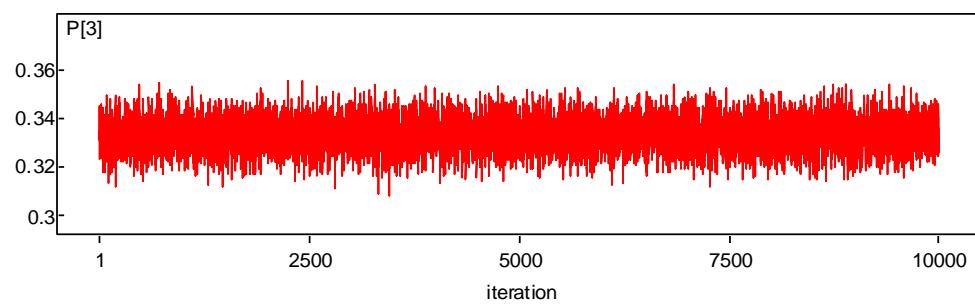
2. Output WinBUGS

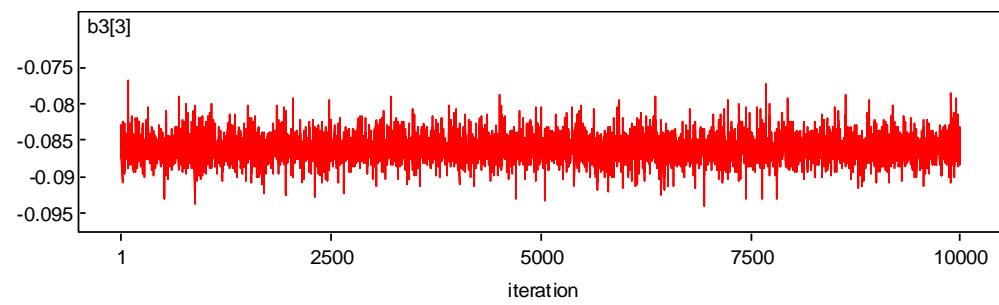
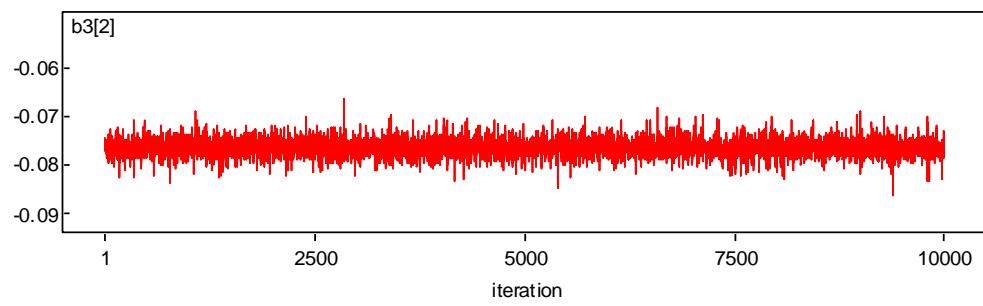
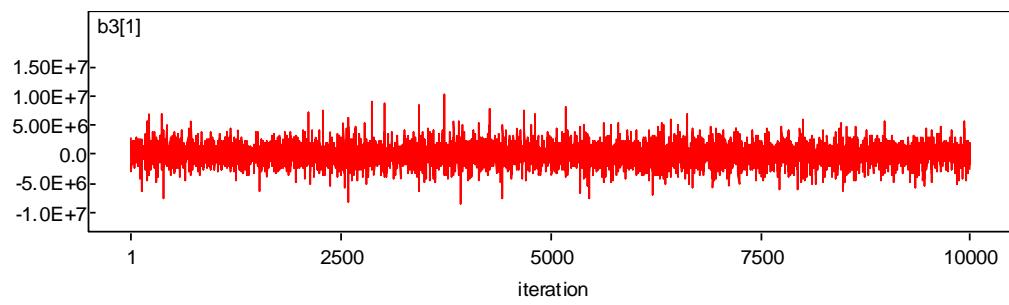
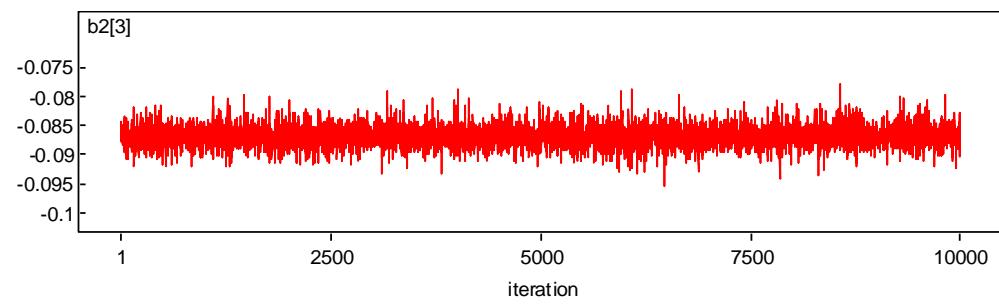
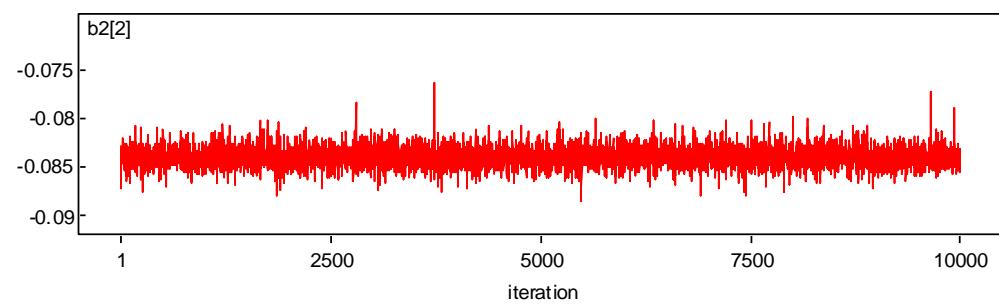
Statistik:

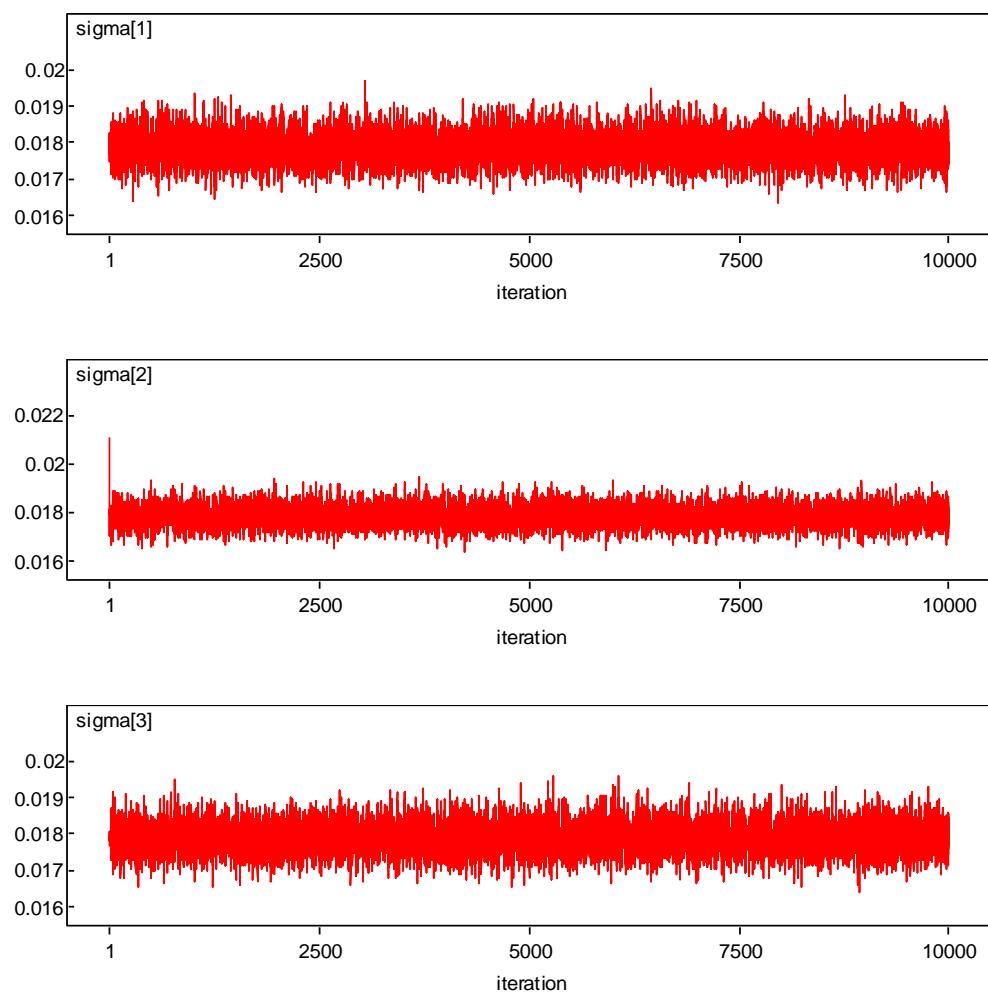
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.3335	0.006557	6.338E-5	0.3206	0.3335	0.3464	1	10000
P[2]	0.3333	0.006634	7.401E-5	0.3203	0.3333	0.346	1	10000
P[3]	0.3332	0.006586	5.782E-5	0.3202	0.3331	0.3464	1	10000
b1[1]	-0.09508	8.202E-4	8.637E-6	-0.09671	-0.09512	-0.09326	1	10000
b1[2]	-0.03812	0.01825	1.659E-4	-0.0751	-0.03772	-0.004926	1	10000
b1[3]	-0.01041	8.199E-4	8.517E-6	-0.01227	-0.01036	-0.008802	1	10000
b2[1]	-0.03814	0.01775	1.955E-4	-0.07478	-0.03778	-0.003755	1	10000
b2[2]	-0.08405	8.268E-4	8.648E-6	-0.08566	-0.0841	-0.0822	1	10000
b2[3]	-0.08699	0.001441	1.311E-5	-0.08986	-0.08708	-0.08377	1	10000
b3[1]	-6092.0	1.425E+6	13530.0	-3.046E+6	-8216.0	2.979E+6	1	10000
b3[2]	-0.07648	0.001435	1.348E-5	-0.0795	-0.07649	-0.07339	1	10000
b3[3]	-0.08622	0.001428	1.418E-5	-0.08899	-0.08633	-0.08298	1	10000
sigma[1]	0.01786	4.329E-4	4.24E-6	0.01703	0.01785	0.01872	1	10000
sigma[2]	0.01786	4.315E-4	4.727E-6	0.01702	0.01785	0.01871	1	10000
sigma[3]	0.01788	4.273E-4	4.137E-6	0.01706	0.01787	0.01873	1	10000

History:

