



---

TESIS - SS14 2501

**PEMILIHAN THRESHOLD OPTIMUM  
MENGUNAKAN METODE BOOTSTRAP DALAM  
ESTIMASI VALUE AT RISK DATA RETURN SAHAM  
PERUSAHAAN SEKTOR ASURANSI DI BEI DENGAN  
PENDEKATAN GARCH-EXTREME VALUE THEORY**

ELY KURNIAWATI  
NRP. 1314 201 004

Dosen Pembimbing :  
Dr. rer.pol. Heri Kuswanto, M.Si.  
Dr. Ir. Setiawan, MS.

PROGRAM MAGISTER  
JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2016



THESIS - SS14 2501

**BOOTSTRAP METHOD FOR OPTIMUM THRESHOLD  
SELECTION IN ESTIMATING VALUE AT RISK USING  
GARCH-EXTREME VALUE THEORY  
(CASE STUDY: STOCK RETURN OF INSURANCE  
COMPANIES LISTED IN BEI)**

ELY KURNIAWATI  
NRP. 1314 201 004

Supervisor:  
Dr. rer.pol. Heri Kuswanto, M.Si.  
Dr. Ir. Setiawan, MS.

MAGISTER PROGRAM  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS AND NATURAL SCIENCES  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2016

**PEMILIHAN THRESHOLD OPTIMUM MENGGUNAKAN METODE  
BOOTSTRAP DALAM ESTIMASI VALUE AT RISK DATA RETURN  
SAHAM PERUSAHAAN SEKTOR ASURANSI DI BEI DENGAN  
PENDEKATAN GARCH-EXTREME VALUE THEORY**

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

**di  
Institut Teknologi Sepuluh Nopember  
Oleh:**

**ELY KURNIAWATI  
NRP. 1314201004**

**Tanggal Ujian : 19 Juli 2016  
Periode Wisuda : September 2016**

**Disetujui oleh :**

  
**1. Dr. rer. pol. Heri Kuswanto, M.Si.  
NIP. 19820326 200312 1 004**

**(Pembimbing I)**

  
**2. Dr. Ir. Setiawan, MS.  
NIP. 19601030 198701 1 001**

**(Pembimbing II)**

  
**3. Dr. rer. pol. Dedy Dwi Prastyo, M.Si.  
NIP. 19831204 200812 1 002**

**(Penguji)**

  
**4. Dr. Suhartono  
NIP. 19710929 199512 1 001**

**(Penguji)**

**Direktur Program Pascasarjana,**



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

# PEMILIHAN THRESHOLD OPTIMUM MENGGUNAKAN METODE BOOTSTRAP DALAM ESTIMASI VALUE AT RISK DATA RETURN SAHAM PERUSAHAAN SEKTOR ASURANSI DI BEI DENGAN PENDEKATAN GARCH-EXTREME VALUE THEORY

Nama mahasiswa : Ely Kurniawati  
NRP : 1314201004  
Pembimbing : Dr. rer.pol. Heri Kuswanto, M.Si.  
Co-Pembimbing : Dr. Ir. Setiawan, MS.

## ABSTRAK

*Value at Risk* (VaR) merupakan salah satu alat pengukur resiko yang digunakan untuk memprediksi besarnya kerugian maksimal dari suatu portofolio dalam kurun waktu tertentu dengan tingkat keyakinan yang ditetapkan. Asumsi yang digunakan dalam perhitungan VaR konvensional adalah normalitas data, yang seringkali tidak ditemukan dalam data finansial. Selain itu, data finansial juga memiliki volatilitas tinggi yang menyebabkan varians pengamatan tidak konstan. Oleh karena itu perhitungan VaR dalam penelitian ini dilakukan dengan pendekatan EVT yang dikombinasikan dengan metode GARCH. Model GARCH digunakan untuk estimasi volatilitas yang ada pada data finansial, sedangkan EVT dengan pendekatan *Peak Over Threshold* (POT) digunakan untuk estimasi distribusi residual dari model GARCH tersebut. Dalam pendekatan POT, pemilihan *threshold* merupakan hal yang kritical karena mempengaruhi hasil estimasi. Pada penelitian ini dilakukan simulasi untuk mendapatkan nilai *threshold* optimum dengan pendekatan *bootstrap*. Hasilnya menunjukkan bahwa *threshold* optimum berada pada kuantil 1% - 3% dari data. Sedangkan pada data riil, dengan pendekatan *bootstrap*, *threshold* optimum berada pada kuantil 2,3% - 2,7% yang berada pada rentang hasil simulasi tersebut. Kajian aplikasi dilakukan terhadap data return saham 3 perusahaan *go public* di BEI, yaitu PT. Lippo General Insurance (LPGI), PT. Panin Insurance (PNIN), dan PT. Asuransi Multi Artha Guna (AMAG). Hasil perhitungan VaR dengan pendekatan ARMA-GARCH dan EVT-GARCH memberikan pola yang sama, yaitu PT.Lippo General Insurance cenderung memiliki nilai resiko paling besar, diiringi dengan nilai keuntungan yang besar juga. Sedangkan kedua perusahaan lainnya memiliki nilai VaR yang hampir sama. Sehubungan dengan penerapan beberapa *threshold* dalam penelitian ini, perbedaan penentuan *threshold* memberikan hasil estimasi VaR yang tidak jauh berbeda. Berdasarkan hasil *backtesting*, pendekatan ARMA-GARCH maupun EVT-GARCH dapat mengidentifikasi pola volatilitas dalam data, akan tetapi EVT-GARCH memiliki keunggulan dalam mengidentifikasi nilai ekstrim. Hal ini berlaku pada kuantil 0,5% dan 1 %. Sedangkan pada kuantil 5%, kedua pendekatan memberikan hasil yang tidak jauh berbeda.

Kata kunci : *Return*, GARCH-EVT, POT, *Value at Risk*, *Threshold optimum*, *Bootstrap*

**BOOTSTRAP METHOD FOR OPTIMUM THRESHOLD SELECTION IN  
ESTIMATING VALUE AT RISK USING GARCH-EXTREME VALUE  
THEORY (CASE STUDY: STOCK RETURN OF INSURANCE COMPANIES  
LISTED IN BEI)**

Student Name : Ely Kurniawati  
Student ID : 1314201004  
Supervisor : Dr.rer.pol. Heri Kuswanto, M.Si.  
Co Supervisor : Dr. Ir. Setiawan, MS.

**ABSTRACT**

Value at Risk (VaR) is a method in quantifying and controlling risk of a portfolio. It measures the maximum value of risk in a time frame and in an assigned confidence level. Variance Covariance method is the most widely used method due to its simplicity in calculation. However it requires normal distribution assumption to the data and is invalid when the data series have a fat tail indicated by high occurrence of extreme events. Imposing normal distribution assumption to a fat tail data will lead to underestimate the risk. This paper will evaluate VaR estimation using combination of GARCH and Extreme Value Theory (EVT) to accommodate volatility and extreme event in financial data. GARCH is applied to model the presence of volatility, while EVT with Peak Over Threshold (POT) approach is applied to model the extreme events of GARCH error term. Threshold choice is a critical step in POT analysis, due to its effect on estimation result. This study also carries out bootstrap simulation to find out the optimum threshold. The result shows that optimum threshold is located in 1% - 3% quantile of data. As the empirical study, this research examines stock return of 3 go public companies listed in BEI, i.e. PT. Lippo General Insurance (LPGI), PT. Panin Insurance (PNIN) and PT. Asuransi Multi Artha Guna (AMAG). The optimum threshold of the empirical data is located in 2,3% - 2,7% quantile of data. The VaR calculation using both ARMA-GARCH and EVT-GARCH yield on similar pattern showing that PT.Lippo General Insurance tend to have highest risk as well as highest gain. This study reveals that different threshold setting does not give significant effect in VaR estimation. Based on backtesting result, both ARMA-GARCH and EVT-GARCH are able to identify volatility pattern, however the latter is superior in identifying extreme events.

Key word: Return, GARCH-EVT, POT, Value at Risk, Threshold optimum, Bootstrap

## KATA PENGANTAR

Puji syukur penulis panjatkan ke hadapan Tuhan Yang Maha Esa, penguasa ilmu pengetahuan dan saksi atas setiap kejadian, berkat perlindungan-Nya pengerjaan serta penulisan Tesis dengan judul **“Pemilihan Threshold Optimum Menggunakan Metode Bootstrap dalam Estimasi Value at Risk Data Return Saham Perusahaan Sektor Asuransi Di BEI dengan Pendekatan Garch-Extreme Value Theory”** ini dapat terselesaikan dengan baik.

Penulisan Tesis ini adalah salah satu syarat yang harus dipenuhi dalam memperoleh gelar Tesis sesuai dengan kurikulum Jurusan Statistika FMIPA-ITS Surabaya. Dalam penyelesaian Tesis serta laporan ini penulis tidak terlepas dari bantuan serta dukungan dari berbagai pihak. Oleh karena itu penulis ingin mengucapkan terima kasih sebesar-besarnya kepada:

1. Keluarga besar penulis atas segala doa, dukungan materi, motivasi, kepercayaan dan kasih sayang.
2. Bapak Dr. Suhartono, M.Sc selaku Ketua Jurusan Statistika-ITS, sekaligus penguji yang memberikan banyak masukan berharga.
3. Bapak Dr.rer.pol Heri Kuswanto, M.Si. selaku ketua program studi Pascasarjana Statistika-ITS, sekaligus dosen pembimbing yang telah banyak memberikan bimbingan dan saran selama pengerjaan Tesis ini.
4. Bapak Dr. Ir. Setiawan, MS selaku dosen pembimbing atas masukan dan bimbingannya.
5. Bapak Dr.rer.pol. Dedy Dwi Prasetyo, M.Si. selaku dosen penguji yang telah memberikan tambahan ilmu selama proses perbaikan laporan Tesis ini.
6. Bapak Prof. Dr. Drs. I Nyoman Budiantara, M.Si., selaku dosen wali yang telah membimbing dan mengarahkan sejak awal perkuliahan.
7. Teman-teman S2 Statistika Angkatan 2014 yang telah berjuang bersama-sama menyelesaikan perkuliahan di Jurusan Statistika ITS
8. Pihak-pihak lain yang telah mendukung dan membantu penyusunan Tugas Akhir ini yang tidak mungkin penulis sebutkan satu per satu. Terima kasih.

Penulis menyadari bahwa penyusunan Tesis ini masih jauh dari sempurna, maka kritik dan saran yang membangun akan senantiasa penulis harapkan demi

kesempurnaan di masa mendatang. Semoga laporan ini dapat memberikan sumbangan yang bermanfaat bagi semua pihak.

*“Allah will raise to higher ranks those of you who have faith and knowledge“ (58:11)*

Surabaya, Agustus 2016

**Penulis**

## DAFTAR ISI

|  |      |
|--|------|
| <b>HALAMAN JUDUL</b>   | i    |
| <b>LEMBAR PENGESAHAN</b>   | v    |
| <b>ABSTRAK</b>   | vii  |
| <b>ABTRACT</b>   | ix   |
| <b>KATA PENGANTAR</b>  | xi   |
| <b>DAFTAR ISI</b>  | xiii |
| <b>DAFTAR TABEL</b>  | xv   |
| <b>DAFTAR GAMBAR</b>   | xvii |
| <b>DAFTAR LAMPIRAN</b>   | xix  |
| <b>BAB I : PENDAHULUAN</b>   | 1    |
| 1.1 Latar Belakang   | 1    |
| 1.2 Rumusan Permasalahan   | 6    |
| 1.3 Tujuan Penelitian  | 6    |
| 1.4 Manfaat Penelitian   | 7    |
| 1.5 Batasan Penelitian   | 7    |
| <b>BAB II : KAJIAN PUSTAKA</b>                                       | 9    |
| 2.1 Analisis Time Series   | 9    |
| 2.2 Kestasioneran Dats   | 9    |
| 2.3 Model ARMA   | 12   |
| 2.4 <i>Generalized Autoregressive Conditional Heteroscedasticity</i> | 17   |
| 2.5 <i>Extreme Value Theory</i> dan <i>Value at Risk</i>             | 21   |
| 2.6 Return Saham   | 31   |
| 2.7 <i>Backtesting</i>   | 32   |
| <b>BAB III : METODOLOGI PENELITIAN</b>                               | 33   |
| 3.1 Sumber Data  | 33   |
| 3.2 Metode Analisis  | 34   |
| 3.3 Diagram Alir Penelitian  | 38   |
| <b>BAB IV : ANALISIS DAN PEMBAHASAN</b>                              |      |
| 4.1 Studi Simulasi Pemilihan <i>Threshold</i> Optimum                | 39   |
| 4.2 Studi Aplikasi Data Saham  | 41   |
| 4.2.1 Karakteristik Saham Perusahaan                                 | 42   |
| 4.2.2 Pemodelan Return Saham   | 46   |
| 4.2.2.1 Pemodelan Return Saham dengan Pendekatan ARMA                | 46   |
| 4.2.2.2 Pemodelan Return Saham dengan GARCH                          | 50   |
| 4.2.2.3 Pemodelan Return Saham dengan EVT                            | 52   |
| 4.2.3 Estimasi Nilai VaR   | 54   |
| 4.2.3.1 Estimasi Nilai VaR dengan Pendekatan ARMA-GARCH              | 54   |
| 4.2.3.2 Estimasi Nilai VaR dengan Pendekatan GARCH-EVT               | 55   |
| 4.2.4 Perbandingan Metode Perhitungan Nilai VaR                      | 58   |
| <b>BAB V : KESIMPULAN DAN SARAN</b>                                  |      |
| 5.1 Kesimpulan   | 65   |
| 5.2 Saran  | 65   |
| <b>DAFTAR PUSTAKA</b>  | 67   |

|                        |    |
|------------------------|----|
| <b>LAMPIRAN</b>        | 69 |
| <b>BIODATA PENULIS</b> | 95 |

## DAFTAR TABEL

|   |    |
|---|----|
| <b>Tabel 2.1</b> : Pola ACF dan PACF dari Model ARMA(p,q)                   | 14 |
| <b>Tabel 3.1</b> : Struktur Data Harga Saham dan <i>Return</i> Saham        | 33 |
| <b>Tabel 3.2</b> : Parameter untuk Membangkitkan Data                       | 35 |
| <b>Tabel 4.1</b> : Karakteristik Data Saham                                 | 44 |
| <b>Tabel 4.2</b> : Hasil Uji <i>Augmented Dickey Fuller</i>                 | 46 |
| <b>Tabel 4.3</b> : Estimasi Parameter Model ARMA                            | 49 |
| <b>Tabel 4.4</b> : Uji Asumsi <i>White Noise</i> ARMA(1,0)                  | 50 |
| <b>Tabel 4.5</b> : Uji Lagrange Multiplier                                  | 51 |
| <b>Tabel 4.6</b> : Estimasi Parameter dan Uji Signifikansi Model ARMA-GARCH | 51 |
| <b>Tabel 4.7</b> : Estimasi Parameter Model GPD                             | 53 |
| <b>Tabel 4.8</b> : Estimasi Nilai VaR (ARMA-GARCH)                          | 54 |
| <b>Tabel 4.9</b> : Estimasi Nilai <i>Dynamic</i> VaR ( <i>Loss</i> )        | 56 |
| <b>Tabel 4.10</b> : Estimasi Nilai <i>Dynamic</i> VaR ( <i>Gain</i> )       | 57 |
| <b>Tabel 4.11</b> : Hasil <i>Backtesting</i> ( <i>Left Tail</i> )           | 62 |
| <b>Tabel 4.12</b> : Hasil <i>Backtesting</i> ( <i>Right Tail</i> )          | 63 |

## DAFTAR GAMBAR

|   |    |
|---|----|
| <b>Gambar 2.1 :</b> Ilustrasi Pemilihan Nilai Ekstrim Metode POT                              | 23 |
| <b>Gambar 2.2 :</b> PDF dari Distribusi Normal (a), Student-t (b), Frechet (c) dan Gumbel (d) | 29 |
| <b>Gambar 3.1 :</b> Diagram Alir Tahapan Analisis   | 38 |
| <b>Gambar 4.1 :</b> Histogram data simulasi   | 40 |
| <b>Gambar 4.2 :</b> Bar Chart Posisi <i>Threshold</i> Optimum Hasil Simulasi                  | 41 |
| <b>Gambar 4.3 :</b> <i>Time Series Plot</i> Harga Saham                                       | 42 |
| <b>Gambar 4.4 :</b> <i>Time Series Plot</i> Return Saham                                      | 43 |
| <b>Gambar 4.5 :</b> <i>Clustered volatility return</i> Saham                                  | 44 |
| <b>Gambar 4.6 :</b> QQ Plot Data <i>Return</i>  | 45 |
| <b>Gambar 4.7 :</b> Kurva Distribusi Data <i>return</i> Saham                                 | 45 |
| <b>Gambar 4.8 :</b> Plot ACF PACF Data <i>return</i>  | 47 |
| <b>Gambar 4.9 :</b> Bar Chart Posisi <i>Threshold</i> Optimum Data                            | 53 |
| <b>Gambar 4.10 :</b> Estimasi <i>Loss</i> (bawah) dan <i>Gain</i> (atas) pada saham AMAG      | 59 |
| <b>Gambar 4.11 :</b> Estimasi <i>Loss</i> (bawah) dan <i>Gain</i> (atas) pada saham LPGI      | 60 |
| <b>Gambar 4.12 :</b> Riil Estimasi <i>Loss</i> (bawah) dan <i>Gain</i> (atas) pada saham PNIN | 61 |

## DAFTAR LAMPIRAN

|                    |  |    |
|--------------------|--|----|
| <b>Lampiran 1</b>  | : Data Harga Saham dan <i>Return</i> pada Saham<br>AMAG, LPGI dan PNIN | 69 |
| <b>Lampiran 2</b>  | : Statistika Deskriptif Harga Saham dan <i>Return</i><br>pada Saham    | 70 |
| <b>Lampiran 3</b>  | : Hasil Uji <i>Augmented Dickey Fuller</i>                             | 71 |
| <b>Lampiran 4A</b> | : Hasil Uji Signifikansi Parameter Model ARMA<br>Saham AMAG            | 72 |
| <b>Lampiran 4B</b> | : Hasil Uji Signifikansi Parameter Model ARMA<br>Saham LPGI            | 75 |
| <b>Lampiran 4C</b> | : Hasil Uji Signifikansi Parameter Model ARMA<br>Saham PNIN            | 78 |
| <b>Lampiran 5</b>  | : Hasil Uji Lagrange Multiplier  | 81 |
| <b>Lampiran 6A</b> | : Hasil Estimasi Parameter Model ARMA(1,0)-<br>GARCH(1,1) AMAG         | 82 |
| <b>Lampiran 6B</b> | : Hasil Estimasi Parameter Model ARMA(1,0)-<br>GARCH(1,1) LPGI         | 83 |
| <b>Lampiran 6C</b> | : Hasil Estimasi Parameter Model ARMA(1,0)-<br>GARCH(1,1) PNIN         | 84 |
| <b>Lampiran 7</b>  | : R Code   | 85 |

# **BAB 1**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Berkenaan dengan integrasi masyarakat ekonomi ASEAN, sektor asuransi merupakan salah satu sektor jasa keuangan yang diliberalisasi. Sebagaimana ditulis oleh Setiawan (2013), dalam pasar tunggal yang terintegrasi nantinya, perusahaan asuransi yang berbasis di negara ASEAN tidak lagi dihadapkan pada aturan pembatasan untuk mendirikan usaha di negara ASEAN lainnya. Dengan jumlah populasi terbesar di Asia Tenggara dan masyarakat kelas menengah yang tumbuh cepat mencapai 42,7% pada 2009, Indonesia berpotensi menjadi *big market* bagi industri perasuransian Asia Tenggara. Di sisi lain, Setiawan (2013) juga mengungkapkan bahwa 85% penduduk Indonesia belum memiliki akses terhadap asuransi, yang mengindikasikan bahwa sektor perasuransian di Indonesia masih *underdeveloped*.

Data dari Asosiasi Asuransi Jiwa Indonesia (AAJI) menyatakan bahwa penetrasi pasar asuransi terhadap Produk Domestik Bruto (PDB) pada 2015 masih sangat kecil yaitu sebesar 2,4%. Rendahnya nilai tersebut mengindikasikan masih sedikit sekali produk asuransi yang dibeli masyarakat. Untuk melihat tingkat kinerja perusahaan-perusahaan asuransi tersebut, masyarakat bisa melihat bagaimana performa mereka di pasar modal.

Dari sisi investor, salah satu ukuran perkembangan kinerja perusahaan dapat dilihat dari tingkat likuiditas, volatilitas dan *return* saham. Demikian juga pada perusahaan asuransi *go public* yang terdaftar di Bursa Efek Indonesia (BEI). Semakin tinggi likuiditas suatu saham, maka semakin tinggi frekuensi transaksi suatu saham, yang selanjutnya menunjukkan bahwa saham tersebut semakin diminati investor. Tujuan seorang investor dalam melakukan investasi saham adalah untuk memaksimalkan return dengan resiko minimal. *Value at Risk* (VaR) merupakan salah satu alat pengukuran resiko yang digunakan untuk memprediksi besarnya kerugian maksimal dari suatu portofolio dalam kurun waktu tertentu dengan tingkat keyakinan yang ditetapkan (Franke, Hardle, & Hafner, 2011).

Metode ini merupakan pendekatan yang paling sering digunakan karena menghasilkan sebuah nilai tunggal yang menggambarkan keseluruhan resiko yang dihadapi suatu institusi. VaR biasa digunakan untuk mengukur resiko kerugian return saham, untuk mengukur resiko klaim asuransi, resiko pada nilai tukar mata uang, dan beberapa data finansial lainnya.

Terdapat tiga metode pokok dalam menghitung VaR, yaitu *variance-covariance method* (VCM), *monte carlo simulation* (MCS) dan *historical simulation* (HS), yang mana masing-masing memiliki kelebihan dan kekurangan. Pendekatan VCM unggul dalam kemudahan perhitungan, tetapi memerlukan asumsi kenormalan data. Metode MCS memiliki kemampuan untuk menangani distribusi return yang bermacam-macam, tetapi menjadi tidak efektif ketika menangani portofolio yang kompleks (Odening & Hinrichs, 2002). Sementara metode HS menggunakan data pengamatan masa lampau untuk mengestimasi nilai VaR sehingga metode ini relatif sederhana untuk diaplikasikan. Dengan menggunakan pendekatan distribusi empiris, sampel dapat diduga dengan baik pada kuantil tengah, akan tetapi menjadi tidak reliabel pada kuantil atas mengingat metode ini hanya berdasar pada sedikit pengamatan (Gencay & Selcuk, 2004).

Dalam perhitungan VaR sangat diperlukan kemampuan untuk memahami pola volatilitas data, termasuk jika terdapat kondisi ekstrim. Gencay dan Selcuk (2004) menyebutkan bahwa berdasarkan sifat dasarnya, pergerakan-pergerakan ekstrim dalam suatu serial data berhubungan dengan ekor (*tail*) distribusinya. Beberapa studi yang berhubungan dengan *tail* suatu distribusi menunjukkan bahwa kebanyakan data deret waktu finansial memiliki ekor yang gemuk (*fat tailed*). Menurut Franke, Hardle dan Hafner (2011), disebutkan bahwa distribusi dari return yang seringkali memiliki bentuk leptokurtosis (*fat-tailed*). Untuk resiko ekstrim pada kuantil atas dan pada investasi beresiko tinggi, penaksiran VaR dengan asumsi normalitas akan mendapatkan nilai yang *underestimate*. Meskipun dengan menambahkan jumlah data, informasi yang diberikan sangat terbatas dalam menjelaskan kerugian maupun keuntungan ekstrim yang terjadi. Pendekatan *Extreme Value Theory* (EVT) dapat menjadi alternatif solusi untuk mengatasi kondisi ekstrim tersebut. Berbeda dengan pendekatan konvensional yang dijelaskan di atas, EVT dapat memodelkan titik ekstrim pada kuantil secara lebih baik

(Bensalah, 2000). Dalam EVT terdapat dua metode dalam menjelaskan perilaku nilai ekstrim pada distribusi data, yaitu *Block Maxima Model* (BMM) dan *Peak Over Threshold* (POT). Metode BMM memodelkan distribusi asimtotik dari observasi maximum (minimum), yang selanjutnya mengikuti salah satu dari ketiga distribusi Gumbel, Frechet, atau Weibull. Bentuk standar dari ketiga distribusi tersebut diberikan oleh distribusi *Generalized Extreme Value* (GEV). Metode yang kedua, yaitu POT, memodelkan distribusi dari pengamatan yang melebihi suatu nilai *threshold* yang ditetapkan. Distribusi tersebut berupa *Generalized Pareto Distribution* (GPD) (Franke, Hardle, & Hafner, 2011).

Menurut Coles (2001) memodelkan dengan menggunakan BMM seringkali kurang memberi informasi karena hanya nilai maksimum dari masing-masing blok yang dikategorikan sebagai ekstrim. Kondisi ini diperparah jika dalam blok tertentu mengandung kejadian ekstrim yang lebih sering muncul dibandingkan blok lainnya. Jika pada data serial tersedia informasi mengenai data sampai level jam ataupun data harian, maka akan lebih baik jika keseluruhan data dilibatkan, tanpa membuat blok. Di sisi lain, pendekatan POT dapat menganalisis data dengan lebih efisien dan dipandang lebih aplikatif (McNeil, Frey & Embrecht, 2005). Sehingga metode EVT yang selanjutnya digunakan dalam penelitian ini difokuskan pada pendekatan POT.

Dalam pendekatan POT, hasil estimasi parameter sangat dipengaruhi oleh pemilihan *threshold*. Dalam penelitian yang dilakukan oleh Chen (2014), digunakan pendekatan *Mean Excess Function* (MEF) untuk menentukan *threshold*. Selanjutnya disebutkan bahwa tidak terdapat pendekatan matematis dalam menginterpretasikan *threshold* dari MEF, melainkan berdasarkan penampilan visual. Hal ini menjadikan pendekatan ini sedikit subjektif. Menurut Odening dan Hinrichs (2002), perbedaan pemilihan *threshold* dapat berakibat pada tingkat kebaikan taksiran yang dihasilkan. Semakin banyak data ekstrim yang dimasukkan ke dalam penaksiran, menghasilkan varians yang kecil, tetapi menghasilkan taksiran parameter yang bias. Semakin sedikit data ekstrim yang dimasukkan ke dalam penaksiran, maka data yang ada tidak cukup untuk menaksir model, akibatnya menghasilkan varians yang besar. Untuk dapat mengatasi permasalahan tersebut, Danielson, Haan, Peng dan Vries (2001) mengembangkan suatu metode

*bootstrap* yang digunakan untuk penentuan fraksi sampling yang ada dalam persamaan penaksir ekor distribusi yg dihasilkan dari metode POT. Namun sejauh ini belum pernah dilakukan evaluasi terhadap performa *threshold* optimum yang diperoleh dari pendekatan *bootstrap* ini. Oleh sebab itu dalam penelitian ini akan dikaji mengenai performa *threshold* optimum apabila diaplikasikan pada data dengan tipe distribusi normal, dan *fat tailed*.

Data deret waktu finansial cenderung memiliki pola volatilitas yang tinggi sehingga menyebabkan varians pengamatan menjadi tidak konstan. Untuk dapat menangani kondisi tersebut, digunakan pendekatan yang digunakan McNeil dan Frey (2000) dalam penelitiannya, yaitu dengan mengkombinasikan GARCH dan EVT. GARCH digunakan untuk estimasi volatilitas yang ada pada data log return, sedangkan EVT dengan pendekatan POT digunakan untuk estimasi distribusi residual model GARCH, yang selanjutnya digunakan untuk menaksir nilai VaR. Hasil dari penelitian tersebut menunjukkan bahwa pendekatan GARCH-EVT ini memberikan hasil yang lebih baik daripada metode yang mengesampingkan adanya *fat-tailed* dan sifat volatilitas dari data.

Penelitian mengenai VaR dengan pendekatan EVT telah banyak dilakukan dalam berbagai studi kasus. Andreev, Tinykov, Ovchinnikova dan Parahin (2012) melakukan penelitian tentang perhitungan VaR dengan pendekatan EVT-POT untuk mengatasi error yang mungkin terjadi ketika VaR didekati dengan metode konvensional. Hasil yang diperoleh sesuai dengan dugaan awal yang dibuat, yaitu EVT-POT memberikan hasil yang lebih baik dibandingkan metode konvensional. Penelitian lain yang dilakukan Haryanto (2012) menduga nilai resiko nilai tukar lima mata uang terhadap USD dengan membandingkan metode EVT terhadap pendekatan distribusi transformasi kernel. Hasil perbandingan tersebut menunjukkan perhitungan nilai resiko yang tidak jauh berbeda. Dalam penelitian yang lain, Gencay, Selcukk dan Ulugulyagci (2003) membandingkan perhitungan VaR-EVT dengan metode pemodelan GARCH, Var-Covar, dan Historical simulation. Prediksi kuantil pada model GARCH diketahui berfluktuasi lebih besar dibandingkan pada kuantil model GDP (General Pareto Distribution). Hal ini menunjukkan bahwa GDP lebih robust dalam pemodelan maupun dalam perhitungan VaR. Selain menggambarkan tahapan dalam analisis VaR, Benschlah

(2000) melakukan studi empiris pada data *exchange rate* Dolar Canada/USD selama rentang waktu 5 tahun untuk dilihat besarnya VaR dengan pendekatan EVT. Selanjutnya, Chen (2014) melakukan penelitian dengan tujuan untuk melakukan analisis resiko dari investasi emas dengan aplikasi metode EVT pada data harian harga emas. Ukuran resiko yang diteliti adalah VaR dan *Expected Shortfall* (ES). Hasil estimasi VaR dan ES diperoleh dari proses *fitting* dengan menggunakan model EVT-POT. Hasilnya menunjukkan bahwa harga emas sangat *volatile*, tapi masih lebih aman dibandingkan logam mulia lainnya.

