

**ESTIMASI RISIKO INVESTASI SAHAM
PERUSAHAAN SEKTOR KONSUMER
MENGUNAKAN VALUE AT RISK
DAN EXPECTED SHORTFALL**

SKRIPSI

Disusun oleh :

Kalis Rifo Irwandi

175020100111003

**Diajukan Sebagai Salah Satu Syarat
Untuk Meraih Derajat Sarjana Ekonomi**



**JURUSAN ILMU EKONOMI
FAKULTAS EKONOMI DAN BISNIS
UNIVERSITAS BRAWIJAYA**

MALANG

2021

LEMBAR PENGESAHAN

Skripsi dengan judul :




"Estimasi Risiko Investasi Saham Perusahaan Sektor Konsumer Menggunakan Value at Risk dan Expected Shortfall"

Yang disusun oleh :

Nama : Kalis Rifo Irwandi
 NIM : 175020100111003
 Fakultas : Ekonomi dan Bisnis Universitas Brawijaya
 Jurusan : Ilmu Ekonomi
 Program Studi: S1 Ekonomi Pembangunan
 Konsentrasi : Perencanaan Pembangunan

telah dipertahankan di depan Dewan Penguji pada tanggal 26 Juli 2021 dan dinyatakan memenuhi syarat untuk diterima.

SUSUNAN DEWAN PENGUJI

1. Dias Satria, SE., M.App.EC., Ph.D.
 NIP. 198208072005011002
 (Dosen Pembimbing) 
2. David Kaluge, SE., MS., M.Ec.Dev., Ph.D.
 NIP. 196012251987011001
 (Dosen Penguji I) 
3. Vietha Devia SS, SE., ME., Ph.D.
 NIK. 2012048712072001
 (Dosen Penguji II) 

Malang, 26 Juli 2021
 Ketua Program Studi
 S1 Ekonomi Pembangunan,



Dra. Marlina Ekawaty M.Si., Ph.D
 NIP. 196503111989032001



SURAT PERNYATAAN

Yang bertanda tangan di bawah ini, saya :

Nama : **Kalis Rifo Irwandi**
 Tempat, tanggal lahir : **Wonogiri, 04 Juni 1999**
 NIM : **175020100111003**
 Jurusan : **Ilmu Ekonomi**
 Program Studi : **S1 Ekonomi Pembangunan**
 Konsentrasi : **Perencanaan Pembangunan**
 Alamat : **Jl. Simpanan Piranha Atas No. 22h RT15/RW02**

Menyatakan dengan sesungguhnya bahwa SKRIPSI yang berjudul :

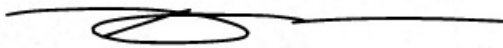
**Estimasi Risiko Investasi Saham Perusahaan Sektor Konsumer
 Menggunakan Value at Risk dan Expected Shortfall**

yang saya tulis adalah benar-benar hasil karya saya sendiri dan bukan merupakan plagiat atau saduran dari Skripsi orang lain.

Apabila dikemudian hari ternyata pernyataan saya tidak benar, maka saya bersedia menerima sanksi akademis yang berlaku (dicabutnya predikat kelulusan dan gelar kesarjanaannya)

Demikian pernyataan ini saya buat dengan sesungguhnya, untuk dapat dipergunakan sebagaimana mestinya.

Mengetahui,
 Dosen Pembimbing,



Dias Satria, SE., M.App.Ec., Ph.D.
 NIP. 198208072005011002

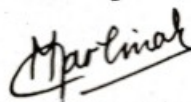
Malang, 21 Juni 2021

Yang membuat pernyataan,



Kalis Rifo Irwandi
 NIM. 175020100111003

Mengetahui,
 Ketua Program Studi,



Dra. Marlina Ekawaty, M.Si., Ph.D.
 NIP. 196503111989032001



DAFTAR ISI

LEMBAR PENGESAHAN.....	ii
SURAT PERNYATAAN.....	iii
RIWAYAT HIDUP.....	iv
KATA PENGANTAR.....	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR.....	x
DAFTAR TABEL.....	xi
DAFTAR LAMPIRAN.....	xii
ABSTRAK.....	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	6
1.3 Tujuan Penelitian.....	6
1.4 Manfaat Penelitian.....	7
BAB II KAJIAN PUSTAKA.....	8
2.1 Kerangka Teori.....	8
2.1.1 Risiko Investasi.....	8
2.1.2 <i>Return</i> Saham.....	10
2.1.3 Konsep Volatilitas.....	11
2.1.4 Model Volatilitas.....	13
2.1.5 Value at Risk.....	14
2.1.6 Expected Shortfall.....	17
2.2 Penelitian Terdahulu.....	18
BAB III METODE PENELITIAN.....	21
3.1 Pendekatan Penelitian.....	21
3.2 Tempat dan Waktu Penelitian.....	21
3.3 Definisi Operasional dan Pengukuran Variabel Penelitian.....	22
3.4 Populasi dan Penentuan Sampel.....	22
3.5 Metode Pengumpulan Data.....	23
3.6 Metode Analisis.....	23
3.6.1 Proses ARMA.....	25
3.6.2 Proses GARCH.....	28
3.6.3 Value at Risk.....	32



3.6.4 Expected Shortfall.....	35
BAB IV HASIL DAN PEMBAHASAN.....	37
4.1 Hasil.....	37
4.1.1 Analisis Statistik Deskriptif.....	37
4.1.2 Proses ARMA.....	41
4.1.2.1 Uji stasioneritas.....	41
4.1.2.2 Identifikasi Autokorelasi.....	42
4.1.2.3 Estimasi Parameter.....	47
4.1.2.4 Pemeriksaan Diagnostik.....	51
4.1.3 Proses GARCH.....	56
4.1.3.1 Uji Efek ARCH.....	56
4.1.3.2 Estimasi Parameter.....	57
4.1.3.3 Pemeriksaan Diagnostik.....	61
4.1.4 Value at Risk.....	62
4.1.4.1 Backtesting.....	62
4.1.4.2 <i>Forecasting VaR</i>	64
4.1.5 Expected Shortfall.....	65
4.1.5.1 Backtesting.....	65
4.1.5.2 <i>Forecasting ES</i>	66
4.2 Pembahasan.....	67
4.2.1 Karakteristik Volatilitas <i>Return</i> Saham.....	67
4.2.1.1 Volatility Clustering.....	67
4.2.1.2 Efek Asimetris.....	69
4.2.2 Estimasi Risiko Investasi.....	70
BAB V KESIMPULAN, IMPLIKASI, DAN SARAN.....	75
5.1 Kesimpulan.....	75
5.2 Implikasi.....	76
5.2.1 Implikasi Teoritis.....	76
5.2.1 Implikasi Praktis.....	76
5.3 Saran.....	76
DAFTAR PUSTAKA.....	78
LAMPIRAN.....	83



DAFTAR GAMBAR

Gambar 1.1: Perkembangan IHSG dan Indeks Sektoral Tahun 2020.....1

Gambar 4.1: Harga dan *Return* Saham ICBP (A), HMSP (B), dan KLBF (C).....37

Gambar 4.2: Harga dan *Return* Saham UNVR (D), WOOD (E), dan HRTA (F).....38

Gambar 4.3: Plot ACF dan PACF ICBP.....43


Gambar 4.4: Plot ACF dan PACF HMSP.....44

Gambar 4.5: Plot ACF dan PACF KLBF.....44

Gambar 4.6: Plot ACF dan PACF UNVR.....45

Gambar 4.7: Plot ACF dan PACF WOOD.....46

Gambar 4.8: Plot ACF dan PACF HRTA.....46



DAFTAR TABEL

Tabel 3.1: ACF dan PACF Teoritis ARMA.....	26
Tabel 4.1: Statistik Deskriptif <i>Return</i> Saham.....	39
Tabel 4.2: Hasil Uji Stasioneritas.....	41
Tabel 4.3: Estimasi Parameter Model ARMA ICBP.....	47
Tabel 4.4: Estimasi Parameter Model ARMA HMSP.....	48
Tabel 4.5: Estimasi Parameter Model ARMA KLBF.....	49
Tabel 4.6: Estimasi Parameter Model ARMA UNVR.....	49
Tabel 4.7: Estimasi Parameter Model ARMA WOOD.....	50
Tabel 4.8: Estimasi Parameter Model ARMA HRTA.....	50
Tabel 4.9: Pemeriksaan Diagnostik Model ARMA.....	51
Tabel 4.10: Pemeriksaan Diagnostik Model ARMA HMSP dan KLBF.....	54
Tabel 4.11: Estimasi Parameter Model ARMA HMSP.....	55
Tabel 4.12: Estimasi Parameter Model ARMA KLBF.....	55
Tabel 4.13: Hasil Uji Efek ARCH.....	56
Tabel 4.14: Estimasi Parameter Model GARCH ICBP.....	57
Tabel 4.15: Estimasi Parameter Model GARCH HMSP.....	58
Tabel 4.16: Estimasi Parameter Model GARCH KLBF.....	59
Tabel 4.17: Estimasi Parameter Model GARCH UNVR.....	59
Tabel 4.18: Estimasi Parameter Model GARCH WOOD.....	60
Tabel 4.19: Estimasi Parameter Model GARCH HRTA.....	60
Tabel 4.20: Hasil Uji <i>Weighted</i> ARCH LM.....	61
Tabel 4.21: Hasil Uji <i>Sign and Size Bias</i>	62
Tabel 4.22: <i>Backtesting</i> VaR (99%) 250 Observasi Terakhir.....	63
Tabel 4.23: <i>Forecasting</i> VaR (99%) 1 Periode ke Depan.....	65
Tabel 4.24: <i>Backtesting</i> ES (99%).....	66
Tabel 4.25: <i>Forecasting</i> ES (99%) 1 Periode ke Depan.....	66
Tabel 4.26: Estimasi Risiko dengan VaR (99%) dan ES (99%) Tahun 2020.....	71
Tabel 4.27: Peramalan Risiko dengan VaR (99%) dan ES (99%) (Rp).....	74