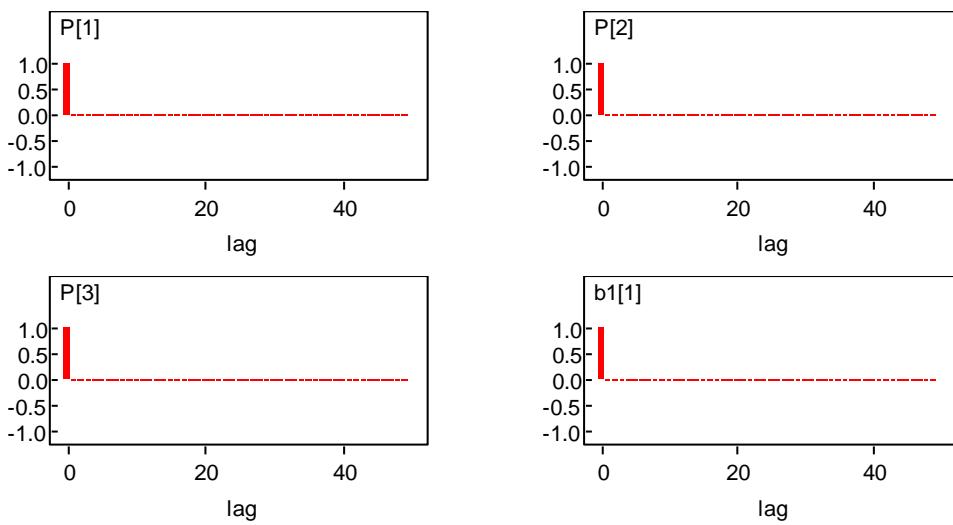


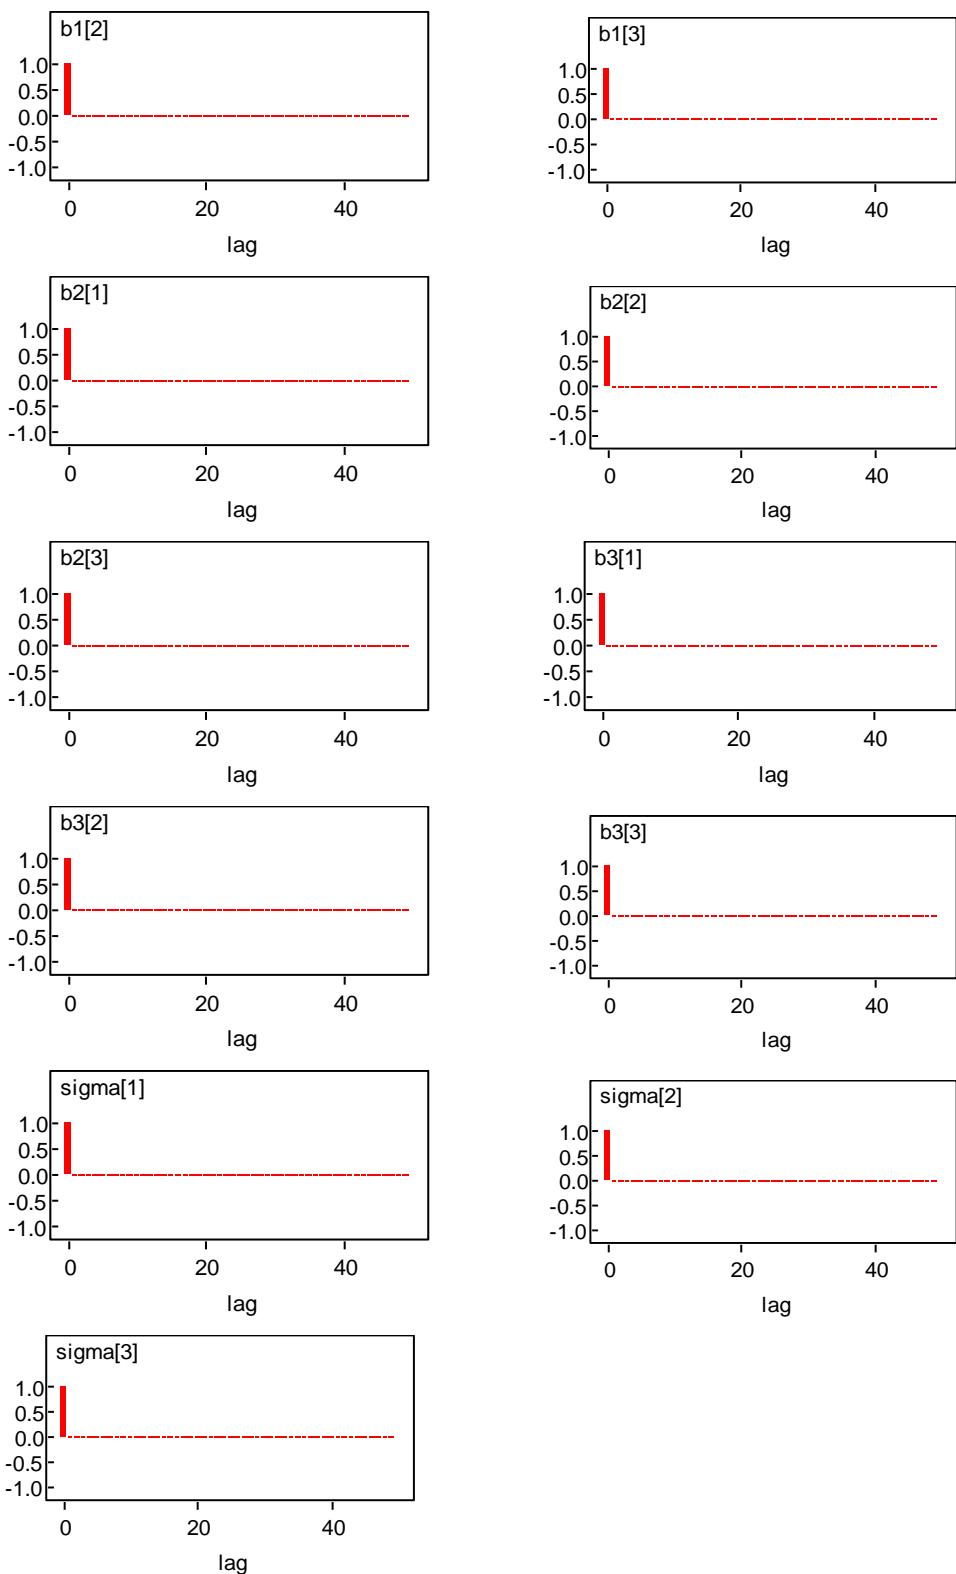




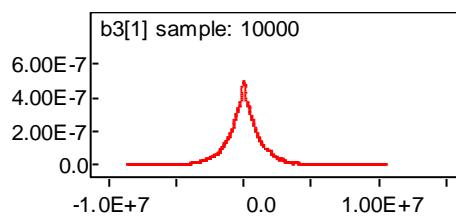
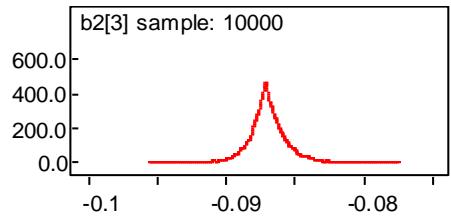
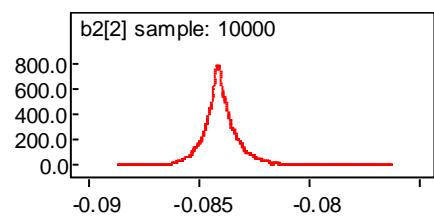
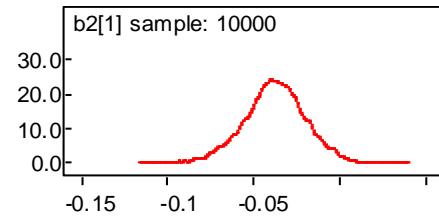
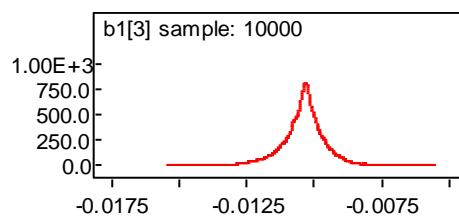
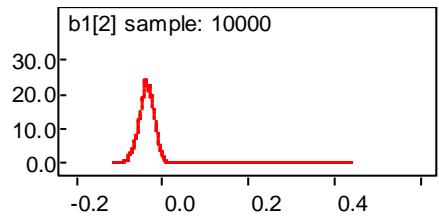
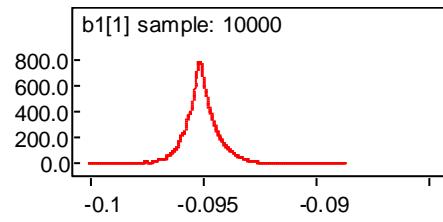
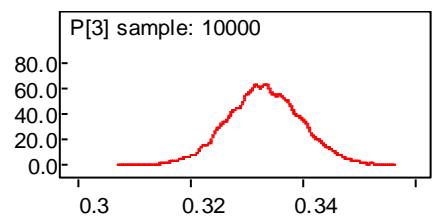
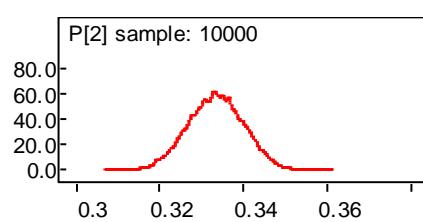
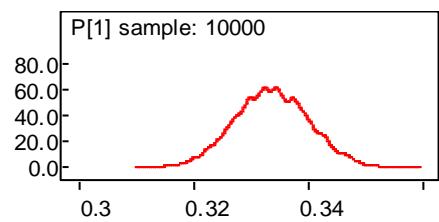


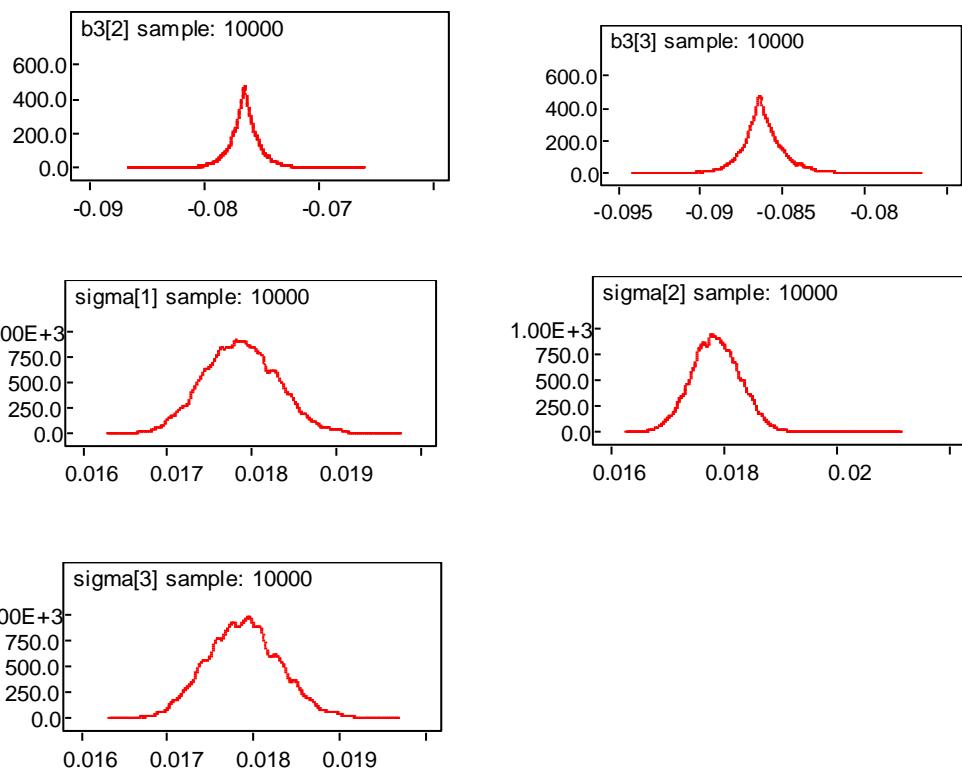
Autokorelasi:





Density:

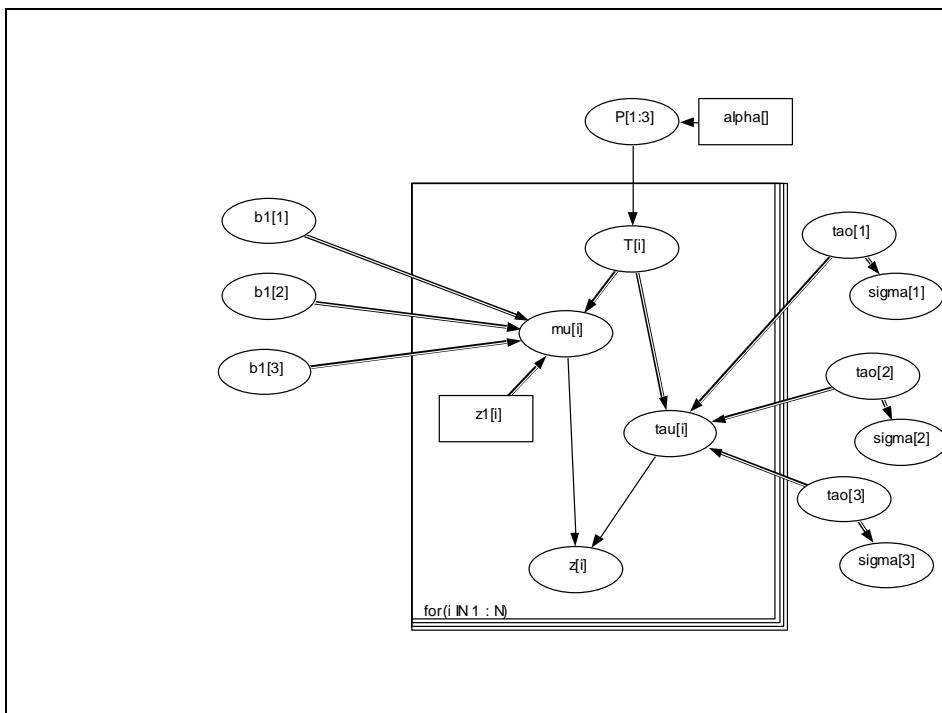




Lampiran K TLKM MLAR(3;[2],[3],[4])

1. Doodle dan code WinBUGS

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ ddexp(-0.09308,1715.0)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
  b1[2] ~ ddexp(-0.08148,1712.0)
  tao[3] ~ dgamma(0.001,0.001)
  sigma[3] <- sqrt(2) / tao[3]
  b1[3] ~ ddexp(-0.08269,1578.0)
}

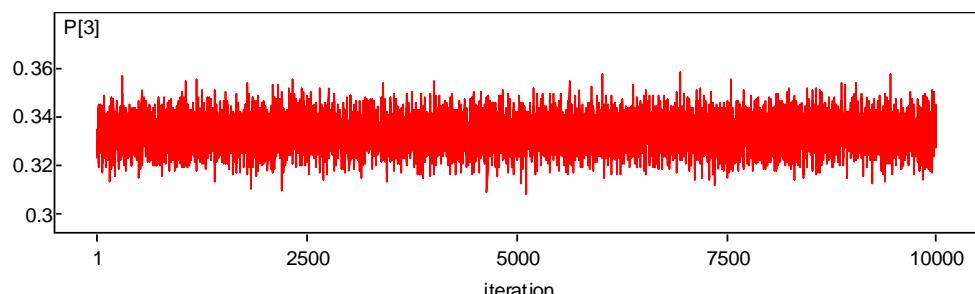
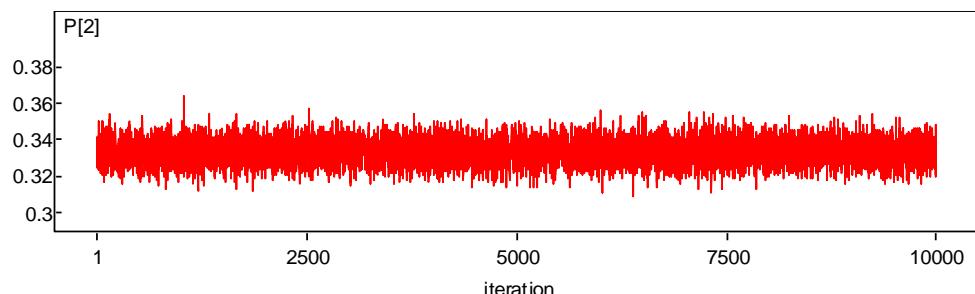
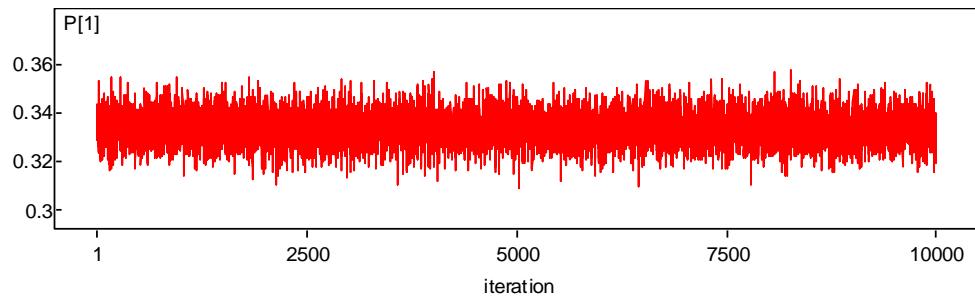
```

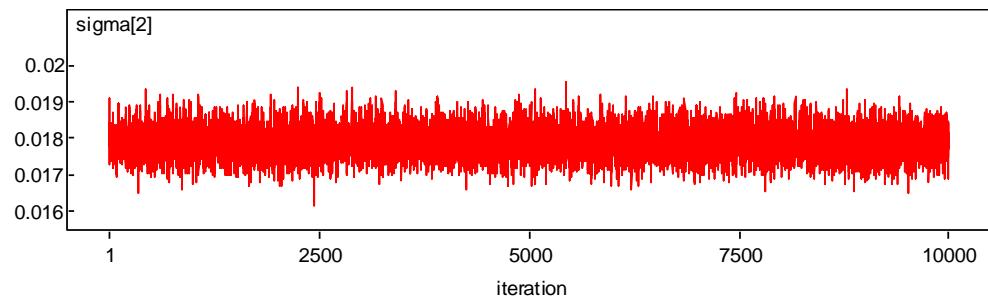
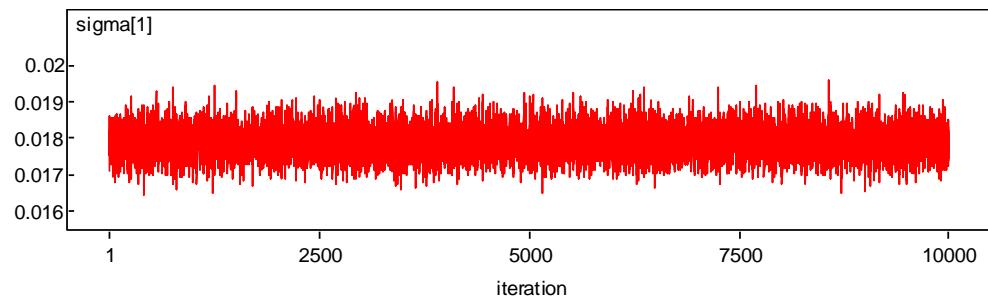
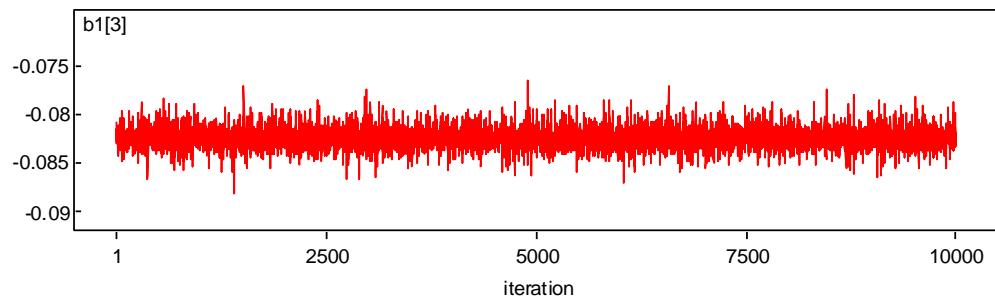
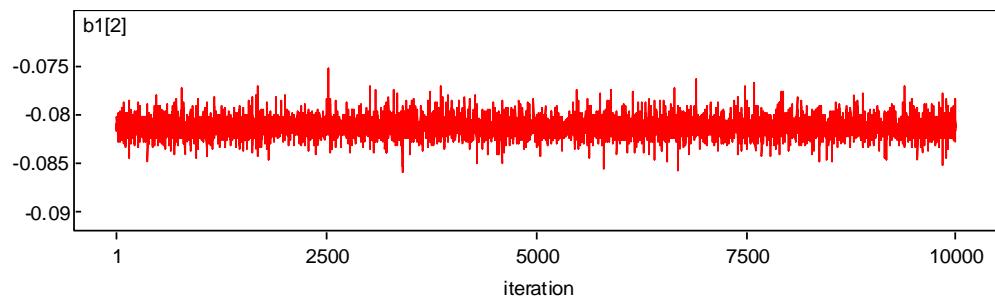
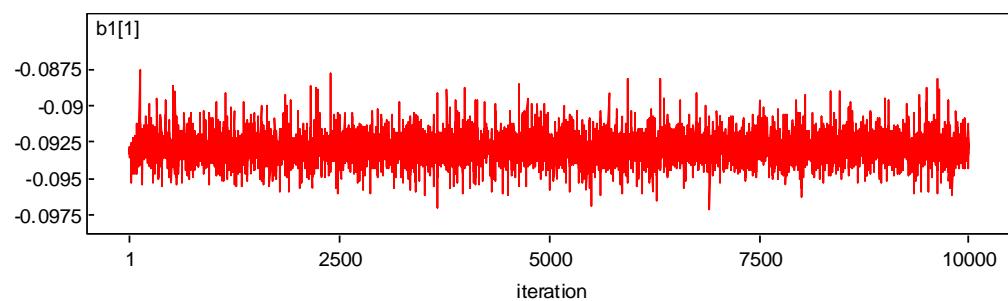
2. Output WinBUGS

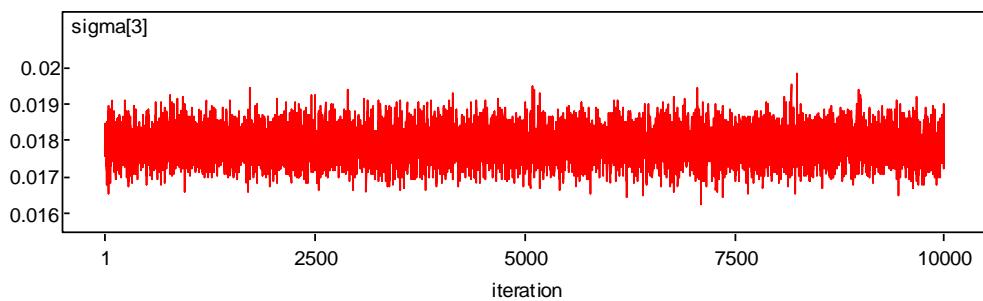
Statistika:

node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.3335	0.006532	6.385E-5	0.321	0.3335	0.3465	1	10000
P[2]	0.3334	0.006641	6.404E-5	0.3205	0.3333	0.3463	1	10000
P[3]	0.3331	0.006595	5.594E-5	0.3203	0.3331	0.3461	1	10000