Penelitian yang memasukkan efek volatilitas pada data dan efek *tail* dari distribusi data dilakukan antara lain oleh Fernandes (2000) yang bertujuan untuk melakukan analisis VaR pada aplikasi data return pada Chilean dan US dengan pendekatan EVT-GARCH. Hasil yang diperoleh menunjukkan bahwa pendekatan EVT memberikan hasil yang lebih baik dibanding metode konvensional. Penelitian yang lain dilakukan oleh Singh (2011) menggunakan *univariate* EVT untuk memodelkan data yang mengandung pola ekstrim pada indeks *ASX-All Ordinaries* (Australia) dan S&P-500 (Amerika). Analisis dilakukan dengan membangun model GARCH(1,1) dengan pendekatan PML, selanjutnya melakukan pendekatan EVT pada residual dari model GARCH tersebut. Berdasarkan hasil *backtesting*, EVT memberikan hasil yang lebih baik dibandingkan dengan model GARCH(1,1) dan Riskmetrics. McNeil dan Frey (2000) melakukan analisis serupa dengan studi kasus lima data *log return*, yaitu indeks S&P, indeks DAX, harga saham BMW, kurs USD/Pound, dan harga emas. Penelitian ini melakukan analisis komprehensif untuk mendapatkan nilai VaR dan ES dengan pendekatan GARCH- EVT. Pemilihan nilai *threshold* dilakukan dengan melakukan simulasi *monte carlo* dan tingkat kebaikan model dievaluasi dengan menggunakan metode *backtesting*.

Selaras dengan penelitian-penelitian tersebut, penelitian kali ini difokuskan pada studi kasus data saham perusahaan asuransi *go public* yang tercatat di BEI. Perusahaan asuransi yang dipilih adalah PT. Lippo General Insurance (LPGI), PT. Panin Insurance (PNIN), dan PT. Asuransi Multi Artha Guna (AMAG). Pemilihan ketiga perusahaan tersebut berdasarkan hasil riset yang dilakukan oleh Lembaga Riset Media Asuransi (LRMA) mengenai perusahaan asuransi terbaik tahun 2015. LPGI merupakan asuransi umum terbaik kelompok

ekuitas 0,5 sampai 1,5 triliun rupiah, PNIN merupakan asuransi umum terbaik kelompok ekuitas 200 sampai 500 miliar rupiah. Sedangkan AMAG dipilih sebagai salah satu perusahaan asuransi umum yang tidak masuk dalam kategori terbaik.

Diduga pola volatilitas harga saham tersebut membentuk distribusi dengan *fat tailed*, sehingga pendekatan GARCH-EVT diharapkan memberikan hasil yang lebih *robust* dalam perhitungan *Value at Risk* dibandingkan dengan teknik pemodelan yang sudah ada. Selain itu dilakukan evaluasi terhadap performa *threshold* optimum yang diperoleh dari pendekatan *bootstrap* untuk diaplikasikan pada data dengan tipe distribusi normal dan *fat tailed*.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, rumusan masalah pada penelitian ini adalah bagaimana mendapatkan nilai *threshold* optimum dengan metode *bootstrap* pada data dengan tipe distribusi normal dan *fat tailed* dan melakukan evaluasi terhadap performa nilai tersebut. Untuk melihat apakah pendekatan GARCH-EVT lebih *robust*, perlu diketahui akurasi VaR GARCH-EVT dibandingkan VaR dengan pendekatan ARMA-GARCH, dilihat dari hasil *backtesting*. Pendekatan GARCH-EVT dilakukan dengan tiga pilihan *threshold*, yaitu *threshold* optimum dari studi simulasi, 5% kuantil, dan 10% kuantil.

## 1.3 Tujuan Penelitian

Setelah merumuskan permasalahan yang ingin dikaji dalam penelitian ini, maka tujuan dilakukannya penelitian ini ditetapkan sebagai berikut:

1. Mendapatkan nilai *threshold* optimum dengan metode *bootstrap* pada data dengan tipe distribusi normal dan *fat tailed* dan melakukan evaluasi terhadap performa nilai tersebut.
2. Melakukan estimasi nilai *Value at Risk* return saham dengan pendekatan ARMA-GARCH dan GARCH-EVT dengan tiga pilihan *threshold*, yaitu *threshold* optimum dari studi simulasi, 5% kuantil, dan 10% kuantil.
3. Membandingkan kebaikan model VaR antara pendekatan ARMA-GARCH dan GARCH-EVT dari 3 macam nilai *threshold* (*threshold* optimum dari studi simulasi, 5% dan 10% kuantil) berdasarkan hasil *backtesting*.

#### **1.4 Manfaat Penelitian**

Dengan dilakukannya penelitian ini, diharapkan dapat memberikan manfaat antara lain sebagai berikut :

1. Memberikan masukan kepada para investor mengenai tingkat performa perusahaan asuransi dilihat dari pasar modal.
2. Memberikan referensi penerapan metode GARCH-EVT untuk menghitung VaR dan sebagai masukan untuk penelitian lanjutan.

#### **1.5 Batasan Masalah**

Sebelum melakukan penelitian ini, maka ketiga hal berikut ini penting untuk dijadikan batasan, yaitu:

1. Perhitungan VaR dilakukan secara univariat dengan asumsi variabel makroekonomi dan tingkat performa perusahaan pesaing dianggap tidak memberikan pengaruh.
2. Metode VaR yang digunakan untuk perbandingan adalah metode ARMA-GARCH.
3. Untuk alasan kemudahan perhitungan, analisis volatilitas return saham dilakukan dengan pendekatan GARCH(1,1).

*(Halaman ini sengaja dikosongkan)*

## BAB 2

### KAJIAN PUSTAKA

Pada bagian ini akan dijelaskan teori-teori yang berkaitan dengan analisis yang digunakan dalam penelitian ini, yang meliputi konsep dasar *time series*, model ARIMA, model GARCH, *Extreme Value Theory* untuk perhitungan *Value at Risk*, dan penjelasan mengenai *return* dan tingkat *loss* dari suatu aset/saham.

#### 2.1 Analisis Time Series

Data *time series* merupakan pengamatan yang diambil secara berurutan berdasarkan waktu, contohnya adalah data bulanan, mingguan, harian dan sebagainya. Data *time series* banyak ditemukan pada bidang ekonomi, bisnis, teknik, dan ilmu sosial. Pada penelitian ini, data *time series* yang digunakan adalah data finansial (keuangan). Sifat dasar pada data *time series* adalah adanya keterkaitan waktu antar pengamatan. Teknik analisis yang digunakan untuk mempelajari adanya keterkaitan ini disebut sebagai analisis *time series*, yang memerlukan pengembangan model stokastik dan model dinamis (Box, Jenkins & Reinsel, 2008: 1). Beberapa tujuan dalam mempelajari *time series* antara lain adalah mempelajari fluktuasi observasi dari waktu ke waktu, meramalkan nilai pada waktu yang akan datang serta mengontrol suatu sistem tertentu (Wei, 2006:1).

#### 2.2 Kestasioneran Data

Suatu proses stokastik dikatakan *strictly* stasioner jika sifat-sifat proses tersebut tidak dipengaruhi oleh perubahan waktu, yaitu observasi  $z_1, z_2, \dots, z_n$  akan memiliki sifat distribusi yang sama dengan observasi  $z_{t-k}$ . Dengan kata lain, suatu proses yang stasioner tidak dipengaruhi oleh perubahan waktu  $k$  (Box, Jenkins & Reinsel, 2008: 24). Secara statistik, *series* data  $\{Y_t\}$  dikatakan stasioner dalam *mean* apabila  $E(Y_t) = E(Y_{t-k}) = \mu$  dan stasioner dalam *varians* apabila  $\text{Var}(Y_t) = \text{Var}(Y_{t-k}) = \sigma^2$ .

### 2.2.1 Autocorrelation Function (ACF)

Autokorelasi merupakan kondisi yang menunjukkan adanya korelasi antara data deret waktu  $Y_t$  dengan  $Y_{t-k}$  yang dipisahkan oleh waktu *lag*  $k$ . ACF dapat digunakan untuk mengidentifikasi model deret waktu dan melihat kestasioneran data dalam mean. Berdasarkan Wei (2006), nilai ACF diberikan oleh persamaan berikut ini:

$$\rho_k = \frac{\text{Cov}(Y_t, Y_{t-k})}{\sqrt{\text{Var}(Y_t)}\sqrt{\text{Var}(Y_{t-k})}} \quad (2.1)$$

Fungsi autokorelasi yang dihitung berdasarkan sampel data dituliskan sebagai berikut (Wei, 2006: 20)

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1+k}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, \quad k = 0, 1, 2, \dots, \quad (2.2)$$

dengan  $\bar{Y} = \sum_{i=1}^n \frac{Y_i}{n}$  adalah rata-rata dari data deret waktu,  $\hat{\gamma}_k$  adalah nilai autokovarians pada lag ke- $k$ ,  $\hat{\gamma}_0$  adalah varians dari  $Y_t$ , dan  $n$  adalah banyaknya observasi.

### 2.2.2 Partial Autocorrelation Function (PACF)

*Partial autocorrelation function* (PACF) digunakan untuk mengukur keeratan hubungan antara variabel  $Y_t$  dan  $Y_{t-k}$  setelah mengeliminasi pengaruh dari variabel  $Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-k+1}$  terhadap kedua variabel tersebut. Secara matematis, PACF ditulis sebagai  $\phi_{kk} = \text{Corr}(Y_t, Y_{t-k} | Y_{t-1}, \dots, Y_{t-k+1})$ . Perhitungan PACF empiris dijabarkan oleh Durbin (1960) dalam Wei (2006: 22) yaitu

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad k = 0, 1, 2, \dots, \quad (2.3)$$

dengan  $\hat{\phi}_{k+1, j} = \hat{\phi}_{kj} - \hat{\phi}_{k+1, k+1} \hat{\phi}_{k, k+1-j}$ ,  $j = 1, 2, \dots, k$ ,  $\hat{\rho}_k$  dan  $\hat{\phi}_{kk}$  masing-masing merupakan nilai ACF dan PACF pada *lag* ke- $k$  yang diperoleh dari data empiris.

### 2.2.3 Uji Akar Unit (Unit Root Test)

Uji akar unit pertama kali dikembangkan oleh Dickey dan Fuller yang dikenal dengan uji akar unit Dickey-Fuller (DF). Proses awal unit root dinyatakan dengan:

$$Y_t = \rho Y_{t-1} + \varepsilon_t, \quad -1 \leq \rho \leq 1, \quad (2.4)$$

dengan  $\varepsilon_t$  adalah *error* yang bersifat *white noise*. Jika  $\rho=1$ , maka dikatakan bahwa data deret waktu tersebut mengandung *unit root* atau merupakan proses non stasioner. Untuk menguji *unit root* lebih mudah jika meregresikan  $Y_t$  terhadap lag dari  $Y_{t-1}$  dan mengestimasi nilai  $\rho=1$  sehingga persamaan (2.4) dapat ditulis sebagai berikut:

$$\begin{aligned} Y_t &= \rho Y_{t-1} + \varepsilon_t \\ Y_t - Y_{t-1} &= \rho Y_{t-1} - Y_{t-1} + \varepsilon_t \\ &= (\rho - 1) Y_{t-1} + \varepsilon_t, \end{aligned} \quad (2.5)$$

sehingga menjadi:

$$\Delta Y_t = \delta Y_{t-1} + \varepsilon_t, \text{ dimana } \Delta Y_t = Y_t - Y_{t-1} \text{ dan } \delta = (\rho - 1).$$

Untuk menguji apakah data mengandung unit root atau tidak, Dickey-Fuller menyarankan untuk melakukan tiga model regresi:

$$\Delta Y_t = \delta Y_{t-1} + \varepsilon_t, \quad (2.6)$$

$$\Delta Y_t = \beta_1 + \delta Y_{t-1} + \varepsilon_t, \quad (2.7)$$

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \varepsilon_t, \quad (2.8)$$

Persamaan (2.7) memasukkan unsur konstanta dan persamaan (2.8) memasukkan unsur konstanta dan variabel tren waktu. Dalam setiap model, jika data deret waktu mengandung *unit root* berarti data tidak stasioner. Hipotesis untuk uji *unit root* adalah:

$H_0: \delta = 0$  (data mengandung unit root atau tidak stasioner)

$H_1: \delta < 0$  (data tidak mengandung unit root atau stasioner)

Statistik uji

$$\hat{\tau} = \frac{\hat{\delta}}{s.e.(\hat{\delta})}.$$

Jika nilai  $\hat{\tau}$  lebih kecil dari nilai kritis  $\tau$  *Dickey-Fuller*, dengan derajat bebas  $n$  dan signifikansi  $\alpha$ , maka  $H_0$  ditolak dan data dinyatakan sudah stasioner.

Uji akar unit Dickey-Fuller pada persamaan (2.6), (2.7) dan (2.8) adalah model sederhana dan diasumsikan bahwa  $\varepsilon_t$  tidak berkorelasi. Pada banyak kasus dinyatakan bahwa  $\varepsilon_t$  saling berkorelasi. Dickey-Fuller kemudian mengembangkan uji *unit root* yang disebut *Augmented Dickey-Fuller* (ADF) dengan menambahkan nilai *lag* variabel  $\Delta Y_t$ . Uji ADF merupakan estimasi yang mengikuti regresi berikut:

$$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \sum_{i=1}^l \alpha_i \Delta Y_{t-i} + \varepsilon_t, \quad (2.9)$$

dimana  $\Delta Y_{t-1} = (Y_{t-1} - Y_{t-2})$ ,  $\Delta Y_{t-2} = (Y_{t-2} - Y_{t-3})$ , dan seterusnya. Hipotesis dan uji yang digunakan dalam ADF *test* sama dengan hipotesis dan uji dalam DF *test*.

Suatu deret waktu yang tidak stasioner harus diubah menjadi data stasioner. Pada data yang tidak stasioner dalam varians dilakukan transformasi Box-Cox, sedangkan pada data yang tidak stasioner dalam rata-rata dilakukan *differencing*. *Differencing* adalah menghitung perubahan atau selisih nilai observasi (Wei, 2006). Pada data deret waktu *financial*, kondisi stasioner dalam *mean* umumnya tidak dapat dipenuhi pada data series harga. Sementara itu analisis dengan menggunakan data log *return* umumnya memberikan hasil stasioner dalam *mean* (Tsay, 2005). Untuk kondisi non stasioner dalam varians, umumnya tidak diatasi dengan transformasi, melainkan dengan pemodelan ARCH/GARCH.

### 2.3 Model Autoregressive Moving Average (ARMA)

Model ARMA( $p, q$ ) yang merupakan kombinasi dari model AR( $p$ ) dan MA( $q$ ) digunakan untuk memodelkan series data yang berpola stasioner. Model AR( $p$ ) menjelaskan bahwa observasi ke- $t$  dipengaruhi oleh  $p$  observasi sebelumnya, sedangkan model MA( $q$ ) menjelaskan bahwa observasi ke- $t$  dipengaruhi oleh error pada waktu ke- $t$  dan  $q$  error sebelumnya. Bentuk umum model ARMA( $p, q$ ) adalah sebagai berikut:

$$\phi_p(B)(Y_t - \mu) = \theta_q(B)\varepsilon_t, \quad (2.10)$$

dengan,

$p$  dan  $q$ : Orde model AR dan MA,

$B$  : Operator *backward shift* yang didefinisikan sebagai  $B^j Y_t = Y_{t-j}$ ,

$\phi_p(B)$  : Komponen  $AR(p)$  yang dijabarkan sebagai  $\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ ,

$\theta_q(B)$  : Komponen  $MA(q)$  yang dijabarkan sebagai  $\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ ,

$\mu$  : *Mean* dari *series*  $\{Y_t\}$ , dan

$\varepsilon_t$  : *Error* yang bersifat *white noise* dengan *mean* 0 dan varians  $\sigma_\varepsilon^2$ .

Apabila *series*  $\{Y_t\}$  tidak stasioner dalam *mean*, maka perlu dilakukan *differencing* sebanyak  $d$  kali sampai mendapatkan *series* yang stasioner. Akibatnya, model  $ARMA(p,q)$  akan tereduksi menjadi model  $ARIMA(p,d,q)$  dengan bentuk

$$\phi_p(B)(1-B)^d(Y_t - \mu) = \theta_q(B)\varepsilon_t, \quad (2.11)$$

dengan  $d$  adalah orde *differencing*.

Pemilihan model ARIMA yang sesuai untuk suatu data deret waktu dapat dilakukan dengan menggunakan prosedur Box-Jenkins. Prosedur pembentukan model ARIMA meliputi beberapa tahapan yaitu identifikasi, estimasi, cek diagnosa dan peramalan. Tahap identifikasi dilakukan dengan mengamati plot ACF dan PACF dari data yang selanjutnya digunakan untuk mendapatkan dugaan sementara model ARIMA yang sesuai. Tahap selanjutnya melakukan estimasi dan uji signifikansi parameter apakah model dugaan sementara yang telah diestimasi cukup sesuai dengan data deret waktunya. Tahap cek diagnosa dilakukan pada residual dari model, untuk dilihat apakah bersifat *white noise* dan berdistribusi normal.

### 2.3.1 Identifikasi Orde Model ARMA(p,q)

Penentuan orde dari model  $AR(p)$ ,  $MA(q)$ , dan  $ARMA(p,q)$  dapat dilihat dari plot ACF dan PACF. Karakteristik dari model AR, MA, ARMA, dan ARIMA berdasarkan plot ACF dan PACF yang telah stasioner ditampilkan pada Tabel 2.1 (Bowerman dan O'Connell, 1993:475).

**Tabel 2.1** Pola ACF dan PACF dari Model ARMA ( $p, q$ )

| Proses                      | ACF                             | PACF                            |
|-----------------------------|---------------------------------|---------------------------------|
| AR( $p$ )                   | Turun cepat secara eksponensial | Terpotong setelah lag $p$       |
| MA( $q$ )                   | Terpotong setelah lag $q$       | Turun cepat secara eksponensial |
| AR( $p$ ) atau<br>MA( $q$ ) | Terpotong setelah lag $q$       | Terpotong setelah lag $p$       |
| ARMA( $p, q$ )              | Turun cepat secara Eksponensial | Turun cepat secara Eksponensial |
| White Noise<br>(Random)     | Tidak ada yang signifikan       | Tidak ada yang signifikan       |

### 2.3.2 Estimasi Parameter Model ARMA( $p, q$ )

Salah satu metode yang dapat digunakan untuk mengestimasi parameter model ARMA( $p, q$ ) adalah metode *maximum likelihood estimation* (MLE). Metode tersebut memiliki keunggulan dibandingkan metode lainnya yaitu menggunakan semua informasi yang terdapat dalam data. Selain itu, metode MLE juga dapat menghasilkan informasi dari sampel besar ke dalam kondisi umum.

Bentuk umum model ARMA( $p, q$ ) yang stasioner pada persamaan (2.10) dapat dijabarkan sebagai berikut :

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \phi_2 \dot{Y}_{t-2} + \dots + \phi_p \dot{Y}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}, \quad (2.12)$$

dengan  $\dot{Y}_t = Y_t - \mu$ , dan  $\varepsilon_t$  adalah bersifat *white noise* dan berdistribusi  $N(0, \sigma_\varepsilon^2)$ ,

maka pdf bersama dari  $\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)'$  ditulis sebagai berikut:

$$P(\boldsymbol{\varepsilon} | \boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_\varepsilon^2) = (2\pi\sigma_\varepsilon^2)^{-n/2} \exp\left[-\frac{1}{2\sigma_\varepsilon^2} \sum_{t=1}^n \varepsilon_t^2\right], \quad (2.13)$$

dengan  $\varepsilon_t = \dot{Y}_t - \phi_1 \dot{Y}_{t-1} - \phi_2 \dot{Y}_{t-2} - \dots - \phi_p \dot{Y}_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$ .

Diberikan  $\mathbf{Y} = (Y_1, Y_2, \dots, Y_n)'$ , dan diasumsikan bahwa *initial condition* antara  $\mathbf{Y}_* = (Y_{1-p}, Y_{2-p}, \dots, Y_{-1}, Y_0)'$  dan  $\boldsymbol{\varepsilon}_* = (\varepsilon_{1-q}, \varepsilon_{2-q}, \dots, \varepsilon_{-1}, \varepsilon_0)'$  diketahui, maka fungsi *conditional log-likelihood* didefinisikan sebagai berikut:

$$\ln L_*(\boldsymbol{\varepsilon} | \boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_\varepsilon^2) = -\frac{n}{2} \ln 2\pi\sigma_\varepsilon^2 - \frac{S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})}{2\sigma_\varepsilon^2}, \quad (2.14)$$

dengan fungsi *conditional sum of square* diberikan oleh persamaan berikut ini:

$$S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}) = \sum_{t=1}^n \varepsilon_t^2(\boldsymbol{\phi}, \mu, \boldsymbol{\theta} | \mathbf{Y}_*, \boldsymbol{\varepsilon}_*, \mathbf{Y}). \quad (2.15)$$

Nilai-nilai  $\hat{\boldsymbol{\phi}}$ ,  $\hat{\mu}$ , dan  $\hat{\boldsymbol{\theta}}$  yang memaksimalkan persamaan (2.14) disebut sebagai *conditional maximum likelihood estimator*. Dan dikarenakan fungsi  $\ln L_*(\boldsymbol{\varepsilon} | \boldsymbol{\phi}, \mu, \boldsymbol{\theta}, \sigma_\varepsilon^2)$  melibatkan data hanya pada unsur  $S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})$ , maka estimator yang diperoleh akan sama dengan *conditional least square estimator* yang diperoleh dari meminimalkan fungsi *conditionl sum of square*  $S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})$ , yang diketahui tidak memuat parameter  $\sigma_\varepsilon^2$ .

Terdapat beberapa alternatif dalam menentukan kondisi inisial dari  $\mathbf{Y}_*$  dan  $\boldsymbol{\varepsilon}_*$ . Berdasarkan pada asumsi bahwa variabel  $\{Y_t\}$  bersifat stasioner dengan  $\varepsilon_t$  yang memenuhi asumsi  $N(0, \sigma^2)$ , maka nilai  $Y_t$  dan  $\varepsilon_t$  yang tidak diketahui masing-masing dapat digantikan dengan nilai  $\bar{Y}$  dan 0 sehingga didapatkan  $S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta})$  dan didefinisikan sebagai berikut:

$$S_*(\boldsymbol{\phi}, \mu, \boldsymbol{\theta}) = \sum_{t=p+1}^n \varepsilon_t^2(\boldsymbol{\phi}, \mu, \boldsymbol{\theta} | \mathbf{Y}). \quad (2.16)$$

Dengan demikian, berdasarkan Wei (2006), nilai  $\sigma_\varepsilon^2$  dapat diestimasi menggunakan persamaan (2.17) sebagai berikut:

$$\hat{\sigma}_\varepsilon^2 = \frac{S_*(\hat{\boldsymbol{\phi}}, \hat{\mu}, \hat{\boldsymbol{\theta}})}{n - (2p + q + 1)}. \quad (2.17)$$

### 2.3.3 Cek Diagnosa

Pembentukan model ARMA memiliki dua asumsi yang harus dipenuhi yaitu residual yang didapatkan bersifat *white noise* dan berdistribusi normal. Proses disebut *white noise* jika  $\varepsilon_t$  bersifat identik dan independen terhadap fungsi distribusi yang lain dengan  $E(\varepsilon_t) = 0$  dan  $\text{var}(\varepsilon_t) = \sigma_\varepsilon^2$  (Wei, 2006:153). Pengujian asumsi independen dilakukan dengan menggunakan uji *Ljung-Box* yang didasarkan pada nilai ACF dengan hipotesis sebagai berikut:

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

$H_1$  : minimal terdapat satu  $\rho_k$  yang tidak sama dengan nol,  $k= 1,2,\dots,K$

Statistik uji

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

dengan  $n$  adalah banyaknya residual,  $\hat{\rho}_k$  adalah nilai autokorelasi residual pada lag ke- $k$ , dan  $m$  merupakan orde ARMA ( $m = p + q$ ). Jika  $Q > \chi^2_{(\alpha; K-m)}$ , maka tolak  $H_0$  dan dikatakan bahwa residual saling independen.

Varians residual dikatakan homogen jika tidak terdapat korelasi antar kuadrat residual. Pengujian asumsi varians residual homogen dilakukan dengan menggunakan uji portmanteau  $Q$  dengan hipotesis sebagai berikut (Wei, 2006:373):

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

$H_1$  : minimal terdapat satu  $\rho_i \neq 0, i = 1, 2, \dots, k$

Statistik uji:

$$Q(k) = n(n+2) \sum_{i=1}^k (n-i)^{-1} \hat{\rho}_i^2 (\hat{\varepsilon}_i^2),$$

daerah penolakan : tolak  $H_0$  jika  $Q > \chi^2_{(\alpha; k)}$

dengan  $n$  adalah banyaknya residual, dan  $\hat{\rho}_i (\hat{\varepsilon}_i^2)$  adalah ACF dari residual kuadrat pada lag ke- $i$ . Jika  $Q > \chi^2_{(\alpha; k)}$ , maka dikatakan bahwa residual homogen.

Asumsi lain yang harus dipenuhi yaitu residual berdistribusi normal. Pengujian kenormalan dapat dihitung dengan menggunakan Kolmogorov-Smirnov dengan hipotesis sebagai berikut:

$H_0 : F(\varepsilon_t) = F_0(\varepsilon_t)$  (residual berdistribusi normal)

$H_1 : F(\varepsilon_t) \neq F_0(\varepsilon_t)$  (residual tidak berdistribusi normal)

Statistik uji :

$$D = \sup_x |F(\varepsilon_t) - F_0(\varepsilon_t)|,$$

dengan  $F(\varepsilon_t)$  adalah fungsi peluang kumulatif yang dihitung dari data sampel,  $F_0(\varepsilon_t)$  adalah fungsi peluang kumulatif distribusi normal atau fungsi yang

dihipotesiskan., dan  $sup$  adalah nilai supremum (maksimum) semua  $x$  dari  $|F(\varepsilon_t) - F_0(\varepsilon_t)|$ . jika  $D > D_{(\alpha;n)}$ , maka tolak  $H_0$  dan dinyatakan bahwa residual tidak berdistribusi normal.

### 2.3.4 Pemilihan Model Terbaik

Pendugaan model ARMA sering kali tidak tunggal sehingga diperlukan suatu kriteria tertentu untuk memilih model terbaik dari beberapa model yang didapatkan. Menurut Wei (2006: 156), kriteria yang dapat digunakan sebagai alternatif untuk memilih model ARMA terbaik berdasarkan residual yaitu AIC (*Akaike's Information Criterion*) dan SBC (*Schwartz's Bayesian Criterion*). AIC dikembangkan oleh Akaike (1973) yang didefinisikan sebagai berikut:

$$AIC(M) = n \ln \hat{\sigma}_\varepsilon^2 + 2M \quad , \quad (2.18)$$

dengan  $M$  merupakan banyaknya parameter dari model,  $\hat{\sigma}_\varepsilon^2$  merupakan estimasi MLE dari  $\sigma_\varepsilon^2$  dan  $n$  adalah jumlah pengamatan.

SBC dikenalkan oleh Schwartz (1978) yang didasarkan pada pengembangan konsep bayesian untuk meminimumkan proses AIC. SBC didefinisikan sebagai berikut:

$$SBC(M) = n \ln \hat{\sigma}_\varepsilon^2 + M \ln n \quad . \quad (2.19)$$

Jika terdapat dua atau lebih model ARMA, maka pemilihan model terbaik dilakukan dengan melihat nilai AIC dan SBC yang paling minimum dari semua model yang didapatkan.

## 2.4 Generalized Autoregressive Conditional Heteroscedasticity (GARCH)

Data deret waktu finansial telah diteliti memiliki bentuk *volatility clustering*, yaitu pada suatu periode tertentu memiliki volatilitas tinggi dan di periode lain memiliki volatilitas yang rendah (Tsay, 2005: 98). Hal ini terjadi terus menerus sepanjang waktu sehingga data deret waktu finansial memiliki varians bersyarat yang tidak tetap atau dapat juga dikatakan bersifat tidak stasioner dalam varians. Untuk mengatasi kondisi kondisi tersebut, Engle (1982) mengembangkan model ARCH (*Autoregressive Conditional Heteroscedasticity*) yang merupakan

fungsi dari error yang terjadi pada waktu sebelumnya dengan varians bersyarat yang tidak konstan dan varians tidak bersyarat konstan.

### 2.4.1 Uji Heteroskedastisitas

Untuk mengidentifikasi apakah suatu model tersebut mengandung ARCH/GARCH maka dapat dilakukan dengan cara menghitung nilai ACF dan PACF dari kuadrat residual yang dihasilkan oleh model ARIMA dan dapat juga memakai uji *Lagrange Multiplier* (LM).