DAFTAR LAMPIRAN

Lampiran 1: Harga Penutupan Saham Harian 6 Perusahaan Sektor Konsumer... 83

Lampiran 2: *Return* Saham Harian 6 Perusahaan Sektor Konsumer..... 83

Lampiran 3: Sintaks R - Persiapan Data..... 84

Lampiran 4: Sintaks R - Grafik Harga dan *Return* Saham..... 84

Lampiran 5: Sintaks R - Statistik Deskriptif..... 85

Lampiran 6: Sintaks R - Uji Stasioneritas..... 85

Lampiran 7: Sintaks R - Plot ACF dan PACF..... 85

Lampiran 8: Sintaks R - Fungsi ARMA..... 86

Lampiran 9: Sintaks R - Estimasi Parameter ARMA..... 87

Lampiran 10: Sintaks R - Pemeriksaan Diagnostik Model ARMA..... 87

Lampiran 11: Sintaks R - Estimasi Parameter ARMA Ke-2..... 88

Lampiran 12: Sintaks R - Kombinasi Ordo ARMA Terbaik..... 88

Lampiran 13: *Output* R - Kombinasi Ordo ARMA Terbaik..... 88

Lampiran 14: Sintaks R - Uji Efek ARCH..... 89

Lampiran 15: Sintaks R - Fungsi GARCH..... 89

Lampiran 16: Sintaks R - Estimasi GARCH dan Pemeriksaan Diagnostik..... 90

Lampiran 17: *Output* R - Estimasi GARCH ICBP..... 90

Lampiran 18: *Output* R – Uji *Weighted ARCH* LM ICBP..... 91

Lampiran 19: *Output* R – Uji *Sign Bias* ICBP..... 91

Lampiran 20: *Output* R - Estimasi GARCH HMSP..... 91

Lampiran 21: *Output* R – Uji *Weighted ARCH* LM HMSP..... 92

Lampiran 22: *Output* R – Uji *Sign Bias* HMSP..... 92

Lampiran 23: *Output* R - Estimasi GARCH KLBF..... 92

Lampiran 24: *Output* R – Uji *Weighted ARCH* LM KLBF..... 93

Lampiran 25: *Output* R – Uji *Sign Bias* KLBF..... 93

Lampiran 26: *Output* R - Estimasi GARCH UNVR..... 93

Lampiran 27: *Output* R – Uji *Weighted ARCH* LM UNVR..... 94

Lampiran 28: *Output* R – Uji *Sign Bias* UNVR..... 94

Lampiran 29: *Output* R - Estimasi GARCH WOOD..... 94



Lampiran 30: <i>Output R – Uji Weighted ARCH LM WOOD</i>	95
Lampiran 31: <i>Output R – Uji Sign Bias WOOD</i>	95
Lampiran 32: <i>Output R - Estimasi GARCH HRTA</i>	95
Lampiran 33: <i>Output R – Uji Weighted ARCH LM HRTA</i>	96
Lampiran 34: <i>Output R – Uji Sign Bias HRTA</i>	96
Lampiran 35: <i>Sintaks R - Backtesting VaR (99%)</i>	96
Lampiran 36: <i>Output R - ICBP VaR Backtest Report</i>	97
Lampiran 37: <i>Output R - HMSP VaR Backtest Report</i>	97
Lampiran 38: <i>Output R - KLBF VaR Backtest Report</i>	98
Lampiran 39: <i>Output R - UNVR VaR Backtest Report</i>	98
Lampiran 40: <i>Output R - WOOD VaR Backtest Report</i>	99
Lampiran 41: <i>Output R - HRTA VaR Backtest Report</i>	99
Lampiran 42: <i>Sintaks R - Grafik Return Saham dengan VaR (99%)</i>	100
Lampiran 43: <i>Output R – Grafik Return ICBP dengan VaR (99%)</i>	100
Lampiran 44: <i>Output R - Grafik Return HMSP dengan VaR (99%)</i>	101
Lampiran 45: <i>Output R - Grafik Return KLBF dengan VaR (99%)</i>	101
Lampiran 46: <i>Output R - Grafik Return UNVR dengan VaR (99%)</i>	102
Lampiran 47: <i>Output R - Grafik Return WOOD dengan VaR (99%)</i>	102
Lampiran 48: <i>Output R - Grafik Return HRTA dengan VaR (99%)</i>	103
Lampiran 49: <i>Sintaks R - Forecasting VaR (99%) 1 Periode ke Depan</i>	103
Lampiran 50: <i>Sintaks R - Backtesting ES (99%)</i>	104
Lampiran 51: <i>Sintaks R - Forecasting ES (99%) 1 Periode ke Depan</i>	104
Lampiran 52: <i>Hasil Backtesting ES (99%) ICBP</i>	105
Lampiran 53: <i>Hasil Backtesting ES (99%) HMSP</i>	105
Lampiran 54: <i>Hasil Backtesting ES (99%) KLBF</i>	106
Lampiran 55: <i>Hasil Backtesting ES (99%) UNVR</i>	106
Lampiran 56: <i>Hasil Backtesting ES (99%) WOOD</i>	107
Lampiran 57: <i>Hasil Backtesting ES (99%) HRTA</i>	107
Lampiran 58: <i>Hasil Estimasi VaR (99%)</i>	108
Lampiran 59: <i>Hasil Estimasi ES (99%)</i>	108



ABSTRACT

Irwandi, K. R. (2021). Consumer Goods Sector Stock Risk Estimation Using Value at Risk and Expected Shortfall. Undergraduate Thesis, Department of Economics, Faculty of Economics and Business, University of Brawijaya. Dias Satria, SE., M.App.EC., Ph.D.

Since early March 2020, Covid-19 has been spreading throughout Indonesia. Indonesian stock market reacted to the emergence of positive Covid-19 cases with severe volatility shocks at the start of the pandemic. Within a month, JCI had dropped by 37% from its beginning position in 2020. Despite this negative sentiment, consumer sector outperformed JCI and other sectoral indexes during the start of the pandemic and for several months afterward. Using VaR and ES methods, this study aims to estimate the potential risk of stock investment in six consumer sector companies. ARMA-GARCH model is used to estimate VaR and ES values based on the volatility characteristics of stock returns in these six companies. The study found that the six stock returns exhibit volatility clustering and leptokurtosis. While asymmetric effect were not detected in any of the six stock returns. Overall, HRTA and WOOD have the highest maximum potential loss as well as the highest possibility for severe losses compared to ICBP, HMSP, and UNVR.

Keywords: Value at Risk, Expected Shortfall, ARMA-GARCH, Market Risk, Stock Market.

ABSTRAK

Irwandi, K. R. (2021). Estimasi Risiko Investasi Saham Perusahaan Sektor Konsumer Menggunakan Value at Risk dan Expected Shortfall. Skripsi, Jurusan Ilmu Ekonomi, Fakultas Ekonomi dan Bisnis, Universitas Brawijaya. Dias Satria, SE., M.App.EC., Ph.D.

Sejak awal Maret 2020, Indonesia tengah berjuang melawan penyebaran Covid-19. Di awal pandemi, pasar saham Indonesia merespon perkembangan kasus positif Covid-19 dengan guncangan volatilitas yang kuat. Dalam waktu satu bulan, IHSG bahkan tercatat turun hingga 37% dari posisi awal tahun 2020. Di tengah sentimen negatif tersebut, performa sektor konsumer di awal pandemi dan beberapa bulan setelahnya sempat lebih baik dari IHSG serta indeks sektoral lainnya. Penelitian ini bertujuan untuk mengestimasi potensi risiko investasi saham pada enam perusahaan sektor konsumer dengan metode VaR dan ES. Dengan mempertimbangkan karakteristik volatilitas *return* saham pada keenam perusahaan tersebut, maka estimasi nilai VaR dan ES dilakukan dengan pendekatan model ARMA-GARCH. Hasil penelitian menunjukkan bahwa terdapat karakteristik pengelompokan volatilitas serta leptokurtosis pada keenam *return* saham tersebut. Sedangkan keberadaan efek asimetris tidak ditemukan pada keenam *return* saham. Secara keseluruhan, saham HRTA dan WOOD memiliki potensi kerugian maksimum serta potensi kerugian ekstrem yang relatif lebih besar dibanding ICBP, HMSP, dan UNVR.

Kata kunci: Value at Risk, Expected Shortfall, ARMA-GARCH, Risiko Pasar, Pasar Saham.


BAB I
PENDAHULUAN

1.1 Latar Belakang

Ketidakpastian ekonomi sering kali mengejutkan pengamat pasar dan menyebabkan kerugian finansial yang besar. Belajar dari peristiwa di masa lalu, penggelembungan harga saham (*stock price bubble*) Jepang yang mulai pecah pada akhir tahun 1989 mampu menyebabkan hilangnya modal sebesar \$2.7 triliun (Jorion, 2007). Peristiwa tersebut menjadi salah satu pendorong tumbuhnya industri manajemen risiko, yang membantu investor untuk terhindar dari kerugian finansial yang besar.

Pada tahun 2020, pandemi Covid-19 menjadi faktor ketidakpastian baru bagi perekonomian global. Di Indonesia sendiri sejak diumumkannya kasus pertama positif Covid-19 pada 2 Maret 2020, IHSG (Indeks Harga Saham Gabungan) sempat turun 37.49% secara *year to date* (ke level 3938) pada 24 Maret 2020, dan menjadi level penutupan terendah sepanjang tahun 2020 (PKSK, 2020).

Gambar 1.1: Perkembangan IHSG dan Indeks Sektoral Tahun 2020



Sumber: Pusat Kebijakan Sektor Keuangan (2020), telah diolah kembali.



Di tengah sentimen negatif tersebut, performa sektor konsumen (*consumer goods industry*) selama pandemi jauh lebih baik dari IHSG, dimana penurunan terendah indeks harga saham sektor konsumen (indeks JAKCONS) masih lebih tinggi dari IHSG, yaitu 32.98% secara *year to date* (ke level 1375.7) pada 19 Maret 2020, dan level tertingginya adalah 1971.2 (-3.97% *ytd*) pada 27 Agustus 2020 (PKSK, 2020). Performa indeks JAKCONS secara *year to date* juga sempat memimpin indeks harga saham sektoral yang lain, sebelum disusul oleh sektor pertambangan (indeks JAKMINE) dan sektor keuangan (indeks JAKFIN).

Saham dari sektor konsumen merupakan *defensive stock*, yaitu saham dari perusahaan yang kinerjanya cenderung stabil pada berbagai fase siklus bisnis (Chen, 2020). Perusahaan yang diklasifikasikan pada sektor konsumen oleh BEI (Bursa Efek Indonesia) bergerak di industri makanan dan minuman, tembakau, farmasi, kosmetik, serta peralatan rumah tangga (Indonesia Stock Exchange, 2020). Sehingga produk dari perusahaan tersebut cenderung dibeli masyarakat karena tuntutan kebutuhan, terlepas dari kondisi perekonomian.

Meskipun demikian, bukan berarti investasi di perusahaan sektor konsumen bebas dari risiko. Performa indeks sektor konsumen sejak level tertingginya di bulan Agustus 2020 secara *year to date* cenderung menurun, dan mulai disalip oleh indeks sektoral lain termasuk IHSG. Oleh karena itu untuk meminimalisir risiko, investor dapat melakukan pengukuran risiko investasi pada perusahaan sektor konsumen.