b1[1]	-0.09297	8.234E-4	9.599E-6	-0.09458	-0.09302	-0.09113	1	10000
b1[2]	-0.08134	8.307E-4	8.461E-6	-0.08295	-0.0814	-0.07948	1	10000
b1[3]	-0.08252	9.225E-4	9.32E-6	-0.08426	-0.0826	-0.0804	1	10000
sigma[1]	0.01789	4.319E-4	4.104E-6	0.01707	0.01788	0.01876	1	10000
sigma[2]	0.01789	4.299E-4	4.313E-6	0.01706	0.01788	0.01875	1	10000
sigma[3]	0.01788	4.347E-4	4.019E-6	0.01703	0.01787	0.01876	1	10000

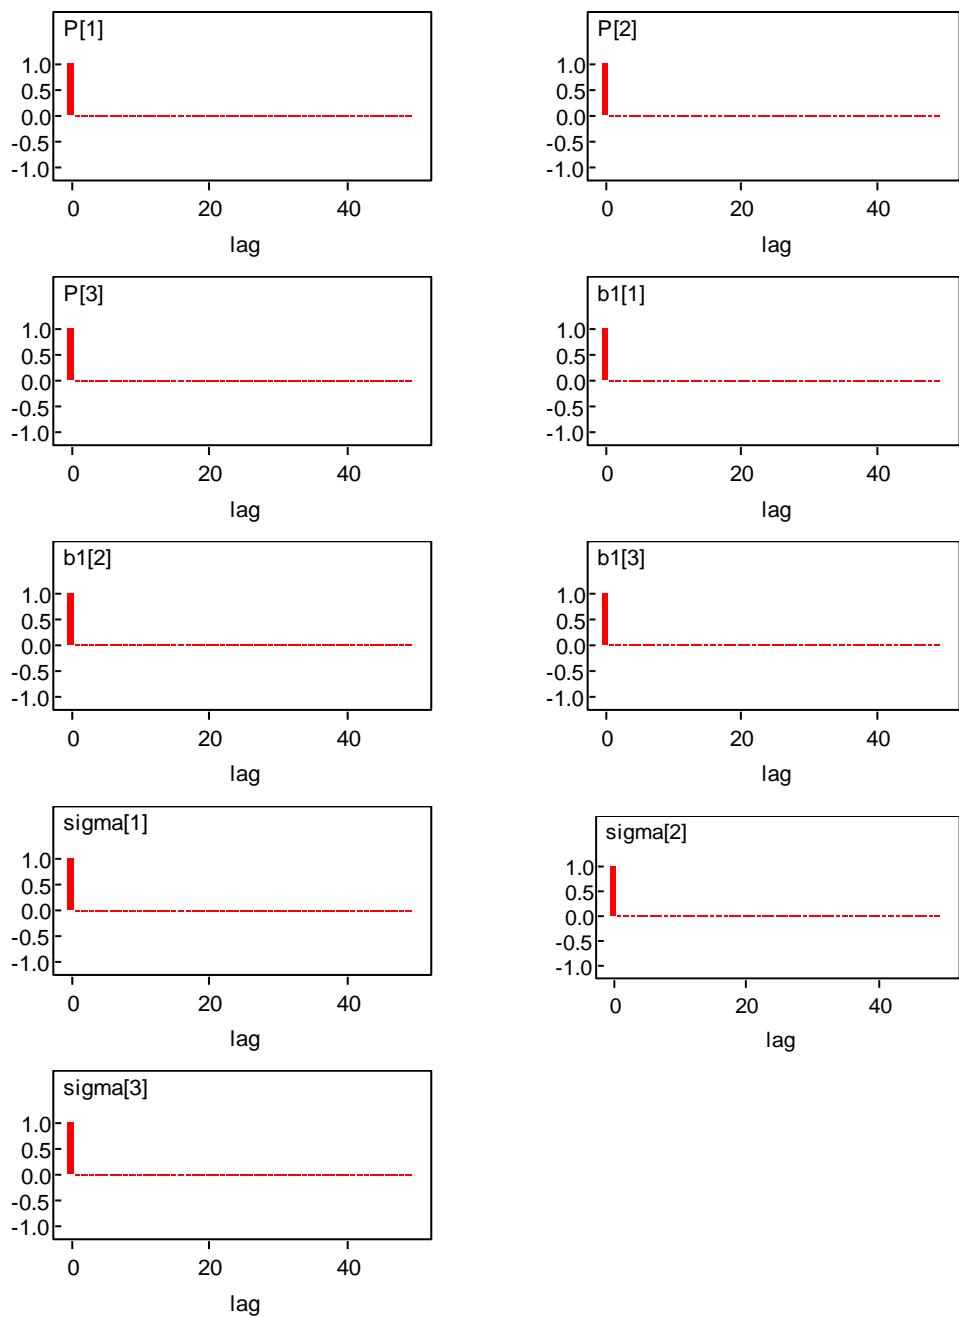
History:



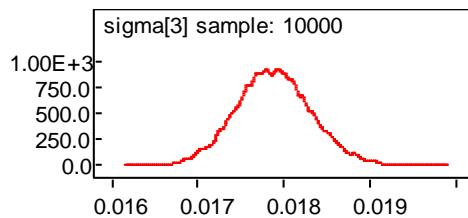
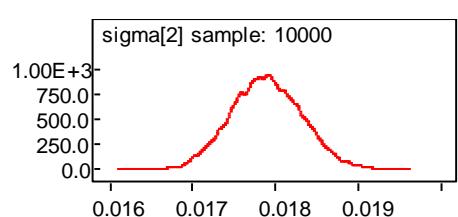
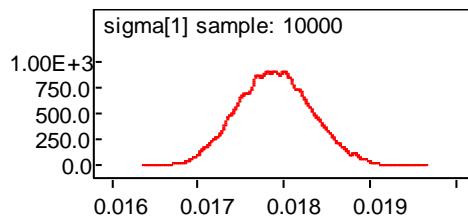
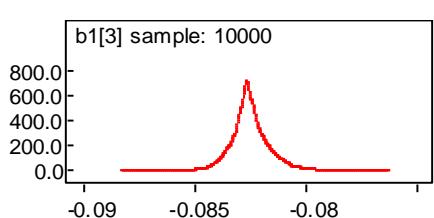
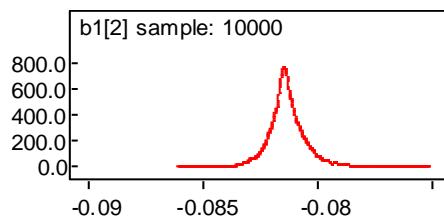
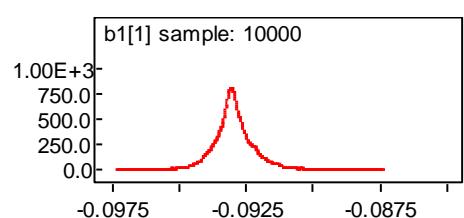
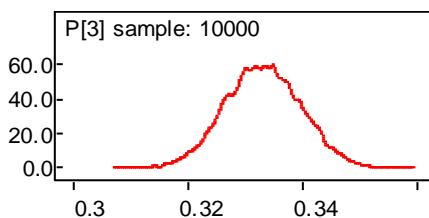
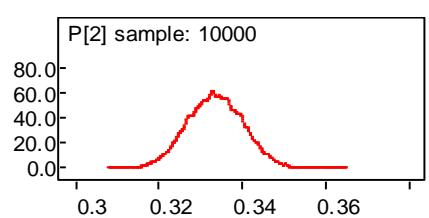
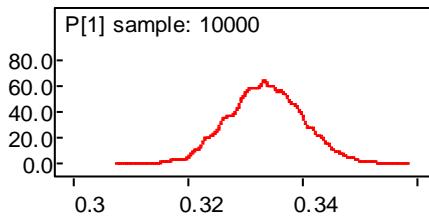




Autokorelasi:



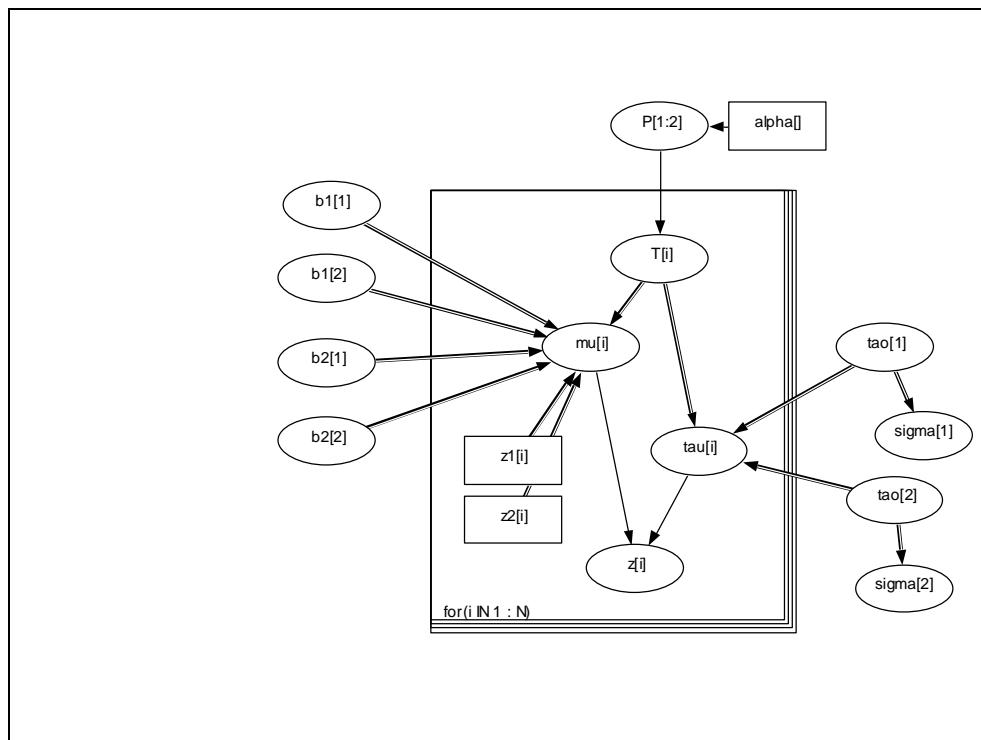
Density:



Lampiran L UNVR MLAR(2;2,[11])

1. *Doodle dan code WinBUGS*

Doodle:



Code:

```

model;
{
  for( i in 1 : N ) {
    z[i] ~ ddexp(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] ~ ddexp(-0.26541,1701.0)
  b1[2] ~ ddexp(0.05798,1715.0)
  tao[2] ~ dgamma(0.001,0.001)
  sigma[2] <- sqrt(2) / tao[2]
  for( i in 1 : N ) {
    tau[i] <- tao[T[i]]
  }
  tao[1] ~ dgamma(0.001,0.001)
  sigma[1] <- sqrt(2) / tao[1]
  b2[1] ~ ddexp(-0.09637,1316.0)
  b2[2] ~ ddexp( 0.0,1.0E-6)
}

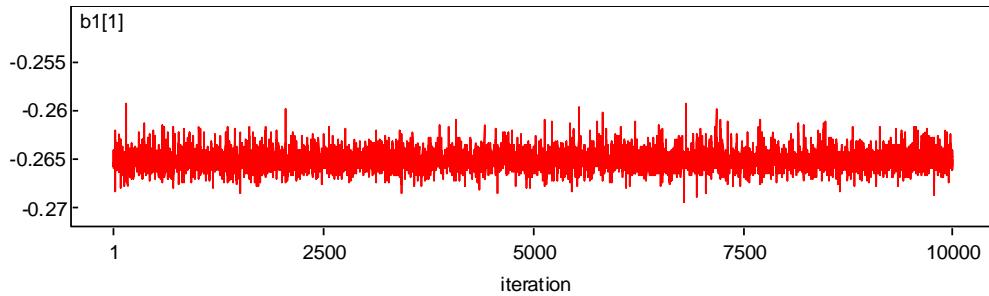
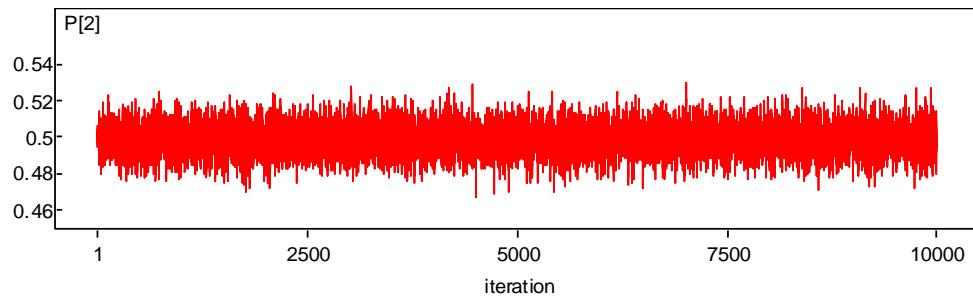
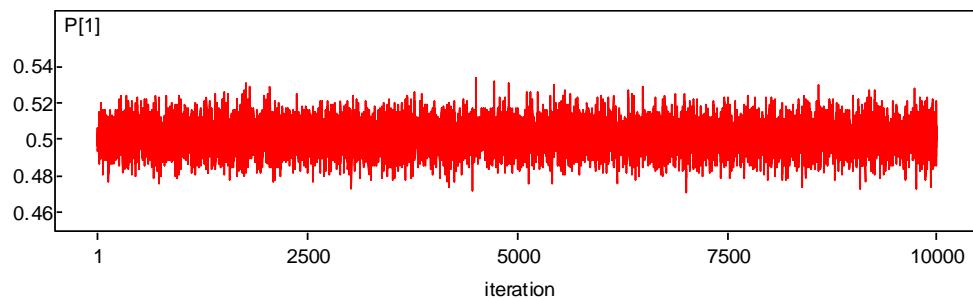
```

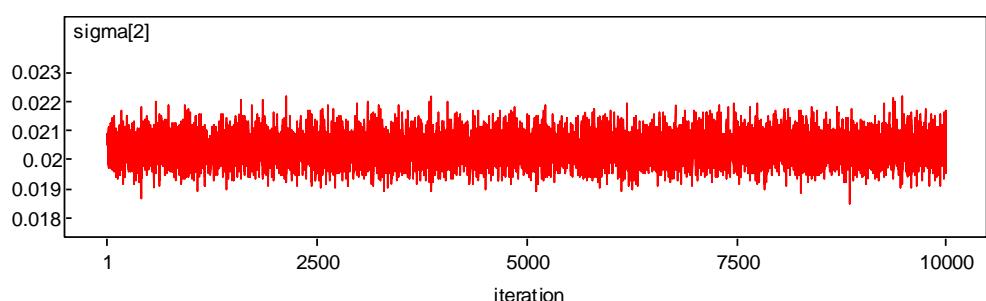
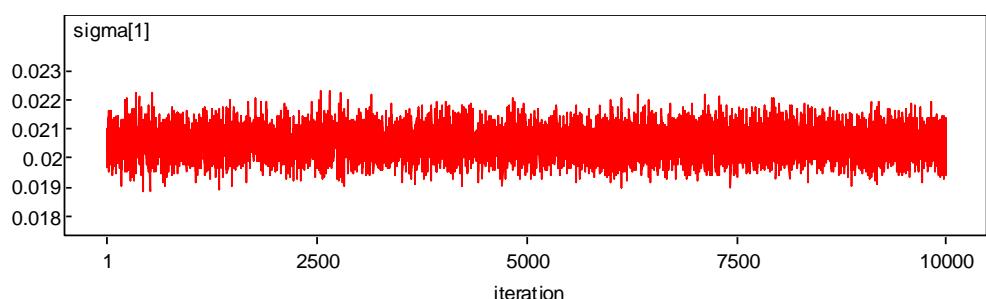
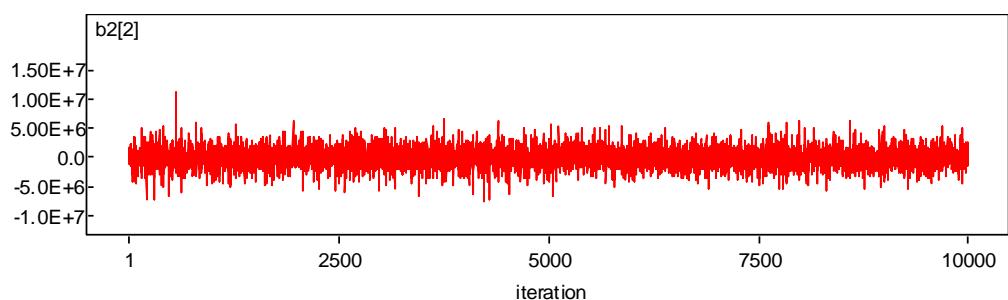
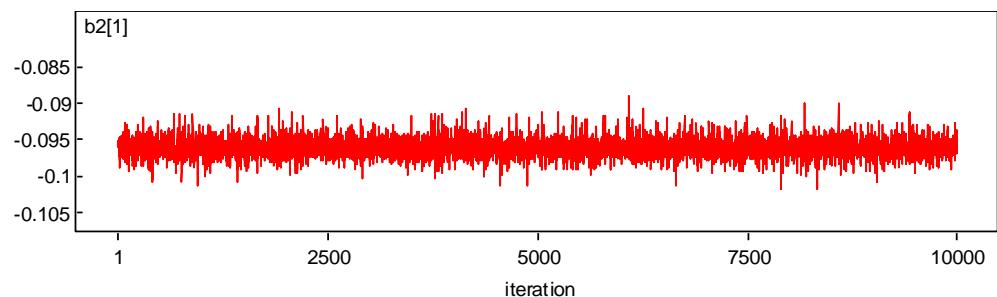
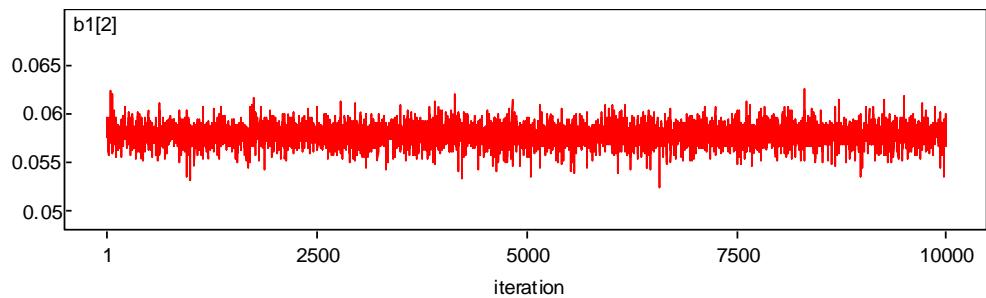
2. Output WinBUGS

Statistika:

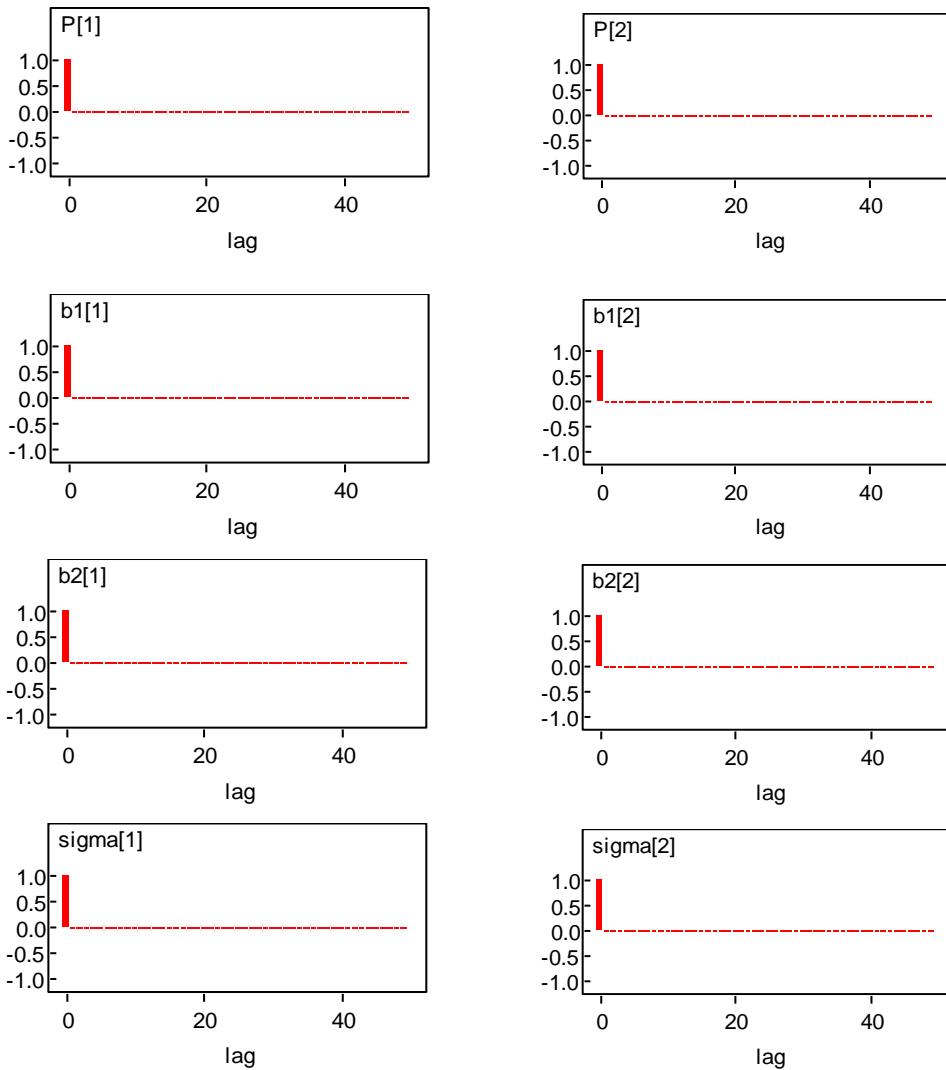
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.5014	0.008547	9.385E-5	0.4848	0.5013	0.518	1	10000
P[2]	0.4986	0.008547	9.385E-5	0.4821	0.4987	0.5152	1	10000
b1[1]	-0.2652	8.667E-4	9.641E-6	-0.2668	-0.2653	-0.2631	1	10000
b1[2]	0.05787	8.409E-4	9.524E-6	0.056	0.05792	0.05955	1	10000
b2[1]	-0.09621	0.001057	9.957E-6	-0.09828	-0.09629	-0.09382	1	10000
b2[2]	10630.0	1.403E+6	14740.0	-3.051E+6	15380.0	2.987E+6	1	10000
sigma[1]	0.02052	4.949E-4	5.031E-6	0.01957	0.02051	0.02151	1	10000
sigma[2]	0.02039	4.901E-4	4.748E-6	0.01945	0.02038	0.02137	1	10000

History:

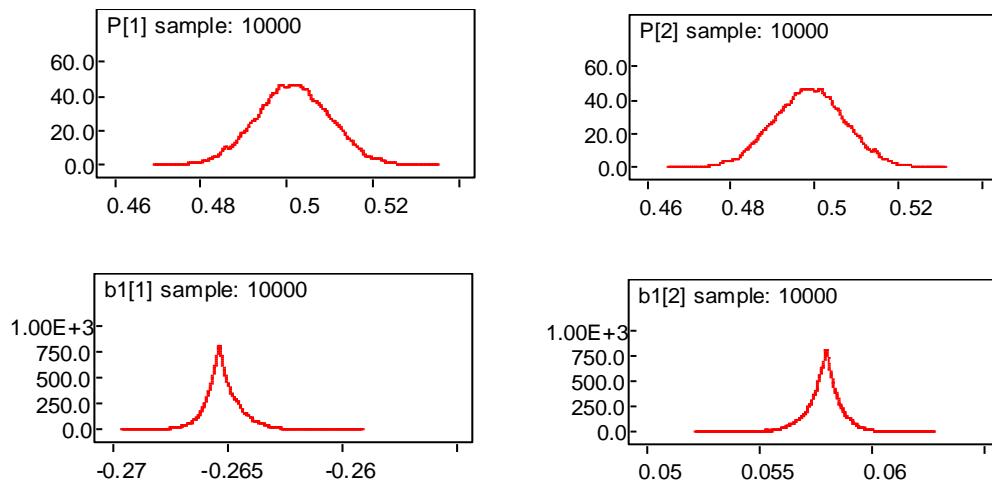


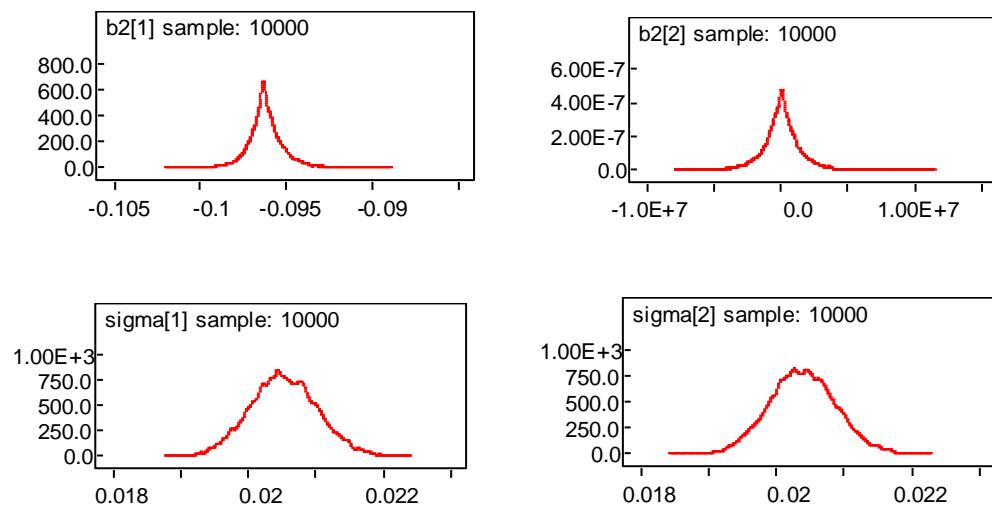


Autokorelasi:



Density:

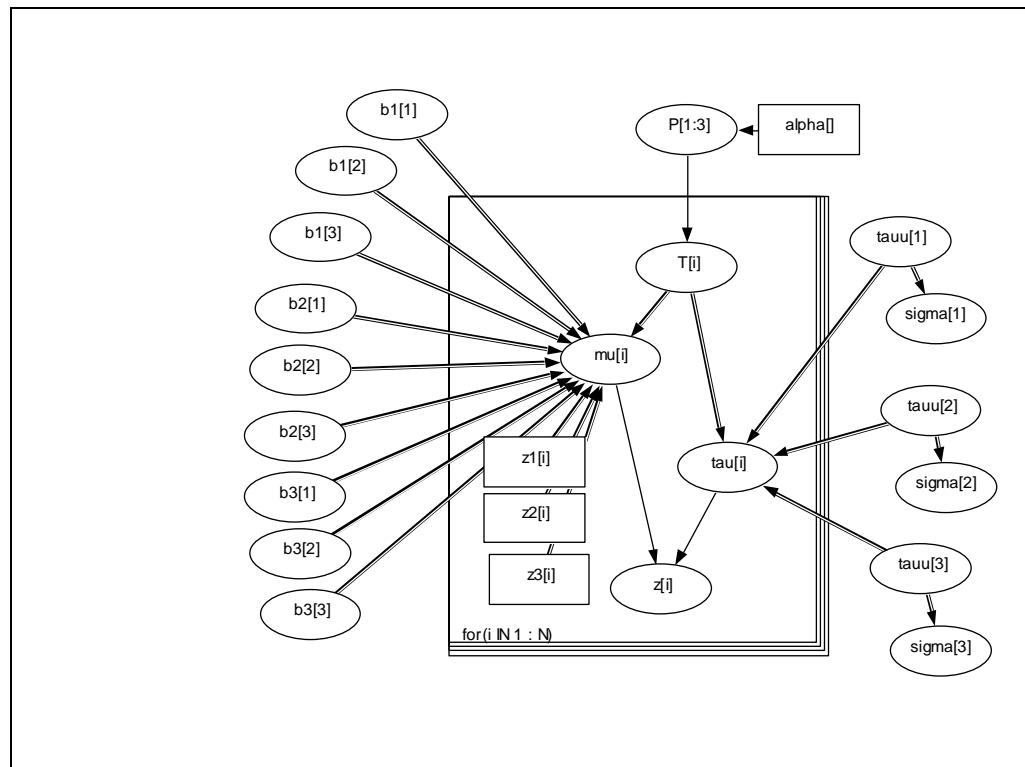




Lampiran M UNVR MLAR(3;2,[11],(2,[11]))

1. Doodle dan code WinBUGS

Doodle:



Code:

```
model;
{
```

```

for( i in 1 : N ) {
  z[i] ~ ddexp(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] ~ ddexp(-0.2654,1701.0)
b1[2] ~ ddexp( 0.0,1.0E-6)
tauu[2] ~ dgamma(0.001,0.001)
sigma[2] <- sqrt(2) / tauu[2]
for( i in 1 : N ) {
  tau[i] <- tauu[T[i]]
}
tauu[1] ~ dgamma(0.001,0.001)
sigma[1] <- sqrt(2) / tauu[1]
b2[1] ~ ddexp(-0.09637,11320.0)
b2[2] ~ ddexp( 0.0,1.0E-6)
b1[3] ~ ddexp(-0.265,1740.0)
b2[3] ~ ddexp(-0.09651,1286.0)
tauu[3] ~ dgamma(0.001,0.001)
sigma[3] <- sqrt(2) / tauu[3]
b3[1] ~ ddexp( 0.0,1.0E-6)
b3[2] ~ ddexp(0.05798,1715.0)
b3[3] ~ ddexp(0.05874,166.9)
}

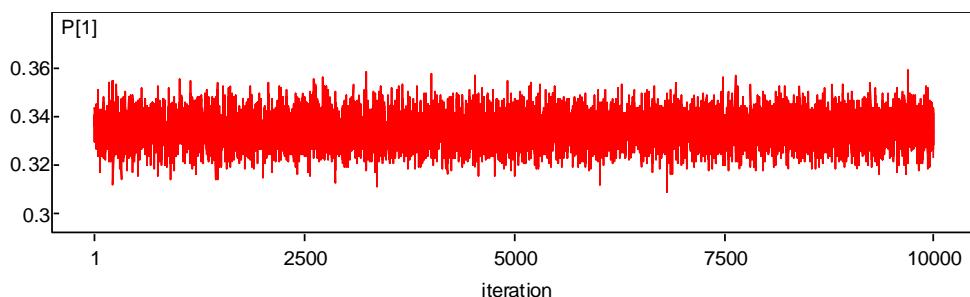
```

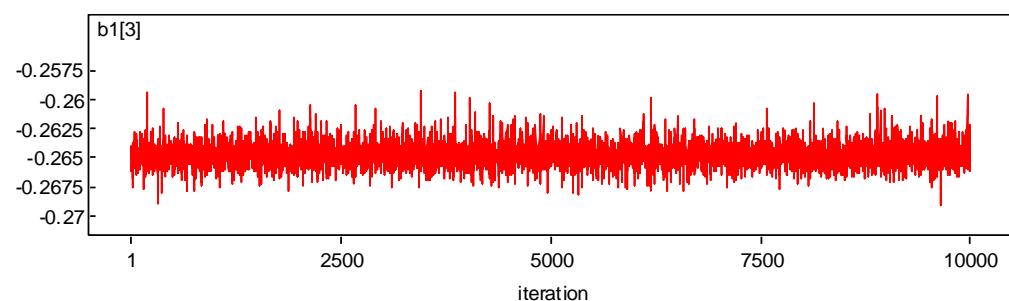
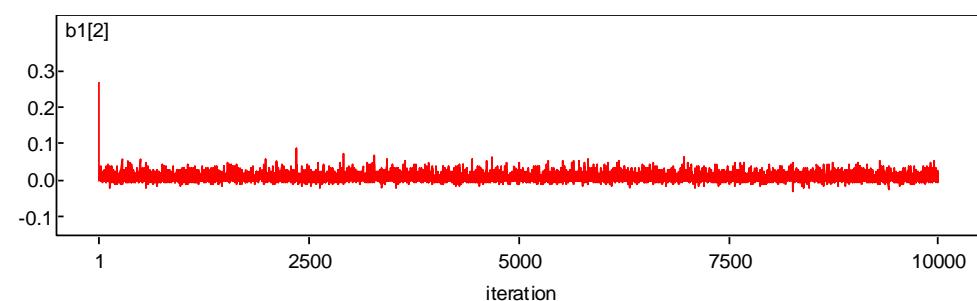
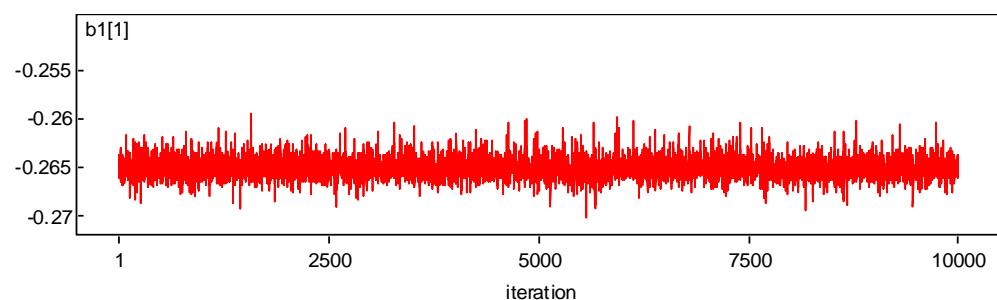
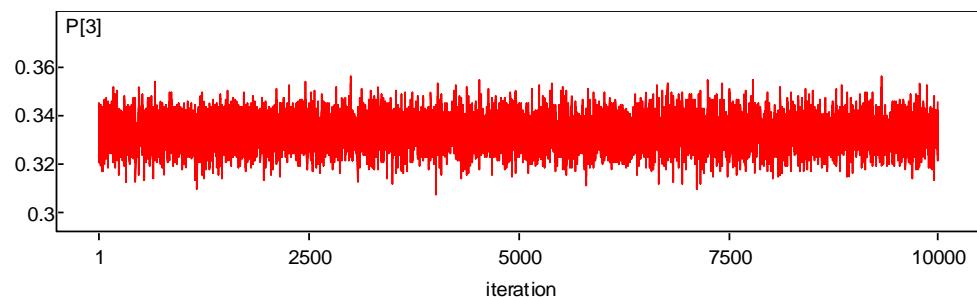
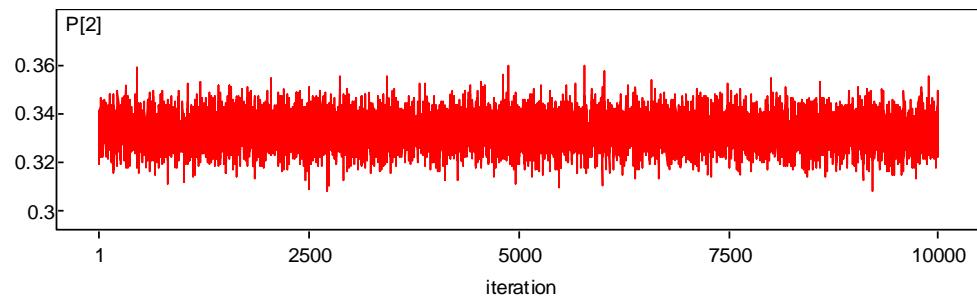
2. Output WinBUGS

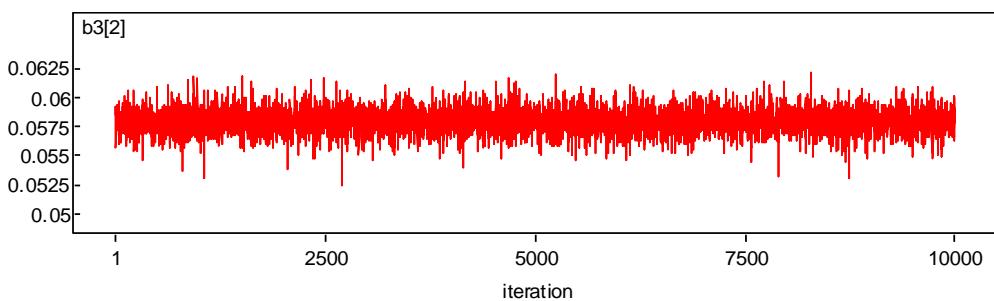
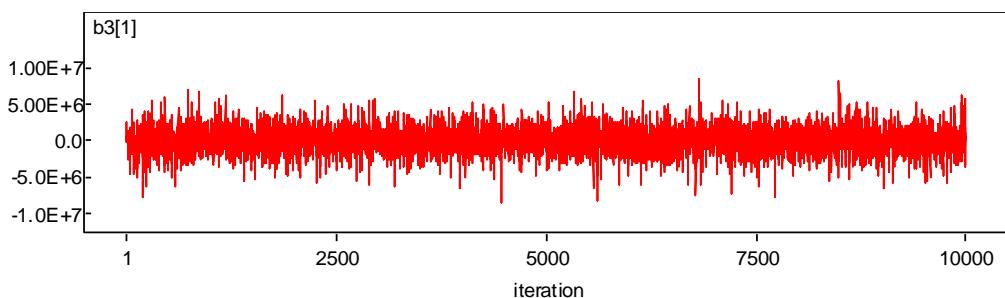
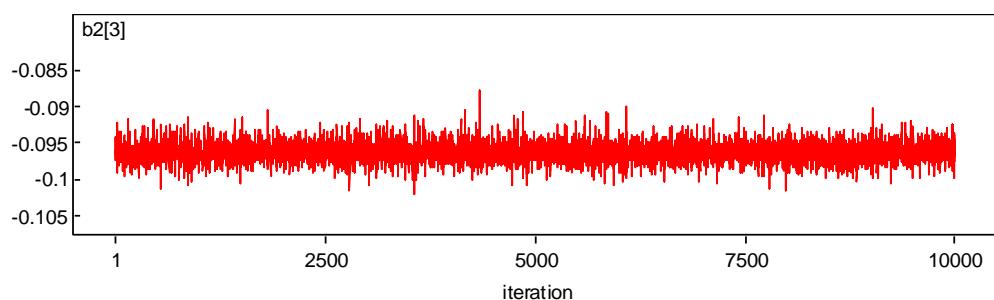
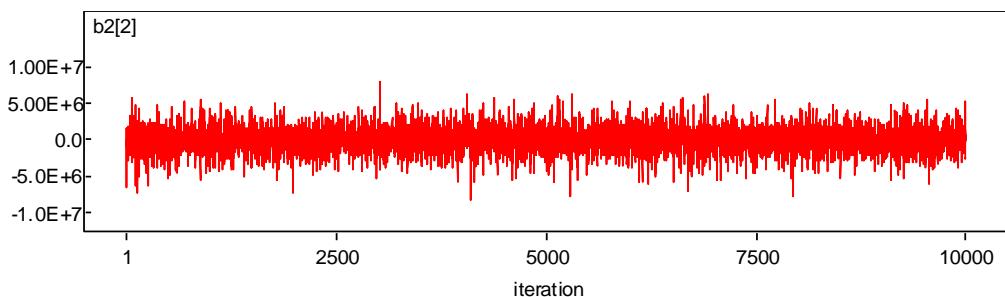
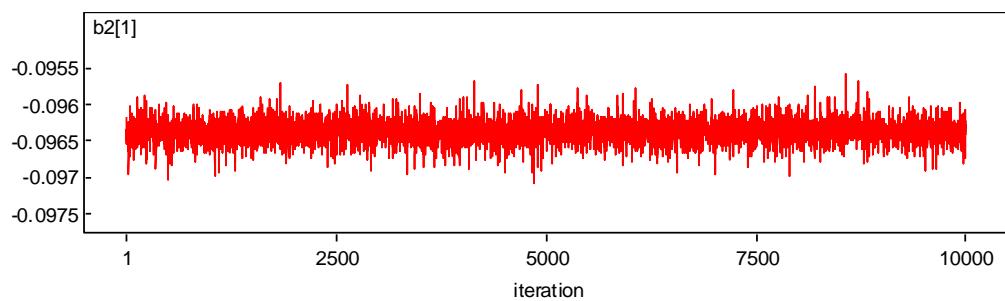
Statistik:

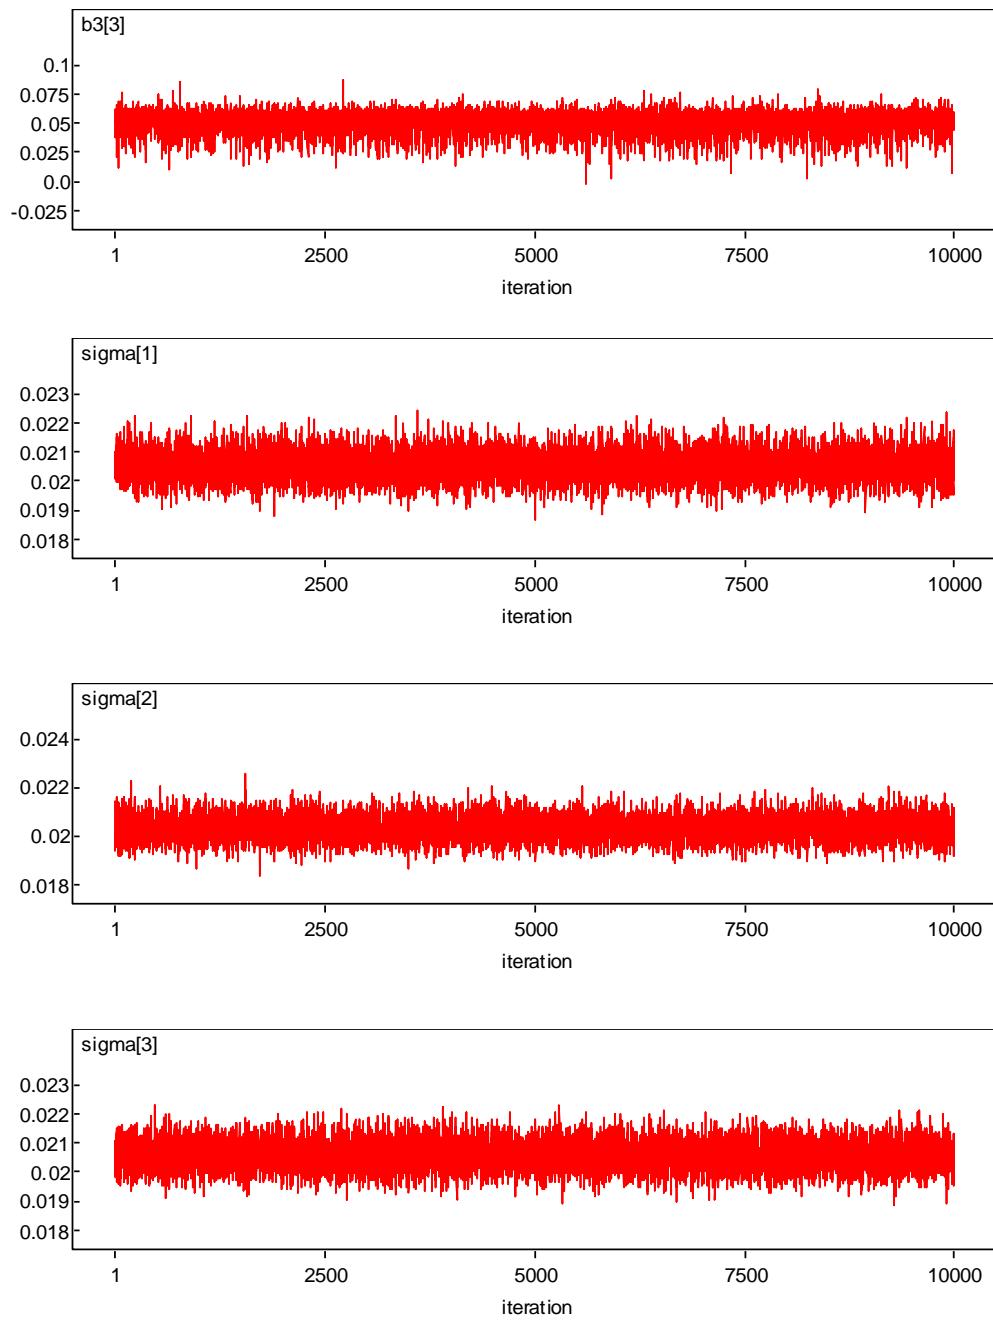
node	mean	sd	MC error	2.5%	median	97.5%	start	sample
P[1]	0.3345	0.006578	6.381E-5	0.3218	0.3343	0.3475	1	10000
P[2]	0.3328	0.006592	6.173E-5	0.3196	0.3327	0.3458	1	10000
P[3]	0.3328	0.006536	6.393E-5	0.32	0.3328	0.3455	1	10000
b1[1]	-0.2652	8.841E-4	9.083E-6	-0.2668	-0.2653	-0.2631	1	10000