Untuk menguji adanya heteroskedastisitas dalam varians residual dengan pendekatan ACF dan PACF, digunakan langkah sebagai berikut (Wei, 2006: 372):

1. Melakukan pemilihan model terbaik dengan menggunakan model ARIMA sehingga diperoleh nilai residualnya dan setelah itu masing-masing residual dikuadratkan. Nilai tersebut digunakan untuk menghitung varians sampel residual sebagai berikut:

$$\hat{\sigma}_\varepsilon^2 = \sum_{t=1}^n \frac{\varepsilon_t^2}{n} \quad (2.20)$$

dengan  $n$  adalah banyaknya residual.

2. Menghitung dan membuat plot autokorelasi sampel dari kuadrat residual dengan formula:

$$\rho(i) = \frac{\sum_{t=i+1}^n (\hat{\varepsilon}_t^2 - \hat{\sigma}^2)(\hat{\varepsilon}_{t-i}^2 - \hat{\sigma}^2)}{\sum_{t=1}^n (\hat{\varepsilon}_t^2 - \hat{\sigma}^2)^2} \quad (2.21)$$

Dengan cara yang sama dilakukan perhitungan untuk PACF. Selanjutnya dilakukan pengecekan apakah ACF dan PACF tersebut membentuk suatu pola. Keberadaan pola pada plot tersebut selain mengindikasikan adanya ARCH/GARCH, dapat digunakan sebagai dugaan order model tersebut.

Pengujian lain yang digunakan untuk melihat adanya efek heteroskedastisitas adalah uji LM. Misalkan terdapat suatu proses AR(p), tahapan uji LM yang diusulkan oleh Engle (1982) untuk menguji adanya proses ARCH yaitu:

1. Menggunakan metode kuadrat terkecil untuk mendapatkan AR (p):

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.22)$$

2. Menghitung besarnya kuadrat residual, kemudian meregresikan nilai tersebut sehingga diperoleh taksiran sebagai berikut:

$$\hat{\varepsilon}_t^2 = \hat{\alpha}_0 + \hat{\alpha}_1 \hat{\varepsilon}_{t-1}^2 + \dots + \hat{\alpha}_p \hat{\varepsilon}_{t-p}^2. \quad (2.23)$$

3. Melakukan pengujian parameter:

$$H_0 : \alpha_1 = \dots = \alpha_p = 0$$

$$H_1 : \text{minimal ada satu } \alpha_i \neq 0, i = 1, 2, \dots, p$$

Statistik Uji:

$n'R^2$  dengan  $n' = n - p$ , dimana  $n$  adalah jumlah residual dibawah  $H_0$ .

Tolak  $H_0$  jika  $n'R^2 > \chi_p^2$ , yang berarti bahwa terdapat efek ARCH dalam model.

#### 2.4.2 Model Autoregressive Conditional Heteroscedasticity (ARCH)

Sebelum mendefinisikan proses ARCH pada data deret waktu, pertama perlu diketahui perbedaan antara varians bersyarat dengan varians tidak bersyarat. Dimisalkan model AR(1), rata-rata bersyarat dari  $Y_t$  adalah  $\phi_1 Y_{t-1}$  sedangkan rata-rata tidak bersyarat adalah nol (Engle, 1982).

Sebagaimana diasumsikan bahwa  $Var(\varepsilon_t) = \sigma_\varepsilon^2$  yang juga merupakan varians bersyarat terhadap  $Y_{t-1}$ . Artinya  $Y_{t-1}$  konstan dan sumber variasi dari  $Y_t$  adalah  $\varepsilon_t$ . Dapat ditunjukkan sebagai berikut:

$$\begin{aligned} Var(Y_t | Y_{t-1}) &= Var[(\phi_1 Y_{t-1} + \varepsilon_t) | Y_{t-1}] \\ &= Var(\phi_1 Y_{t-1} | Y_{t-1}) + Var(\varepsilon_t | Y_{t-1}) \\ &= 0 + Var(\varepsilon_t | Y_{t-1}) \\ &= \sigma_\varepsilon^2 \end{aligned}$$

dengan asumsi varians bersyarat  $\varepsilon_t$  konstan. Jika varians bersyarat tidak konstan, maka varians bersyarat terhadap  $Y_{t-1}$  adalah

$$Var(\varepsilon_t | Y_{t-1}) = \sigma_t^2 \quad (2.24)$$

Sedangkan untuk varians tidak bersyarat adalah:

$$\begin{aligned} Var(Y_t) &= Var(\phi_1 Y_{t-1} + \varepsilon_t) \\ &= \phi_1^2 Var(Y_{t-1}) + Var(\varepsilon_t) \end{aligned}$$

dengan  $Var(Y_t) = Var(Y_{t-1}) = \sigma_y^2$  dan  $Var(\varepsilon_t) = \sigma_\varepsilon^2$ .

Varians tidak bersyarat adalah  $\sigma_y^2$ . Jika dibandingkan varians bersyarat dengan varians tidak bersyarat terhadap  $Y_{t-1}$ , didapatkan bahwa varians tidak bersyarat kemungkinan konstan, sedangkan varians bersyarat kemungkinan bervariasi dari waktu ke waktu (tidak konstan).

Untuk itu, Engle (1982) mengusulkan suatu model untuk varians tidak konstan yang tergantung pada nilai-nilai masa lalu atau dikenal sebagai model *Autoregressive Conditional Heteroscedasticity* (ARCH), yang didefinisikan sebagai

$$\varepsilon_t = e_t \sigma_t \quad (2.25)$$

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t) \quad (2.26)$$

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \quad (2.27)$$

dengan  $e_t \sim N(0,1)$  dan  $\sigma_t$  positif. Model diatas disebut sebagai model ARCH(1).

Fungsi untuk varians waktu adalah  $\psi_{t-1} = (Y_{t-1}, Y_{t-2}, \dots)$ , yang merupakan himpunan informasi yang tersedia pada waktu  $t-1$ .

### 2.4.3 Model Generalized ARCH (GARCH)

Pada dasarnya model ARCH dengan GARCH adalah sama, yang membedakan adalah model GARCH tidak hanya tergantung pada kuadrat *error* waktu sebelumnya tetapi juga tergantung pada varians waktu sebelumnya. Sedangkan model ARCH hanya tergantung pada kuadrat *error* waktu sebelumnya. Model GARCH( $p, q$ ) dinyatakan sebagai (Bollerslev, 1986):

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t)$$

dengan

$$\begin{aligned} h_t &= \alpha_0 + \beta_1 h_{t-1} + \beta_2 h_{t-2} + \dots + \beta_p h_{t-p} + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 \\ &= \alpha_0 + \sum_{i=1}^p \beta_i h_{t-i} + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 \end{aligned} \quad (2.28)$$

dimana,  $\alpha_0 > 0$ ,  $\alpha_i \geq 0$  untuk  $i = 1, 2, \dots, p$  dan  $\beta_i \geq 0$  untuk  $i = 1, 2, \dots, q$ .

Untuk lebih sederhana dimisalkan proses GARCH(1, 1)

$$\varepsilon_t | \psi_{t-1} \sim N(0, h_t)$$

dengan

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \quad (2.29)$$

dimana  $\alpha_0 > 0$ ,  $\alpha_1 \geq 0$  dan  $\beta_1 \geq 0$ .

$$\frac{\varepsilon_t}{\sqrt{h_t}} | \psi_{t-1} \sim N(0,1)$$

Urutan  $Z_1, Z_2, \dots, Z_T$  didefinisikan dengan  $Z_t = \frac{\varepsilon_t}{\sqrt{h_t}}$  yang selanjutnya nilai  $Z_t$

ini digunakan untuk analisis lanjutan untuk estimasi VaR dengan pendekatan EVT POT.

## 2.5 Extreme Value Theory dan Value at Risk

*Value at risk* (VaR) merupakan suatu alat pengukuran resiko yang digunakan untuk memprediksi besarnya kerugian maksimal dari suatu portofolio dalam kurun waktu tertentu dengan tingkat keyakinan yang ditetapkan. Misalkan F adalah distribusi kerugian Y dari suatu investasi dalam kurun waktu tertentu dan  $0 < q^* < 1$ , dimana nilai  $q^*$  yang biasa digunakan adalah  $q^* = 0,95$  dan  $q^* = 0,99$ . Maka, nilai value at risk didefinisikan sebagai nilai kuantil ke- $q^*$  dari distribusi F.

$$VaR_{q^*}(Y) = y_{q^*} = F^{-1}(q^*) \quad (2.30)$$

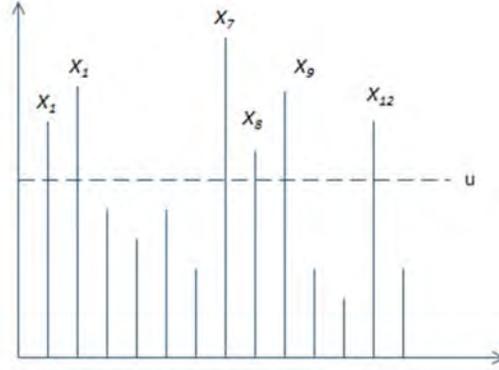
Menurut Franke, Hardle dan Hafner (2011), disebutkan bahwa distribusi dari return yang seringkali memiliki bentuk leptokurtosis (*fat-tailed*) menyebabkan kerugian lebih sering muncul jika dianalisis dengan asumsi normalitas. Untuk resiko ekstrim pada kuantil atas dan pada investasi beresiko tinggi, penaksiran VaR akan mendapatkan nilai yang *under-estimate*. Pendekatan *Extreme Value Theory* (EVT) dapat menjadi alternatif solusi untuk mengatasi kondisi ekstrim tersebut. Berbeda dengan pendekatan konvensional yang dijelaskan, EVT dapat memodelkan titik ekstrim pada kuantil secara lebih baik (Bensalah, 2000). Dalam EVT, terdapat dua metode dalam menjelaskan perilaku nilai ekstrim pada distribusi data, yaitu *Block Maxima Model* (BMM) dan *Peak Over Threshold* (POT). Metode

BMM memodelkan distribusi asimtotik dari observasi maximum (minimum), yang selanjutnya mengikuti salah satu dari ketiga distribusi Gumbel, Frechet, atau Weibull. Bentuk standar dari ketiga distribusi tersebut diberikan oleh distribusi *Generalized Extreme Value* (GEV). Metode yang kedua, yaitu POT, memodelkan distribusi dari pengamatan yang melebihi suatu nilai threshold yang ditetapkan. Distribusi tersebut berupa *Generalized Pareto Distribution* (GPD), (Franke, Hardle, and Hafner, 2011).

Menurut Coles (2001) memodelkan dengan menggunakan BMM seringkali kurang memberi informasi karena hanya nilai maksimum dari masing-masing blok yang dikategorikan sebagai ekstrim. Kondisi ini diperparah jika dalam blok tertentu mengandung kejadian ekstrim yang lebih sering dibandingkan blok lainnya. Jika pada data serial tersedia informasi mengenai data sampai level jam ataupun data harian, maka akan lebih baik jika keseluruhan data dilibatkan, tanpa membuat blok. Di sisi lain, pendekatan POT dapat menganalisis data dengan lebih efisien dan dipandang lebih aplikatif (McNeil, Frey & Embrecht, 2005). Sehingga metode EVT yang selanjutnya digunakan dalam penelitian ini difokuskan pada pendekatan POT.

### 2.5.1 Metode Peak Over Threshold (POT)

Pendekatan yang digunakan dalam menentukan nilai ekstrim pada metode POT ini berdasarkan suatu nilai patokan yang disebut *threshold*. Terdapat suatu sampel pengamatan  $Y_t$ ,  $t = 1, 2, \dots, n$ , dengan fungsi distribusi  $F(x) = P\{X_t \leq x\}$ . Untuk menentukan nilai ekstrim dari sampel tersebut, ditentukan nilai *threshold*,  $u$ . Gambar 2.1 berikut ini memberikan gambaran lebih jelas mengenai konsep metode POT. Nilai ekstrim diperoleh jika  $X_t > u$  untuk semua  $t$ , dimana  $t = 1, 2, \dots, n$  dan diberikan oleh  $y = X_t - u$ . Pada ilustrasi, nilai-nilai ekstrim yang diidentifikasi melebihi threshold,  $u$  ditunjukkan oleh nilai  $X_1, X_2, X_7, X_8, X_9$ , dan  $X_{12}$ .



**Gambar 2.1** Ilustrasi pemilihan nilai ekstrim metode *Peak Over Threshold*

Diberikan distribusi probabilitas untuk  $y$ ,  $F_u(y) = P\{X - u \leq y \mid X > u\}$ , yang juga dapat dituliskan dalam bentuk berikut ini,

$$F_u(y) = \frac{P\{X - u \leq y, X > u\}}{P(X > u)} \quad (2.31)$$

$$= \frac{F(y+u) - F(u)}{1 - F(u)},$$

dan karena  $x = y + u$  untuk  $X > u$ , persamaan di atas dapat dituliskan dalam

$$F(x) = [1 - F(u)]F_u(y) + F(u), \quad X > u. \quad (2.32)$$

Semakin tinggi nilai *threshold*,  $u$ , maka data ekstrim akan semakin mengikuti distribusi *Generalized Pareto Distribution* (GPD). Secara umum, GPD diberikan sebagai berikut:

$$G(x-u) = \begin{cases} 1 - \left(1 + \xi \left(\frac{x-u}{\sigma}\right)\right)^{-1/\xi}, & 0 \leq (x-u) \leq u - \frac{\sigma}{\xi} & \text{jika } \xi < 0 \\ & 0 \leq (x-u) \leq \infty & \text{jika } \xi > 0 \\ 1 - \exp\left(-\frac{(x-u)}{\sigma}\right), & & \xi = 0 \end{cases}, \quad (2.33)$$

dengan  $\sigma$  adalah parameter skala (*scale*), dan  $\xi$  adalah parameter bentuk (*shape*).

Berdasarkan nilai parameter bentuk ( $\xi$ ), nilai  $\xi > 0$  mengindikasikan bahwa GPD berdistribusi Pareto, yang merupakan kasus yang paling relevan dalam analisis *time series* finansial dikarenakan terdapat *fat tailed* pada distribusinya. Kategori kedua adalah jika  $\xi = 0$  maka GPD akan berdistribusi eksponensial, dan berdistribusi

pareto tipe 2 jika  $\xi < 0$ . Nilai *tail* pada GPD juga memberikan interpretasi lain, yaitu jika  $\xi < 0$ , maka nilai ekstrim akan memiliki batasan yang terbatas. Sedangkan jika  $\xi \geq 0$ , maka nilai ekstrim memiliki batasan yang tidak terbatas. Semakin besar nilai  $\xi$  maka ekor distribusi akan semakin gemuk (*fat tailed*) yang berdampak peluang terjadinya nilai ekstrim semakin besar.

Selanjutnya untuk mendapatkan estimator untuk ekor distribusi, persamaan (2.32) dapat ditulis ulang dengan nilai  $F_u(y)$  didekati dengan GPD fungsi pada persamaan (2.33). Sehingga diperoleh hasil sebagai berikut,

$$F(x) = [1 - F(u)]G(x-u) + F(u) \quad (2.34)$$

Dan dengan menentukan *threshold* yang tinggi sebesar  $u$ , nilai  $F(u)$  dapat didefinisikan sebagai  $(n - n_u)/n$ , dengan  $n$  adalah ukuran sampel, sedangkan  $n_u$  adalah jumlah pengamatan yang melebihi *threshold*. Sebagai hasilnya, diperoleh persamaan baru sebagai berikut,

$$\begin{aligned} \hat{F}(x) &= \left[1 - \frac{n - n_u}{n}\right]G(x-u) + \frac{n - n_u}{n} \\ &= \frac{n_u}{n}G(x-u) + \frac{n - n_u}{n} \\ &= 1 + \frac{n_u}{n}(G(x-u) - 1) . \end{aligned}$$

Sehingga estimator untuk ekor distribusi (*tail estimator*) adalah,

$$\hat{F}(x) = 1 - \frac{n_u}{n} \left(1 + \hat{\xi} \left(\frac{x-u}{\hat{\sigma}}\right)\right)^{-1/\hat{\xi}}, \quad (2.35)$$

dengan  $\hat{\xi}$  dan  $\hat{\sigma}$  adalah estimator MLE dari parameter distribusi GPD.

Dalam aplikasi pada penelitian ini, prosedur perhitungan estimasi kuantil pada distribusi GPD akan sedikit dimodifikasi, yaitu jumlah data pada ekor distribusi  $n_u = k$ , dimana  $k \ll n$ . Sehingga nilai *threshold* diberikan oleh data ke- $(k+1)$  pada statistik order. Misalkan  $z_{(1)} \geq z_{(2)} \geq \dots \geq z_{(n)}$  adalah residual model GARCH (1,1) yang telah diurutkan. Maka GPD dengan parameter  $\hat{\xi}$  dan  $\hat{\sigma}$  akan sesuai dengan data  $(z_{(1)} - z_{(k+1)}, \dots, z_{(k)} - z_{(k+1)})$ , yaitu selisih data ekstrim terhadap

*threshold*  $z_{(k+1)}$ . Maka bentuk persamaan estimator ekor distribusi pada (2.35) menjadi sebagai berikut ini :

$$\hat{F}(z) = 1 - \frac{k}{n} \left( 1 + \hat{\xi} \left( \frac{z - z_{(k+1)}}{\hat{\sigma}} \right) \right)^{-1/\hat{\xi}} . \quad (2.36)$$

### 2.5.2 Bootstrap untuk mendapatkan *threshold optimum*

Pemilihan *threshold* dilakukan dengan menggunakan metode *double bootstrap* yang diperkenalkan oleh Danielsson et al. (2001). Misalkan terdapat residual  $Z_1, Z_2, \dots, Z_n$  adalah variabel random yang i.i.d dari suatu data dengan distribusi *fat-tailed* dengan fungsi distribusi  $F$ , dan memiliki *tail index*  $1/\gamma$ . Tujuannya adalah untuk meminimize MSE asimtotik (AMSE) dari estimator  $\hat{\gamma} = \gamma_n$  dengan memilih nilai  $k$  tertentu, dan  $\gamma$  diestimasi menggunakan estimator Hill, yang berdistribusi normal asimtotik,

$$\gamma_n(k) = \frac{1}{k} \sum_{i=1}^k (\log Z_{n,(n-i+1)} - \log Z_{n,(n-k)}) \quad (2.37)$$

AMSE dari  $\gamma_n$  diberikan oleh

$$AMSE(n, k) = Asym E (\gamma_n(k) - \gamma)^2 \quad (2.38)$$

Nilai AMSE diberikan oleh prosedur bootstrap untuk mendapatkan nilai  $k$  optimum (*minimized*). Resample  $Z_{n_1}^* = \{Z_1^*, \dots, Z_{n_1}^*\}$  diambil dengan pengembalian dari kelompok  $Z_n = \{Z_1, Z_2, \dots, Z_n\}$  dan untuk  $k_1 < n_1$ , dihitung

$$\gamma_{n_1}^*(k_1) = \frac{1}{k_1} \sum_{i=1}^{k_1} (\log Z_{n_1,(n_1-i+1)} - \log Z_{n_1,(n_1-k)}) \quad (2.39)$$

Penaksiran AMSE oleh bootstrap diberikan oleh:

$$\widehat{AMSE}(n_1, k_1) = E \left[ (\gamma_{n_1}^*(k) - \gamma_n(k)) \mid Z_n \right] \quad (2.40)$$

dimana  $k$  dipilih sedemikian hingga  $\gamma_n(k)$  konsisten. Dikarenakan  $k$  tidak diketahui, maka  $\gamma_n(k)$  pada persamaan (2.39) diberikan oleh persamaan berikut ini:

$$M_{n_1}(k_1) = \frac{1}{k_1} \sum_{i=1}^{k_1} (\log Z_{n_1,(n_1-i+1)} - \log Z_{n_1,(n_1-k)}) \quad (2.41)$$

yang selanjutnya diestimasi menggunakan *bootstrap*,

$$M_{n_1}^*(k_1) = \frac{1}{k_1} \sum_{i=1}^{k_1} \left( \log Z_{n_1, (n_1-i+1)}^* - \log Z_{n_1, (n_1-k)}^* \right) \quad (2.42)$$

Penaksiran AMSE untuk  $n_1$  dan  $k_1$  oleh *bootstrap* diberikan oleh:

$$Q(n_1, k_1) = E \left[ \left( M_{n_1}^*(k) - 2(\gamma_{n_1}^*)^2 \right) \middle| Z_n \right] \quad (2.43)$$

Untuk nilai  $n_1$  tertentu, nilai  $k_1$  dicoba berulang kali hingga mendapatkan nilai optimal  $\hat{k}_{n_1}^*$  yang diperoleh dari meminimalkan  $Q(n_1, k_1)$ . Prosedur yang sama digunakan untuk nilai  $n_2$  yang lebih kecil ( $n_1^2/n$ ), untuk selanjutnya didapatkan nilai optimal optimal  $\hat{k}_{n_2}^*$  yang diperoleh dengan meminimalkan  $Q(n_2, k_2)$ .

Selanjutnya ditentukan nilai  $n_1$  tertentu yang berbeda dari sebelumnya, kemudian dicari nilai  $\hat{k}_{n_1}^*$  dan  $\hat{k}_{n_2}^*$  optimal. Diulang seterusnya sampai diperoleh nilai  $n_1$  yang meminimalkan

$$R_{n_1} = \frac{\left( Q(n_1, k_{n_1}^*) \right)^2}{Q(n_1, k_{n_1}^*)}.$$

Selanjutnya dengan  $n_1$  dan  $n_2$ , dan nilai optimal  $\hat{k}_{n_1}^*$  dan  $\hat{k}_{n_2}^*$ , maka nilai optimal dari fraksi observasi di bagian ekor distribusi diberikan oleh :

$$\hat{k}_n^{opt} = \left[ \frac{\left( \hat{k}_{n_1}^* \right)^2}{\hat{k}_{n_2}^*} \left[ \frac{\left( \log \hat{k}_{n_1}^* \right)^2}{2 \log n_1 - \log \hat{k}_{n_1}^*} \right]^{\left( \log n_1 - \log \hat{k}_{n_1}^* \right) / \log n_1} \right] \quad (2.44)$$

### 2.5.3 Distribusi Normal, Student-t, Frechet dan Gumbel

Simulasi pemilihan *threshold* optimum yang dijelaskan dalam sub bab sebelumnya dilakukan terhadap 4 jenis distribusi, yaitu distribusi normal, student-t, frechet dan gumbel. Karakteristik masing-masing distribusi tersebut dijelaskan sebagaimana berikut ini:

a. Distribusi Normal

Distribusi normal merupakan distribusi probabilitas yang paling banyak digunakan dalam analisis statistika. Distribusi ini sangat penting dikarenakan adanya *central limit theory* yang menyebutkan bahwa rata-rata dari variable random yang saling independen akan berdistribusi normal jika jumlah sampelnya besar. Fungsi kepadatan peluang (pdf) normal adalah sebagai berikut:

$$f(x | \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2}\left(\frac{x - \mu}{\sigma}\right)^2\right), \quad (2.45)$$

dengan  $\mu$  menyatakan rata-rata atau ekspektasi dari distribusi datanya, dan  $\sigma$  menyatakan ukuran standar deviasi.

Bentuk sederhana dari distribusi normal adalah distribusi normal standar. Yaitu distribusi normal dengan kondisi rata-rata 0 dan standar deviasi 1. Distribusi normal standar seringkali digunakan sebagai Patoka dalam mencari probabilitas terjadinya suatu kejadian, demikian juga digunakan dalam membuat *confidence interval* dan statistik uji. Fungsi kepadatan peluang (pdf) normal standar adalah:

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

b. Distribusi Student-t

Dalam statistika probabilitas, distribusi *Student's t* atau dikenal dengan distribusi-t, merupakan bagian dari distribusi kontinu yang muncul ketika melakukan penaksiran rata-rata dari populasi berdistribusi normal dengan kondisi jumlah sampel kecil. Distribusi ini dikembangkan oleh William S. Gosset di bawah *pseudonym Student*. Jika distribusi normal memberikan gambaran untuk populasi secara keseluruhan, maka distribusi-t memberikan gambaran mengenai sampel yang diambil dari populasi.

Misalkan sampel diambil dari  $n$  pengamatan berdistribusi normal, distribusi-t dengan derajat bebas  $\nu = n - 1$  dapat didefinisikan sebagai distribusi lokasi dari rata-rata yang sesungguhnya (*true mean*) relatif terhadap rata-rata sampel dibagi dengan standar deviasi, setelah sebelumnya dikalikan dengan nilai

normalisasi  $\sqrt{n}$ . Dalam pendekatan ini, distribusi-t digunakan untuk menaksir selang kepercayaan rata-rata. Fungsi kepadatan peluang (pdf) distribusi-t adalah:

$$f(t) = \frac{\Gamma\left(\frac{v+1}{2}\right)}{\sqrt{v\pi}\Gamma\left(\frac{v}{2}\right)} \left(1 + \frac{t^2}{v}\right)^{-\frac{v+1}{2}}, \quad (2.47)$$

dengan  $v$  adalah jumlah derajat bebas dan  $\Gamma$  adalah fungsi gamma.

#### c. Distribusi Frechet

Distribusi Frechet juga dikenal sebagai invers dari distribusi Weibull, dan merupakan contoh khusus dari distribusi nilai ekstrim (*generalized extreme value distribution*). Fungsi distribusi kumulatif dari distribusi Frechet adalah:

$$F(x; \alpha, m, s) = e^{-\left(\frac{x-m}{s}\right)^{-\alpha}}, \quad (2.48)$$

dengan  $\alpha > 0$  adalah parameter bentuk,  $m$  adalah parameter lokasi, dan  $s > 0$  adalah parameter skala. Distribusi Frechet masuk ke dalam distribusi *max stable*. Sedangkan distribusi Frechet dengan variabel random bernilai negatif merupakan distribusi *min stable*.

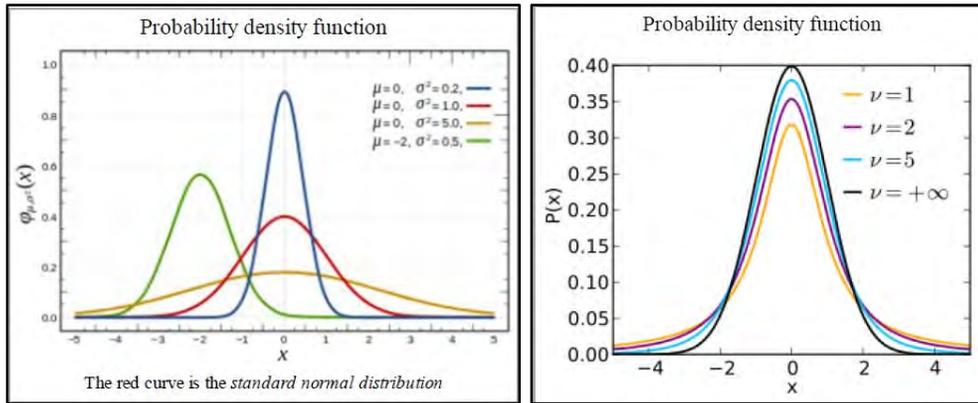
#### d. Distribusi Gumbel

Distribusi gumbel digunakan untuk memodelkan distribusi minimum ataupun maksimum dari sejumlah sampel dengan bermacam-macam distribusi. Distribusi ini sangat bermanfaat dalam memprediksi kejadian ekstrim. Distribusi gumbel merupakan bentuk khusus dari *generalized extreme distribution*. Selain itu juga dikenal sebagai distribusi log-weibull ataupun distribusi *double exponential*. Fungsi distribusi kumulatif dari distribusi gumbel adalah:

$$F(x; \mu, \beta) = e^{-e^{-(x-\mu)/\beta}}, \quad (2.49)$$

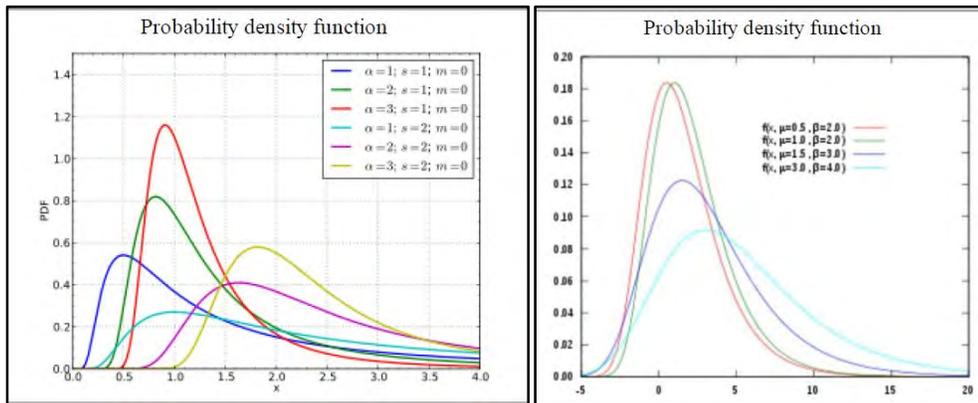
dengan  $\mu$  adalah parameter lokasi, dan  $\beta$  adalah parameter skala.

Sebagai gambaran mengenai bentuk distribusi-distribusi di atas, Gambar 2.2 berikut ini memberikan pdf masing-masing distribusi dengan beberapa macam setting parameter.