Value at Risk (VaR) merupakan metode pengukuran risiko investasi yang sering digunakan. Dengan konsep sederhana yang mudah dihitung serta

diaplikasikan, VaR menjadi standar pengukuran risiko bagi manajemen risiko keuangan (Yamai dan Yoshiba, 2005). Metode VaR dapat mengukur potensi kerugian maksimum dengan tingkat kepercayaan (*confidence level*) tertentu (Kissell, 2014). Misalnya nilai VaR Rp10 juta pada tingkat kepercayaan 99%, berarti hanya terdapat 1% kemungkinan bahwa kerugian maksimum yang diderita dapat lebih besar dari Rp10 juta.

Di sisi lain, VaR tidak bisa memberikan informasi tentang besaran kerugian yang dapat diderita oleh investor jika nilai VaR terlampaui (Alexander, 2008b). Sehingga ketika terjadi *market crash*, maka hasil estimasi nilai VaR menjadi kurang bisa diandalkan. Karena terdapat kemungkinan bahwa potensi risiko yang telah diestimasi nilainya jauh lebih rendah dari potensi risiko yang sebenarnya.

Untuk mengatasi kekurangan tersebut dapat digunakan *Expected Shortfall* (ES), yaitu metode pengukuran risiko yang memperhatikan ekspektasi kerugian yang melebihi nilai VaR (Yamai dan Yoshiba, 2005).

Pendekatan non parametrik dan parametrik adalah dua metode yang paling umum untuk mengestimasi nilai VaR dan ES (Danielsson, 2011). Pendekatan nonparametrik tidak mengasumsikan model statistik serta tidak memerlukan estimasi parameter. Sedangkan pendekatan parametrik berfokus pada estimasi distribusi *return* serta proyeksi risiko dari distribusi yang telah diestimasi. Metode nonparametrik populer adalah simulasi historis (*historical simulation*), sedangkan metode parametrik (*variance-covariance*) yang paling populer adalah EWMA dan GARCH.

Pada data finansial sering kali ditemukan fenomena *leptokurtosis*, *volatility clustering*, serta *leverage effect*. Dalam Brooks (2008), *leptokurtosis* didefinisikan sebagai kecenderungan pada data finansial untuk memiliki distribusi *heavy tail*. Sedangkan *volatility clustering* didefinisikan sebagai kecenderungan volatilitas untuk berkorelasi positif dengan volatilitas di periode sebelumnya. Kemudian *leverage effect* didefinisikan sebagai fenomena peningkatan volatilitas ketika harga saham jatuh, yang lebih tinggi dari peningkatan volatilitas akibat kenaikan harga saham dengan besaran yang sama.

Dalam pendekatan parametrik, *volatility clustering* dapat ditangkap oleh model ARCH (*Autoregressive Conditional Heteroskedasticity*) yang dikemukakan oleh Engle (1982), atau GARCH (*Generalized ARCH*) yang dikembangkan oleh Bollerslev (1986) (Gujarati dan Porter, 2008). Model ARCH memungkinkan volatilitas untuk dipengaruhi guncangan di periode sebelumnya, sedangkan model GARCH memungkinkan volatilitas untuk dipengaruhi dirinya sendiri di masa lalu.

Model GARCH telah digunakan dalam penelitian Spierdijk (2016) untuk menghitung VaR. Spierdijk mengombinasikan model ARMA (*Autoregressive Moving Average*) dengan model GARCH sebagai pendekatan ARMA-GARCH. Model ARMA menjadi model basis untuk memperkirakan ekspektasi *return* (*conditional mean*), sedangkan model GARCH digunakan untuk mengestimasi volatilitas (*conditional variance*) dari informasi yang didapat dari model ARMA.

Walaupun mampu mengakomodasi fenomena *volatility clustering*, model GARCH tersebut masih mengasumsikan respon simetris terhadap setiap efek

guncangan volatilitas (*volatility shock*) pada harga aset. Oleh karena itu, perlu dipertimbangkan model GARCH asimetris seperti model GJR-GARCH yang dikemukakan oleh Glosten, Jagannathan, dan Runkle (1993). Model GARCH asimetris memungkinkan respon asimetris terhadap guncangan volatilitas, sehingga dapat mengakomodasi fenomena *leverage effect*.

Model GARCH asimetris digunakan pada penelitian Sari, Achsani, dan Sartono (2017) dalam pendekatan ARMA-GARCH untuk memodelkan volatilitas *return* saham di pasar saham Asia. Mereka menemukan adanya efek asimetris (*leverage effect*) dan menyimpulkan bahwa performa model GARCH asimetris lebih baik untuk memodelkan volatilitas indeks harga saham yang mereka teliti.

Hal tersebut selaras dengan penelitian Miron dan Tudor (2010), yang juga menemukan adanya efek asimetris pada empat data *return* dari pasar saham Rumania dan Amerika Serikat. Mereka menambahkan bahwa distribusi normal tidak bisa menangkap sifat *leptokurtosis* pada data, sehingga penggunaan distribusi *student-t* dan GED lebih baik untuk memodelkan volatilitas.

Mengacu pada penelitian terdahulu tersebut, maka penelitian ini berusaha untuk mengukur risiko investasi di perusahaan sektor konsumen menggunakan VaR dan ES dengan pendekatan parametrik. Melalui pendekatan tersebut, dinamika volatilitas *return* saham akan dimodelkan dengan ARMA-GARCH.

Selanjutnya, penelitian ini juga mempertimbangkan penggunaan model GARCH asimetris serta distribusi *student-t* untuk mengakomodasi fenomena *leverage effect* dan *leptokurtosis*.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan sebelumnya, dapat diketahui bahwa pemodelan volatilitas menjadi kunci utama dalam menghitung risiko investasi dengan metode VaR dan ES. Sehingga untuk mendapatkan model yang mampu menggambarkan volatilitas *return* saham sektor konsumen dengan baik, keberadaan fenomena *leptokurtosis*, *volatility clustering*, serta *leverage effect* tidak bisa diabaikan.

Oleh karena itu, rumusan masalah yang akan dibahas pada penelitian ini meliputi

1. Bagaimana estimasi risiko investasi saham perusahaan sektor konsumen?
2. Bagaimana karakteristik volatilitas *return* saham dari perusahaan sektor konsumen?
3. Apakah terdapat fenomena *leptokurtosis*, *volatility clustering*, serta *leverage effect* pada *return* saham dari perusahaan sektor konsumen?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, maka tujuan yang ingin dicapai pada penelitian ini meliputi


1. Menghitung estimasi risiko investasi saham dari perusahaan sektor konsumen.
2. Menggambarkan karakteristik volatilitas *return* saham dari perusahaan sektor konsumen.

3. Mengidentifikasi keberadaan fenomena leptokurtosis, *volatility clustering*, serta *leverage effect* pada *return* saham perusahaan sektor konsumen.

1.4 Manfaat Penelitian

Manfaat yang diharapkan dari hasil penelitian ini adalah sebagai berikut:

1. Menambah wawasan mengenai penerapan model risiko VaR dan ES dengan pendekatan ARMA-GARCH pada data finansial.
2. Memberikan informasi yang dapat digunakan sebagai acuan bagi para investor dalam menentukan kebijakan berinvestasi.
3. Menambah referensi bagi penelitian-penelitian selanjutnya.



BAB II

KAJIAN PUSTAKA

2.1 Kerangka Teori

2.1.1 Risiko Investasi

Terdapat beberapa definisi risiko, namun sebagian besar merujuk pada peluang dari suatu kejadian yang tidak terduga (Fraser dkk., 2014). Dalam sebuah perusahaan terdapat dua jenis sumber risiko, yaitu risiko bisnis (*business risk*) dan risiko finansial (*financial risk*) (Gitman, 2006). Risiko bisnis adalah potensi ketidakmampuan dari sebuah perusahaan untuk menutupi biaya operasinya. Sedangkan risiko finansial adalah potensi ketidakmampuan perusahaan terhadap kewajiban finansialnya.

Menurut Jorion (2007), risiko keuangan merujuk pada potensi kerugian akibat aktivitas pasar keuangan. Risiko tersebut dapat diklasifikasikan menjadi beberapa jenis:

1. *Market Risk*

Market risk atau risiko pasar merupakan risiko kerugian akibat pergerakan harga pasar. Risiko pasar melibatkan risiko yang berasal dari pergerakan variabel keuangan, seperti harga saham, suku bunga, nilai tukar, dan harga komoditas.

2. *Liquidity Risk*

Liquidity risk atau risiko likuiditas merupakan risiko kerugian yang muncul dari tingkat kemudahan aset untuk dikonversikan (ditukar) menjadi uang tunai. Risiko ini dapat terjadi ketika transaksi tidak dapat dilakukan pada harga pasar akibat kurangnya minat pembeli pada aset tersebut.

3. *Credit Risk*

Credit risk atau risiko kredit merupakan risiko kerugian dari kemungkinan *counterparty* (debitur) gagal untuk memenuhi kewajibannya (gagal bayar).

4. *Operational Risk*

Operational risk atau risiko operasional merupakan risiko kerugian dari setiap proses kegiatan usaha, baik dari proses internal, kegagalan sistem, maupun peristiwa eksternal.

Risiko adalah variabel laten, yaitu variabel yang tidak dapat diukur dengan cara yang sama seperti mengukur suhu dengan termometer (Danielsson, 2011).

Oleh karena itu keberadaan risiko investasi tidak dapat diukur secara langsung, melainkan perlu digambarkan dari pergerakan harga pasar. Risiko umumnya dianggap sebagai volatilitas, yang diukur dengan standar deviasi (Fraser dkk., 2014).

Penggunaan standar deviasi sebagai ukuran risiko dipopulerkan oleh Markowitz (1952). Sejak saat itu, standar deviasi umumnya digunakan sebagai ukuran risiko. Namun, standar deviasi tidak memperhatikan arah pergerakan harga pasar, sehingga juga menunjukkan risiko pergerakan harga yang naik.

Sedangkan investor umumnya hanya khawatir dengan pergerakan harga yang turun (Fraser dkk., 2014). Oleh karena itu munculah *downside risk metric*, yaitu metrik yang hanya berfokus pada *return* yang tidak memenuhi target (Alexander, 2008b). Salah satu ukuran risiko yang berfokus pada *downside risk* adalah *Value at Risk (VaR)*.

Istilah "*value at risk*" berasal dari alat manajemen risiko yang dikembangkan oleh Till Guldemann di J.P. Morgan pada akhir 1980-an (Jorion, 2007). Dennis Weatherstone, ketua J.P. Morgan pada saat itu menginginkan metrik sederhana namun komprehensif, yang mencakup seluruh profil risiko bank selama 24 jam kedepan. Kemudian dengan menggunakan teori portofolio Markowitz, dibuatlah alat manajemen risiko yang disebut sebagai "*4:15 report*" (Adamko dkk., 2015).

Alat manajemen risiko tersebut selanjutnya dikenal sebagai *Value at Risk* (VaR), yang menjadi salah satu ukuran risiko paling penting yang digunakan dalam industri keuangan.