b1[2]	0.006784	0.01041	1.115E-4	-0.007693	0.004256	0.03242	1	10000
b1[3]	-0.2648	8.239E-4	8.809E-6	-0.2664	-0.2649	-0.2629	1	10000
b2[1]	-0.09637	1.237E-4	1.13E-6	-0.09664	-0.09637	-0.09611	1	10000
b2[2]	-12380.0	1.407E+6	14430.0	-3.043E+6	-1035.0	2.965E+6	1	10000
b2[3]	-0.09634	0.001104	1.203E-5	-0.09855	-0.09641	-0.09386	1	10000
b3[1]	1181.0	1.423E+6	13120.0	-3.057E+6	8410.0	2.974E+6	1	10000
b3[2]	0.05798	8.225E-4	8.247E-6	0.0562	0.05799	0.05973	1	10000
b3[3]	0.05125	0.008967	9.362E-5	0.02927	0.05283	0.06481	1	10000
sigma[1]	0.02053	4.946E-4	5.314E-6	0.01957	0.02052	0.02153	1	10000
sigma[2]	0.02032	4.901E-4	4.932E-6	0.01939	0.02031	0.02132	1	10000
sigma[3]	0.02058	4.93E-4	4.106E-6	0.01963	0.02058	0.02155	1	10000

History:

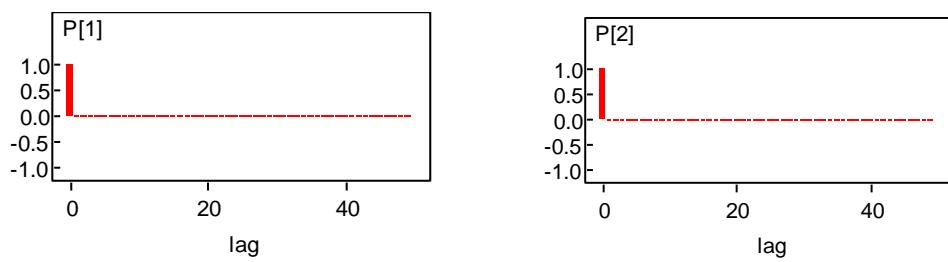


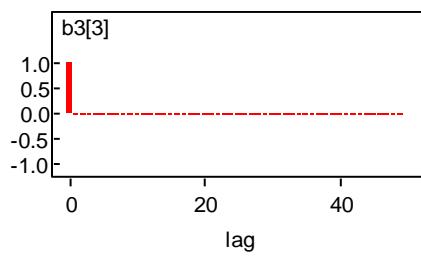
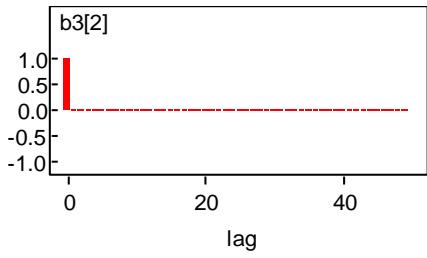
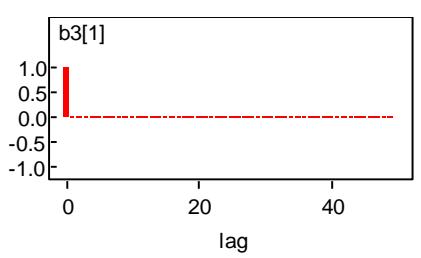
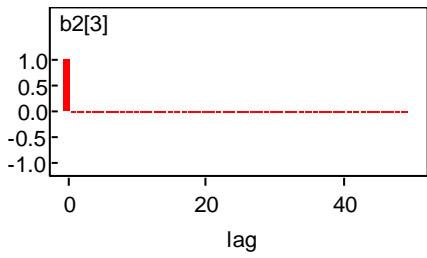
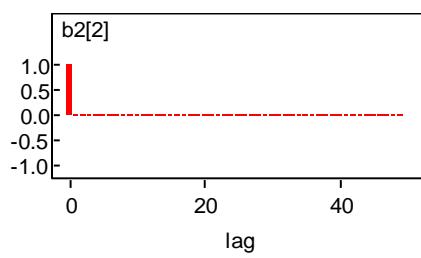
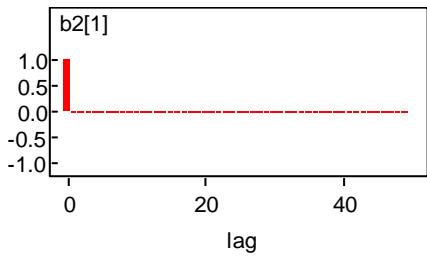
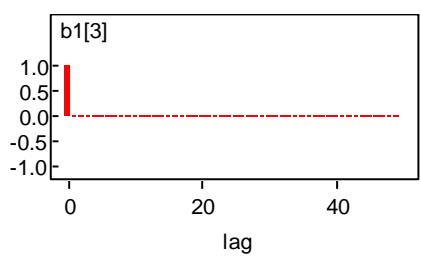
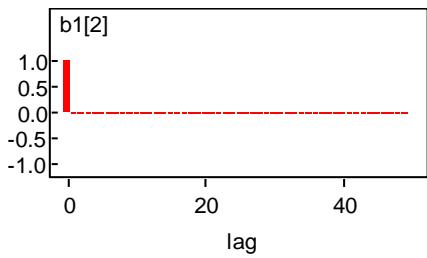
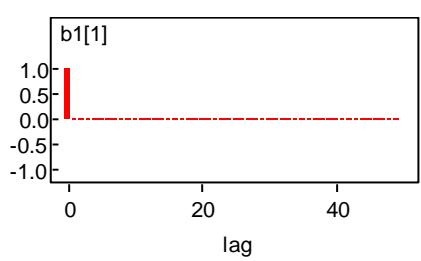
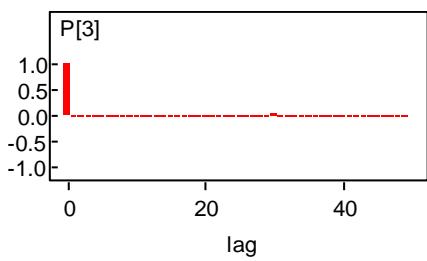


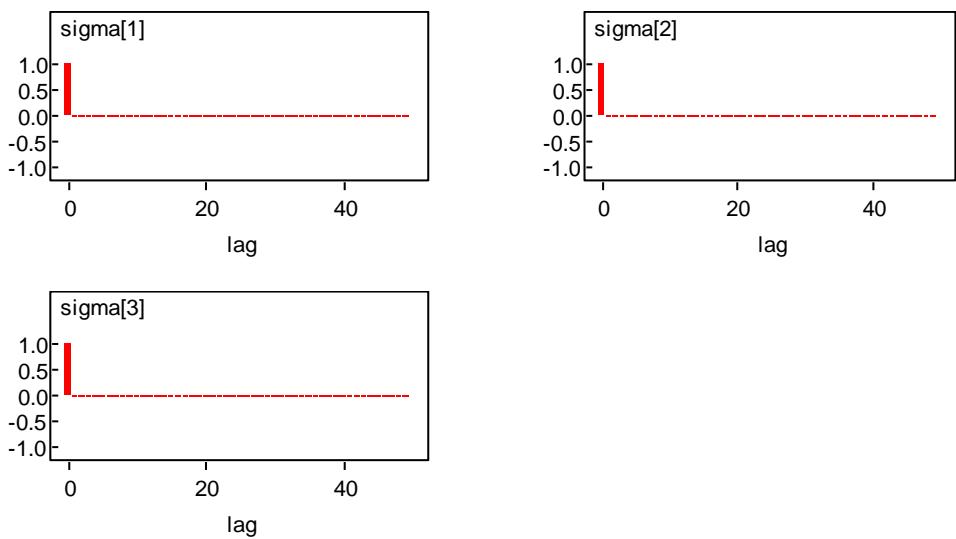




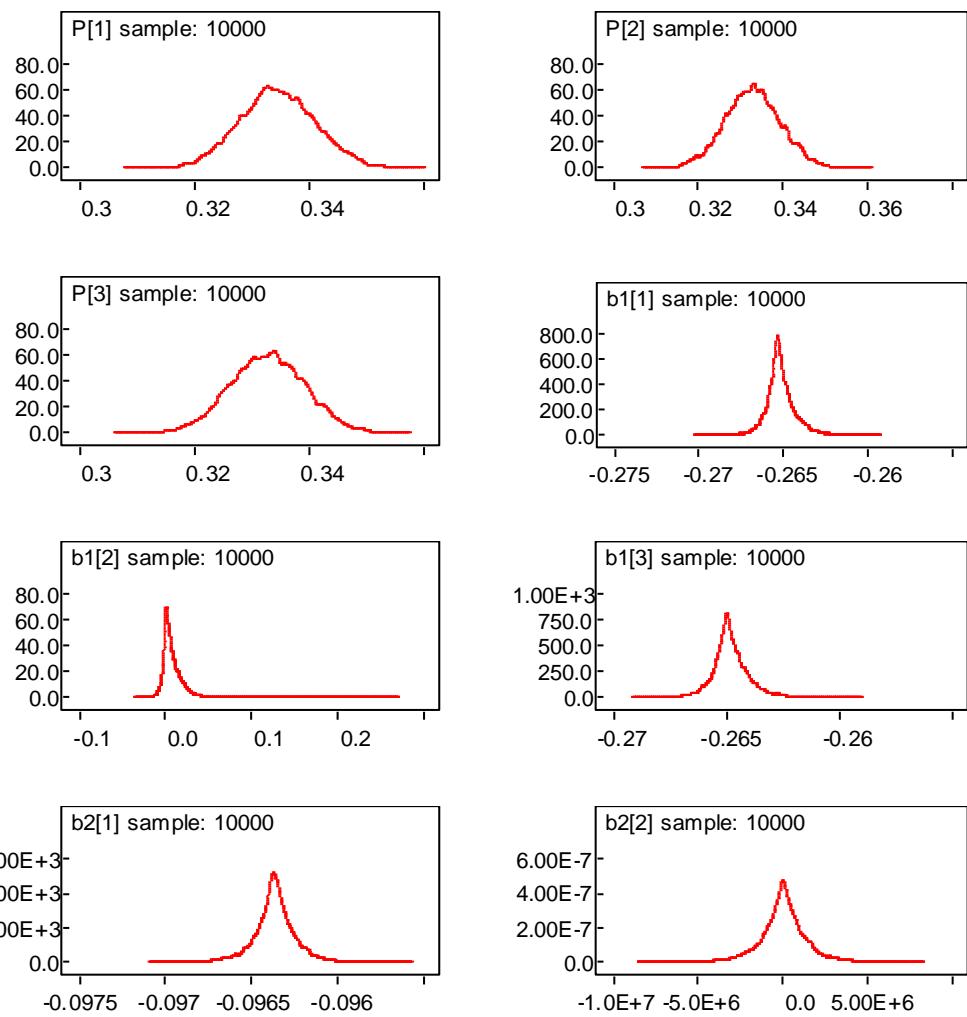
Autokorelasi

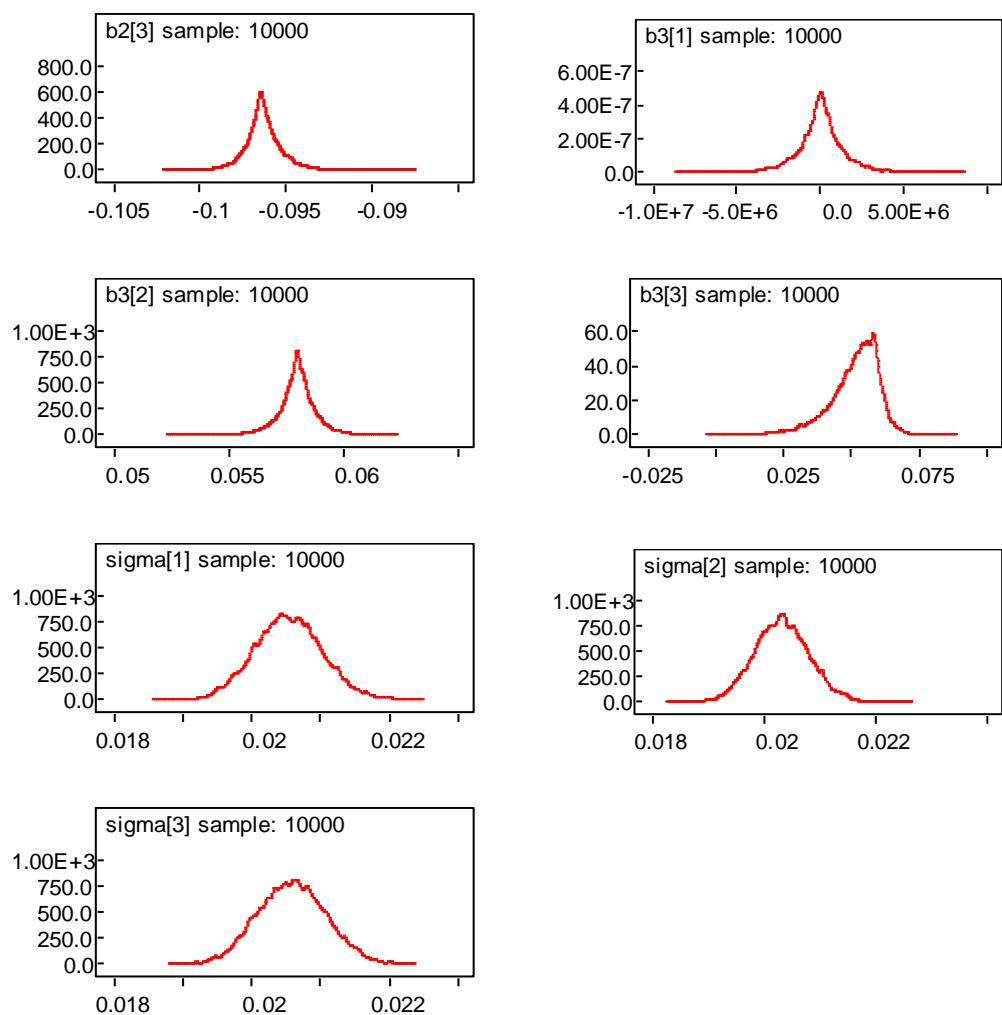






Density:





BIODATA PENULIS