(a)

(b)



(c)

(d)

**Gambar 2.2** pdf dari distribusi normal (a), student's t (b), frechet (c) dan gumbel (d)

### 2.5.4 Perhitungan VaR Pendekatan GARCH-EVT

Setelah diperoleh nilai dugaan untuk parameter bentuk ( $\xi$ ) dan parameter skala ( $\sigma$ ), EVT dapat dimanfaatkan untuk mendapatkan taksiran nilai VaR. Dengan nilai probabilitas  $q^* > F(u)$ , nilai VaR yang merupakan estimator quantil pada metode POT, diperoleh dengan melakukan invers terhadap persamaan tail pada persamaan (2.23). Hasilnya diberikan oleh persamaan berikut ini

$$VaR_t(\alpha) = z_{(k+1)} + \frac{\hat{\sigma}}{\xi} \left[ \left( \frac{1-q^*}{k/n} \right)^{-\xi} - 1 \right] \quad (2.50)$$

dimana,  $z_{(k+1)} = threshold$

$\hat{\sigma}$  = estimator parameter *scale*

$\hat{\xi}$  = estimator parameter *shape*

$n$  = ukuran sampel

$k$  = pengamatan yang melebihi batas *threshold*

Dengan menggunakan model GARCH(1,1) untuk menangani volatilitas data finansial, maka ramalan VaR 1 hari ke depan dalam penelitian ini disebut dengan pendekatan GARCH-EVT, atau disebut juga *dynamic Value at Risk* (Singk, et al., 2011) yang dihitung berdasarkan persamaan berikut ini:

$$VaR_q = \hat{\mu}_{t+1} + \hat{\sigma}_{t+1} VaR_t(\alpha) \quad (2.51)$$

Menurut McNeil dan Frey (2000) pendekatan GARCH-EVT ini dilakukan dalam 2 tahap, yaitu :

1. Memodelkan data dengan pendekatan GARCH(1,1). Model ini menghasilkan residual yang akan digunakan pada (2) dan juga peramalan 1 hari ke depan untuk  $\hat{\mu}_{t+1}$  dan  $\hat{\sigma}_{t+1}$ .
2. Menerapkan pendekatan EVT-POT pada residual yang diperoleh dari (1) untuk estimasi nilai  $VaR_t(\alpha)$  yang selanjutnya digunakan untuk menghitung VaR GARCH-EVT seperti persamaan (2.51).

### 2.5.5 Perhitungan VaR Pendekatan ARMA-GARCH

Perhitungan VaR dengan pendekatan ARMA-GARCH digunakan sebagai metode perbandingan dari pendekatan GARCH-EVT. Misalkan terdapat sampel pengamatan,  $t = 1, 2, \dots, n$ , dengan  $n$  adalah ukuran sampel. Dan diasumsikan  $r_t$  merupakan suatu proses dengan nilai  $r_t = \mu_t + \varepsilon_t$ , dimana  $\varepsilon_t$  mengikuti fungsi distribusi  $F$  dengan mean 0 dan varians  $\sigma_t^2$ . Maka nilai VaR dapat dihitung dengan menggunakan persamaan berikut,

$$VaR_t(\alpha) = \hat{\mu}_t + F^{-1}(\alpha) \hat{\sigma}_t \quad (2.52)$$

dimana  $F^{-1}(\alpha)$  adalah nilai kuantil ke- $q^*$  dari fungsi distribusi normal. Taksiran nilai  $\mu_t$  dan  $\sigma_t$  diperoleh dari rata-rata dan varians sampel. Akan tetapi varians sampel sebagai taksiran nilai  $\sigma_t$  dapat memberikan taksiran resiko yang tidak tepat

apabila dihadapkan pada data dengan distribusi *fat tailed*. Untuk mengatasi hal tersebut, standar deviasi pada persamaan (2.52) dapat didekati dengan menggunakan model statistika, yaitu varians dari model ARCH dan GARCH (Gencay & Selcuk, 2004).

## 2.6 Return saham

Kebanyakan penelitian finansial tidak menggunakan variabel harga saham melainkan *return* saham sebagai subyeknya. Menurut Campbell, Lo, dan MacKinlay (1997) dalam Tsay (2002), hal ini dikarenakan 2 alasan utama. Alasan pertama adalah untuk sebagian investor, return saham merupakan sebuah ringkasan lengkap dari suatu peluang investasi. Alasan keduanya, bahwa return saham lebih mudah untuk dianalisis secara statistika.

Terdapat beberapa definisi dari sebuah *return* saham. Antara lain adalah *One period simple return*, *multi-period simple return*, *continuous compounding*, *continuously compounded return*, *portfolio return*, dan *excess return* (Tsay, 2002). Dalam penelitian ini, jenis *return* yang akan dianalisis adalah *continuously compounded return* yang selanjutnya disebut *return*. *Return* diukur dengan mendapatkan nilai dari persentase logaritma natural perubahan harga saham. Secara

matematis perhitungannya seperti berikut 
$$r_t = \ln \left( \frac{p_t}{p_{t-1}} \right).$$

dimana  $r_t$  adalah return saham pada periode ke-t,  $p_t$  adalah harga penutupan saham pada periode ke-t sedangkan  $p_{t-1}$  adalah harga penutupan saham pada periode ke-(t-1) (Tsay, 2002).

Terdapat beberapa properti statistika yang berhubungan return saham, yaitu rata-rata, varians, *skewness* dan kurtosis. Rata-rata mengukur pusat distribusi, sedangkan varians mengukur tingkat penyebaran/variabilitas data. Selanjutnya, nilai *skewness* dan kurtosis berhubungan dengan tingkat simetri data dan ketebalan ekor (*tail*) distribusi. Nilai kurtosis untuk distribusi normal adalah 3. Sehingga untuk data dengan nilai kurtosis lebih dari 3, dapat dinyatakan sebagai kondisi *positive excess kurtosis (leptokurtic)*. Kondisi ini mengindikasikan adanya *fat-tail*, yang berarti bahwa distribusi data tersebut memiliki kepadatan yang lebih pada

bagian ekor jika dibandingkan dengan kepadatan pada distribusi normal. Sebaliknya, distribusi data dengan nilai kurtosis kurang dari 3 dinyatakan sebagai kondisi *negative excess kurtosis (platykurtic)* yang mengindikasikan ekor distribusi yang pendek (Tsay, 2002).

## 2.7 Backtesting

Dikarenakan pentingnya perhitungan VaR, maka diperlukan suatu mekanisme validasi model, yaitu suatu proses yang secara umum mengecek apakah suatu model sudah cukup baik (Jorion, 2001). Selanjutnya, secara lebih spesifik, untuk pengecekan akurasi hasil estimasi VaR dilakukan *backtesting*. Menurut Jorion (2001), *backtesting* adalah suatu metode statistika yang digunakan untuk memverifikasi kerugian aktual (*actual lost*) sesuai dengan kerugian yang diramalkan (*projected lost*).

Metode *backtesting* yang digunakan dalam penelitian ini adalah *violation based method* (McNeil & Frey, 2000), yaitu dengan cara membandingkan nilai risiko yang dihasilkan oleh model VaR dengan nilai risiko aktual di pasar. Jika terdapat nilai prediksi kuantil ke- $q^*$  ( $\hat{r}_q^t$ ), dan nilai aktual *return* ke- $(t+1)$  berupa nilai  $r_{t+1}$ , maka terjadi *violation* pada prediksi tersebut jika  $r_{t+1} > \hat{r}_q^t$ , dengan fungsi risiko yang didefinisikan sebagai berikut:

$$I_{q,t} = \begin{cases} 1, & r_{t+1} > \hat{r}_q^t \\ 0, & r_{t+1} \leq \hat{r}_q^t \end{cases} \quad (2.53)$$

Hasil dari persamaan (2.53) akan dibandingkan dengan *expected violation* yang diberikan oleh:

$$Expected\ violation = (1 - q^*) \times n, \quad (2.54)$$

dimana  $n$  adalah banyaknya prediksi yang dilakukan. Model VaR tidak akurat jika nilai VaR yang dihasilkan lebih besar dari nilai *expected*. Hal ini menunjukkan bahwa estimasi risiko yang didapatkan tidak sesuai dengan kondisi aktual di pasar saham.

## BAB 3

### METODOLOGI PENELITIAN

#### 3.1 Sumber Data

Dalam penelitian ini dilakukan studi simulasi dan studi aplikasi. Data yang digunakan dalam studi simulasi adalah data bangkitan sejumlah 1000 yang berdistribusi normal dan berdistribusi *fat tailed* (distribusi t, distribusi Frechet dan distribusi Gumbel). Studi aplikasi pada data saham menggunakan data penutupan harga saham di 3 perusahaan asuransi go publik yang terdaftar di IDX. Perusahaan-perusahaan tersebut adalah Lippo General Insurance (LPGI), Panin Insurance (PNIN) dan Asuransi Multi Artha Guna (AMAG). Data penutupan harga saham harian diperoleh dengan mengunduh database melalui yahoo finance yang dipublikasikan pada <https://finance.yahoo.com/>. Adapun struktur data yang digunakan dalam analisis ini adalah sebagai berikut :

**Tabel 3.1** Struktur Data Harga Saham dan *Return*

| t    | $P_{1,t}$    | $P_{2,t}$    | $P_{3,t}$    | $r_{1,t}$    | $r_{2,t}$    | $r_{3,t}$    |
|------|--------------|--------------|--------------|--------------|--------------|--------------|
| 1    | $P_{1,1}$    | $P_{2,1}$    | $P_{3,1}$    | $r_{1,1}$    | $r_{2,1}$    | $r_{3,1}$    |
| 2    | $P_{1,2}$    | $P_{2,2}$    | $P_{3,2}$    | $r_{1,2}$    | $r_{2,2}$    | $r_{3,2}$    |
| ⋮    | ⋮            | ⋮            | ⋮            | ⋮            | ⋮            | ⋮            |
| ⋮    | ⋮            | ⋮            | ⋮            | ⋮            | ⋮            | ⋮            |
| ⋮    | ⋮            | ⋮            | ⋮            | ⋮            | ⋮            | ⋮            |
| 3150 | $P_{1,3150}$ | $P_{2,3150}$ | $P_{3,3150}$ | $r_{1,3150}$ | $r_{2,3150}$ | $r_{3,3150}$ |

dengan :

- $P_{1,t}$  : Harga penutupan harian saham Lippo General Insurance (LPGI)
- $P_{2,t}$  : Harga penutupan harian saham Panin Insurance (PNIN)
- $P_{3,t}$  : Harga penutupan harian saham Asuransi Multi Artha Guna (AMAG)
- $r_{1,t}$  : *Return* harian saham Lippo General Insurance (LPGI)
- $r_{2,t}$  : *Return* harian saham Panin Insurance (PNIN)
- $r_{3,t}$  : *Return* harian saham Asuransi Multi Artha Guna (AMAG)

### 3.2 Metode Analisis

Sebelum dilakukan analisis data sesuai dengan tujuan penelitian, dilakukan analisis data awal, yang meliputi :

1. Menghitung nilai *return* harian harga saham dengan menggunakan persamaan berikut ini, untuk kemudian nilai ini digunakan dalam analisis selanjutnya.

$$r_{i,t} = \ln \left( \frac{P_{i,t}}{P_{i,t-1}} \right)$$
$$= (\ln P_{i,t} - \ln P_{i,t-1})$$

dimana,  $P_{i,t}$  adalah harga penutupan harian saham asuransi ke-i dan pada hari ke-t.

2. Melakukan identifikasi pola data dengan melakukan analisis eksplorasi data yang meliputi :

- a. Perhitungan statistika deskriptif sehingga dapat diketahui ukuran pemusatan dan penyebaran data. Selain itu dengan ukuran kurtosis dan *skewness* dapat diduga kesimetrisan distribusi data *return*.
- b. Membuat histogram dari data *return* untuk mengetahui sebaran data secara visual. Informasi lain yang dapat diperoleh dari histogram data adalah dugaan adanya *skewness*, dan perilaku data pada *tail*.
- c. Sehubungan dengan dugaan awal data berdistribusi *fat tailed*, maka dilakukan tail analysis berupa plot Q-Q (quantil-quantil).

Plot Q-Q yang dibuat diplotkan sesuai dengan distribusi normal sehingga dapat diketahui apakah distribusi data mengandung *fat tailed*. Jika titik-titik yang diplotkan berada pada garis lurus, maka data terindikasi berdistribusi normal. Sesudah dilakukan analisis data awal tersebut, berdasarkan tujuan yang ingin dicapai dalam penelitian ini, maka metode analisis data yang digunakan adalah :

- 3.2.1 Melakukan kajian simulasi untuk mendapatkan nilai *threshold* optimum *bootstrap* pada beberapa tipe distribusi data.

Kajian simulasi dilakukan dengan tahapan sebagai berikut :

1. Membangkitkan data dengan distribusi normal dan *fat tailed* masing-masing sejumlah  $n=1000$  data. Distribusi *fat tailed* yang digunakan dalam

penelitian ini adalah distribusi t, distribusi Frechet dan distribusi Gumbel. Masing-masing dengan parameter yang ditetapkan sebagai berikut:

**Tabel 3.2** Parameter untuk Membangkitkan Data

| Distribusi | Parameter  |
|------------|--|
| Normal     | Rata-rata : 0<br>Standar deviasi : 0,05 dan 1                              |
| t          | Rata-rata : 0<br>Standar deviasi : 0,05 dan 1<br>Derajat bebas : 4 dan 8   |
| Gumbel     | <i>Location</i> : 0<br><i>Scale</i> : 0,05 dan 1                           |
| Frechet    | <i>Location</i> : 0<br><i>Scale</i> : 0,05 dan 1<br><i>Shape</i> : 4 dan 8 |

2. Mendapatkan nilai *threshold* optimum dari metode *bootstrap* untuk data bangkitan pada poin (1).

Langkah-langkah untuk mendapatkan nilai optimum *threshold* adalah sebagai berikut:

- a. Mengambil sejumlah  $n_1$  sampel dari total 1000 data pada poin (1).
- b. Batas bawah dan atas untuk tiap pengulangan  $k_1$  dan  $k_2$  bootstrap adalah 0,05 dan 0,15 dari sampel dalam  $n_1$ .
- c. Dari sejumlah  $n_1$ , ditentukan nilai  $k_1$  mulai dari batas bawah sampai dengan batas atas. Dilakukan pengulangan  $k_1$  sebanyak panjang interval tersebut, sehingga diperoleh  $k_1$  optimum dengan meminimumkan persamaan (2.43).
- d. Ambil  $n_2$  dengan ketentuan  $n_2 = \frac{n_1^2}{n}$ .
- e. Dari sejumlah  $n_2$ , ditentukan nilai  $k_2$  mulai dari batas bawah sampai dengan batas atas. Dilakukan pengulangan  $k_2$  sebanyak panjang

interval tersebut, sehingga diperoleh  $k_2$  optimum dengan meminimumkan persamaan (2.43).

- f. Dihitung Rasio  $R_{n_1}$ .
  - g. Diulangi proses dari (c) sampai dengan (f), untuk kemudian dipilih nilai optimum yang meminimumkan rasio pada (f).
  - h. Selanjutnya dari (g) diperoleh nilai optimum  $k_1, k_2, n_1$  dan  $n_2$  untuk kemudian dihitung  $k_{opt}$  pada persamaan (2.44) yang merupakan nilai optimum untuk threshold.
3. Mengulang langkah (1) dan (2) sebanyak 500 kali.
  4. Mendapatkan performa nilai *threshold* yang diperoleh untuk masing-masing distribusi data.

3.2.2 Melakukan estimasi nilai *Value at Risk* return saham dengan pendekatan ARMA-GARCH dan GARCH- EVT dengan tiga pilihan *threshold*, yaitu *threshold* optimum dari studi simulasi, 5% kuantil, dan 10% kuantil.

Sebelum dilakukan perhitungan VaR, dilakukan pemodelan ARMA dan GARCH dengan tahapan sebagai berikut:

1. Melakukan identifikasi model ARMA berdasarkan plot ACF dan PACF.
2. Melakukan estimasi parameter dugaan model ARMA.
3. Melakukan pemeriksaan asumsi *white noise* residual dengan menggunakan uji Ljung Box dan kenormalan distribusi residual menggunakan uji Kolmogorov Smirnov.
4. Melakukan pemilihan model terbaik berdasar kriteria AIC dan SBC.
5. Melakukan uji LM untuk mengetahui ada tidaknya efek ARCH/GARCH pada residual.
6. Jika terdapat efek ARCH/GARCH, maka dilakukan pemodelan GARCH. Setelah diperoleh pemodelan GARCH, maka perhitungan VaR dapat dilakukan, dengan tahapan sebagai berikut:
  1. Mendapatkan nilai VaR dengan pendekatan ARMA-GARCH pada tiap *window* yang dihitung sesuai dengan persamaan (2.52).

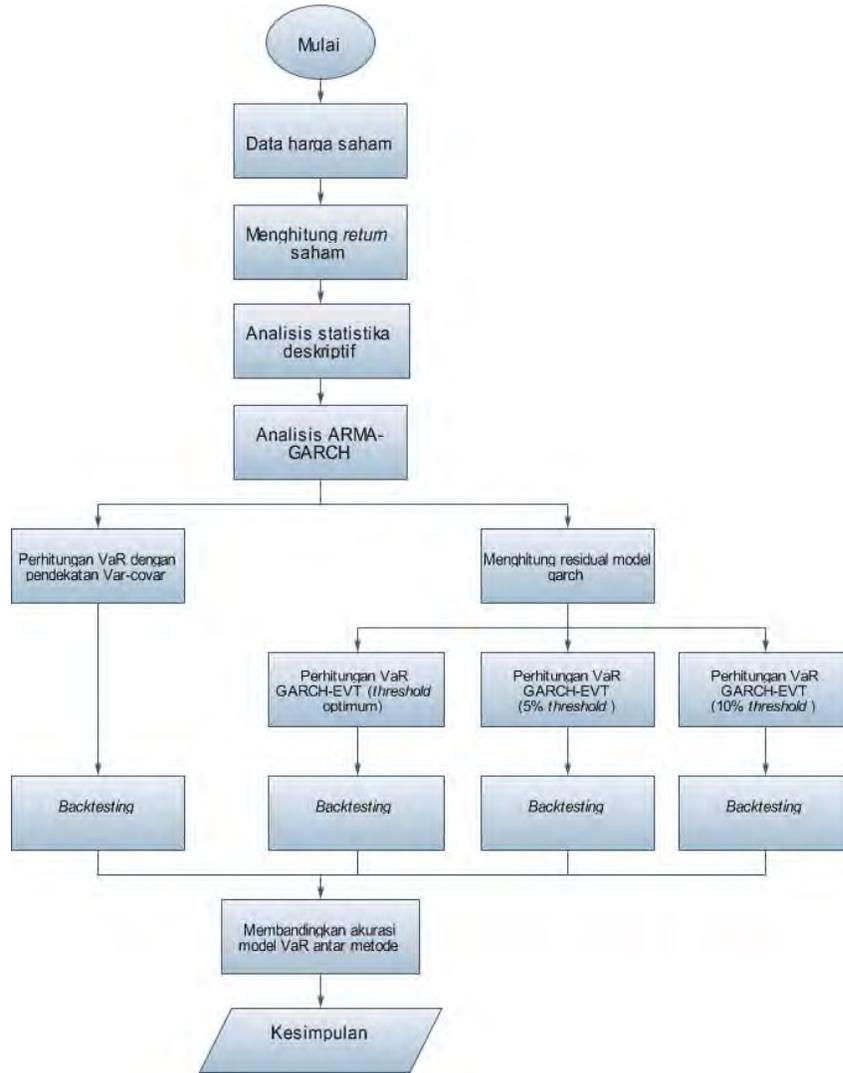
2. Mendapatkan residual model GARCH dan melakukan pengambilan nilai ekstrim dengan tiga pilihan *threshold*, yaitu *threshold* optimum dari studi simulasi, 5% kuantil, dan 10% kuantil.
3. Mendapatkan nilai VaR dengan pendekatan GARCH-EVT pada tiap *window* yang dihitung sesuai persamaan (2.51).

3.2.3 Membandingkan kebaikan model VaR antara metode ARMA-GARCH dan EVT-GARCH dari 3 macam nilai *threshold* (*threshold* optimum dari studi simulasi, 5% kuantil, dan 10% kuantil) berdasarkan hasil *backtesting*. Metode *backtesting* yang digunakan adalah *violation based method* (McNeil & Frey, 2000).

1. Membandingkan nilai risiko yang dihasilkan oleh model VaR dengan nilai risiko aktual di pasar pada masing-masing *window* sesuai dengan persamaan (2.53), selanjutnya disebut sebagai nilai *violation*.
2. Menghitung nilai *expected violation* yang diperoleh dari persamaan (2.54), dimana total prediksi yang dilakukan dalam penelitian ini adalah sebanyak 1564.
3. Membandingkan hasil perhitungan (1) terhadap (2) dari keempat model VaR.

### 3.3 Diagram Alir Penelitian

Diagram alir memberikan gambaran dari tahapan-tahapan analisis yang dilakukan dalam penelitian ini, seperti disajikan dalam Gambar 3.1 berikut ini:



**Gambar 3.1** Diagram alir tahapan Analisis

## **BAB 4**

### **ANALISIS DAN PEMBAHASAN**

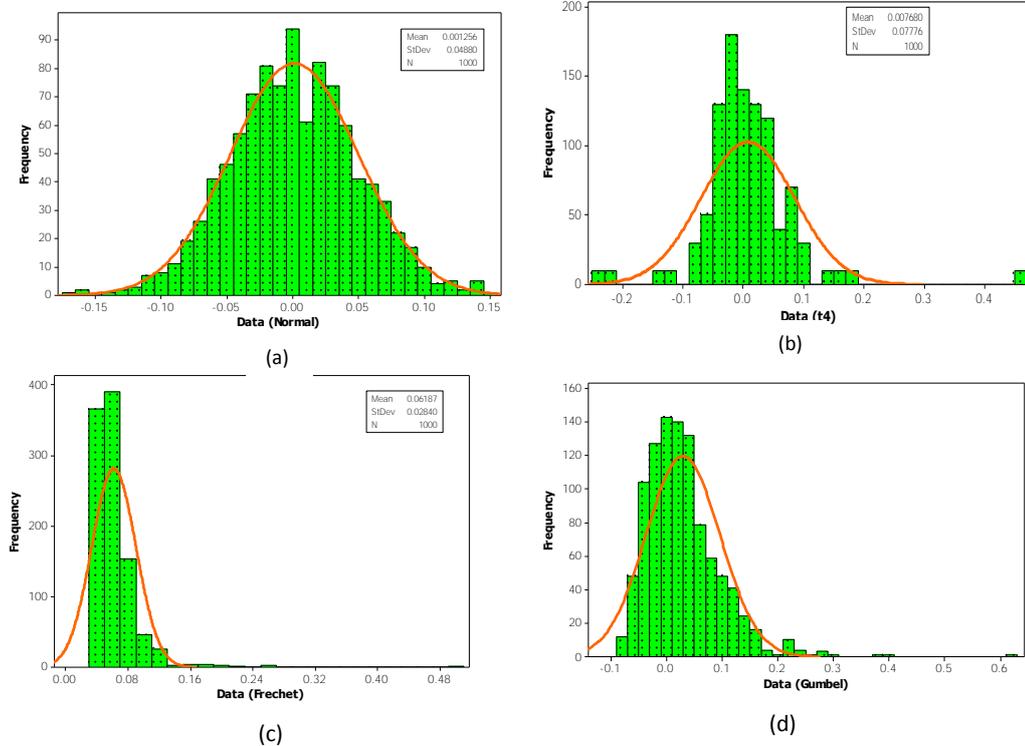
Pada bagian ini akan dilakukan kajian simulasi berkaitan dengan penentuan *threshold* optimum yang digunakan dalam menentukan nilai ekstrim dengan pendekatan *Peak Over Threshold* (POT). Selain itu juga dilakukan perhitungan nilai *Value at Risk* (VaR) pada data saham perusahaan Asuransi Multi Artha Guna (AMAG), Lippo General Insurance (LPGI), dan Panin Insurance (PNIN), dengan pendekatan GARCH dan *Extreme Value Theory* (EVT) dengan menggunakan beberapa skenario penentuan *threshold*.

#### **4.1 Studi Simulasi Pemilihan *Threshold* Optimum**

Sebagaimana dijelaskan pada bab sebelumnya, bahwa dalam analisis EVT dengan pendekatan POT, pemilihan *threshold* merupakan salah satu tahapan yang kritical karena mempengaruhi taksiran parameter distribusi ekstrim. Dalam sub bab ini dilakukan kajian simulasi pemilihan *threshold* optimum dengan menggunakan pendekatan yang dikembangkan oleh Danielson et al. (2001). *Threshold* optimum diperoleh dengan meminimumkan fungsi asimtotik MSE (AMSE) pada persamaan (2.40) yang didekati dengan metode bootstrap. Perhitungan *threshold* optimum dilakukan pada proses perhitungan VaR untuk data riil, serta data simulasi. Dalam hal ini, data simulasi dibangkitkan mengikuti distribusi normal serta distribusi *fat tailed*, yaitu distribusi t, Frechet, dan Gumbel.

Pada masing-masing tipe distribusi dibangkitkan data sejumlah 1000 dan dilakukan replikasi sebanyak 500 kali. Sehingga jumlah keseluruhan data simulasi pada masing-masing tipe distribusi adalah sebanyak 500.000 data, serta nilai *threshold* optimum ( $k_{opt}$ ) yang diperoleh untuk masing-masing tipe distribusi adalah sebanyak 500. Histogram pada Gambar 4.1 berikut ini dapat memberikan gambaran mengenai penyebaran data simulasi masing-masing tipe distribusi. Distribusi t, Frechet dan Gumbel menunjukkan adanya *excess kurtosis* dibandingkan dengan distribusi normal. Pada ketiga distribusi tersebut terlihat adanya data ekstrim pada ekor distribusi, yang merupakan indikasi *fat tailed*. Data simulasi dari keempat tipe

distribusi dengan pola sebaran yang tidak sama ini selanjutnya dianalisis dengan pendekatan *bootstrap* untuk mendapatkan *threshold* optimum.



**Gambar 4.1** Histogram data simulasi dari distribusi:

Normal (a), t dengan  $df = 4$  (b), Frechet (c), dan Gumbel (d).

Hasil dari proses *bootstrap* untuk mendapatkan *threshold* optimum dapat dilihat pada Gambar 4.2 berikut. Dengan menggunakan beberapa setting parameter yang berbeda, keseluruhan distribusi data memberikan hasil yang hampir sama. Profil posisi *threshold* optimum pada tipe distribusi normal, t dan Gumbel memiliki pola yang sama dalam 1000 data bangkitan. Ketiga tipe distribusi tersebut menunjukkan bahwa dari 500 replikasi, posisi *threshold* paling sering terjadi pada data urutan ke 10-29, yaitu kuantil ke 1-3%. Sedangkan untuk data berdistribusi Frechet, dari 500 replikasi menunjukkan bahwa posisi *threshold* yang paling sering terjadi berada pada urutan ke 100-109, yaitu pada kuantil 10-12%.



**Gambar 4.2** Bar Chart Posisi *Threshold* Optimum dari Hasil Simulasi  
a.) Distribusi Normal, b.) Distribusi t, c.) Distribusi Gumbel dan  
d.) Distribusi Frechet

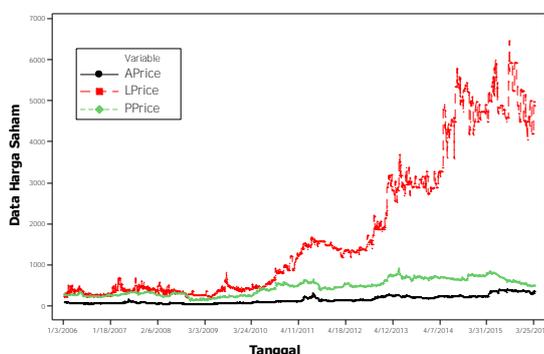
## 4.2 Studi Aplikasi pada Data Saham

Sub bab ini membahas mengenai analisis VaR pada data *return* 3 perusahaan asuransi dengan sebelumnya melakukan analisis deskriptif untuk mengetahui karakteristik *return* saham. Selanjutnya dilakukan pemodelan ARMA,

GARCH, dan EVT yang digunakan sebagai pendekatan dalam perhitungan nilai VaR. Hasil perbandingan perhitungan VaR antar pendekatan tersebut dibandingkan melalui proses *backtesting*.

#### 4.2.1 Karakteristik Saham Perusahaan

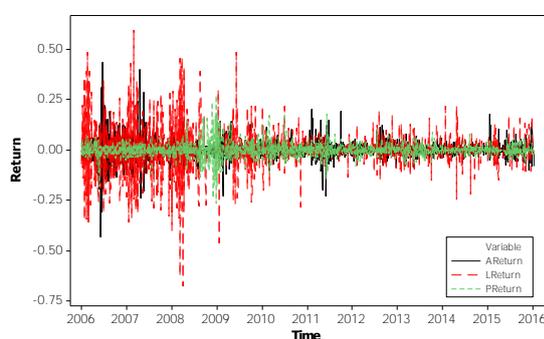
Untuk mendapatkan gambaran awal dalam memahami pola data harga saham, dapat dilakukan analisis secara visual berdasarkan plot *time series*. Gambar berikut ini menunjukkan plot *time series* harga saham pada perusahaan Asuransi Multi Artha Guna (AMAG), Lippo General Insurance (LPGI), dan Panin Insurance (PNIN).