2.1.2 Return Saham

Return adalah hasil pendapatan yang dinikmati oleh investor dari kegiatan investasi yang dilakukannya (Ang, 1997). Menurut Tandellin (2010), *return* merupakan salah satu faktor pendorong untuk berinvestasi, sekaligus imbalan atas keberanian investor untuk menanggung risiko investasi yang dilakukannya.

Istilah *return* dapat dibagi menjadi dua jenis, yaitu *realized return* dan *expected return* (Jogiyanto, 2010). *Realized return* merupakan *return* yang sudah terjadi dan dihitung berdasarkan data historis. Sedangkan *expected return* merupakan *return* yang belum terjadi dan diinginkan di masa depan. *Realized return* dapat digunakan untuk meramalkan *expected return*, serta mengukur kinerja perusahaan berdasarkan data historis.

Menurut Tandellin (2010), komponen pembentuk *return* saham dapat dibagi menjadi dua, yaitu *capital gain (loss)* (laba/rugi modal) dan dividen. *Capital gain (loss)* adalah keuntungan (kerugian) yang diperoleh dari selisih harga jual dan harga beli saham. Sedangkan dividen adalah pembagian laba perusahaan kepada pemilik saham setiap periode tertentu.

Return dari perubahan harga (*capital gain (loss)*) dapat dihitung menggunakan dua cara, yaitu *simple return* (menggunakan persentase) atau *compounded return* (menggunakan logaritma). Namun karena *return* terdistribusi secara *log-normal*, maka lebih tepat untuk didefinisikan menggunakan logaritma natural (Kissell, 2014). Secara matematis, kedua cara tersebut dapat didefinisikan sebagai berikut:

Percentage Price Return (Simple Return)

$$r_t = \frac{P_t}{P_{t-1}} - 1$$

Log Price Return (Continuously Compounded Return)

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

Dimana,

r_t : Return pada periode t

P_t : Harga saham pada periode t

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

\ln : Logaritma natural

2.1.3 Konsep Volatilitas

Volatilitas mengacu pada kondisi yang tidak stabil, cenderung bervariasi, dan sulit diperkirakan (Juanda dan Junaidi, 2012). Dalam pasar saham, istilah volatilitas digambarkan sebagai ketidakpastian dari potensi pergerakan harga saham (Kissell, 2014). Ketika volatilitas tinggi maka harga saham dapat naik turun dalam waktu yang singkat, sedangkan ketika volatilitas rendah maka harga saham dapat dikatakan relatif stabil.

Volatilitas sering digunakan sebagai tolak ukur dari risiko aset keuangan (Brooks, 2008). Banyak model pengukuran risiko pasar yang menggunakan parameter volatilitas sebagai input utamanya. Oleh karena itu, dengan mengetahui volatilitas para investor dapat menghitung tingkat risiko yang harus ditanggung sebelum masuk ke pasar.

Menurut Natenberg (2007), terdapat empat interpretasi terhadap makna volatilitas yang beredar di pasar, yaitu:

1. *Future Volatility*

Merupakan volatilitas di masa depan yang ingin diketahui oleh investor, sifatnya masih berupa tebakan untuk mengetahui arah pasar.

2 *Historical Volatility*

Merupakan volatilitas yang merepresentasikan perubahan harga di masa lalu. Volatilitas ini sering dipelajari untuk memperkirakan volatilitas di masa yang akan datang.

3 *Forecast Volatility*

Merupakan estimasi volatilitas di masa depan, yang diramalkan dengan berbagai model matematis.

4 *Implied Volatility*

Merupakan ekspektasi pasar terhadap volatilitas yang akan terjadi di masa depan.

Historical volatility mengukur volatilitas dengan menggunakan simpangan baku (standar deviasi) dari data historis *return* saham (Brooks, 2008). Secara matematis, standar deviasi dari *return* saham dapat didefinisikan sebagai berikut (Kissell, 2014):

$$\sigma_i = \sqrt{\frac{1}{n-1} \sum_{k=1}^n (r_{ik} - \bar{r}_i)^2}$$

Dimana,

σ_i : Standar deviasi

r_{ik} : *Return* saham pada satu periode observasi

\bar{r}_i : Rata-rata dari seluruh observasi *return* saham

n : Jumlah observasi

Menurut Natenberg (2007), *historical volatility* merupakan salah satu pendekatan realistis terhadap *future volatility*, karena standar deviasi dari data historis dapat digunakan untuk menggambarkan potensi volatilitas di masa



depan. Oleh karena itu, *historical volatility* sering digunakan dalam pasar keuangan bersama dengan *implied volatility* sebagai pembanding untuk menentukan keputusan (Kissell, 2014).

2.1.4 Model Volatilitas

Sebagai tolak ukur dari risiko aset keuangan, volatilitas menjadi salah satu konsep penting yang sering dijadikan objek penelitian bagi akademisi maupun praktisi. Oleh karena itu, keberadaan volatilitas menjadi tantangan tersendiri bagi peneliti untuk dimodelkan dengan pendekatan yang lebih baik.

Pendekatan model yang mengasumsikan residual konstan (*homoscedastic*) seperti *exponential smoothing*, maupun ARIMA (*Autoregressive Integrated Moving Average*) gagal untuk menangkap fenomena pada data finansial yang cenderung memiliki residual tidak konstan (*heteroscedastic*) (Montgomery, Jennings, dan Kulahci, 2015).

Menurut Brooks (2008), jika residual bersifat *heteroscedastic* tetapi dipaksakan dengan asumsi *homoscedastic*, maka estimasi standar error bisa menjadi salah dan menghasilkan peramalan volatilitas yang kurang tepat. Oleh karena itu, peneliti mulai mempertimbangkan model yang tidak mengasumsikan homoskedastisitas, serta model yang mampu menggambarkan perkembangan varians dari residual.

Model klasik ARCH (*Autoregressive Conditional Heteroskedasticity*) yang dikemukakan oleh Engle (1982) berhasil memodelkan *conditional variance* (varians bersyarat). Model tersebut kemudian dikembangkan menjadi GARCH (*Generalized ARCH*) oleh muridnya Bollerslev (1986) sehingga memungkinkan *conditional variance* untuk dipengaruhi dirinya sendiri di periode sebelumnya.

Kedua model tersebut mampu menangkap fenomena *volatility clustering*, yaitu kecenderungan dimana guncangan (*shock*) besar pada harga aset untuk diikuti

oleh guncangan besar lain, atau kecenderungan tingkat volatilitas saat ini untuk berkorelasi positif dengan periode sebelumnya (Brooks, 2008).

Model GARCH generasi awal mengasumsikan respon simetris terhadap setiap efek guncangan pada harga aset. Oleh karena itu, model tersebut belum bisa mengakomodasi respon asimetris terhadap guncangan yang dapat terjadi di pasar saham. Fenomena ini disebut dengan *leverage effect*, yang pertama kali dikemukakan oleh Black (1976), yaitu ketika harga saham jatuh maka biasanya akan diikuti oleh peningkatan volatilitas. Peningkatan volatilitas ini tidak sebanding dengan peningkatan volatilitas ketika harga saham naik dengan besaran yang sama Brooks (2008).

Menurut Wu (2001), kondisi asimetris umumnya akan muncul ketika pasar saham sedang *crash*, yaitu ketika terjadi guncangan negatif yang kuat pada harga saham. Kondisi ini dapat berasal dari pengaruh biaya transaksi, gesekan pasar, maupun perubahan sentimen pasar. Oleh karena itu, harga saham membutuhkan waktu lebih lama untuk kembali pada posisi normal (Aliyev, Ajayi, dan Gasim, 2020).

Kegagalan model awal GARCH untuk mengakomodasi *leverage effect* mendorong munculnya berbagai pengembangan model GARCH alternatif yang memungkinkan respon asimetris terhadap pasar. Salah satu model GARCH asimetris yang populer adalah GJR-GARCH, model tersebut dikemukakan oleh Glosten, Jagannathan, dan Runkle (1993) untuk mengatasi kelemahan model GARCH simetris dalam menangkap fenomena efek asimetris pada volatilitas.

2.1.5 Value at Risk

VaR merupakan alat ukur statistik yang dapat digunakan untuk mengukur potensi kerugian maksimum selama periode tertentu dalam tingkat kepercayaan

tertentu (Yamai dan Yoshiba, 2005). Metode ini banyak digunakan pada bidang yang terpapar ketidakpastian seperti bidang keuangan (Sarykalin, 2008). VaR populer untuk mengelola risiko keuangan karena mampu meringkas ukuran risiko pasar (*market risk*) ke dalam satuan angka yang mudah dipahami (Jorion, 2007).

Dimana potensi kerugian maksimum yang diukur dengan metode ini dapat dikonversikan ke satuan mata uang, sehingga mudah dipahami dan diaplikasikan sebagai acuan dalam pengambilan kebijakan.

Terdapat tiga tahapan yang perlu dilakukan untuk menghitung nilai VaR, yaitu menentukan tingkat kesalahan (α), menetapkan periode *holding* (h), serta mengidentifikasi distribusi probabilitas untung dan rugi (Dañielsson, 2011).

Tingkat kesalahan (α) atau tingkat kepercayaan ($1-\alpha$) yang digunakan dalam VaR dapat disesuaikan dengan tingkat risiko yang siap diterima (*attitude to risk*) (Alexander, 2008b). Dimana semakin konservatif maka tingkat kesalahan yang digunakan semakin kecil, sehingga meningkatkan tingkat kepercayaan terhadap nilai VaR. Dengan kata lain, nilai VaR semakin tinggi sedangkan probabilitas kerugian yang melampaui nilai VaR semakin rendah.

Periode *holding* (h) merupakan jangka waktu pemengangan aset, jangka waktu tersebut biasanya satu hari, namun juga dapat disesuaikan dengan kondisi tertentu (Dañielsson, 2011). Selain tingkat kepercayaan ($1-\alpha$) yang semakin tinggi, panjang periode *holding* (h) yang semakin panjang juga dapat memperbesar nilai VaR (Alexander, 2008b).

Jika dibandingkan dengan penyesuaian tingkat kesalahan (α) dan periode *holding* (h), identifikasi distribusi probabilitas untung dan rugi merupakan bagian tersulit dari tahapan untuk menghitung nilai VaR (Dañielsson, 2011). Oleh karena itu, biasanya perubahan nilai aset dari waktu ke waktu diasumsikan terdistribusi secara normal (Hull, 2018). Meskipun dalam kondisi tertentu asumsi tersebut

dapat dilanggar, sehingga diperlukan model statistik tertentu untuk mengestimasi distribusi untung dan rugi tersebut.