Penulis yang mempunyai nama lengkap Brina Miftahurrohmah merupakan anak pertama dari satu bersaudara. Penulis merupakan putri dari pasangan Bapak Sutikno dan Ibu Saelah yang lahir di Lamongan pada tanggal 29 November 1990. Riwayat Pendidikan Penulis ditempuh di SDN Karangsambigalih I Kabupaten Lamongan, SMP Negeri 2 Sugio dan SMA Negeri 1 Lamongan. Setelah lulus dari SMA Negeri I Lamongan, penulis melanjutkan kuliah di PIKTI Jurusan Teknik Informatika ITS pada tahun 2009. Pada tahun 2010 penulis mengikuti tes masuk program D3 Reguler dan diterima sebagai mahasiswa Jurusan Statistika ITS angkatan 2010. Pada tahun 2013 penulis mengikuti tes masuk program lintas jalur S1 Statistika ITS dan diterima sebagai mahasiswa lintas jalur S1 Jurusan Statistika ITS angkatan 2013. Setelah menyelesaikan program Lintas Jalur S1, penulis melanjutkan studi selama 1,5 tahun di Program studi Magister Statistika ITS. Selama kuliah di Jurusan Statistika ITS, penulis tergabung dalam berbagai kegiatan organisasi. Pada tahun kedua kuliah, penulis tergabung dalam divisi SCC (*Statistics Computer Course*) sebagai staf Humas dan FORSIS sebagai tim sekretaris. Pada tahun ketiga, penulis masih tergabung dalam divisi SCC sebagai staf pelatihan. Saat sebagai mahasiswa baru penulis juga pernah menjabat sebagai sie publikasi dan dokumentasi dalam MTW dan pernah mengikuti pelatihan LKMM pra-TD. Jika ingin berdiskusi mengenai tugas akhir ini, maka dapat menghubungi email: brinakiirochan@gmail.com.