**Gambar 4.3** *Time Series Plot* Harga Saham

Gambar 4.3 di atas menunjukkan bahwa terjadi perubahan level harga saham PT. Lippo General Insurance, dari level di bawah Rp.1000,- pada periode tahun 2006 sampai 2010, kemudian naik secara bertahap pada periode 2011-2012, 2013-2014 dan terakhir berada pada level harga RP.5000,- pada periode tahun 2015- 2016. Pada kedua perusahaan yang lain juga mengalami kenaikan, yaitu PT. Asuransi Multi Artha Guna dari level Rp.100,- menuju level Rp.400,-, dan PT. Panin Insurance mengalami kenaikan harga saham dari level Rp.200,- menjadi Rp.700,-. Dilihat lebih jauh pada tiap-tiap periode kenaikan harga saham, dapat diketahui bahwa harga saham pada masing-masing perusahaan sangat berfluktuasi. Akan tetapi saham LPGI terlihat memiliki fluktuasi yang paling tinggi dibandingkan 2 saham lainnya sehingga diduga memiliki nilai resiko yang lebih tinggi.

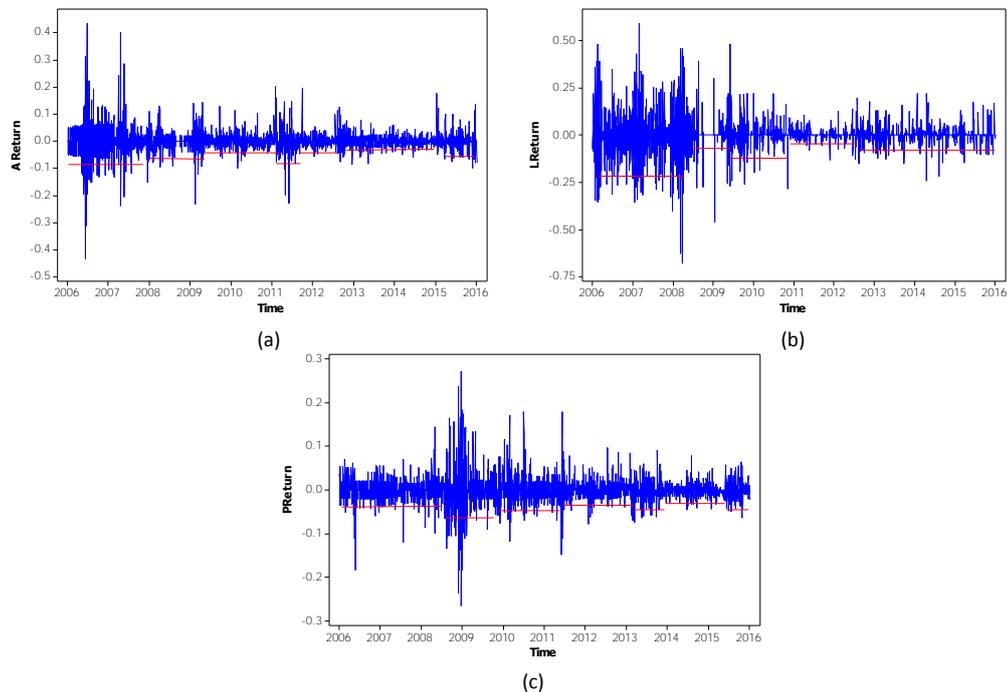
Dalam melakukan investasi, seorang investor mengharapkan untuk memperoleh *return* yang tinggi dengan kerugian yang minimal. Akan tetapi saham dengan *return* yang tinggi memiliki kecenderungan untuk resiko yang tinggi pula. Kondisi *return* pada ketiga perusahaan tersebut diberikan pada Gambar 4.4 berikut. Terlihat bahwa nilai *return* cenderung berada pada sekitar nilai nol dan bersifat stasioner dalam *mean*. Dan terlihat bahwa nilai *return* saham LPGI cenderung memiliki volatilitas yang lebih tinggi dibandingkan dengan saham AMAG dan PNIN.



**Gambar 4.4** *Time Series Plot Return Saham*

Untuk dapat melihat gambaran volatilitas *return* secara lebih jelas, ditunjukkan oleh plot *return* masing-masing saham disertai *clustered volatility*-nya pada Gambar 4.5. Yang dimaksud dengan *clustered volatility* adalah suatu kondisi nilai *return* pada suatu periode tertentu memiliki volatilitas tertentu, dan pada periode yang lain memiliki tingkat volatilitas yang berbeda. Terlihat bahwa pada plot ketiga *return* saham terbentuk *clustered volatility*. Hal ini menyebabkan munculnya kasus heteroskedastisitas dan juga terdapatnya nilai ekstrim. Kondisi *return* yang cenderung memiliki nilai ekstrim dan bersifat heteroskedastis inilah yang menjadi landasarn digunakan pendekatan metode GARCH dan EVT.

Karakteristik masing-masing data saham secara kuantitatif diberikan pada Tabel 4.1 berikut ini. Saham LPGI cenderung memberikan rata-rata keuntungan yang paling besar, disusul AMAG dan terakhir PNIN. Meskipun demikian, LPGI juga memberikan nilai kerugian maksimum dibandingkan AMAG dan PNIN, yang ditunjukkan oleh minimum *return*.



**Gambar 4.5** Clustered Volatility Return Saham AMAG (a), LPGI (b) dan PNIN (c)

**Tabel 4.1** Karakteristik Data Saham

| Ukuran  | Harga Saham |         |        | Return    |          |           |
|---------|-------------|---------|--------|-----------|----------|-----------|
|         | AMAG        | LPGI    | PNIN   | AMAG      | LPGI     | PNIN      |
| Mean    | 150,89      | 1820,10 | 455,22 | 0,000524  | 0,00120  | 0,00024   |
| Varians | 96,24       | 1761,70 | 191,45 | 0,001771  | 0,00634  | 0,000988  |
| Min     | 40,10       | 198,20  | 127,23 | -0,435465 | -0,67789 | -0,265913 |
| Max     | 410,00      | 6475,00 | 913,70 | 0,435465  | 0,59250  | 0,272566  |
| Skew    | 0,87        | 0,93    | 0,16   | 0,43      | 0,05     | 0,37      |
| Kurt    | -0,18       | -0,60   | -1,27  | 20,20     | 12,59    | 12,81     |

Nilai *skewness* menunjukkan bahwa data *return* tidak terdistribusi secara simetris, yaitu nilai *skewness* positif. Sedangkan nilai kurtosis menunjukkan bahwa nilai *return* saham menunjukkan adanya *excess kurtosis*. Plot Q-Q pada Gambar 4.6 berikut ini menunjukkan nilai-nilai *return* menyebar menjauhi garis lurus, menunjukkan bahwa data tidak berdistribusi normal.



## 4.2.2 Pemodelan *Return* Saham

Pemodelan *return* saham dimaksudkan untuk memperoleh gambaran awal model ARMA, GARCH dan EVT, yang dapat digunakan sebagai landasan dalam menaksir nilai VaR pada setiap *window*.

### 4.2.2.1 Pemodelan *Return* Saham dengan pendekatan ARMA

Prosedur pembentukan model ARMA pada data *return* saham menggunakan pendekatan *Box-Jenkins method*, yang meliputi tahap pengujian kestasioneran data, identifikasi model, estimasi parameter dan pengujian signifikansi, selanjutnya cek diagnosa pada residual dari model, untuk dilihat apakah bersifat *white noise* dan berdistribusi normal.

#### 1. Pengujian Kestasioneran Data

Untuk melihat apakah data sudah stasioner dalam mean dan varians dapat dilihat berdasarkan plot *time series* secara visual. Diduga nilai *return* sudah stasioner dalam *mean* dan berfluktuasi di sekitar nilai nol. Akan tetapi untuk memperkuat pernyataan tersebut, dilakukan pengujian stasioneritas *mean* dengan menggunakan uji *Augmented Dickey-Fuller* (ADF). Pengujian ADF dipilih karena memiliki kemampuan untuk menangkap order *autoregressive* yang lebih tinggi daripada uji DF (Enders, 2015). Berikut ini adalah hipotesa untuk pengujian ADF:

$H_0: \delta = 0$  (data mengandung unit root atau tidak stasioner)

$H_1: \delta < 0$  (data tidak mengandung unit root atau stasioner)

Statistik uji: t (Tabel 4.3)

**Tabel 4.2** Hasil Uji *Augmented Dickey Fuller*

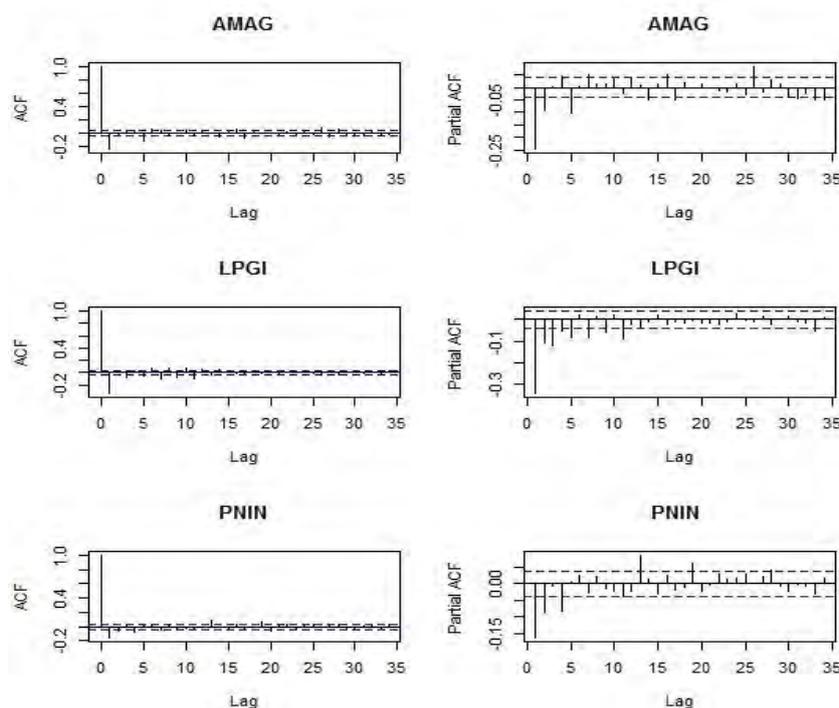
| Saham | $\hat{\tau}$ | $\tau$ -tabel | P-value |
|-------|--------------|---------------|---------|
| AMAG  | -13,615      | 1,28          | 0,01    |
| LPGI  | -17,187      | 1,28          | 0,01    |
| PNIN  | -13,55       | 1,28          | 0,01    |

Tabel 4.2 menunjukkan bahwa nilai  $|\hat{\tau}|$  lebih besar dari nilai kritis  $\tau$  *Dickey-Fuller*, dan diperkuat oleh nilai *P-value* yang kurang dari signifikansi 5%. Dapat disimpulkan bahwa *return* bersifat stasioner dalam *mean*. Pengujian stasioneritas dalam varians tidak dilakukan, mengingat sifat *return* yang memiliti

volatilitas yang tinggi. Sebagaimana dituliskan oleh Mc.Neil, Frey dan Embrechts (2005), observasi terhadap data *return* DAX dibandingkan data simulasi berdistribusi normal menunjukkan pola yang sangat berbeda. Data DAX memiliki pola *volatility clustering*, yaitu berubah-ubahnya varians data dari satu periode ke periode lainnya. Sehingga untuk mengatasinya digunakan pendekatan ARCH/GARCH.

## 2. Identifikasi Model

Identifikasi model didasarkan pada pola yang ada pada plot ACF dan PACF data *return* pada Gambar 4.8. Dari plot ACF dan PACF, dugaan model awal untuk AMAG adalah  $ARMA(0,[1,5,6])$  dan  $ARMA([1,2,5,26],0)$ , yang menunjukkan bahwa *return* hari ini dipengaruhi oleh *return* pada satu, dua, lima dan dua puluh enam hari sebelumnya.



**Gambar 4.8** Plot ACF dan PACF data *Return*

Untuk LPGI, dugaan model ARMA diberikan oleh,  $ARMA(0,[1,3,6,7,8,9,10,11,12])$  dan  $ARMA([1,2,3,5,7,9,11],0)$ , yang menunjukkan bahwa *return* hari ini dipengaruhi oleh *return* pada satu, dua, tiga, lima, tujuh, sembilan dan sebelas hari sebelumnya. Dan untuk PNIN, dugaan model

ARMA diberikan oleh,  $ARMA(0,[1,2,3,13,19])$  dan  $ARMA([1,2,4,13,19],0)$ , yang menunjukkan bahwa *return* hari ini dipengaruhi oleh *return* pada satu, dua, empat, tiga belas dan sembilan belas periode sebelumnya.

Order-order ARMA yang didapatkan melalui plot ACF dan PACF di atas kurang mampu merepresentasikan keadaan di lapangan, mengingat lemahnya justifikasi bahwa *return* hari ini dipengaruhi oleh beberapa periode sebelumnya dengan lag yang tidak beraturan. Oleh sebab itu, untuk mendapatkan model terbaik yang selanjutnya digunakan untuk estimasi VaR pada tiap *window*, dugaan model ARMA yang digunakan adalah model umum, yaitu  $ARMA(1,1)$ ,  $ARMA(1,0)$  dan  $ARMA(0,1)$ . Hal ini didasarkan pada kenyataan mengenai hubungan bahwa  $MA(\infty)$  dapat direpresentasikan menjadi  $AR(1)$  dan sebaliknya. Selain itu terdapat beberapa penelitian sebelumnya yang melakukan pemodelan ARMA pada data *return* saham dan didapatkan bahwa model terbaik yang merepresentasikan fluktuasi dari *return* saham adalah  $ARMA(1,1)$ ,  $ARMA(1,0)$  atau  $ARMA(0,1)$ . Penelitian-penelitian tersebut antara lain oleh Einarsen (2014) yang menyebutkan bahwa  $ARMA(1,1)$  lebih direkomendasikan daripada model ARMA dengan order lebih tinggi, yang cenderung tidak stabil dalam peramalan.

### 3. Estimasi dan Pengujian Signifikansi Parameter

Berdasarkan dugaan model ARMA yang sudah ditetapkan, dilakukan estimasi parameter dan uji sinifikansi parameternya. Hasil pendugaan model ARMA tersebut ditunjukkan oleh Tabel 4.3. Pada tingkat signifikansi 5%, *t-tabel* yang digunakan dalam uji signifikansi adalah sebesar 1,96. Tidak semua model memberikan estimasi parameter yang signifikan. Untuk memberikan gambaran lebih lanjut, dilakukan pengecekan asumsi residual.

**Tabel 4.3** Estimasi Parameter Model ARMA

| Saham | Model     | Par        | Estimasi | $t$ -hitung | $P$ -value |
|-------|-----------|------------|----------|-------------|------------|
| AMAG  | ARMA(1,1) | $\phi_1$   | 0,01794  | 0,25        | 0,8050     |
|       |           | $\theta_1$ | 0,28760  | 4,13        | <,0001     |
|       | ARMA(1,0) | $\phi_1$   | -0,24764 | -12,93      | <,0001     |
|       | ARMA(0,1) | $\theta_1$ | 0,27118  | 14,25       | <,0001     |
| LPGI  | ARMA(1,1) | $\phi_1$   | 0,17508  | 4,03        | <,0001     |
|       |           | $\theta_1$ | 0,57676  | 16,02       | <,0001     |
|       | ARMA(1,0) | $\phi_1$   | -0,34392 | -18,54      | <,0001     |
|       | ARMA(0,1) | $\theta_1$ | 0,42283  | 23,63       | <,0001     |
| PNIN  | ARMA(1,1) | $\phi_1$   | 0,32648  | 3,82        | <,0001     |
|       |           | $\theta_1$ | 0,50778  | 6,53        | 0,0001     |
|       | ARMA(1,0) | $\phi_1$   | -0,16397 | -8,41       | <,0001     |
|       | ARMA(0,1) | $\theta_1$ | 0,19203  | 9,91        | <,0001     |

#### 4. Pengecekan Asumsi Residual

Asumsi residual yang harus dipenuhi dalam pemodelan ARMA adalah residual *white noise* dan berdistribusi normal. Residual dikatakan *white noise* jika bersifat independen dan identik. Berdasarkan data hasil pengujian asumsi residual yang terdapat pada Tabel 4.4, diketahui bahwa semua nilai residual tidak bersifat *white noise*. Hal ini sudah diduga akan terjadi berdasarkan analisis awal yang menyatakan terdapatnya *clustered volatility* pada data *return* sehingga memunculkan kasus heteroskedastisitas. Kondisi ini akan diatasi dengan memodelkan varians menggunakan pendekatan GARCH.

Pengujian asumsi yang kedua adalah uji kenormalan residual. Pengujian dilakukan dengan uji *Kolmogorov-Smirnov*, dan diperoleh hasil bahwa pada tingkat signifikansi 5%, residual model ARMA tidak berdistribusi normal. Kondisi ini diduga dikarenakan banyaknya *outlier* pada data *return*, yang dalam analisis ini disebut sebagai nilai ekstrim.

**Tabel 4.4** Uji Asumsi *White Noise* ARMA(1,0)

| Saham | Lag | $\chi^2_{hitung}$ | df | P-value  |
|-------|-----|-------------------|----|----------|
| AMAG  | 6   | 59,98             | 5  | < 0,0001 |
|       | 12  | 78,58             | 11 | < 0,0001 |
|       | 18  | 107,15            | 17 | < 0,0001 |
| LPGI  | 6   | 73,16             | 5  | < 0,0001 |
|       | 12  | 109,8             | 11 | < 0,0001 |
|       | 18  | 115,68            | 17 | < 0,0001 |
| PNIN  | 6   | 36,17             | 5  | < 0,0001 |
|       | 12  | 45,72             | 11 | < 0,0001 |
|       | 18  | 77,96             | 17 | < 0,0001 |

Berdasarkan uraian pada tahapan di atas, model ARMA yang ditetapkan untuk ketiga data *return* saham adalah ARMA (1,0). Hal ini didasarkan pada tingkat signifikansi parameter pada model tersebut dan juga prinsip *parsimony*.

#### 4.2.2.2 Pemodelan *Return* Saham dengan GARCH

Dari hasil analisis sebelumnya diketahui bahwa terdapat ketidakidentikan dalam varians residual yang ditunjukkan dengan adanya efek ARCH/GARCH pada residual model ARMA. Sehingga pemodelan pada data *return* dilakukan dengan menggunakan metode GARCH. Akan tetapi, sebelum dilakukan pemodelan, dilakukan pengujian secara statistik menggunakan *Lagrange Multiplier* (LM). Hasil uji LM tersebut ditunjukkan oleh tabel 4.5 berikut ini dan didapatkan bahwa semua nilai  $nR^2$  lebih besar dari nilai  $\chi^2_{0,05,m}$  yang menunjukkan bahwa residual model ARMA memiliki efek ARCH/GARCH secara signifikan.

Untuk mendapatkan estimasi parameter model GARCH, dilakukan pemodelan secara serentak dengan melibatkan model ARMA yang ditetapkan sebelumnya. Selanjutnya dilakukan pengujian signifikansi parameter. Adapun model GARCH yang digunakan dalam analisis ini adalah GARCH(1,1), sehingga untuk ketiga data *return* saham ditetapkan model ARMA-GARCH sebagai berikut.

**Tabel 4.5 Uji Lagrange Multiplier**

| m  | AMAG     | LPGI     | PNIN     | $\chi^2_{0,05;m}$ |
|----|----------|----------|----------|-------------------|
| 1  | 129.9900 | 277.0150 | 282.9345 | 3.8415            |
| 2  | 200.0235 | 288.2954 | 314.8438 | 5.9915            |
| 3  | 209.5666 | 297.2905 | 383.4195 | 7.8147            |
| 4  | 230.0769 | 308.6364 | 399.9122 | 9.4877            |
| 5  | 254.3102 | 316.5908 | 418.1130 | 11.0705           |
| 6  | 284.3221 | 325.6152 | 460.8461 | 12.5916           |
| 7  | 284.4037 | 329.7410 | 470.5807 | 14.0671           |
| 8  | 295.1133 | 347.3460 | 471.2179 | 15.5073           |
| 9  | 299.2890 | 366.6676 | 474.0619 | 16.9190           |
| 10 | 307.3221 | 382.2718 | 474.6508 | 18.3070           |

Tabel 4.6 memberikan hasil estimasi parameter model ARMA-GARCH data *return* saham untuk masing-masing perusahaan, yang ditaksir mengikuti persamaan berikut:  $h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1}$

**Tabel 4.6 Estimasi Parameter dan Uji Signifikansi Parameter Model ARMA-GARCH**

| Saham | Model                   | Par        | Estimasi | <i>t</i> – hitung | <i>P</i> – value         |
|-------|-------------------------|------------|----------|-------------------|--------------------------|
| AMAG  | ARMA(1,0)<br>GARCH(1,1) | $\phi_1$   | -0.16640 | -7.061            | $1,65 \times 10^{-12}$   |
|       |                         | $\alpha_0$ | 0.00003  | 6.322             | $2,58 \times 10^{-10}$   |
|       |                         | $\alpha_1$ | 0.12300  | 8.835             | $< 2,00 \times 10^{-16}$ |
|       |                         | $\beta_1$  | 0.86670  | 66.071            | $< 2,00 \times 10^{-16}$ |
| LPGI  | ARMA(1,0)<br>GARCH(1,1) | $\phi_1$   | -0.20720 | -8.741            | $< 2,00 \times 10^{-16}$ |
|       |                         | $\alpha_0$ | 0.00008  | 5.281             | $1,29 \times 10^{-7}$    |
|       |                         | $\alpha_1$ | 0.07250  | 7.131             | $9,93 \times 10^{-13}$   |
|       |                         | $\beta_1$  | 0.90890  | 73.966            | $< 2,00 \times 10^{-16}$ |
| PNIN  | ARMA(1,0)<br>GARCH(1,1) | $\phi_1$   | -0.13540 | -6.16             | $7,29 \times 10^{-10}$   |
|       |                         | $\alpha_0$ | 0.00001  | 4.285             | $1,82 \times 10^{-5}$    |
|       |                         | $\alpha_1$ | 0.09877  | 8.338             | $< 2,00 \times 10^{-16}$ |
|       |                         | $\beta_1$  | 0.89140  | 71.748            | $< 2,00 \times 10^{-16}$ |

Dari tabel di atas, dapat diketahui bahwa model ARMA-GARCH pada saham AMAG, LPGI dan PNIN memiliki parameter yang telah signifikan. Hal ini ditunjukkan dari nilai  $|t - hitung|$  yang lebih besar dari nilai  $t - tabel$  yaitu sebesar 1,96. Berdasarkan pemodelan ARMA-GARCH yang telah dilakukan, model *return* saham dapat dituliskan secara matematis sebagai berikut:

1. Saham PT. Artha Multi Guna (AMAG)

$$\text{ARMA}(1,0) : \hat{Y}_t = -0,16640Y_{t-1}$$

$$\text{GARCH}(1,1) : h_t = 0,00003 + 0,12300\varepsilon_{t-1}^2 + 0,86670h_{t-1}$$

2. Saham PT. Lippo General Insurance (LPGI)

$$\text{ARMA}(1,0) : \hat{Y}_t = -0,20720Y_{t-1}$$

$$\text{GARCH}(1,1) : h_t = 0,00008 + 0,07250\varepsilon_{t-1}^2 + 0,90890h_{t-1}$$

3. Saham PT. Panin Insurance (PNIN)

$$\text{ARMA}(1,0) : \hat{Y}_t = -0,13540Y_{t-1}$$

$$\text{GARCH}(1,1) : h_t = 0,00001 + 0,09877\varepsilon_{t-1}^2 + 0,89140h_{t-1}$$

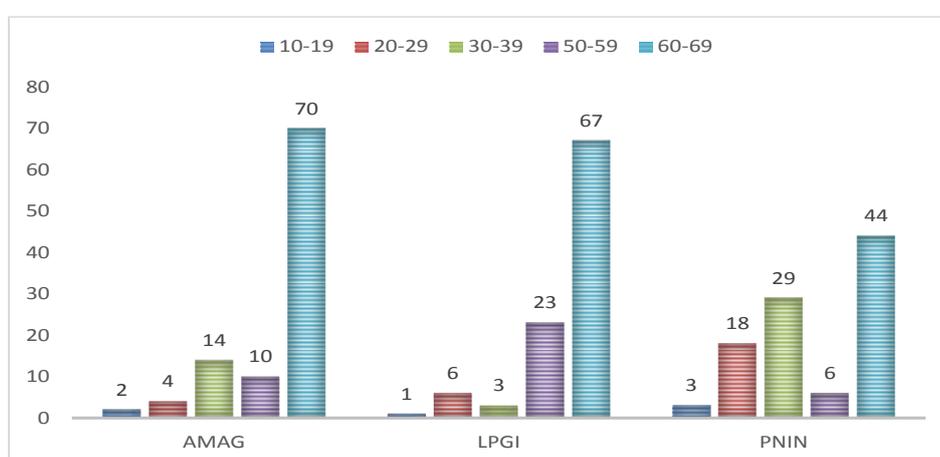
Ketiga model di atas selanjutnya digunakan sebagai model dasar dalam melakukan estimasi nilai VaR dalam setiap *window*.

#### 4.2.2.3 Pemodelan *Return* Saham dengan *Extreme Value Theory*

Analisis deskriptif pada sub bab sebelumnya menyatakan bahwa data *return* ketiga saham mengindikasikan adanya *excess kurtosis*. Kondisi ini diduga karena banyaknya nilai ekstrim yang terdapat pada data *return*, sehingga digunakan pendekatan EVT. Pada penelitian ini, pemodelan EVT yang digunakan adalah metode *Peak Over Threshold* (POT), yaitu mengambil nilai-nilai ekstrim yang melebihi suatu *threshold* tertentu. Agar dapat menangkap nilai ekstrim negatif (*Loss*), analisis dilakukan dengan membuat nilai negatif *return*. Dan untuk mendapatkan nilai ekstrim positif (*Gain*), analisis dilakukan pada data *return* asal. Nilai *threshold* adalah pengamatan ke- $(k+1)$  setelah diurutkan. Sehingga data yang dikategorikan ekstrim adalah sejumlah  $k$  pengamatan.

Dalam penelitian ini nilai *threshold* yang diambil adalah data pada kuantil 5% dan 10%. Selain itu juga dilakukan evaluasi terhadap nilai *threshold* optimum

yang diperoleh dengan pendekatan *bootstrap* sebagaimana yang dilakukan pada data simulasi. Hasil *bootstrap* untuk mendapatkan *threshold* optimum pada data riil yang ditunjukkan oleh diagram batang pada Gambar 4.9 berikut ini. Diagram batang berikut menyatakan bahwa ketiga data *return* memiliki posisi *threshold* optimum dengan pola yang sama. Dari 100 kali replikasi, diperoleh hasil bahwa posisi *threshold* berada pada data urutan ke-(60-69). Dari 2564 data *return* yang ada, hal ini menunjukkan bahwa *threshold* optimum berada pada kuantil ke 2,3 – 2,7 %. Nilai ini selanjutnya digunakan dalam perhitungan VaR dengan pendekatan GARCH-EVT. Adapun nilai *threshold* yang ditetapkan adalah pada kuantil 2,5 % dari data tiap *window*.



**Gambar 4.9** Bar Chart Posisi Threshold Optimum dari Hasil Simulasi Data Return (AMAG, LPGI dan PNIN)

Secara keseluruhan, distribusi nilai ekstrim dari data return saham mengikuti distribusi General Pareto Distribution (GPD) dengan hasil estimasi parameter seperti dalam Tabel 4.7.

**Tabel 4.7** Estimasi Parameter Distribusi GPD

| Saham | $k$ | $\xi$    | $s.d$   |
|-------|-----|----------|---------|
| AMAG  | 50  | 0,23365  | 0,04619 |
|       | 100 | 0,52464  | 0,02259 |
| LPGI  | 50  | 0,06209  | 0,07583 |
|       | 100 | -0,10473 | 0,11759 |
| PNIN  | 50  | 0,03783  | 0,03956 |
|       | 100 | 0,21274  | 0,02591 |

### 4.2.3 Estimasi Nilai VaR

Perhitungan VaR pada satu periode ke depan dilakukan dengan metode *sliding window* dengan ukuran *window* 1000, sehingga peramalan VaR yang diperoleh sejumlah 1564 data. Untuk mengetahui perbedaan keakuratan metode yang digunakan, perhitungan tingkat resiko saham dilakukan pada tiga kuantil yaitu 5%, 1%, dan 0,5%.

#### 4.2.3.1 Estimasi Nilai VaR dengan Pendekatan ARMA-GARCH

Metode perhitungan VaR dalam hal ini dihitung hanya dari data return, tidak melibatkan residual dari model. Hasil perhitungan nilai VaR dengan pendekatan ARMA-GARCH sejumlah 1564 data disajikan berupa nilai rata-rata, pada masing-masing kuantil yang diberikan oleh Tabel 4.8 di bawah ini. Nilai VaR pada *left tail* menunjukkan tingkat kerugian atau *loss*, sedangkan nilai pada *right tail* menunjukkan potensi keuntungan atau *gain*.