Dengan asumsi bahwa perubahan nilai aset pada satu hari periode *holding* terdistribusi secara normal, maka secara matematis VaR dapat didefinisikan sebagai berikut (Hull, 2018):

$$\text{VaR} = \mu + \sigma N^{-1}(\alpha)$$

Dimana,

μ : Rata-rata hitung (*mean*) dari perubahan nilai aset

σ : Volatilitas (standar deviasi) dari perubahan nilai aset

N^{-1} : *Inverse cumulative normal distribution function*

α : Probabilitas kerugian yang melampaui nilai VaR

Selain mengasumsikan distribusi normal, definisi matematis tersebut juga mengasumsikan bahwa volatilitas tidak berubah seiring waktu. Dañielsson (2011) menyebut konsep ini sebagai *unconditional volatility* (σ), yaitu volatilitas sepanjang periode waktu. Di sisi lain, terdapat konsep *conditional volatility* (σ_t), yaitu volatilitas dalam periode waktu tertentu yang bergantung pada kondisi sebelumnya.

Konsep *conditional volatility* terkait dengan fenomena *volatility clustering*, yaitu kecenderungan pengelompokan volatilitas di pasar keuangan, dimana pasar memiliki periode stabil dan tidak stabil (Holton, 2014). Sejak mendapat perhatian luas melalui publikasi Engle (1982), fenomena ini menjadi salah satu fakta empiris (*stylized facts*) yang diakui dari *return* aset finansial (Dañielsson, 2011).

Dalam menghitung VaR dengan pendekatan parametrik, *return* harian aset finansial yang menunjukkan fenomena *volatility clustering* dapat disimulasikan dengan penerapan model GARCH (Alexander, 2008b). Keluarga model GARCH

mampu mendeskripsikan dinamika volatilitas *return* aset finansial, sehingga model GARCH menjanjikan peramalan volatilitas serta peramalan nilai VaR yang lebih baik dibanding model parametrik lainnya (Danielsson, 2011).

2.1.6 *Expected Shortfall*

Sebagai indikator risiko, VaR memiliki kelemahan yaitu mengabaikan potensi kerugian yang dapat diderita oleh investor jika nilai VaR terlampaui (Alexander, 2008b). Jika didapatkan nilai VaR 100 hari pada tingkat kepercayaan 99%, maka dapat dipastikan bahwa potensi kerugian yang diderita pada 99 dari 100 hari tersebut tidak melampaui nilai VaR. Di sisi lain, potensi kerugian dari penurunan harga aset yang drastis pada salah satu dari 100 hari tersebut tidak mampu dijelaskan oleh VaR (99%). Akibatnya, potensi kerugian dengan peluang sebesar 1% tersebut tidak mampu diantisipasi.

Kekurangan dari metode VaR tersebut dapat diatasi dengan *Conditional Value at Risk* (CVaR) atau sering disebut juga *Expected Shortfall* (ES). CVaR adalah metode pengukuran risiko yang mengukur potensi kerugian di bagian ekor distribusi (Rockafellar dan Uryasev, 2002). Pada kasus tertentu CVaR sama dengan ES, namun keduanya merupakan indikator risiko yang berbeda (Uryasev dan Rockafellar, 2001). CVaR sama dengan ES ketika kerugian memiliki distribusi kontinu, dimana informasi tentang besaran kerugian yang melampaui nilai VaR digambarkan sebagai ekspektasi bersyarat di bawah kuantil yang terkait dengan probabilitas (α) tertentu (Danielsson, 2011).

Dalam berbagai literatur, VaR dapat dinyatakan sebagai bilangan positif atau negatif. Yamai dan Yoshida (2005) serta Danielsson (2011) mengasumsikan VaR sebagai bilangan positif. Sedangkan Cai (2020) mendefinisikan VaR sebagai bilangan negatif. Perbedaan tersebut bukan merupakan inkonsistensi,

karena baik keuntungan maupun kerugian dapat dinyatakan sebagai bilangan positif.

Jika mengacu pada VaR sebagai bilangan positif, maka secara matematis ES dapat didefinisikan sebagai berikut:

$$ES_{\alpha} = E[r_t | r_t \geq VaR_{\alpha}]$$

Sedangkan jika mengacu pada VaR sebagai bilangan negatif, maka ES dapat dituliskan sebagai berikut:

$$ES_{\alpha} = E[r_t | r_t \leq VaR_{\alpha}]$$

Dimana r_t merupakan *return* (perubahan nilai aset) pada periode t , sedangkan α merupakan probabilitas (tingkat kesalahan) dari kerugian yang melampaui nilai VaR.

2.2 Penelitian Terdahulu

Penelitian terdahulu yang berusaha mengestimasi risiko investasi dengan VaR adalah penelitian Spierdijk (2016), yang menggunakan pendekatan ARMA-GARCH simetris untuk memodelkan volatilitas dari *return saham* harian SBM Offshore (SBMO). Pendekatan tersebut merupakan kombinasi antara model ARMA (*Autoregressive Moving Average*) dengan model GARCH simetris (*Generalized Autoregressive Conditional Heteroskedasticity*), sehingga mampu mengakomodasi fenomena *volatility clustering*.

Di sisi lain, penelitian yang berusaha untuk memodelkan volatilitas dengan mempertimbangkan fenomena *volatility clustering* dan *leverage effect* terdapat pada penelitian Erginbay, Thalassinos, dan Muratoglu (2014). Mereka meneliti volatilitas indeks saham dari lima pasar negara berkembang Eropa, yaitu Turki, Bulgaria, Republik Ceko, Polandia dan Hungaria dengan model GARCH, GJR-GARCH dan EGARCH. Mereka menemukan guncangan volatilitas (*volatility*

shocks) yang konsisten di keempat pasar tersebut dan menyimpulkan bahwa terdapat *leverage effect*, dimana pengaruh berita buruk (*bad news*) dapat meningkatkan volatilitas di pasar.

Penelitian tersebut selaras dengan penelitian Sari dkk. (2017). Mereka berusaha memodelkan volatilitas *return* di pasar saham Asia dengan pendekatan model GARCH simetris dan beberapa model GARCH asimetris (EGARCH, GJR-GARCH, TGARCH, IGARCH, APARCH, dan CGARCH). Mereka menemukan bahwa model GARCH simetris tidak cocok untuk digunakan pada seluruh indeks saham yang mereka uji, dimana volatilitas *return* di pasar saham Indonesia dan Hong Kong digambarkan dengan baik oleh model APARCH, sedangkan volatilitas *return* di pasar saham Jepang dan Singapura digambarkan dengan baik oleh model TGARCH. Oleh karena itu mereka menyimpulkan adanya efek asimetris dari pengaruh *bad news* dan *good news* terhadap volatilitas *return* saham di sana.

Kemudian pemodelan volatilitas yang mengakomodasi *leptokurtosis*, *volatility clustering*, serta *leverage effect* terdapat pada penelitian Aliyev dkk. (2020). Mereka memodelkan volatilitas *return* indeks harga saham harian Nasdaq-100 dengan model GARCH simetris serta model GARCH asimetris (EGARCH dan GJR-GARCH). Mereka menemukan keberadaan efek asimetris yang nampak pada model GARCH asimetris, sehingga dampak guncangan negatif terhadap volatilitas lebih tinggi daripada guncangan positif dengan ukuran yang sama. Selain itu, mereka juga menemukan fenomena *leptokurtosis*, yang kemudian diakomodasi menggunakan distribusi *student-t*.

Penelitian lain yang serupa adalah Miron dan Tudor (2010), yang dalam penelitiannya membandingkan performa beberapa model (GARCH, EGARCH, PGARCH, dan TGARCH) dengan tiga distribusi (normal, *student-t*, GED) untuk memodelkan volatilitas empat data *return* yang berbeda dari pasar saham

Rumania dan AS. Mereka menemukan adanya efek asimetris pada keempat *return* saham tersebut. Mereka menyimpulkan bahwa performa model EGARCH lebih baik dari model asimetris lain. Selain itu, mereka juga menemukan bahwa distribusi normal kurang mampu untuk menjelaskan volatilitas, karena gagal menangkap sifat *leptokurtosis* pada data.

The logo of Universitas Brawijaya is a large, stylized emblem. It features a central figure, likely a deity or a historical figure, standing and holding various symbols. The figure is flanked by two smaller figures, possibly children or attendants. The entire emblem is enclosed within a shield-like border. The text "UNIVERSITAS BRAWIJAYA" is written in a bold, sans-serif font across the top of the shield.

UNIVERSITAS BRAWIJAYA

BAB III METODE PENELITIAN

3.1 Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif, yaitu pendekatan penelitian yang bertujuan untuk menjelaskan suatu fenomena dengan data numerik yang dianalisis secara statistik (Muijs, 2004). Pada penelitian ini, pendekatan kuantitatif digunakan untuk mengestimasi risiko investasi dari perusahaan sektor konsumen, serta mengidentifikasi karakteristik volatilitas *return* saham dari perusahaan sektor konsumen.

Di sisi lain, penelitian ini menggunakan analisis *univariate*, yaitu pendekatan analisis yang digunakan untuk mengamati perubahan satu variabel dari waktu ke waktu (Trochim, 2006). Oleh karena itu, estimasi risiko investasi dari perusahaan sektor konsumen yang digunakan pada penelitian ini tidak menggambarkan risiko investasi pada seluruh perusahaan yang termasuk kedalam sektor konsumen.

3.2 Tempat dan Waktu Penelitian

Tempat atau lokasi penelitian ini adalah pasar saham di negara Indonesia. Sedangkan untuk waktu penelitian yang digunakan pada masing-masing variabel bervariasi. Seluruh data deret waktu (*time series*) harga saham harian yang digunakan pada penelitian ini memiliki periode akhir yang sama, yaitu 30 Desember 2020. Namun karena terdapat perbedaan tanggal penawaran umum perdana (IPO) beberapa saham serta permasalahan ketersediaan data, maka periode awal dari setiap variabelnya berbeda-beda.

Periode awal dari harga saham harian PT Indofood CBP Sukses Makmur Tbk (ICBP), PT H.M. Sampoerna Tbk (HMSP), PT Kalbe Farma Tbk (KLBF),

serta PT Unilever Indonesia Tbk (UNVR) dimulai dari 2 Januari 2007. Sedangkan PT Integra Indocabinet Tbk (WOOD) dan PT Hartadinata Abadi Tbk (HRTA) dimulai dari 22 Juni 2017.

3.3 Definisi Operasional dan Pengukuran Variabel Penelitian

Variabel yang digunakan dalam penelitian ini adalah *return* saham harian dari PT Indofood CBP Sukses Makmur Tbk (ICBP), PT H.M. Sampoerna Tbk (HMSP), PT Kalbe Farma Tbk (KLBF), PT Unilever Indonesia Tbk (UNVR), PT Integra Indocabinet Tbk (WOOD), serta PT Hartadinata Abadi Tbk (HRTA).

Skala pengukuran dari harga saham harian keenam perusahaan tersebut adalah rasio, namun ketika dihitung *return* dari perubahan harganya, skala pengukuran berubah dari rasio menjadi interval. Skala pengukuran interval tidak memiliki nol absolut (*true zero*) seperti skala rasio, sehingga memungkinkan adanya nilai negatif (Ho, 2013).

3.4 Populasi dan Penentuan Sampel

Dari berbagai perusahaan yang terdaftar di BEI dan masuk kedalam sektor konsumen, pada penelitian ini akan dipilih enam perusahaan untuk dilakukan estimasi risiko investasi. Perusahaan tersebut merupakan perwakilan dari setiap subsektor industri barang konsumsi, yang dipilih berdasarkan kapitalisasi pasar terbesar untuk setiap subsektor pada kuartar keempat di tahun 2020 (Indonesia Stock Exchange, 2020). Dengan kata lain, keenam perusahaan sektor konsumen yang diamati pada penelitian ini merupakan *market leader* di bidang industrinya masing-masing.

Keenam perusahaan tersebut adalah PT Indofood CBP Sukses Makmur Tbk (ICBP), PT H.M. Sampoerna Tbk (HMSP), PT Kalbe Farma Tbk (KLBF), PT

Unilever Indonesia Tbk (UNVR), PT Integra Indocabinet Tbk (WOOD), serta PT Hartadinata Abadi Tbk (HRTA). Perusahaan tersebut mewakili setiap subsektor dari industri barang konsumsi berdasarkan klasifikasi JASICA, yaitu makanan dan minuman, rokok, farmasi, kosmetik dan keperluan rumah tangga, peralatan rumah tangga, dan lainnya.

Karena penelitian ini menggunakan analisis *univariate*, artinya estimasi risiko investasi dari keenam perusahaan tersebut tidak menggambarkan risiko investasi pada seluruh perusahaan di sektor konsumen. Oleh karena itu, populasi yang digunakan adalah seluruh data deret waktu (*time series*) harga saham harian dari masing-masing perusahaan tersebut. Sedangkan sampel dari penelitian ini adalah seluruh populasi yang digunakan.

3.5 Metode Pengumpulan Data

Penelitian ini menggunakan jenis data sekunder, yaitu data yang diperoleh dari lembaga terkait dan telah terlebih dahulu mengumpulkan data tersebut. Data yang digunakan dalam penelitian ini diperoleh dari situs *finance.yahoo.com*. Data tersebut berupa data *time series* penutupan harga saham harian dari PT Indofood CBP Sukses Makmur Tbk (ICBP), PT H.M. Sampoerna Tbk (HMSP), PT Kalbe Farma Tbk (KLBF), PT Unilever Indonesia Tbk (UNVR), PT Integra Indocabinet Tbk (WOOD), serta PT Hartadinata Abadi Tbk (HRTA).

3.6 Metode Analisis

Penelitian ini menggunakan gabungan metode analisis statistik deskriptif dan statistik inferensia. Statistik deskriptif merupakan metode analisis untuk mengorganisasi, menyajikan, serta mendeskripsikan data dengan bantuan tabel, grafik, dan ringkasan statistik. Sedangkan statistik inferensia merupakan metode

analisis yang menggunakan sampel untuk membantu membuat keputusan atau melakukan prediksi terhadap populasi (Mann, 2016).

Dalam penelitian ini, statistik deskriptif digunakan untuk memahami karakteristik data *return* saham dengan bantuan tabel, grafik, dan ringkasan statistik. Sedangkan statistik inferensia digunakan untuk mengestimasi volatilitas *return* saham dengan model statistik. Hasil estimasi volatilitas tersebut kemudian digunakan sebagai input untuk mengukur risiko saham melalui penghitungan VaR dan ES.

Pendekatan model yang digunakan untuk mengestimasi volatilitas mengikuti proses ARMA-GARCH, yaitu penggabungan model ARMA (*Autoregressive Moving Average*) dengan model GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*). Dimana proses ARMA digunakan untuk memodelkan *conditional mean* (rata-rata bersyarat), sedangkan proses GARCH digunakan untuk memodelkan *conditional variance* (varians bersyarat) (Li, Ling, dan McAleer, 2002).

Spesifikasi model ARMA(1,1) dan GARCH(1,1) secara matematis dapat didefinisikan sebagai berikut (Spierdijk, 2016):

$$r_t = \mu_t + \varepsilon_t$$

$$r_t = \mu_t + \sigma_t z_t$$

$$\mu_t = \mu + \gamma r_{t-1} + \theta (r_{t-1} - \mu_{t-1})$$

$$\sigma_t^2 = \omega + \alpha (r_{t-1} - \mu_{t-1})^2 + \beta \sigma_{t-1}^2$$

Dimana,

r_t : *Return*

μ_t : *Mean*

ε_t : *Error*

σ_t : *Standar deviasi*

- z_t : Proses *white noise*
- μ : Konstanta *mean equation* (model ARMA)
- γ : Koefisien AR
- θ : Koefisien MA
- r_{t-1} : Ordo dari proses AR(1)
- $r_{t-1} - \mu_{t-1}$: Ordo dari proses MA(1)
- σ_t^2 : *Conditional variance*
- ω : Konstanta *variance equation* (model GARCH)
- α : Koefisien ARCH
- β : Koefisien GARCH
- $(r_{t-1} - \mu_{t-1})^2$: Ordo dari proses ARCH(1)
- σ_{t-1}^2 : Ordo dari proses GARCH(1)

3.6.1 Proses ARMA

1 Identifikasi

a Uji stasioneritas

Untuk menggunakan model AR dan MA terdapat asumsi yang harus dipenuhi, yaitu data harus bersifat stasioner (Levendis, 2018).

Menurut Brooks (2008), data deret waktu (*time series*) dinyatakan stasioner ketika *mean* (rata-rata hitung) dan varians konstan.

Uji ADF (*Augmented Dickey-Fuller test*) adalah uji stasioneritas yang paling sering digunakan, dimana uji ini melihat kestasioneran data *time series* berdasarkan keberadaan *unit root* (Levendis, 2018).

Hipotesis statistik dari uji ADF adalah:

H_0 : Terdapat *unit root* (data tidak stasioner)

H_1 : Tidak terdapat *unit root* (data stasioner)

Untuk menolak H_0 , maka nilai p -value harus lebih kecil dari tingkat signifikansi (α) dan nilai $test\ statistic$ harus lebih kecil (negatif) dari setiap $Dickey-Fuller\ critical\ value$.

Menurut Brooks (2008), data $time\ series$ yang tidak stasioner bisa distasionerkan dengan melakukan $differencing$. Dimana tingkatan $differencing$ pada data akan menjadi ordo dari proses integrasi $I(d)$ model $ARIMA(p,d,q)$. Sehingga data yang sudah stasioner pada tingkat level (tanpa $differencing$) akan memiliki spesifikasi model $ARIMA(p,0,q)$, atau setara dengan $ARMA(p,q)$.

b Identifikasi autokorelasi

Pola autokorelasi dan autokorelasi parsial dapat digunakan untuk menentukan kombinasi ordo dari proses $AR(p)$ dan $MA(q)$ (Box dkk., 2016). Kombinasi ordo dari proses $AR(p)$ dan $MA(q)$ ditentukan dari perbandingan ACF dan PACF empiris yang diestimasi langsung dari data, dengan ACF dan PACF teoritis yang terkait dengan model tertentu (Levendis, 2018). Dimana karakteristik ACF dan PACF teoritis pada model ARMA dapat diringkas menjadi:

Tabel 3.1: **ACF dan PACF Teoritis ARMA**

	$AR(p)$	$MA(q)$	$ARMA(p,q)$
ACF	<i>Tails off</i>	<i>Cuts off after lag q</i>	<i>Tails off</i>
PACF	<i>Cuts off after lag p</i>	<i>Tails off</i>	<i>Tails off</i>

Sumber: Shumway dan Stoffer (2017)

2. Estimasi Parameter

Estimasi parameter dari spesifikasi model tentatif $ARIMA/ARMA$ dapat dilakukan dengan metode $least\ squares$ maupun $maximum\ likelihood$ (Brooks, 2008). Menurut Hyndman dan Athanasopoulos (2018),



estimasi parameter model ARIMA yang menggunakan MLE (*Maximum Likelihood Estimation*) mirip dengan estimasi parameter yang menggunakan metode *least squares* seperti OLS (*Ordinary Least Squares*). MLE berusaha untuk mencari nilai parameter yang memaksimalkan *log likelihood*, sedangkan OLS berusaha untuk mencari nilai parameter yang meminimalkan jumlah residual kuadrat.

3 Pemeriksaan Diagnostik

a Uji *white noise*

Spesifikasi model ARMA dari kombinasi ordo p dan q yang memadai (*adequate*) akan mengikuti proses *white noise* (Montgomery dkk., 2015). Menurut Box dkk. (2016), sifat *white noise* dari residual dapat diuji dengan *Portmanteau test* yang berdasar pada fungsi autokorelasi (ACF) dari residual. Uji ini kemudian dikembangkan menjadi *Ljung-Box test*, dengan hipotesis statistik sebagai berikut (Montgomery dkk., 2015):

H_0 : Residual bersifat *white noise*

H_1 : Residual tidak bersifat *white noise*

Dimana H_0 dapat diterima jika nilai *p-value* lebih kecil dari tingkat signifikansi (α), yang berarti bahwa residual bersifat independen dan tidak memiliki autokorelasi.

b Perbandingan kriteria informasi

Jika terdapat dua model yang lolos uji *white noise*, maka dapat dipilih model terbaik dengan perbandingan kriteria informasi, seperti AIC yang diusulkan oleh Akaike (1974) atau kriteria informasi bayesian (BIC) yang dikemukakan oleh Schwarz (1978) (Box dkk., 2016). Model terbaik dipilih berdasarkan nilai kriteria informasi

terkecil, dimana AIC memberikan penalti yang lebih longgar dibanding BIC.