**Tabel 4.8** Estimasi Nilai VaR (ARMA-GARCH)

| Kuantil                  | AMAG    |        | LPGI    |        | PNIN    |        |
|--------------------------|---------|--------|---------|--------|---------|--------|
|                          | Mean    | Stdev  | Mean    | Stdev  | Mean    | Stdev  |
| <i>Left Tail (Loss)</i>  |         |        |         |        |         |        |
| 0,5%                     | -0,0729 | 0,0349 | -0,1143 | 0,0389 | -0,0645 | 0,0256 |
| 1%                       | -0,0659 | 0,0316 | -0,1033 | 0,0354 | -0,0583 | 0,0232 |
| 5%                       | -0,0466 | 0,0227 | -0,0731 | 0,0258 | -0,0412 | 0,0166 |
| <i>Right Tail (Gain)</i> |         |        |         |        |         |        |
| 0,5%                     | 0,0727  | 0,0346 | 0,1137  | 0,0379 | 0,0644  | 0,0251 |
| 1%                       | 0,0656  | 0,0313 | 0,1026  | 0,0344 | 0,0582  | 0,0227 |
| 5%                       | 0,0464  | 0,0223 | 0,0725  | 0,0248 | 0,0411  | 0,0161 |

Berdasarkan nilai VaR pada *left tail*, dapat dinyatakan bahwa pada tingkat keyakinan 95%, seorang investor yang menginvestasikan uang sejumlah Rp.1.000.000,000- pada saham AMAG, akan mengalami kerugian maksimal sebesar Rp. 46.600.000,-. Dapat juga dikatakan bahwa terdapat kemungkinan sebesar 5% bahwa seorang investor yang berinvestasi sebesar Rp.1000.000.000,- pada saham AMAG akan mengalami kerugian minimal Rp. 46.600.000,-. Interpretasi yang sama berlaku untuk saham dan kuantil yang lainnya. Pada kuantil

yang lebih kecil, diperoleh nilai VaR yang semakin negatif menunjukkan tingkat kerugian yang semakin besar. Nilai VaR pada *right tail* dapat diartikan bahwa jika seorang investor yang menginvestasikan uang sejumlah Rp.1.000.000,000- pada saham AMAG, juga akan memiliki potensi keuntungan sebesar Rp.72.700.000,- pada tingkat keyakinan 95%. Interpretasi yang sama berlaku untuk saham dan kuantil yang lainnya. Pada kuantil yang lebih kecil, diperoleh nilai VaR yang semakin besar menunjukkan potensi keuntungan yang semakin besar.

Nilai *loss* pada *return* saham LPGI memiliki nilai yang paling kecil, menunjukkan bahwa tingkat resiko berinvestasi pada saham LPGI adalah paling besar. Sementara itu kedua saham lainnya memiliki tingkat resiko yang hampir sama. Di sisi lain, nilai *gain* saham LPGI menunjukkan nilai yang paling besar dibandingkan kedua saham lainnya. Hal ini menunjukkan bahwa semakin besar kemungkinan resiko yang didapat oleh seorang investor akan dibarengi dengan semakin tingginya kemungkinan keuntungan yang diperoleh. Keputusan dalam memilih investasi sepenuhnya bergantung cara pandang investor.

#### **4.2.3.2 Estimasi Nilai VaR dengan Pendekatan GARCH-EVT**

Nilai VaR dengan pendekatan GARCH-EVT yang digunakan dalam penelitian ini disebut dengan *dynamic VaR*, diperoleh dengan dua tahapan yaitu menggunakan model ARMA(1,0)-GARCH(1,1) untuk menduga tingkat volatilitas ( $\sigma$ ) dan rata-rata ( $\mu$ ) *return* saham pada hari berikutnya. Pada tahap kedua, residual model GARCH(1,1) digunakan untuk mengestimasi nilai kuantil berdasarkan distribusi GPD yang selanjutnya digunakan untuk perhitungan VaR. Tingkat kuantil yang dipilih untuk *threshold* adalah 10% dan 5%. Dengan menggunakan ukuran *window* sebesar 1000 pengamatan, maka nilai *threshold* yang berada pada urutan ke- $(k+1)$  akan memiliki nilai 51 dan 101, sehingga  $k=50$  dan 100. Sementara itu, nilai *threshold* optimum yang diperoleh adalah 2,5%, sehingga nilai  $k=25$  data.

Hasil perhitungan nilai VaR pada *left tail (loss)* dengan pendekatan GARCH-EVT sejumlah 1564 data disajikan berupa nilai rata-rata pada masing-masing kuantil yang diberikan oleh Tabel 4.9.

**Tabel 4.9** Estimasi Nilai *Dynamic VaR (Loss)*

| k   | Kuantil | AMAG   |        | LPGI   |        | PNIN   |        |
|-----|---------|--------|--------|--------|--------|--------|--------|
|     |         | Mean   | s.d    | Mean   | s.d    | Mean   | s.d    |
| 25  | 0,5%    | 0,0829 | 0,0427 | 0,1701 | 0,0510 | 0,0709 | 0,0268 |
|     | 1%      | 0,0671 | 0,0348 | 0,1314 | 0,0403 | 0,0591 | 0,0181 |
|     | 5%      | 0,0369 | 0,0185 | 0,0611 | 0,0279 | 0,0389 | 0,0181 |
| 50  | 0,5%    | 0,0824 | 0,0415 | 0,1706 | 0,0507 | 0,0724 | 0,0284 |
|     | 1%      | 0,0669 | 0,0337 | 0,1322 | 0,0404 | 0,0605 | 0,0237 |
|     | 5%      | 0,0392 | 0,0204 | 0,0617 | 0,0270 | 0,0373 | 0,0157 |
| 100 | 0,5%    | 0,0832 | 0,0419 | 0,1710 | 0,0515 | 0,0740 | 0,0293 |
|     | 1%      | 0,0684 | 0,0346 | 0,1334 | 0,0419 | 0,0621 | 0,0247 |
|     | 5%      | 0,0388 | 0,0200 | 0,0619 | 0,0262 | 0,0367 | 0,0152 |

Berdasarkan nilai VaR pada Tabel 4.9, dapat dinyatakan bahwa pada pemilihan *threshold* kuantil 5% (k=50) dan tingkat keyakinan 95%, seorang investor yang menginvestasikan uang sejumlah Rp.1.000.000,000- pada saham AMAG, akan mengalami kerugian maksimal sebesar Rp. 39.200.000,-. Dapat juga dikatakan bahwa terdapat kemungkinan sebesar 5% bahwa seorang investor yang berinvestasi sebesar Rp.1000.000.000,- pada saham AMAG akan mengalami kerugian minimal Rp. 39.200.000,-. Interpretasi yang sama berlaku untuk saham, nilai *threshold* dan kuantil yang lainnya. Perbedaan penggunaan *threshold* pada tingkat 2,5% (k=25), 5% (k=50) dan 10% (k=100), menunjukkan hasil estimasi nilai VaR yang tidak jauh berbeda. Dari sisi perbedaan kuantil, semakin kecil kuantil yang ditetapkan, maka nilai VaR semakin positif menunjukkan bahwa tingkat resiko juga semakin besar. Cara menginterpretasi nilai VaR pada pendekatan EVT-GARCH ini berbeda dari pendekatan ARMA-GARCH dikarenakan *loss* pada pendekatan ini diestimasi dari data negatif *return*.

Sementara itu estimasi untuk *right tail (gain)* didekati dengan *return* data asal dan hasilnya diberikan dalam Tabel 4.10 berikut ini. Nilai VaR pada *gain* menunjukkan potensi keuntungan yang akan diperoleh seorang investor. Berdasarkan nilai VaR pada Tabel 4.10, dapat dinyatakan bahwa pada pemilihan *threshold* pada kuantil 95% (k=50) dan tingkat keyakinan 95%, seorang investor

yang menginvestasikan uang sejumlah Rp.1.000.000,000- pada saham AMAG, akan memperoleh keuntungan sebesar Rp. 45.100.000,-. Sama halnya dengan nilai VaR pada *left tail*, perbedaan penggunaan *threshold* pada tingkat 2,5% (k=25), 5% (k=50) dan 10% (k=100), menunjukkan hasil estimasi nilai VaR yang tidak jauh berbeda.

**Tabel 4.10** Estimasi Nilai VaR *Dynamic (Gain)*

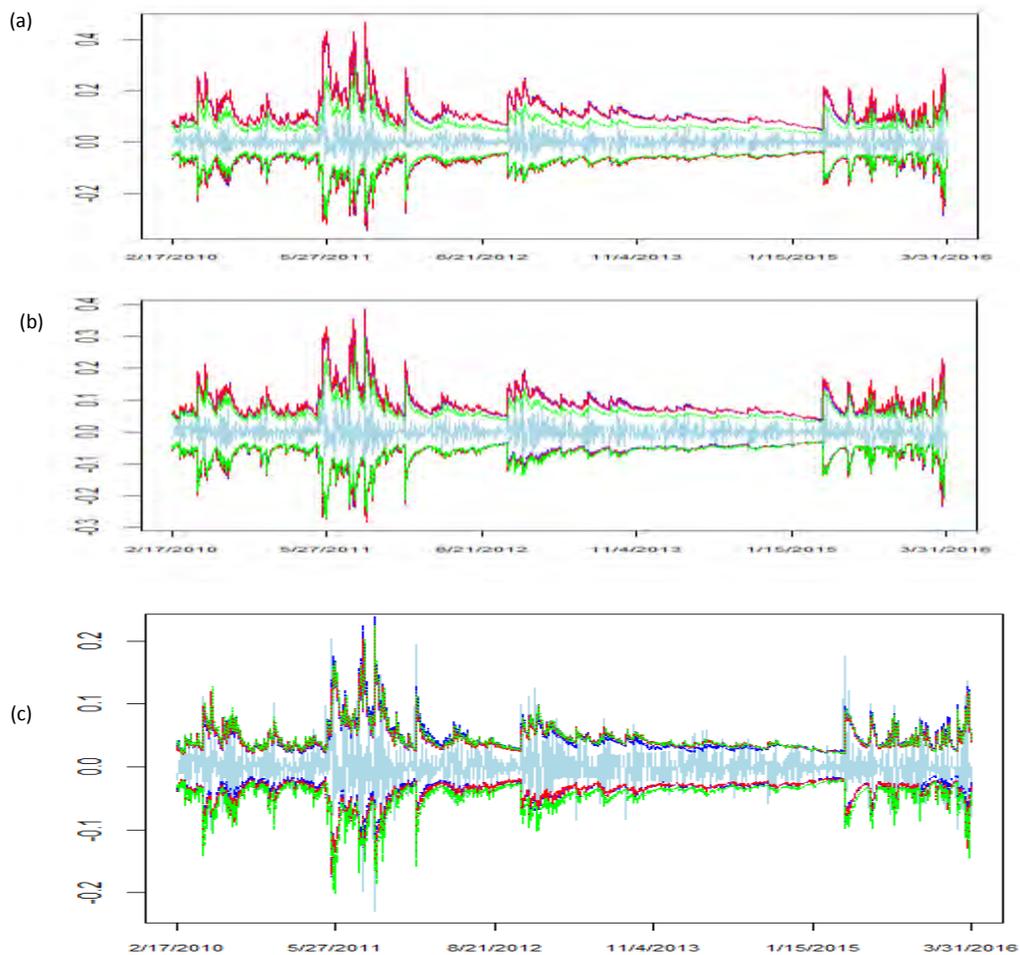
| k   | Kuantil | AMAG   |        | LPGI   |        | PNIN   |        |
|-----|---------|--------|--------|--------|--------|--------|--------|
|     |         | Mean   | s.d    | Mean   | s.d    | Mean   | s.d    |
| 25  | 0,5%    | 0,1144 | 0,0538 | 0,1898 | 0,0570 | 0,0986 | 0,0378 |
|     | 1%      | 0,0882 | 0,0424 | 0,1567 | 0,0480 | 0,0802 | 0,0318 |
|     | 5%      | 0,0454 | 0,0242 | 0,0716 | 0,0259 | 0,0356 | 0,0156 |
| 50  | 0,5%    | 0,1151 | 0,0549 | 0,1828 | 0,0557 | 0,0972 | 0,0377 |
|     | 1%      | 0,0890 | 0,0434 | 0,1501 | 0,0468 | 0,0791 | 0,0319 |
|     | 5%      | 0,0451 | 0,0216 | 0,0716 | 0,0259 | 0,0403 | 0,0157 |
| 100 | 0,5%    | 0,1151 | 0,0544 | 0,1820 | 0,0554 | 0,0965 | 0,0368 |
|     | 1%      | 0,0895 | 0,0425 | 0,1477 | 0,0450 | 0,0782 | 0,0307 |
|     | 5%      | 0,0453 | 0,0221 | 0,0724 | 0,0265 | 0,0411 | 0,0165 |

Secara keseluruhan, estimasi nilai VaR dengan pendekatan EVT-GARCH memberikan hasil yang selaras dengan pendekatan ARMA-GARCH pada sub bab sebelumnya. Nilai *loss (left tail)* pada *return* saham LPGI memiliki nilai yang paling besar, menunjukkan bahwa tingkat resiko berinvestasi pada saham LPGI adalah paling besar. Sementara itu kedua saham lainnya memiliki tingkat resiko yang hampir sama. Di sisi lain, nilai *gain* saham LPGI menunjukkan nilai yang paling besar pula dibandingkan kedua saham lainnya. Hal ini menunjukkan bahwa semakin besar kemungkinan resiko yang didapat oleh seorang investor akan dibarengi dengan semakin tingginya kemungkinan keuntungan yang diperoleh. Keputusan dalam memilih investasi sepenuhnya bergantung cara pandang investor.

#### 4.2.4 Perbandingan antar Metode Perhitungan Nilai VaR

Setelah diketahui bahwa kedua pendekatan yang digunakan dalam mengestimasi nilai VaR memberikan interpretasi hasil dengan pola yang selaras mengenai tingkat *loss* dan *gain* pada ketiga *return* saham tersebut, maka dalam sub bab ini akan diuraikan mengenai pendekatan mana yang lebih baik dalam mengestimasi nilai VaR. Untuk melihat tingkat akurasi tersebut digunakan metode *backtesting*. Metode *backtesting* yang digunakan adalah *violation based method* (McNeil & Frey, 2000). Jika terdapat nilai prediksi kuantil ke- $q$  ( $\hat{r}_q^t$ ), dan nilai aktual *return* ke- $(t+1)$  berupa  $r_{t+1}$ , maka terjadi *violation* pada prediksi tersebut jika  $r_{t+1} > \hat{r}_q^t$ . Nilai *expected* diperoleh dari  $(1-q) \times$  total prediksi, yang dalam penelitian ini adalah 1564. Suatu prediksi dikatakan *underestimate* jika jumlah *violation* lebih besar dari *expected*. Nilai VaR pada setiap *window* di masing-masing kuantil diberikan oleh gambar berikut ini. Gambar 4.10 memberikan plot estimasi nilai VaR pada saham AMAG, yang mana plot di bawah nilai nol menunjukkan plot nilai *loss*, sedangkan plot di atas nilai nol menunjukkan nilai *gain*.

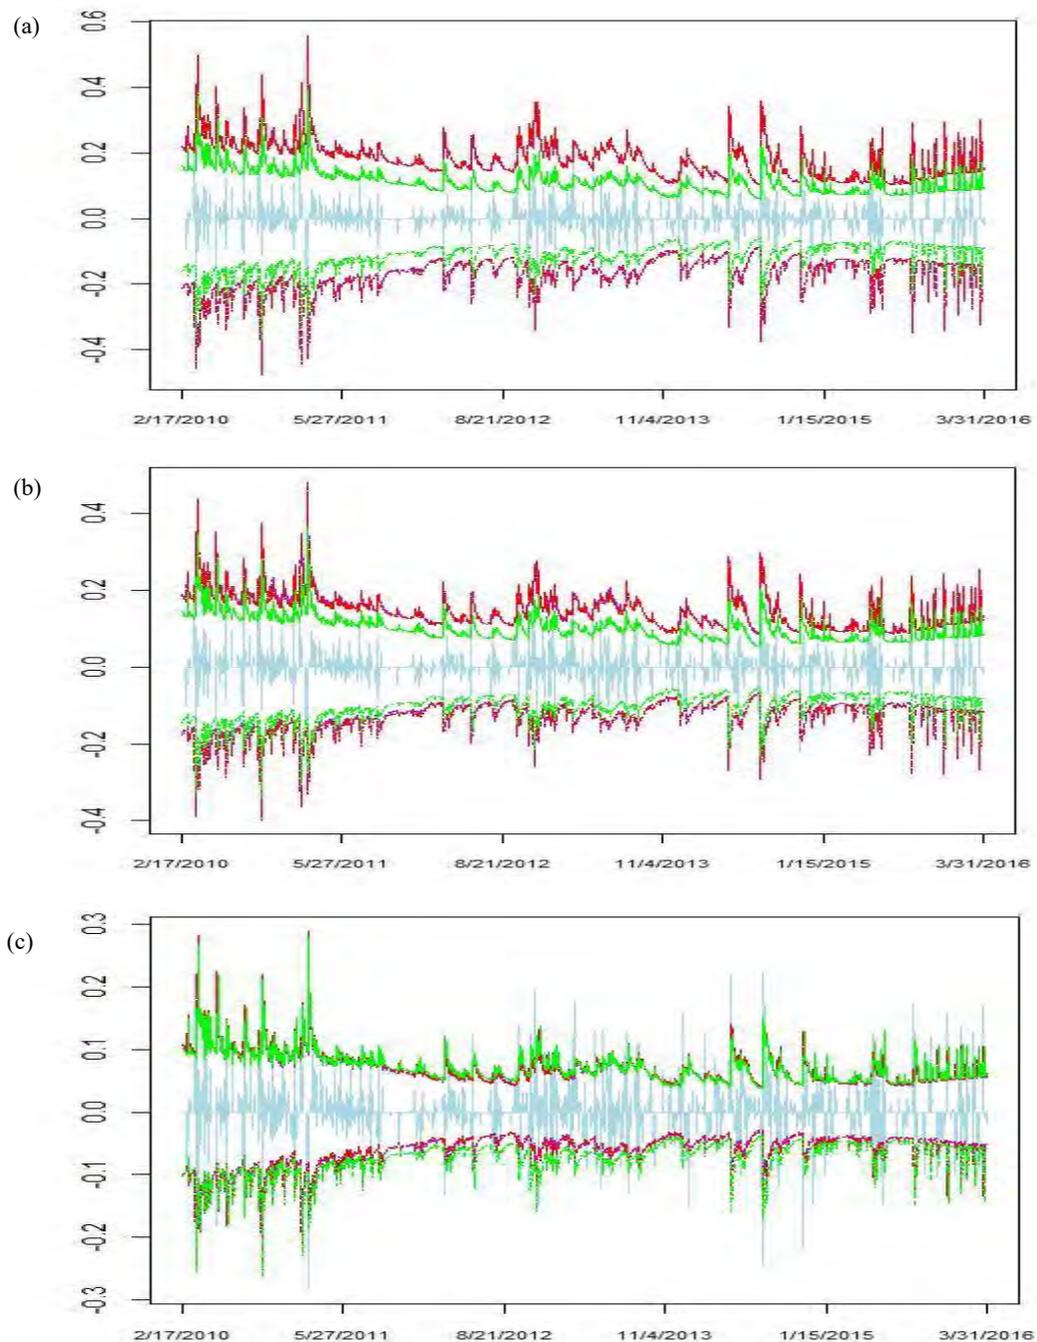
Dapat dilihat bahwa dengan pendekatan EVT-GARCH (biru, merah dan ungu), nilai estimasi *dynamic* VaR dapat mengakomodasi nilai ekstrim dan juga pola volatilitas data. Pendekatan ARMA-GARCH (hijau) dapat menangkap pola volatilitas pada data, akan tetapi masih berada di bawah pendekatan EVT-GARCH dalam menangkap nilai ekstrim. Hal ini berlaku untuk kuantil 0,5% dan 1%. Sedangkan untuk kuantil 5% terlihat bahwa kedua pendekatan memberikan hasil yang tidak jauh berbeda ditunjukkan dengan plot biru, merah, ungu dan hijau yang saling berimpit. Sedangkan untuk perbedaan *threshold*  $k=25$ ,  $k=50$  dan  $k=100$  memberikan hasil estimasi yang tidak jauh berbeda ditunjukkan dengan plot biru, merah dan ungu yang saling berhimpit.



**Gambar 4.10** Estimasi *Loss* (bawah) dan *Gain* (atas) pada saham AMAG dengan pendekatan ARMA-GARCH (hijau), EVT;  $k=25$  (biru),  $K=50$  (ungu) dan EVT;  $K=100$  (merah) pada Kuantil 0,5%(a), 1%(b) dan 5%(c)

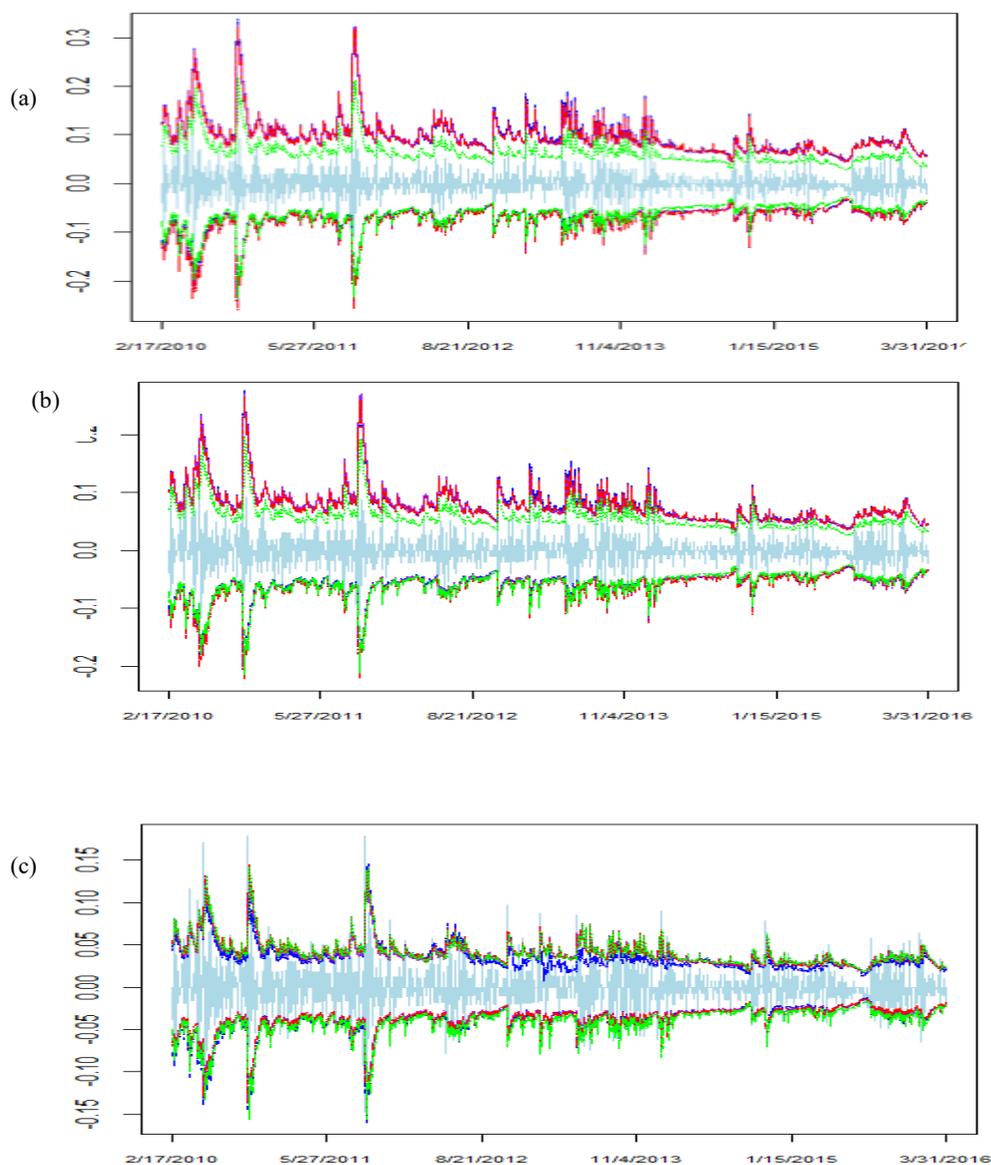
Gambar 4.11 memberikan plot estimasi nilai VaR pada saham LPGI, yang mana plot di bawah nilai nol menunjukkan plot nilai *loss*, sedangkan plot di atas nilai nol menunjukkan nilai *gain*. Sama halnya dengan saham AMAG, dapat dilihat bahwa dengan pendekatan EVT-GARCH (biru, merah dan ungu), nilai estimasi *dynamic* VaR dapat mengakomodasi nilai ekstrim dan juga pola volatilitas data. Pendekatan ARMA-GARCH (hijau) dapat menangkap pola volatilitas pada data, akan tetapi masih berada di bawah pendekatan EVT-GARCH dalam menangkap nilai ekstrim. Hal ini berlaku untuk kuantil 0,5% dan 1%. Sedangkan untuk kuantil 5% terlihat bahwa kedua pendekatan memberikan hasil yang tidak jauh berbeda

ditunjukkan dengan plot biru, merah, ungu dan hijau yang saling berhimpit. Sedangkan untuk perbedaan *threshold*  $k=25$ ,  $k=50$  dan  $k=100$  memberikan hasil estimasi yang tidak jauh berbeda ditunjukkan dengan plot biru, merah dan ungu yang saling berhimpit.



**Gambar 4.11** Estimasi *Loss* (bawah) dan *Gain* (atas) pada saham LPGI dengan pendekatan ARMA-GARCH (hijau), EVT;  $k=25$  (biru),  $K=50$  (ungu) dan EVT;  $K=100$  (merah) pada Kuantil 0,5%(a), 1%(b) dan 5%(c)

Estimasi nilai VaR pada saham PNIN pada Gambar 4.12 memberikan hasil yang selaras dengan data *return* dua perusahaan asuransi sebelumnya.



**Gambar 4.12** Estimasi *Loss* (bawah) dan *Gain* (atas) pada saham PNIN dengan pendekatan ARMA-GARCH (hijau), EVT; K=50 (ungu) dan EVT;K=100(merah) pada Kuantil 0,5%(a), 1%(b) dan 5%(c)

Dapat dilihat bahwa dengan pendekatan EVT-GARCH (biru, merah dan ungu), nilai estimasi *dynamic* VaR dapat mengakomodasi nilai ekstrim dan juga pola volatilitas data. Pendekatan ARMA-GARCH (hijau) dapat menangkap pola

volatilitas pada data, akan tetapi masih berada di bawah pendekatan EVT-GARCH dalam menangkap nilai ekstrim. Hal ini berlaku untuk kuantil 0,5% dan 1%. Sedangkan untuk kuantil 5% terlihat bahwa kedua pendekatan memberikan hasil yang tidak jauh berbeda ditunjukkan dengan plot biru, merah, ungu dan hijau yang saling berimpit. Sedangkan untuk perbedaan *threshold*  $k=25$ ,  $k=50$  dan  $k=100$  memberikan hasil estimasi yang tidak jauh berbeda ditunjukkan dengan plot biru, merah dan ungu yang saling berhimpit.

Secara keseluruhan, berdasarkan Gambar 4.10, 4.11 dan 4.12 mengenai estimasi nilai VaR pada tiap *window* dapat ditunjukkan bahwa pendekatan EVT-GARCH dapat menangkap pola volatilitas pada data sekaligus data ekstrim pada data. Semakin kecil nilai kuantil yang digunakan maka estimasi nilai VaR pada tiap *window* akan semakin besar, yang mengindikasikan bahwa kerugian yang ditaksir semakin besar. Selain berdasarkan plot, tingkat akurasi estimasi VaR masing-masing pendekatan dapat dilihat dari hasil *backtesting* yang disajikan dalam Tabel 4.11 untuk *Loss* dan Tabel 4.12 untuk *gain*.

**Tabel 4.11** Hasil *Backtesting* (Left Tail)

| Kuantil      | Metode Pendekatan    | Saham     |           |           |
|--------------|----------------------|-----------|-----------|-----------|
|              |                      | AMAG      | LPGI      | PNIN      |
| 0,5% kuantil | <b>Expected</b>      | <b>8</b>  | <b>8</b>  | <b>8</b>  |
|              | ARMA(1,0)-GARCH(1,1) | 22        | 22        | 7         |
|              | GARCH-EVT (k=25)     | 15        | 6         | 7         |
|              | GARCH-EVT (k=50)     | 14        | 6         | 6         |
|              | GARCH-EVT (k=100)    | 13        | 6         | 5         |
| 1% kuantil   | <b>Expected</b>      | <b>16</b> | <b>16</b> | <b>16</b> |
|              | ARMA(1,0)-GARCH(1,1) | 28        | 27        | 16        |
|              | GARCH-EVT (k=25)     | 23        | 11        | 12        |
|              | GARCH-EVT (k=50)     | 22        | 11        | 12        |
|              | GARCH-EVT (k=100)    | 22        | 12        | 11        |
| 5% kuantil   | <b>Expected</b>      | <b>82</b> | <b>82</b> | <b>82</b> |
|              | ARMA(1,0)-GARCH(1,1) | 57        | 54        | 50        |
|              | GARCH-EVT (k=25)     | 90        | 71        | 60        |
|              | GARCH-EVT (k=50)     | 82        | 68        | 66        |
|              | GARCH-EVT (k=100)    | 85        | 64        | 64        |

Pada Tabel 4.11 di atas disajikan hasil *backtesting* untuk *left tail (loss)*. Pada 0,5% dan 1% kuantil, pendekatan *EVT* memberikan hasil yang lebih bagus dibandingkan ARMA-GARCH ditunjukkan dengan nilai *violation* yang lebih kecil. Akan tetapi pada saham AMAG, kedua metode memberikan hasil yang *underestimate*. Sedangkan pada 5% kuantil, pendekatan ARMA-GARCH memberikan hasil yang lebih baik dibandingkan EVT-GARCH.

Hasil *backtesting* untuk *right tail (gain)*, disajikan dalam Tabel 4.12 berikut ini. Secara keseluruhan, pendekatan GARCH-EVT memberikan hasil prediksi yang lebih baik jika dibandingkan dengan ARMA-GARCH, terutama pada 0,5% dan 1% kuantil. Pada 5% kuantil, kedua pendekatan ini memberikan hasil yang hampir sama.

**Tabel 4.12** Hasil *Backtesting (Right Tail)*

| Kuantil      | Metode Pendekatan    | Saham     |           |           |
|--------------|----------------------|-----------|-----------|-----------|
|              |                      | AMAG      | LPGI      | PNIN      |
| 0,5% kuantil | <b>Expected</b>      | <b>8</b>  | <b>8</b>  | <b>8</b>  |
|              | ARMA(1,0)-GARCH(1,1) | 27        | 27        | 23        |
|              | GARCH-EVT (k=25)     | 8         | 9         | 7         |
|              | GARCH-EVT (k=50)     | 8         | 9         | 9         |
|              | GARCH-EVT (k=100)    | 8         | 9         | 9         |
| 1% kuantil   | <b>Expected</b>      | <b>16</b> | <b>16</b> | <b>16</b> |
|              | ARMA(1,0)-GARCH(1,1) | 36        | 34        | 42        |
|              | GARCH-EVT (k=25)     | 12        | 12        | 12        |
|              | GARCH-EVT (k=50)     | 17        | 14        | 12        |
|              | GARCH-EVT (k=100)    | 17        | 15        | 12        |
| 5% kuantil   | <b>Expected</b>      | <b>82</b> | <b>82</b> | <b>82</b> |
|              | ARMA(1,0)-GARCH(1,1) | 80        | 61        | 71        |
|              | GARCH-EVT (k=25)     | 85        | 61        | 83        |
|              | GARCH-EVT (k=50)     | 81        | 61        | 65        |
|              | GARCH-EVT (k=100)    | 80        | 61        | 62        |

*(halaman ini sengaja dikosongkan)*

## LAMPIRAN

### Lampiran 1

#### Data Harga Saham dan *Return* pada Saham AMAG, LPGI dan PNIN

| No   | Date      | AMAG         |               | LPGI         |               | PNIN         |               |
|------|-----------|--------------|---------------|--------------|---------------|--------------|---------------|
|      |           | <i>Price</i> | <i>Return</i> | <i>Price</i> | <i>Return</i> | <i>Price</i> | <i>Return</i> |
| 1    | 1/3/2006  | 84.22        | 0             | 210.04       | -0.07275      | 274.04       | 0.036378      |
| 2    | 1/4/2006  | 84.22        | 0             | 202.12       | -0.03844      | 278.93       | 0.017687      |
| 3    | 1/5/2006  | 80.21        | -0.04878      | 210.04       | 0.038436      | 269.15       | -0.03569      |
| 4    | 1/6/2006  | 84.22        | 0.048784      | 241.75       | 0.140606      | 283.83       | 0.053107      |
| 5    | 1/9/2006  | 80.21        | -0.04878      | 221.93       | -0.08554      | 278.93       | -0.01741      |
| 6    | 1/11/2006 | 84.22        | 0.048784      | 241.75       | 0.085542      | 274.04       | -0.01769      |
| 7    | 1/12/2006 | 80.21        | -0.04878      | 241.75       | 0             | 278.93       | 0.017687      |
| 8    | 1/13/2006 | 80.21        | 0             | 301.19       | 0.219837      | 278.93       | 0             |
| 9    | 1/16/2006 | 80.21        | 0             | 277.41       | -0.08224      | 283.83       | 0.017415      |
| 10   | 1/17/2006 | 80.21        | 0             | 253.64       | -0.08958      | 274.04       | -0.0351       |
| ...  | ...       | ...          | ...           | ...          | ...           | ...          | ...           |
| ...  | ...       | ...          | ...           | ...          | ...           | ...          | ...           |
| ...  | ...       | ...          | ...           | ...          | ...           | ...          | ...           |
| ...  | ...       | ...          | ...           | ...          | ...           | ...          | ...           |
| 2557 | 3/22/2016 | 365          | 0.013793      | 4975         | 0             | 505          | 0             |
| 2558 | 3/23/2016 | 365          | 0             | 4975         | 0             | 505          | 0             |
| 2559 | 3/24/2016 | 361          | -0.01102      | 4975         | 0             | 510          | 0.009852      |
| 2560 | 3/25/2016 | 361          | 0             | 4975         | 0             | 510          | 0             |
| 2561 | 3/28/2016 | 355          | -0.01676      | 4975         | 0             | 505          | -0.00985      |
| 2562 | 3/29/2016 | 355          | 0             | 4885         | -0.01826      | 505          | 0             |
| 2563 | 3/30/2016 | 350          | -0.01418      | 4885         | 0             | 500          | -0.00995      |
| 2564 | 3/31/2016 | 323          | -0.08028      | 4885         | 0             | 489          | -0.02225      |

**Lampiran 2**

**Statistika Deskriptif Harga Saham dan Return pada Saham AMAG, LPGI dan PNIN**

**Descriptive Statistics: APrice, AReturn, LPrice, LReturn, PPrice, PReturn**

| Variable | N    | N* | Mean     | SE Mean  | StDev    | Variance  |   |
|----------|------|----|----------|----------|----------|-----------|---|
| Minimum  |      |    |          |          |          |           |   |
| APrice   | 2564 | 0  | 150.89   | 1.90     | 96.24    | 9262.48   |   |
| 40.10    |      |    |          |          |          |           |   |
| AReturn  | 2564 | 0  | 0.000524 | 0.000831 | 0.042087 | 0.001771  | - |
| 0.435465 |      |    |          |          |          |           |   |
| LPrice   | 2564 | 0  | 1820.1   | 34.8     | 1761.7   | 3103725.7 |   |
| 198.2    |      |    |          |          |          |           |   |
| LReturn  | 2564 | 0  | 0.00120  | 0.00157  | 0.07960  | 0.00634   | - |
| 0.67789  |      |    |          |          |          |           |   |
| PPrice   | 2564 | 0  | 455.22   | 3.78     | 191.45   | 36651.86  |   |
| 127.23   |      |    |          |          |          |           |   |
| PReturn  | 2564 | 0  | 0.000240 | 0.000621 | 0.031427 | 0.000988  | - |
| 0.265913 |      |    |          |          |          |           |   |

| Variable | Q1        | Median   | Q3       | Maximum  | Skewness | Kurtosis |
|----------|-----------|----------|----------|----------|----------|----------|
| APrice   | 68.18     | 120.31   | 222.33   | 410.00   | 0.87     | -0.18    |
| AReturn  | -0.013038 | 0.000000 | 0.013029 | 0.435465 | 0.43     | 20.20    |
| LPrice   | 384.4     | 1234.7   | 2985.0   | 6475.0   | 0.93     | -0.60    |
| LReturn  | 0.000000  | 0.000000 | 0.000000 | 0.59250  | 0.05     | 12.59    |
| PPrice   | 269.15    | 464.38   | 630.00   | 913.70   | 0.16     | -1.27    |
| PReturn  | -0.013606 | 0.000000 | 0.013676 | 0.272566 | 0.37     | 12.81    |

### Lampiran 3

#### Hasil Uji *Augmented Dickey Fuller*

1. AMAG  
Augmented Dickey-Fuller Test  
data: AMAG\$Return  
Dickey-Fuller = -13.615, Lag order = 13, p-value = 0.01  
alternative hypothesis: stationary  
Warning message:  
In adf.test(AMAG\$Return) : p-value smaller than printed p-value
  
2. LPGI  
Augmented Dickey-Fuller Test  
data: LPGI\$LReturn  
Dickey-Fuller = -17.187, Lag order = 13, p-value = 0.01  
alternative hypothesis: stationary  
Warning message:  
In adf.test(LPGI\$LReturn) : p-value smaller than printed p-value
  
3. PNIN  
Augmented Dickey-Fuller Test  
data: PNIN\$PReturn  
Dickey-Fuller = -13.55, Lag order = 13, p-value = 0.01  
alternative hypothesis: stationary  
Warning message:  
In adf.test(PNIN\$PReturn) : p-value smaller than printed p-value

Lampiran 4A

Hasil Uji Signifikansi Parameter Model ARMA Saham AMAG

**AR(1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| AR1,1     | -0.24764 | 0.01915        | -12.93  | <.0001         | 1   |

Variance Estimate 0.001663  
Std Error Estimate 0.04078  
AIC -9129.93  
SBC -9124.08  
Number of Residuals 2564

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 59.98      | 5  | <.0001     | -0.022                     | -0.083 | 0.040  | 0.015  | -0.111 | 0.043  |
| 12     | 78.58      | 11 | <.0001     | 0.058                      | -0.008 | 0.015  | 0.039  | -0.033 | 0.031  |
| 18     | 107.15     | 17 | <.0001     | -0.005                     | -0.050 | 0.037  | 0.045  | -0.066 | 0.029  |
| 24     | 110.10     | 23 | <.0001     | 0.017                      | -0.005 | -0.021 | 0.009  | -0.017 | 0.000  |
| 30     | 139.93     | 29 | <.0001     | -0.002                     | 0.077  | -0.034 | 0.040  | -0.012 | -0.052 |
| 36     | 162.94     | 35 | <.0001     | -0.042                     | -0.009 | -0.056 | -0.024 | 0.050  | 0.028  |
| 42     | 185.52     | 41 | <.0001     | -0.041                     | 0.024  | -0.019 | -0.064 | -0.002 | 0.043  |
| 48     | 194.14     | 47 | <.0001     | -0.039                     | 0.008  | 0.031  | 0.008  | -0.025 | 0.002  |

Tests for Normality

| Test               | --Statistic-- |          | -----p Value----- |         |
|--------------------|---------------|----------|-------------------|---------|
| Kolmogorov-Smirnov | D             | 0.137263 | Pr > D            | <0.0100 |
| Cramer-von Mises   | W-Sq          | 20.73915 | Pr > W-Sq         | <0.0050 |
| Anderson-Darling   | A-Sq          | 108.1673 | Pr > A-Sq         | <0.0050 |

Lampiran 4A

Hasil Uji Signifikansi Parameter Model ARMA Saham AMAG

**MA(1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| MA1,1     | 0.27118  | 0.01902        | 14.25   | <.0001         | 1   |

Variance Estimate 0.001652  
Std Error Estimate 0.04064  
AIC -9147.55  
SBC -9141.7  
Number of Residuals 2564

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 36.64      | 5  | <.0001     | 0.001                      | -0.014 | 0.034  | 0.016  | -0.104 | 0.043  |
| 12     | 53.77      | 11 | <.0001     | 0.054                      | -0.001 | 0.017  | 0.041  | -0.031 | 0.030  |
| 18     | 78.68      | 17 | <.0001     | -0.006                     | -0.044 | 0.033  | 0.043  | -0.061 | 0.030  |
| 24     | 81.41      | 23 | <.0001     | 0.012                      | -0.003 | -0.021 | 0.009  | -0.018 | 0.006  |
| 30     | 112.67     | 29 | <.0001     | -0.003                     | 0.079  | -0.033 | 0.041  | -0.017 | -0.052 |
| 36     | 136.59     | 35 | <.0001     | -0.049                     | -0.017 | -0.057 | -0.023 | 0.044  | 0.028  |
| 42     | 156.82     | 41 | <.0001     | -0.039                     | 0.021  | -0.023 | -0.061 | -0.006 | 0.039  |
| 48     | 164.17     | 47 | <.0001     | -0.037                     | 0.011  | 0.028  | 0.009  | -0.021 | 0.002  |

Tests for Normality

| Test               | --Statistic-- |          | -----p Value----- |         |
|--------------------|---------------|----------|-------------------|---------|
| Kolmogorov-Smirnov | D             | 0.140075 | Pr > D            | <0.0100 |
| Cramer-von Mises   | W-Sq          | 20.85111 | Pr > W-Sq         | <0.0050 |
| Anderson-Darling   | A-Sq          | 108.7748 | Pr > A-Sq         | <0.0050 |

Lampiran 4A

Hasil Uji Signifikansi Parameter Model ARMA Saham AMAG

**ARMA(1,1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| MA1,1     | 0.28760  | 0.06960        | 4.13    | <.0001         | 1   |
| AR1,1     | 0.01794  | 0.07267        | 0.25    | 0.8050         | 1   |

Variance Estimate      0.001652  
Std Error Estimate      0.040648  
AIC                              -9145.62  
SBC                              -9133.92  
Number of Residuals      2564

Correlations of Parameter Estimates

| Parameter | MA1,1 | AR1,1 |
|-----------|-------|-------|
| MA1,1     | 1.000 | 0.962 |
| AR1,1     | 0.962 | 1.000 |

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 36.43      | 4  | <.0001     | 0.000                      | -0.010 | 0.035  | 0.017  | -0.104 | 0.043  |
| 12     | 53.54      | 10 | <.0001     | 0.053                      | -0.001 | 0.017  | 0.041  | -0.031 | 0.030  |
| 18     | 78.41      | 16 | <.0001     | -0.006                     | -0.044 | 0.033  | 0.043  | -0.061 | 0.031  |
| 24     | 81.14      | 22 | <.0001     | 0.012                      | -0.003 | -0.021 | 0.009  | -0.018 | 0.006  |
| 30     | 112.57     | 28 | <.0001     | -0.004                     | 0.079  | -0.033 | 0.041  | -0.018 | -0.052 |
| 36     | 136.43     | 34 | <.0001     | -0.049                     | -0.017 | -0.057 | -0.023 | 0.043  | 0.028  |
| 42     | 156.60     | 40 | <.0001     | -0.039                     | 0.021  | -0.023 | -0.061 | -0.006 | 0.039  |
| 48     | 163.91     | 46 | <.0001     | -0.037                     | 0.012  | 0.028  | 0.009  | -0.021 | 0.002  |

Tests for Normality

| Test               | --Statistic--   | -----p Value-----   |
|--------------------|-----------------|---------------------|
| Kolmogorov-Smirnov | D      0.13962  | Pr > D      <0.0100 |
| Cramer-von Mises   | W-Sq   20.88896 | Pr > W-Sq   <0.0050 |
| Anderson-Darling   | A-Sq   108.9498 | Pr > A-Sq   <0.0050 |

**Lampiran 4B**

**Hasil Uji Signifikansi Parameter Model ARMA Saham LPGI**

| <u>AR(1)</u>                       |               |                |                   |                            |        |        |        |        |        |
|------------------------------------|---------------|----------------|-------------------|----------------------------|--------|--------|--------|--------|--------|
| The ARIMA Procedure                |               |                |                   |                            |        |        |        |        |        |
| Maximum Likelihood Estimation      |               |                |                   |                            |        |        |        |        |        |
| Parameter                          | Estimate      | Standard Error | t Value           | Approx Pr >  t             | Lag    |        |        |        |        |
| AR1,1                              | -0.34392      | 0.01855        | -18.54            | <.0001                     | 1      |        |        |        |        |
| Variance Estimate                  |               |                | 0.005588          |                            |        |        |        |        |        |
| Std Error Estimate                 |               |                | 0.07475           |                            |        |        |        |        |        |
| AIC                                |               |                | -6022.57          |                            |        |        |        |        |        |
| SBC                                |               |                | -6016.72          |                            |        |        |        |        |        |
| Number of Residuals                |               |                | 2564              |                            |        |        |        |        |        |
| Autocorrelation Check of Residuals |               |                |                   |                            |        |        |        |        |        |
| To Lag                             | Chi-Square    | DF             | Pr > ChiSq        | -----Autocorrelations----- |        |        |        |        |        |
| 6                                  | 73.16         | 5              | <.0001            | -0.037                     | -0.134 | -0.081 | -0.024 | -0.028 | 0.038  |
| 12                                 | 109.80        | 11             | <.0001            | -0.061                     | 0.034  | -0.042 | 0.020  | -0.083 | 0.017  |
| 18                                 | 115.68        | 17             | <.0001            | -0.016                     | 0.036  | 0.014  | -0.016 | -0.015 | 0.009  |
| 24                                 | 120.65        | 23             | <.0001            | -0.013                     | -0.001 | -0.017 | 0.000  | 0.015  | 0.035  |
| 30                                 | 124.02        | 29             | <.0001            | -0.017                     | -0.007 | 0.008  | -0.022 | 0.017  | 0.012  |
| 36                                 | 134.76        | 35             | <.0001            | -0.019                     | -0.021 | -0.031 | 0.029  | 0.011  | 0.037  |
| 42                                 | 150.69        | 41             | <.0001            | 0.035                      | -0.026 | -0.044 | 0.046  | -0.010 | -0.004 |
| 48                                 | 155.96        | 47             | <.0001            | 0.010                      | 0.027  | 0.003  | -0.024 | -0.011 | -0.021 |
| Tests for Normality                |               |                |                   |                            |        |        |        |        |        |
| Test                               | --Statistic-- |                | -----p Value----- |                            |        |        |        |        |        |
| Kolmogorov-Smirnov                 | D             | 0.197874       | Pr > D            | <0.0100                    |        |        |        |        |        |
| Cramer-von Mises                   | W-Sq          | 45.56121       | Pr > W-Sq         | <0.0050                    |        |        |        |        |        |

Lampiran 4B

Hasil Uji Signifikansi Parameter Model ARMA Saham LPGI

MA(1)

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| MA1,1     | 0.42283  | 0.01789        | 23.63   | <.0001         | 1   |

Variance Estimate 0.005452  
Std Error Estimate 0.073838  
AIC -6085.43  
SBC -6079.58  
Number of Residuals 2564

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 31.22      | 5  | <.0001     | 0.019                      | -0.000 | -0.087 | -0.029 | -0.050 | 0.030  |
| 12     | 80.94      | 11 | <.0001     | -0.073                     | 0.031  | -0.062 | 0.017  | -0.093 | 0.017  |
| 18     | 86.96      | 17 | <.0001     | -0.024                     | 0.036  | 0.010  | -0.010 | -0.016 | 0.005  |
| 24     | 92.28      | 23 | <.0001     | -0.017                     | -0.002 | -0.018 | 0.005  | 0.013  | 0.035  |
| 30     | 94.46      | 29 | <.0001     | -0.012                     | -0.005 | 0.006  | -0.020 | 0.013  | 0.006  |
| 36     | 107.22     | 35 | <.0001     | -0.023                     | -0.019 | -0.031 | 0.032  | 0.016  | 0.043  |
| 42     | 119.51     | 41 | <.0001     | 0.034                      | -0.015 | -0.038 | 0.041  | -0.011 | 0.005  |
| 48     | 125.12     | 47 | <.0001     | 0.011                      | 0.025  | 0.003  | -0.025 | -0.014 | -0.024 |

Tests for Normality

| Test               | --Statistic-- |          | -----p Value----- |         |
|--------------------|---------------|----------|-------------------|---------|
| Kolmogorov-Smirnov | D             | 0.180271 | Pr > D            | <0.0100 |
| Cramer-von Mises   | W-Sq          | 38.89899 | Pr > W-Sq         | <0.0050 |

**Lampiran 4B**

**Hasil Uji Signifikansi Parameter Model ARMA Saham LPGI**

**ARMA(1,1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| MA1,1     | 0.57676  | 0.03600        | 16.02   | <.0001         | 1   |
| AR1,1     | 0.17508  | 0.04342        | 4.03    | <.0001         | 1   |

|                     |          |
|---------------------|----------|
| Variance Estimate   | 0.005435 |
| Std Error Estimate  | 0.073721 |
| AIC                 | -6092.52 |
| SBC                 | -6080.82 |
| Number of Residuals | 2564     |

Correlations of Parameter Estimates

| Parameter | MA1,1 | AR1,1 |
|-----------|-------|-------|
| MA1,1     | 1.000 | 0.894 |
| AR1,1     | 0.894 | 1.000 |

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 25.85      | 4  | <.0001     | -0.009                     | 0.060  | -0.054 | -0.006 | -0.049 | 0.034  |
| 12     | 86.79      | 10 | <.0001     | -0.082                     | 0.033  | -0.073 | 0.020  | -0.099 | 0.020  |
| 18     | 93.17      | 16 | <.0001     | -0.032                     | 0.032  | 0.005  | -0.010 | -0.016 | 0.006  |
| 24     | 98.31      | 22 | <.0001     | -0.019                     | -0.000 | -0.017 | 0.006  | 0.010  | 0.035  |
| 30     | 100.56     | 28 | <.0001     | -0.012                     | -0.004 | 0.008  | -0.022 | 0.012  | 0.004  |
| 36     | 112.35     | 34 | <.0001     | -0.022                     | -0.014 | -0.030 | 0.034  | 0.013  | 0.041  |
| 42     | 124.70     | 40 | <.0001     | 0.034                      | -0.009 | -0.035 | 0.045  | -0.012 | 0.008  |
| 48     | 129.74     | 46 | <.0001     | 0.009                      | 0.023  | 0.002  | -0.024 | -0.012 | -0.024 |

Tests for Normality

| Test               | Statistic     | p Value           |
|--------------------|---------------|-------------------|
| Kolmogorov-Smirnov | D 0.176588    | Pr > D <0.0100    |
| Cramer-von Mises   | W-Sq 36.78723 | Pr > W-Sq <0.0050 |
| Anderson-Darling   | A-Sq 180.8733 | Pr > A-Sq <0.0050 |

Lampiran 4C

Hasil Uji Signifikansi Parameter Model ARMA Saham PNIN

**AR(1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| AR1,1     | -0.16397 | 0.01949        | -8.41   | <.0001         | 1   |

Variance Estimate 0.000961  
 Std Error Estimate 0.031002  
 AIC -10535.7  
 SBC -10529.9  
 Number of Residuals 2564

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 36.12      | 5  | <.0001     | -0.014                     | -0.086 | -0.001 | -0.071 | 0.024  | 0.029  |
| 12     | 45.72      | 11 | <.0001     | -0.029                     | 0.027  | -0.023 | -0.031 | -0.026 | 0.000  |
| 18     | 77.96      | 17 | <.0001     | 0.096                      | -0.003 | -0.040 | 0.026  | -0.031 | 0.005  |
| 24     | 99.89      | 23 | <.0001     | 0.069                      | -0.044 | 0.007  | 0.033  | -0.009 | 0.023  |
| 30     | 108.50     | 29 | <.0001     | 0.026                      | -0.002 | 0.029  | 0.024  | -0.023 | -0.026 |
| 36     | 113.13     | 35 | <.0001     | -0.000                     | 0.002  | -0.029 | 0.017  | -0.015 | -0.020 |
| 42     | 129.67     | 41 | <.0001     | -0.017                     | -0.024 | 0.001  | 0.059  | 0.044  | -0.010 |
| 48     | 157.82     | 47 | <.0001     | -0.031                     | 0.053  | -0.056 | -0.024 | 0.057  | 0.007  |

Tests for Normality

| Test               | --Statistic-- |          | -----p Value----- |         |
|--------------------|---------------|----------|-------------------|---------|
| Kolmogorov-Smirnov | D             | 0.117048 | Pr > D            | <0.0100 |
| Cramer-von Mises   | W-Sq          | 16.93931 | Pr > W-Sq         | <0.0050 |
| Anderson-Darling   | A-Sq          | 90.63274 | Pr > A-Sq         | <0.0050 |

Lampiran 4C

Hasil Uji Signifikansi Parameter Model ARMA Saham PNIN

**MA(1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| MA1,1     | 0.19203  | 0.01939        | 9.91    | <.0001         | 1   |

Variance Estimate      0.000957  
Std Error Estimate      0.03093  
AIC                              -10547.8  
SBC                              -10541.9  
Number of Residuals      2564

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 25.09      | 5  | 0.0001     | 0.011                      | -0.056 | -0.004 | -0.072 | 0.022  | 0.028  |
| 12     | 34.48      | 11 | 0.0003     | -0.028                     | 0.025  | -0.025 | -0.032 | -0.025 | 0.001  |
| 18     | 64.93      | 17 | <.0001     | 0.095                      | -0.000 | -0.037 | 0.024  | -0.029 | 0.006  |
| 24     | 85.81      | 23 | <.0001     | 0.068                      | -0.040 | 0.009  | 0.033  | -0.006 | 0.025  |
| 30     | 94.62      | 29 | <.0001     | 0.027                      | 0.001  | 0.030  | 0.024  | -0.022 | -0.026 |
| 36     | 99.42      | 35 | <.0001     | -0.003                     | 0.001  | -0.029 | 0.016  | -0.017 | -0.021 |
| 42     | 116.22     | 41 | <.0001     | -0.019                     | -0.023 | 0.003  | 0.059  | 0.045  | -0.006 |
| 48     | 142.50     | 47 | <.0001     | -0.030                     | 0.049  | -0.055 | -0.023 | 0.056  | 0.008  |

Tests for Normality

| Test               | --Statistic-- |          | -----p Value----- |         |
|--------------------|---------------|----------|-------------------|---------|
| Kolmogorov-Smirnov | D             | 0.110286 | Pr > D            | <0.0100 |
| Cramer-von Mises   | W-Sq          | 16.40369 | Pr > W-Sq         | <0.0050 |
| Anderson-Darling   | A-Sq          | 88.59328 | Pr > A-Sq         | <0.0050 |

Lampiran 4C

Hasil Uji Signifikansi Parameter Model ARMA Saham PNIN

**ARMA(1,1)**

The ARIMA Procedure

Maximum Likelihood Estimation

| Parameter | Estimate | Standard Error | t Value | Approx Pr >  t | Lag |
|-----------|----------|----------------|---------|----------------|-----|
| MA1,1     | 0.50778  | 0.07782        | 6.53    | <.0001         | 1   |
| AR1,1     | 0.32648  | 0.08544        | 3.82    | 0.0001         | 1   |

Variance Estimate      0.000953  
Std Error Estimate      0.030871  
AIC                              -10556.5  
SBC                              -10544.8  
Number of Residuals      2564

Correlations of Parameter Estimates

| Parameter | MA1,1 | AR1,1 |
|-----------|-------|-------|
| MA1,1     | 1.000 | 0.976 |
| AR1,1     | 0.976 | 1.000 |

Autocorrelation Check of Residuals

| To Lag | Chi-Square | DF | Pr > ChiSq | -----Autocorrelations----- |        |        |        |        |        |
|--------|------------|----|------------|----------------------------|--------|--------|--------|--------|--------|
| 6      | 15.21      | 4  | 0.0043     | -0.000                     | -0.003 | 0.029  | -0.060 | 0.027  | 0.027  |
| 12     | 24.09      | 10 | 0.0074     | -0.030                     | 0.026  | -0.026 | -0.028 | -0.021 | -0.003 |
| 18     | 52.68      | 16 | <.0001     | 0.091                      | -0.001 | -0.034 | 0.029  | -0.028 | 0.005  |
| 24     | 74.93      | 22 | <.0001     | 0.069                      | -0.039 | 0.014  | 0.035  | -0.005 | 0.028  |
| 30     | 83.73      | 28 | <.0001     | 0.030                      | 0.003  | 0.031  | 0.023  | -0.021 | -0.024 |
| 36     | 89.26      | 34 | <.0001     | -0.004                     | -0.001 | -0.033 | 0.014  | -0.020 | -0.021 |
| 42     | 104.07     | 40 | <.0001     | -0.017                     | -0.020 | 0.002  | 0.056  | 0.043  | -0.002 |
| 48     | 129.90     | 46 | <.0001     | -0.029                     | 0.053  | -0.053 | -0.020 | 0.055  | 0.003  |

Tests for Normality

| Test               | --Statistic-- |          | -----p Value----- |         |
|--------------------|---------------|----------|-------------------|---------|
| Kolmogorov-Smirnov | D             | 0.110897 | Pr > D            | <0.0100 |
| Cramer-von Mises   | W-Sq          | 16.37122 | Pr > W-Sq         | <0.0050 |
| Anderson-Darling   | A-Sq          | 88.42913 | Pr > A-Sq         | <0.0050 |

## Lampiran 5

### Hasil Uji Lagrange Multiplier

#### Saham AMAG : ARMA(1,0)

|       | chi-sq   | p-value |
|-------|----------|---------|
| [1,]  | 129.99   | 0       |
| [2,]  | 200.0235 | 0       |
| [3,]  | 209.5666 | 0       |
| [4,]  | 230.0769 | 0       |
| [5,]  | 254.3102 | 0       |
| [6,]  | 284.3221 | 0       |
| [7,]  | 284.4037 | 0       |
| [8,]  | 295.1133 | 0       |
| [9,]  | 299.289  | 0       |
| [10,] | 307.3221 | 0       |