3.6.2 Proses GARCH

1 Identifikasi

a Uji efek ARCH/GARCH

Terdapat beberapa cara untuk memastikan residual dari model ARMA bersifat heteroskedastik, diantaranya dengan penggunaan ACF dan PACF dari residual kuadrat, serta penggunaan *Lagrange Multiplier test* (Box dkk., 2016). Menurut Levendis (2018), metode pengujian LM bergantung pada uji *chi square*, dimana hipotesis statistik dari uji LM adalah:

H_0 : Tidak terdapat efek ARCH

H_1 : Terdapat efek ARCH

Untuk menolak H_0 , maka nilai *p-value* harus lebih besar dari tingkat signifikansi (α), artinya terdapat autokorelasi pada varians dari residual kuadrat yang membuat residual bersifat *heteroscedastic*.

b Identifikasi model GARCH

Menurut Brooks (2008), model simetris GARCH(1,1) sudah cukup untuk mengakomodasi fenomena *volatility clustering* pada data finansial. Banyak penelitian yang menunjukkan bahwa model GARCH dengan ordo rendah seperti model GARCH (1,1) seringkali memadai dalam praktiknya (Box dkk., 2016). Oleh karena itu, penelitian ini menggunakan spesifikasi model GARCH(1,1), yang

secara matematis dapat didefinisikan sebagai berikut (Aliyev dkk., 2020):

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

Dimana,

σ_t^2 : Conditional variance

α_0 : Konstanta

α_1 : Koefisien besarnya dampak guncangan (*volatility shock*)

β_1 : Koefisien lamanya dampak guncangan (*volatility shock*)

ε_{t-1}^2 : Ordo dari proses ARCH(1)

σ_{t-1}^2 : Ordo dari proses GARCH(1)

Selain menggunakan model GARCH(1,1), perlu dipertimbangkan model GARCH asimetris untuk mengakomodasi fenomena *leverage effect* pada data finansial (Hansen & Lunde, 2005). Oleh karena itu, pada penelitian ini digunakan model GJR-GARCH sebagai model pembanding. Model GJR-GARCH(1,1) secara matematis dapat dituliskan dalam persamaan berikut (Brooks, 2008):

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \beta \sigma_{t-1}^2 + \gamma \mu_{t-1}^2 I_{t-1}$$

Dimana $I_{t-1} = 1$ ketika $\mu_{t-1} < 0$

$I_{t-1} = 0$ ketika sebaliknya.

Keberadaan *leverage effect* ditunjukkan dengan nilai $\gamma > 0$, yang menunjukkan perbedaan respon volatilitas ketika terjadi guncangan positif dan negatif. Sedangkan nilai $\gamma = 0$ menunjukkan bahwa volatilitas merespon guncangan positif dan negatif secara simetris.

2 Estimasi parameter

Estimasi parameter dari model keluarga GARCH tidak dapat dilakukan dengan OLS, karena metode untuk meminimalkan jumlah residual kuadrat hanya bergantung pada *conditional mean* saja, bukan *conditional variance* yang menjadi tujuan utama model keluarga GARCH (Brooks, 2008). Oleh karena itu Brooks menyarankan untuk menggunakan MLE, karena metode ini berusaha untuk menemukan nilai parameter yang memaksimalkan *log likelihood*.

Box dkk. (2016) menyarankan penggunaan distribusi *student-t* atau GED (*Generalized Error Distribution*) untuk mengestimasi parameter dari model keluarga GARCH. Hal ini karena adanya fenomena *leptokurtosis* yang menyebabkan estimasi parameter dengan asumsi distribusi normal tidak dapat dilakukan. *Leptokurtosis* adalah kecenderungan pada data *return* aset finansial untuk memiliki distribusi *heavy tails*, dimana kurtosis (keruncingan) melebihi batas distribusi normal (Brooks, 2008).

3 Pemeriksaan Diagnostik

a Uji *Weighted ARCH LM*

Untuk mengetahui apakah model GARCH telah terbebas dari efek ARCH (heteroskedastisitas), dapat digunakan *weighted ARCH LM tests* yang dikembangkan oleh Fisher dan Gallagher (2012) (Ghalanos, 2020a).

Hipotesis statistik dari uji *weighted ARCH LM* adalah:

H_0 : Tidak terdapat efek ARCH

H_1 : Terdapat efek ARCH

Dimana H_0 dapat diterima jika nilai *p-value* lebih besar dari tingkat signifikansi (α), yang berarti bahwa residual terstandarisasi sudah tidak memiliki efek ARCH (tidak bersifat *heteroscedastic*).

b Uji Sign and Size Bias

Untuk menguji keberadaan *leverage effect* dan menentukan apakah model GARCH asimetris dibutuhkan untuk memodelkan volatilitas, Engle dan Ng (1993) memperkenalkan pengujian yang dikenal dengan *sign and size bias tests* (Ghalanos, 2020a).

Terdapat tiga variabel yang diuji, yaitu perbedaan respon guncangan positif dan negatif terhadap volatilitas (*sign bias*), keberadaan bias pada guncangan negatif (*negative size bias*), dan keberadaan bias pada guncangan positif (*positive size bias*). Ketiga pengujian variabel tersebut kemudian digabung menjadi *joint test* yang merupakan regresi dari (Brooks, 2008):

$$\hat{u}_t^2 = \phi_0 + \phi_1 S_{t-1}^- + \phi_2 S_{t-1}^- u_{t-1} + \phi_3 S_{t-1}^+ u_{t-1} + u_t$$

Dimana,

\hat{u}_t^2 : Residual kuadrat terstandarisasi

S_{t-1}^- : Variabel *dummy sign bias*

$S_{t-1}^- u_{t-1}$: Variabel *dummy negative size bias*

$S_{t-1}^+ u_{t-1}$: Variabel *dummy positive size bias*

ϕ_i : Koefisien

u_t : Residual

Hipotesis statistik dari uji *sign and size bias* adalah:

$H_0: \phi_i = 0$ (untuk $i = 1, 2, 3$), atau $\phi_1 + \phi_2 + \phi_3 = 0$

$H_1: \phi_i \neq 0$, atau $\phi_1 + \phi_2 + \phi_3 \neq 0$ (terdapat efek asimetris)

c Perbandingan kriteria informasi

Sama seperti model ARMA, pemilihan model GARCH terbaik juga dapat dilakukan dengan membandingkan nilai AIC dan BIC,



dimana model terbaik memiliki nilai kriteria informasi terkecil (Box dkk., 2016).

3.6.3 Value at Risk

1 Backtesting

Pengukuran risiko dengan metode VaR hanya berguna ketika model dapat mengestimasi risiko dengan baik. Oleh karena itu, penerapan metode ini perlu disertai dengan proses validasi, untuk memeriksa apakah model tersebut memadai. Proses validasi tersebut dapat dilakukan dengan prosedur *backtesting* (Jorion, 2007).

Backtesting adalah prosedur pemeriksaan diagnostik yang bertujuan untuk memeriksa apakah hasil prediksi yang telah dibuat oleh model sesuai dengan kenyataan (Roccioletti, 2016). Dalam penelitian ini, *backtesting* dilakukan untuk menguji apakah estimasi kerugian maksimum (nilai VaR) yang dihasilkan dengan pendekatan ARMA-GARCH mampu mendekati kerugian asli pada data historis.

a Rolling Analysis

Rolling analysis adalah metode yang biasa digunakan untuk *backtesting* model statistik terhadap data historis guna mengevaluasi stabilitas dan akurasi prediksi model dari waktu ke waktu (Zivot dan Wang, 2005). *Backtesting* dengan metode *rolling* membagi data historis menjadi sampel estimasi dan sampel prediksi. Sampel estimasi kemudian di-*rolling* beberapa periode ke depan dan dire-estimasi hingga tidak bisa di-*rolling* lagi.

Dalam penelitian ini, untuk melakukan *rolling* pada model ARMA-GARCH digunakan metode *ugarchroll* dari *package rugarch* yang dikembangkan oleh Ghalanos (2020b) dalam R (R Core Team,

2013). Sebanyak 250 observasi terakhir dari masing-masing data *return* saham pada penelitian ini digunakan untuk memvalidasi model VaR. Sehingga seluruh observasi data *return* saham sebelum 250 observasi terakhir kemudian digunakan sebagai data sampel untuk *di-rolling* satu periode ke depan dan dire-estimasi setiap 50 observasi.

Jika terdapat 3500 observasi, maka 250 observasi terakhir akan digunakan untuk memvalidasi model. Sehingga data sampel yang digunakan adalah 3250 observasi pertama. Dari 3250 observasi pertama tersebut, akan dilakukan estimasi parameter berdasarkan spesifikasi model ARMA-GARCH terbaik. Kemudian hasil estimasi parameter tersebut akan digunakan untuk melakukan *forecasting* 1 periode ke depan. Selanjutnya, hasil *forecasting* tersebut akan dimasukkan ke dalam data sampel (3250 + 1) untuk meramalkan 1 periode berikutnya. Proses tersebut akan terus berulang setiap 50 observasi, dimana setiap 50 observasi akan dilakukan estimasi parameter baru. Setiap proses tersebut akan terus berulang, hingga didapatkan 250 observasi baru.

b Menghitung nilai VaR

Dengan penggunaan asumsi distribusi *student-t*, maka nilai VaR dinamis berdasarkan *conditional mean* (μ_t) serta *conditional volatility* (σ_t) yang dimodelkan oleh ARMA-GARCH dapat dinyatakan sebagai berikut:

$$\text{VaR}_t(\alpha) = \mu_t + \sigma_t F^{-1}(\alpha)$$

Dimana,

α : Probabilitas kerugian yang melampaui nilai VaR

μ_t : Mean equation (conditional mean) dari ARMA

σ_t : Volatility equation (conditional volatility) dari GARCH

F^{-1} : Inverse cumulative distribution function

c Uji Coverage

Terdapat dua uji yang dapat dilakukan untuk mengukur akurasi

nilai VaR, yaitu *unconditional coverage* dan *conditional coverage*

(Angelidis, Benos, dan Degiannakis, 2004). Menurut Alexander

(2008), kedua uji tersebut didasarkan pada jumlah kerugian pada

data historis yang lebih rendah dari estimasi nilai VaR (*exceedances*).

Uji *unconditional coverage* merupakan pengujian *likelihood ratio*

yang dikemukakan oleh Kupiec (1995) untuk memvalidasi spesifikasi

model VaR berdasarkan perbedaan jumlah *exceedances* yang

diamati dengan ekspektasi jumlah *exceedances*. Uji ini memiliki

hipotesis statistik sebagai berikut:

H_0 : *Correct Exceedances* (VaR valid)

H_1 : *Incorrect Exceedances* (VaR tidak valid)

Dimana H_0 dapat diterima jika nilai *p-value* lebih besar dari

tingkat signifikansi (α), yang berarti jumlah *actual exceedances*

masih masuk dalam selang kepercayaan tertentu dari ekspektasi

jumlah *exceedances* berdasarkan jumlah observasi *backtesting*.

Uji *conditional coverage* merupakan pengujian *likelihood ratio*

yang dikembangkan oleh Christoffersen (1998) untuk memvalidasi

spesifikasi model VaR berdasarkan jumlah *exceedances* serta

independence of exceedances (independensi pelanggaran VaR). Uji

ini memiliki hipotesis statistik sebagai berikut:

H_0 : *Correct Exceedances dan Independence of Failures* (VaR valid)

H_1 : *Incorrect Exceedances dan Dependence of Failures* (VaR valid)

Dimana H_0 dapat diterima jika nilai *p-value* lebih besar dari tingkat signifikansi (α), yang berarti jumlah *actual exceedances* masih bisa ditoleransi, serta tidak terjadi pelanggaran VaR secara beruntun.