#### Saham LPGI : ARMA(1,0)

|       | chi-sq   | p-value |
|-------|----------|---------|
| [1,]  | 277.015  | 0       |
| [2,]  | 288.2954 | 0       |
| [3,]  | 297.2905 | 0       |
| [4,]  | 308.6364 | 0       |
| [5,]  | 316.5908 | 0       |
| [6,]  | 325.6152 | 0       |
| [7,]  | 329.741  | 0       |
| [8,]  | 347.346  | 0       |
| [9,]  | 366.6676 | 0       |
| [10,] | 382.2718 | 0       |

#### Saham PNIN : ARMA(1,0)

|       | chi-sq   | p-value |
|-------|----------|---------|
| [1,]  | 282.9345 | 0       |
| [2,]  | 314.8438 | 0       |
| [3,]  | 383.4195 | 0       |
| [4,]  | 399.9122 | 0       |
| [5,]  | 418.113  | 0       |
| [6,]  | 460.8461 | 0       |
| [7,]  | 470.5807 | 0       |
| [8,]  | 471.2179 | 0       |
| [9,]  | 474.0619 | 0       |
| [10,] | 474.6508 | 0       |

## Lampiran 6A

### Hasil Estimasi Parameter Model ARMA(1,0)-GARCH(1,1) Saham AMAG

```
Title: AMAG
GARCH Modelling
Call:
garchFit(formula = ~arma(1, 0) + garch(1, 1), data = Areturn,
include.mean = FALSE, trace = FALSE)

Mean and Variance Equation:
data ~ arma(1, 0) + garch(1, 1)
<environment: 0x0000000015dbf080>
[data = Areturn]

Conditional Distribution:
norm

Coefficient(s):
      ar1      omega      alpha      beta1
-1.6638e-01  3.0371e-05  1.2305e-01  8.6674e-01

Std. Errors:
based on Hessian

Error Analysis:
      Estimate Std. Error t value Pr(>|t|)
ar1  -1.664e-01  2.356e-02  -7.061 1.65e-12 ***
omega  3.037e-05  4.804e-06   6.322 2.58e-10 ***
alpha  1.230e-01  1.393e-02   8.835 < 2e-16 ***
beta1  8.667e-01  1.312e-02  66.071 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
5222.374  normalized: 2.036807

Description:
Thu Jun 09 07:46:28 2016 by user: ely
```

## Lampiran 6B

### Hasil Estimasi Parameter Model ARMA(1,0)-GARCH(1,1) Saham LPGI

```
Title: LPGI  
GARCH Modelling  
  
Call:  
garchFit(formula = ~arma(1, 0) + garch(1, 1), data = Lreturn,  
include.mean = FALSE, trace = FALSE)  
  
Mean and Variance Equation:  
data ~ arma(1, 0) + garch(1, 1)  
<environment: 0x000000006ddd438>  
[data = Lreturn]  
  
Conditional Distribution:  
norm  
  
Coefficient(s):  
      ar1      omega      alpha1      beta1  
-2.0718e-01  7.9266e-05  7.2501e-02  9.0892e-01  
  
Std. Errors:  
based on Hessian  
  
Error Analysis:  
      Estimate Std. Error t value Pr(>|t|)  
ar1  -2.072e-01  2.370e-02  -8.741 < 2e-16 ***  
omega  7.927e-05  1.501e-05   5.281 1.29e-07 ***  
alpha1  7.250e-02  1.017e-02   7.131 9.93e-13 ***  
beta1  9.089e-01  1.229e-02  73.966 < 2e-16 ***  
---  
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
  
Log Likelihood:  
3742.295  normalized: 1.459554  
  
Description:  
Thu Jun 09 07:48:33 2016 by user: ely
```

## Lampiran 6C

### Hasil Estimasi Parameter Model ARMA(1,0)-GARCH(1,1) Saham PNIN

```
Title: PNIN
GARCH Modelling

Call:
garchFit(formula = ~arma(1, 0) + garch(1, 1), data = Pretturn,
include.mean = FALSE, trace = FALSE)

Mean and Variance Equation:
data ~ arma(1, 0) + garch(1, 1)
<environment: 0x0000000015cd5a60>
[data = Pretturn]

Conditional Distribution:
norm

Coefficient(s):
      ar1      omega      alpha1      beta1
-1.3538e-01  1.2882e-05  9.8773e-02  8.9142e-01

Std. Errors:
based on Hessian

Error Analysis:
      Estimate Std. Error t value Pr(>|t|)
ar1  -1.354e-01  2.198e-02  -6.160 7.29e-10 ***
omega  1.288e-05  3.006e-06   4.285 1.82e-05 ***
alpha1  9.877e-02  1.185e-02   8.338 < 2e-16 ***
beta1  8.914e-01  1.242e-02  71.748 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:
5841.213  normalized: 2.278164

Description:
Thu Jun 09 07:49:22 2016 by user: ely
```

## Lampiran 7 : R Code

### a. R Code untuk Perhitungan VaR ARMA-GARCH kuantil 0,5%

```
LPGI=read.csv("D://1-Tesis/1-Thesis/5-Data/LPGI.csv",sep="," ,header=TRUE)
Date=read.csv("D://1-Tesis/1-Thesis/5-Data/Date.csv",sep="," ,header=TRUE)
Lreturn=LPGI[,3]
LT= length(Lreturn)
m      = 1000 #window
n      = 1564 #jumlah 1 day forecast
tau    = 0.005
z.alpha = qnorm(tau,0,1)
z.alpha.r      = qnorm(1-tau,0,1)
library(fGarch)
Loss.garch=0
Prof.garch=0
VaR.garch=rep(0,AT)
VaR.garch.r=rep(0,AT)

#RISIKO
options(warn=1)
for (i in 1:n)
{
model.garch      = garchFit(~arma(1,0)+garch(1,1),data=Lreturn[i:(i+m-
1)],include.mean=FALSE,trace=FALSE)
mean.GARCH      = model.garch@fitted[m]
sd.GARCH        = model.garch@sigma.t[m]
VaR             = mean.GARCH+(sd.GARCH*z.alpha)
VaR.garch[i+m]  = VaR
if(VaR.garch[i+m] > Lreturn[i+m]){
Loss.garch=Loss.garch+1
}else{
Loss.garch
}
}
Loss.garch
return.out      = matrix(Lreturn[(m+1):LT],ncol=1)
VaR.garch.out   = matrix(VaR.garch[(m+1):LT],ncol=1)
write.csv(VaR.garch.out,"D://1-Tesis/VaR.garch.LP.0,5%.csv")
write.csv(return.out,"D://1-Tesis/Return.LP.0,5%.csv")

spacings=c(0.2,0.4,0.6,0.8,1)
win.graph()
ylim<-c(min(VaR.garch.out,return.out),max(VaR.garch.out,return.out))
plot(return.out,lty=1, main="",ty="l",col="light
blue",ylim=ylim,xlab="",ylab="",xaxt="n")
lines(VaR.garch.out,lty=2)
legend(x="bottomright",legend=c("True 1 day log returns","99.5% 1 day VaR
forecast(left tail)"),
lty=1:2,col=c("light blue","green"))
#dates.log.10<-read.table(file="clipboard")
ax.vals.3<-c(1,floor(length(return.out)*spacings))
axis(side=1,at=ax.vals.3,labels=Date[ax.vals.3,],cex.axis=0.7)
```

**a. R Code untuk Perhitungan VaR ARMA-GARCH kuantil 0,5% (lanjutan)**

```
#PROFIT
options(warn=1)
for (i in 1:n)
{
model.garch.r      = garchFit(~arma(1,0)+garch(1,1),data=Lreturn[i:(i+m-
1)],include.mean=FALSE,trace=FALSE)
mean.GARCH.r      = model.garch.r@fitted[m]
sd.GARCH.r        = model.garch.r@sigma.t[m]
VaR.r             = mean.GARCH.r+(sd.GARCH.r*z.alpha.r)
VaR.garch.r[i+m]  = VaR.r
if(VaR.garch.r[i+m] < Lreturn[i+m]){
Prof.garch=Prof.garch+1
}else{
Prof.garch
}
}
}
Prof.garch
return.out        = matrix(Lreturn[(m+1):LT],ncol=1)
VaR.garch.r.out   = matrix(VaR.garch.r[(m+1):LT],ncol=1)
write.csv(VaR.garch.r.out,"D://1-Tesis/VaR.garch.r.LP.0,5%.csv")
write.csv(return.out,"D://1-Tesis/Return.r.LP.0,5%.csv")

spacings=c(0.2,0.4,0.6,0.8,1)
win.graph()
ylim<-c(min(VaR.garch.r.out,return.out),max(VaR.garch.r.out,return.out))
plot(return.out,lty=1, main="",ty="l",col="light
blue",ylim=ylim,xlab="",ylab="",xaxt="n")
lines(VaR.garch.r.out,lty=2)
legend(x="bottomright",legend=c("True 1 day log returns","99.5% 1 day VaR
forecast(right tail)"),
lty=1:2,col=c("light blue","green"))
#dates.log.10<-read.table(file="clipboard")
ax.vals.3<-c(1,floor(length(return.out)*spacings))
axis(side=1,at=ax.vals.3,labels=Date[ax.vals.3,],cex.axis=0.7)
```

**b. R Code untuk Perhitungan VaR GARCH-EVT (Loss) Kuantil 0,5%; k=25.**

```
NLPGI=read.csv("D://1-Tesis/1-Thesis/5-Data/NegLPGI.csv",sep=","header=TRUE)
Date=read.csv("D://1-Tesis/1-Thesis/5-Data/Date.csv",sep=","header=TRUE)
NLreturn=NLPGI[,4]
LT= length(NLreturn)
m      = 1000 #window
n = 1564 #jumlah 1 day forecast
tau      = 0.005
tau2     = 1-0.005
library(fGarch)
library(ismev)
Loss.garch.N=0
Prof.garch.N=0
EVT.VaR.dyn.N=rep(0,LT)
EVT.zq2.N=rep(0,LT)
k=25
NLZ=rep(0,m)
#RISIKO
options(warn=1)
for (i in 1:n)
{
model.garch.N      = garchFit(~arma(1,0)+garch(1,1),data=NLreturn[i:(i+m-
1)],include.mean=FALSE,trace=FALSE)
fore.N            = predict(model.garch.N, n.ahead = 1)
mean.fore.N      = fore.N[1]
sd.fore.N        = fore.N[3]
mean.GARCH.N     = model.garch.N@fitted
sd.GARCH.N       = model.garch.N@sigma.t
NLRes.Garch=residuals(model.garch.N)
for (j in 1:m)
{
NLZ[j]=(NLRes.Garch[j]-mean.GARCH.N[j])/sd.GARCH.N[j]
}
EVTthreshold.N=(sort(NLZ, decreasing = TRUE))[(k+1)]
EVTfit.N=gpd.fit(xdat=NLZ,threshold=EVTthreshold.N,ncpy=NULL,show=FALSE)
EVT.scale.N=EVTfit.N$mle[1]
EVT.shape.N=EVTfit.N$mle[2]
EVT.zq.N=EVTthreshold.N+(EVT.scale.N/EVT.shape.N)*(((m*tau)/k)^(-
EVT.shape.N)-1)
EVT.VaR.N=mean.fore.N+sd.fore.N*EVT.zq.N
EVT.VaR.dyn.N[i+m] = EVT.VaR.N
if(EVT.VaR.dyn.N[i+m] < NLreturn[i+m]){
Loss.garch.N=Loss.garch.N+1
}else{
Loss.garch.N
}
}
}
Loss.garch.N
```

**b. R Code untuk Perhitungan VaR GARCH-EVT (Loss) Kuantil 0,5%; k=25.  
(lanjutan)**

```
NLreturn.save      = matrix(NLreturn[(m+1):AT],ncol=1)
EVT.VaR.dyn.N.save = matrix(EVT.VaR.dyn.N[(m+1):AT],ncol=1)
write.csv(EVT.VaR.dyn.N.save,"D://1-Tesis/Output/LPGI/EVT.dyn.N.LP.0,5%-
25.csv")
write.csv(NLreturn.save,"D://1-Tesis/Output/LPGI/Return.N.LP.0,5%-25.csv")

spacings=c(0.2,0.4,0.6,0.8,1)
win.graph()
ylim<-c(min(-0.26,0.26),max(-0.5,0.5))
plot(NLreturn.save,lty=1, main="Plot 0,995% EVT Dynamic VaR & Actual Negatif
Return(LPGI)",ty="l",col="light blue",ylim=ylim,xlab="",ylab="",xaxt="n")
lines(EVT.VaR.dyn.N.save,lty=2)
legend(x="bottomright",legend=c("True 1 day negatif log returns","99.5% 1 day
Dynamic EVT VaR forecast"),
lty=1:2,col=c("light blue","green"))
#dates.log.10<-read.table(file="clipboard")
ax.vals.3<-c(1,floor(length(NLreturn.save)*spacings))
axis(side=1,at=ax.vals.3,labels=Date[ax.vals.3,],cex.axis=0.7)
```

**c. R Code untuk Perhitungan VaR GARCH-EVT (Gain) Kuantil 0,5% ; k=50.**

```

#Right Tail
NAMAG=read.csv("D://1-Tesis/1-Thesis/5-Data/AMAG.csv",sep="," ,header=TRUE)
Date=read.csv("D://1-Tesis/1-Thesis/5-Data/Date.csv",sep="," ,header=TRUE)
NAreturn=NAMAG[,3]
AT= length(NAreturn)
m      = 1000 #window
n = 1564 #jumlah 1 day forecast
tau      = 0.005
tau2     = 1-0.005
library(fGarch)
library(ismev)
Loss.garch.N=0
Prof.garch.N=0
EVT.VaR.dyn.N=rep(0,AT)
EVT.zq2.N=rep(0,AT)
k=50
NAZ=rep(0,m)
#RISIKO
options(warn=1)
for (i in 1:n)
{
model.garch.N      = garchFit(~arma(1,0)+garch(1,1),data=NAreturn[i:(i+m-
1)],include.mean=FALSE,trace=FALSE)
fore.N            = predict(model.garch.N, n.ahead = 1)
mean.fore.N       = fore.N[1]
sd.fore.N         = fore.N[3]
mean.GARCH.N      = model.garch.N@fitted
sd.GARCH.N        = model.garch.N@sigma.t
NARes.Garch=residuals(model.garch.N)
for (j in 1:m)
{
NAZ[j]=(NARes.Garch[j]-mean.GARCH.N[j])/sd.GARCH.N[j]
}
EVTthreshold.N=(sort(NAZ, decreasing = TRUE))[(k+1)]
EVTfit.N=gpd.fit(xdat=NAZ,threshol=EVTthreshold.N,ncpy=NULL,show=FALSE)
EVT.scale.N=EVTfit.N$mle[1]
EVT.shape.N=EVTfit.N$mle[2]
EVT.zq.N=EVTthreshold.N+(EVT.scale.N/EVT.shape.N)*(((m*tau)/k)^(-
EVT.shape.N)-1)
EVT.VaR.N=mean.fore.N+sd.fore.N*EVT.zq.N
EVT.VaR.dyn.N[i+m] = EVT.VaR.N
if(EVT.VaR.dyn.N[i+m] < NAreturn[i+m]){
Loss.garch.N=Loss.garch.N+1
}else{
Loss.garch.N
}
}
}
Loss.garch.N

```

**c. R Code untuk Perhitungan VaR GARCH-EVT (Gain) Kuantil 0,5%; k=50.  
(lanjutan)**

```
NAreturn.save      = matrix(NAreturn[(m+1):AT],ncol=1)
EVT.VaR.dyn.N.save = matrix(EVT.VaR.dyn.N[(m+1):AT],ncol=1)
write.csv(EVT.VaR.dyn.N.save,"D://1-
Tesis/Output/AMAG/EVT.dyn.N.AM.0,5%.csv")
write.csv(NAreturn.save,"D://1-Tesis/Output/AMAG/Return.N.AM.0,5%.csv")

spacings=c(0.2,0.4,0.6,0.8,1)
win.graph()
ylim<-c(min(-0.26,0.26),max(-0.25,0.45))
plot(NAreturn.save,lty=1, main="Plot 0,99% EVT Dynamic VaR & Actual
Return(AMAG)",ty="l",col="light blue",ylim=ylim,xlab="",ylab="",xaxt="n")
lines(EVT.VaR.dyn.N.save,lty=2)
legend(x="bottomright",legend=c("True 1 day log returns","99.5% 1 day Dynamic
EVT VaR forecast"),
lty=1:2,col=c("light blue","green"))
#dates.log.10<-read.table(file="clipboard")
ax.vals.3<-c(1,floor(length(NAreturn.save)*spacings))
axis(side=1,at=ax.vals.3,labels=Date[ax.vals.3,],cex.axis=0.7)
```

#### d. R Code untuk Simulasi Penentuan Threshold Optimum

```
library(doParallel)
registerDoParallel(cores = 4)
#dat=read.csv("D://1-Tesis/Boot/Norm.csv",sep="," ,header=TRUE)
#data=dat[,3]
n=length(data)
Qstar1=rep(0,1000)
Qstar2=rep(0,1000)
#min.subsamp.prop=0.3
#max.subsamp.prop=0.95
#step.prop=0.05
#min.k.prop=0.05
#max.k.prop=0.15
library(foreach)
Mfunc=function(x,thres)
{
  if (length(x)<1)
  {
    stop("x is empty")
  }
  if (any(is.na(x)))
  {
    stop("x contains NA")
  }
  if (any(x<=0))
  {
    stop("x contains nonpositive values")
  }
  if (length(thres)!=1)
  {
    stop("thres contains multiple values")
  }
  if (is.na(thres))
  {
    stop("thres is NA")
  }
  return(sum((log((x/thres)))^2)/length(x))
}
```

#### d. R Code untuk Simulasi Penentuan Threshold Optimum (lanjutan)

```
Gfunc=function(x,thres)
{
  if (length(x)<1)
  {
    stop("x is empty")
  }
  if (any(is.na(x)))
  {
    stop("x contains NA")
  }
  if (any(x<=0))
  {
    stop("x contains nonpositive values")
  }
  if (length(thres)!= 1)
  {
    stop("thres contains multiple values")
  }
  if (is.na(thres))
  {
    stop("thres is NA")
  }
  return(sum((log((x/thres))))/length(x))
}

Qfunc=function(M,G)
{
  return((M-2*G^2)^2)
}

bootbaru = function(n,minn, maxn, stepn, mink, maxk, stepk)
{
  min.n1 = floor(minn*n)
  max.n1 = floor(maxn*n)
  n1.step = floor(stepn*n)

  listn = seq(min.n1, max.n1,n1.step)
  listk = seq(mink, maxk, stepk)

  nn = length(listn)
  kk = length(listk)

  output = matrix(nrow=5, ncol=nn)

  dat=rnorm(1000,0.5,0.05)
  data=dat
```

#### d. R Code untuk Simulasi Penentuan Threshold Optimum (lanjutan)

```
for (jj in 1:nn)
{
n1 = listn[jj]

min.k1 = floor(mink * n1)
max.k1 = floor(maxk * n1)
k.step = floor(stepk * n1)
k1s = seq(from=min.k1, to=max.k1, by=k.step)
k1.vec = rep(NA, times=length(k1s))
Q1.vec = k1.vec
for (i in 1:length(k1s)){
k1 = k1s[i]
for (l in 1:1000){
boot1.sam = sample(data,n1,replace=TRUE)
sample=sort( boot1.sam[1:n1], decreasing=TRUE)
x.thres=sample[(k1+1)]
sampk1=sample[1:k1]
Mstar= Mfunc(sampk1, x.thres)
Gstar = Gfunc(sampk1, x.thres)
Qstar1[l] = Qfunc(Mstar, Gstar)
}
Q1.est <- mean(Qstar1)
Q1.vec[i] <- Q1.est
}
k1.idx <- which.min(Q1.vec)
k1star <- k1s[k1.idx]
#n2
n2 <- floor( (n1^2 / n))
min.k2 <- floor(mink * n2)
max.k2 <- floor(maxk * n2)
k.step <- floor(stepk * n2)
k2s <- seq(from=min.k2, to=max.k2, by=k.step)
k2.vec <- rep(NA, times=length(k2s))
Q2.vec <- k2.vec
for (i in 1:length(k2s)){
k2 <- k2s[i]
for (l in 1:1000){
boot2.sam = sample(data,n2,replace=TRUE)
sample=sort( boot1.sam[1:n2], decreasing=TRUE)
x.thres=sample[(k2+1)]
sampk2=sample[1:k2]
Mstar= Mfunc(sampk2, x.thres)
Gstar = Gfunc(sampk2, x.thres)
Qstar2[l] = Qfunc(Mstar, Gstar)
}
Q2.est <- mean(Qstar2)
Q2.vec[i] <- Q2.est
}
}
```

#### d. R Code untuk Simulasi Penentuan Threshold Optimum (lanjutan)

```
k2.idx <- which.min(Q2.vec)
  k2star <- k2s[k2.idx]
Rn1 <- (Q1.vec[k1.idx])^2 / Q2.vec[k2.idx]
out=c(Rn1, n1, n2, k1star, k2star)

output[,jj] = out
}

output1 = t(output)

Rnsaja = as.vector(output1[,1])
minimumR = min(Rnsaja)

minRn = which(Rnsaja==minimumR)
hasilmin = output1[minRn,]

list(hasil=output1, hasilmin=hasilmin, data=data)
}

kOpt.func = function(n,minn, maxn, stepn, mink, maxk, stepk,R)
{

k.opt = matrix(nrow=R, ncol=1)
data = matrix(nrow=n, ncol=R)

for (i in 1:R)
{
optsementara = bootbaru(n,minn, maxn, stepn, mink, maxk, stepk)
outputk1 = optsementara$hasilmin[4]
outputk2 = optsementara$hasilmin[5]
outputn1 = optsementara$hasilmin[2]
a= (outputk1)^2 / outputk2
  b = (log(outputk1))^2 / (2 * log(outputn1) - log(outputk1))^2
  c = (log(outputn1) - log(outputk1)) / log(outputn1)
  k.opt[i] = a * b^c
  data[,i]=optsementara$data
}
koptimum = k.opt
Data.save = data
list(hasilakhir=koptimum)
write.csv(koptimum,"D://1-Tesis/Boot/Hasil-norm.csv")
write.csv(Data.save,"D://1-Tesis/Boot/Data-norm.csv")

}
```

## **BAB 5**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan analisis dan pembahasan yang telah dilakukan, maka kesimpulan yang diperoleh dari penelitian ini adalah sebagai berikut:

1. Perhitungan *threshold* optimum dengan metode *bootstrap* menunjukkan bahwa nilai *threshold* optimum hasil simulasi berada pada kuantil 1% - 3% dari data. Sementara itu untuk *threshold* optimum pada data riil berada pada kuantil 2,3% - 2,7%.
2. Kedua pendekatan perhitungan VaR memberikan pola hasil yang sama, yaitu PT. Lippo General Insurance memiliki nilai resiko yang paling besar, diiringi dengan nilai keuntungan yang besar juga. Sedangkan kedua perusahaan lain memiliki nilai VaR yang hampir sama.
3. Perbedaan pemilihan *threshold* pada perhitungan VaR dengan pendekatan EVT-GARCH dalam penelitian ini memberikan hasil estimasi yang tidak jauh berbeda.
4. Berdasarkan hasil *backtesting* pendekatan ARMA-GARCH maupun EVT-GARCH dapat menangkap pola volatilitas dalam data, akan tetapi EVT-GARCH memiliki keunggulan dalam menangkap nilai ekstrim. Hal ini berlaku pada kuantil 0,5% dan 1%. Sedangkan pada kuantil 5%, kedua pendekatan memberikan hasil yang tidak jauh berbeda.

#### **5.2 Saran**

Pada penelitian ini, saran yang dapat diberikan untuk penelitian selanjutnya adalah perlunya untuk mempertimbangkan kemungkinan pengaruh saham perusahaan lain maupun pengaruh variabel eksogen terhadap nilai VaR. Selain itu, seringkali investor melakukan investasi berupa portofolio beberapa saham, sehingga diperlukan metode estimasi nilai VaR terhadap suatu portofolio.

*(halaman ini sengaja dikosongkan)*

## Daftar Pustaka

Andreev, V. O., Tinykov, S. E., Ovchinnikova, O. P., & Parahin, G. P. (2012), "Extreme Value Theory and Peaks Over Threshold Model in the Russian Stock Market", *Journal of Siberian Federal University Engineering & Technologies*, Vol. 1, hal. 111-121.

Bensalah, Y. (2000), "Steps in Applying Extreme Value Theory to Finance: A Review", *Bank of Canada Working Paper 2000*, Vol. 20.

Bob, N. K. (2013), *Value at Risk Estimation: A GARCH-EVT-Copula Approach*, Stockholm University Master Thesis, Stockholm.

Bollerslev, T. (1986), "Generalized Autoregressive Conditional Heteroscedasticity", *Journal of Econometrics*, Vol. 31, hal. 307-327.

Bowerman, B., & O'Connell, R., (1993), *Forecasting and Time Series: An Applied Approach*, Duxbury Press, California.

Box, G., Jenkins, G., & Reinsel, G. (2008), *Time Series Analysis Forecasting and Control*, Prentice-Hall Inc., New Jersey.

Chen, Q. (2014), *The Volatility of the Price of Gold: An Application of Extreme Value Theory*, University of Victoria Thesis, Victoria.

Coles, S. (2001), *An Introduction to Statistical Modelling of Extreme Value*, Springer, London.

Danielsson, J., de Haan, L., Peng, L., & de Vries, C., (2001), "Using a Bootstrap Method to Choose the Sample Fraction in Tail Index Estimation" *Journal of Multivariate Analysis*, Vol. 76, No. 2, Hal. 226-248.

Enders, W. (2015), *Applied Econometric Time Series*, Wiley, United States of America.

Engle, R. F. (1982), "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of Uk Inflation" *Econometrica*, Vol. 50, Issue. 4, Hal. 987-1008.

Einarsen, R.H. (2014), *A Comparative Study of Volatility Forecasting Models*, University of Agder, Norway.

Franke, J., Hardle, W. K., & Hafner, C. M. (2011), *Statistics of Financial Markets*, Springer, Berlin.

Gencay, R., & Selcuk, F. (2004), "Extreme value theory and Value-at-Risk: Relative performance in emerging markets", *International Journal of Forecasting*, Vol. 20, Hal. 287-303.

Gencay, R., Selcuk, F., & Ulugulyagci, A. (2003), "High volatility, thick tail and extreme value theory in value at risk estimation", *Insurance: Mathematics & Economics*, Vol. 33, Hal. 337-356.

Haryanto, B. (2012), *Pendugaan Nilai Resiko dengan Sebaran Transformasi-Kernel dan Sebaran Nilai Ekstrem*, Sekolah Pasca Sarjana IPB, Bogor.

Jorion, P. (2001), *Value at Risk, the New Benchmark*, McGraw-Hill, United States of America.

McNeil, A. J., & Frey, R. (2000), "Estimation of tail-related risk measures for heteroscedastic financial time series: an extreme value approach", *Journal of Empirical Finance*, Vol. 7, Hal. 271-300.

McNeil, A. J., Frey, R., & Embrechts, P. (2005), *Quantitative Risk management: Concepts, Techniques and Tools*, Princeton University Press, Princeton.

Odening, M., & Hinrichs, J. (2002), *Using Extreme Value Theory to Estimate Value at Risk*. *Agricultural Finance Review*, Vol. 63, Issue. 1, Hal. 55-73.

Setiawan, S. (2013), *Prospek dan Daya Saing Sektor Perasuransian Indonesia Di Tengah Tantangan Integrasi Jasa Keuangan ASEAN*. In K. Tulisan, *Serial Analisis Kebijakan Fiskal: Penguatan Hubungan Ekonomi dan Keuangan Internasional dalam Mendukung Pembangunan Nasional*, Nagamedia, Jakarta.

Singh, A. K., Allen, D. E., & Powell, R. J. (2011), "Value at Risk Estimation Using Extreme Value Theory", *19th International Congress on Modelling and Simulation*. Perth: <http://mssanz.org.au/modsim2011>.

Tsay, R. S. (2005), *Analysis of Financial Time Series*, 2<sup>nd</sup> Edition, Wiley-Interscience, Canada.

Wei, W. W. S. (2006), *Time Series Analysis, Univariate and Multivariate Methods*, Pearson.

## BIODATA PENULIS



Penulis dilahirkan pada tanggal 28 September 1983 di Ponorogo. Pendidikan formal yang ditempuh, yaitu SDN 1 Tulung, MTs Negeri 1 Sampung, SMA Negeri 1 Ponorogo. Setelah lulus SMA, penulis diterima di Jurusan Statistika Institut Teknologi Sepuluh Nopember (ITS) Surabaya dan lulus pada Maret 2006. Setelah itu penulis bekerja sebagai SPC Engineer di PT. AIT dan selanjutnya PT. UNISEM Batam. Selain menjadi SPC Engineer, penulis juga mengajar di Universitas Batam untuk kelas malam. Mulai tahun 2012, penulis mengundurkan diri dari pekerjaannya sebagai SPC Engineer dan berfokus untuk menjadi dosen. Demikianlah sehingga penulis melanjutkan program Strata 2 di Jurusan Statistika-ITS pada tahun 2014. Alamat email penulis yang bisa dihubungi adalah [allykoer@gmail.com](mailto:allykoer@gmail.com) dan [elykurniawati@yahoo.co.id](mailto:elykurniawati@yahoo.co.id).