2 Forecasting VaR

Setelah VaR lolos *backtesting*, maka dapat dilakukan *forecasting out-of-sample* pada model ARMA-GARCH dengan periode *holding* satu hari ke depan. Kemudian dapat dihitung nilai VaR berdasarkan proyeksi *mean equation* dan *volatility equation* dari model ARMA-GARCH tersebut.

3.6.4 Expected Shortfall

1 Menghitung nilai ES

Dengan penggunaan asumsi distribusi *student-t* serta ekspektasi *return* (μ) konstan, maka ES dinamis berdasarkan *conditional volatility* (σ_t) yang dimodelkan dengan GARCH dapat dinyatakan sebagai berikut

(Cai, 2020):

$$ES_{t,\alpha} = \frac{\sigma_t}{\alpha} \int_0^\alpha Q_{et}(v) dv$$

Sehingga nilai ES dinamis berdasarkan *conditional mean* (μ_t) serta *conditional volatility* (σ_t) yang dimodelkan dengan ARMA-GARCH dapat dinyatakan sebagai berikut:

$$ES_{t,\alpha} = \mu_t + \sigma_t \frac{\int_0^\alpha Q_{et}(v) dv}{\alpha}$$

Dimana,

α : Probabilitas kerugian yang melampaui nilai VaR

μ_t : Mean equation (conditional mean) dari ARMA

σ_t : Volatility equation (conditional volatility) dari GARCH

Q_{ϵ_t} : Fungsi kuantil (Inverse cumulative distribution function)

2 Backtesting ES

Dalam penelitian ini, digunakan metode *ESTest* dari *package rugarch* dalam R yang dikembangkan oleh Ghalanos (2020b) untuk melakukan *backtesting ES*. Metode ini adalah implementasi dari *expected shortfall test* dari McNeil dan Frey (2000), yang merupakan uji hipotesis satu arah (*one tailed t-test*) dengan hipotesis statistik sebagai berikut:

H_0 : Mean excess shortfall kurang dari nol (ES valid)

H_1 : Mean excess shortfall lebih dari nol (ES tidak valid)

Dimana H_0 dapat diterima jika nilai *p-value* lebih besar dari tingkat signifikansi (α), yang berarti bahwa rata-rata *excess shortfall* (selisih ES dengan *realized return* yang melanggar VaR) kurang dari nol. Dengan kata lain, estimasi nilai ES tidak meremehkan potensi risiko yang sebenarnya.

3 Forecasting ES

Setelah ES lolos *backtesting*, maka nilai ES dengan periode *holding* satu hari ke depan dapat dihitung berdasarkan proyeksi *mean equation* dan *volatility equation* dari model ARMA-GARCH yang telah diestimasi sebelumnya.

BAB IV

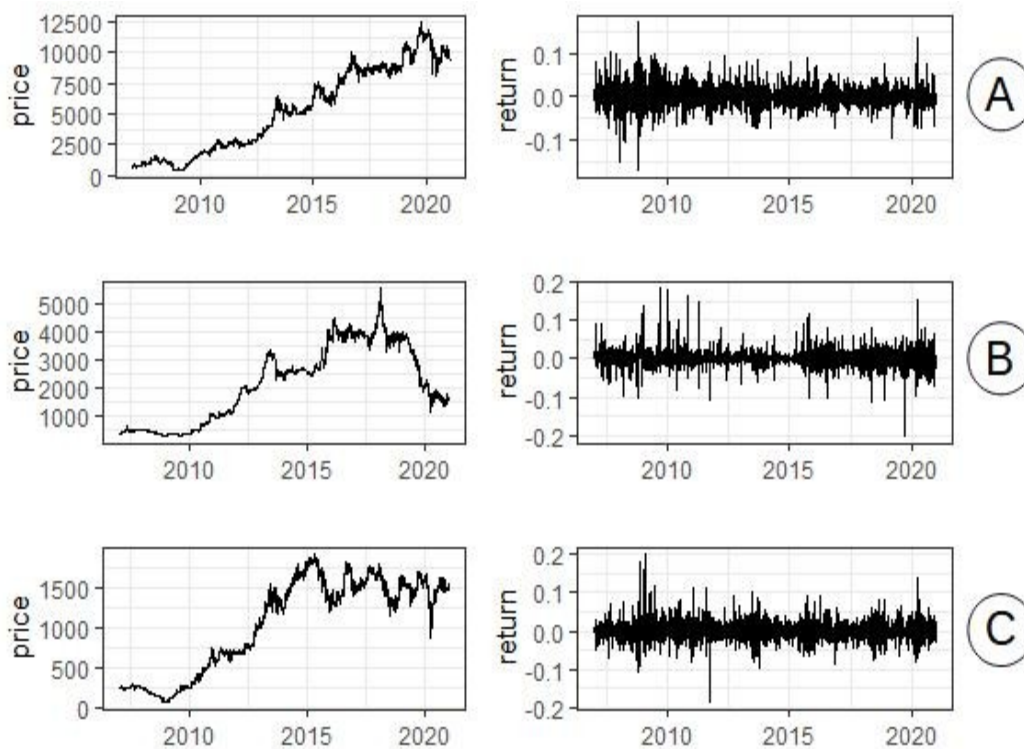
HASIL DAN PEMBAHASAN

4.1 Hasil

4.1.1 Analisis Statistik Deskriptif

Analisis statistik deskriptif digunakan untuk mendeskripsikan karakteristik data *return* saham dari perusahaan sektor konsumen. Setelah mengetahui karakteristik data *return* saham tersebut, tahap selanjutnya adalah analisis statistik inferensia berupa pemodelan volatilitas untuk menghitung nilai VaR dengan pendekatan ARMA-GARCH.

Gambar 4.1: Harga dan *Return* Saham ICBP (A), HMSP (B), dan KLBF (C)




Sumber: Hasil Pengolahan Data, 2021.



Gambar 4.1 dan 4.2 menunjukkan grafik pergerakan harga saham beserta *return* saham (yang dihitung sebagai *continuously compounded return*) dengan kode ICBP, HMSP, KLBK, UNVR, WOOD, dan HRTA. Berdasarkan grafik tersebut, terlihat adanya pola yang menunjukkan keberadaan fenomena *volatility clustering*. Dimana terdapat pengelompokan volatilitas pada periode tertentu ketika harga saham berfluktuasi secara drastis, serta pengelompokan volatilitas saat perubahan harga saham cenderung stabil.

Gambar 4.2: Harga dan *Return* Saham UNVR (D), WOOD (E), dan HRTA (F)



Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.1 menunjukkan ringkasan data dari keenam *return* saham tersebut, dimana tabel ini berisi informasi mengenai ukuran pemusatan data (*central tendency*), ukuran penyebaran data (*variability*), serta hasil uji normalitas untuk menguji kenormalan data *return* saham.

Tabel 4.1: Statistik Deskriptif *Return Saham*

Ukuran Statistik	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
<i>Mean</i>	0.0008	0.0004	0.0005	0.0005	0.0008	-0.0002
Median	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
Minimum	-0.1691	-0.2011	-0.1853	-0.1289	-0.1649	-0.1552
Maksimum	0.1691	0.1813	0.1981	0.1772	0.1887	0.2196
Standar Deviasi	0.0229	0.0201	0.0232	0.0203	0.0298	0.0282
<i>Skewness</i>	0.1563	0.7891	0.6889	0.3839	1.1496	1.2960
Kurtosis	4.9379	15.2250	8.4724	6.1963	6.9698	12.6904
<i>Jarque-Bera statistic</i>	3535	33686.9	10638.6	5629.7	2021.0	6290.3
<i>Jarque-Bera p-value</i>	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
Observasi	3459	3446	3460	3460	895	895

Sumber: Hasil Pengolahan Data, 2021.

Ukuran pemusatan data terdiri dari beberapa ukuran yang dapat digunakan untuk menunjukkan pusat data. Pada Tabel 4.1, ukuran pemusatan data dari keenam *return* saham perusahaan sektor konsumen ditunjukkan dengan nilai *mean* dan median. Dimana keenam *return* saham tersebut nilainya relatif sama, dengan nilai *mean* (rata-rata hitung) yang mendekati nol dan median (nilai tengah) yang bernilai nol. Lima dari enam *return* saham tersebut memiliki *mean* bernilai positif, hanya *return* saham HRTA yang memiliki *mean* bernilai negatif. Artinya secara keseluruhan, harga saham harian HRTA cenderung menurun dibanding posisi sebelumnya. Di sisi lain, saham ICBP dan WOOD menjadi saham dengan nilai *mean* yang paling besar dibanding keempat saham lain, yaitu 0.08%.

Selanjutnya pada Tabel 4.1 juga terdapat informasi mengenai ukuran penyebaran data, yang digunakan untuk menunjukkan sebaran data terhadap nilai pusatnya. Ukuran penyebaran data *return* saham dari keenam perusahaan terdiri dari nilai minimum, nilai maksimum, standar deviasi, *skewness*, dan kurtosis. *Return* saham KLBF memiliki nilai minimum terendah serta memiliki

jangkauan (*range*) persebaran data yang paling lebar, sedangkan *return* saham HRTA memiliki nilai maksimum yang paling tinggi dibandingkan dengan *return* saham lain. Artinya dalam waktu satu hari, saham HRTA pernah mencatatkan kenaikan harga yang lebih tinggi dari kenaikan harga maksimum lima saham lain. Kenaikan tersebut terjadi pada 7 Desember 2020, dimana saham HRTA menjadi salah satu saham yang terangkat oleh sentimen positif dari kedatangan vaksin Covid-19 buatan Sinovac di Indonesia (Putra, 2020).

Jika dilihat berdasarkan nilai standar deviasi (*historical volatility*) dari keenam data *return saham* pada Tabel 4.1, terlihat bahwa *return* saham WOOD dan HRTA memiliki volatilitas yang relatif lebih tinggi dibandingkan *return* saham lain, yaitu 2.98% dan 2.82%. Sedangkan *return* saham HMSP dan UNVR memiliki volatilitas yang relatif lebih kecil, yaitu 2.01% dan 2.03%. Hal tersebut menunjukkan bahwa potensi pergerakan harga saham HMSP dan UNVR relatif lebih stabil, sedangkan potensi pergerakan harga saham WOOD dan HRTA cenderung lebih fluktuatif. Namun perlu diketahui bahwa jumlah observasi *return* saham WOOD dan HRTA jauh lebih pendek dari *return* saham lain, yaitu 895 hari.

Berdasarkan Tabel 4.1, *skewness* dari keenam data *return* saham tersebut bernilai positif, artinya sebaran data cenderung menceng ke kanan (*long right tail*). Di sisi lain, kurtosis dari keenam data *return* saham tersebut nilainya lebih dari 3, lebih besar dari kurtosis pada distribusi normal dan disebut dengan distribusi *leptokurtic* (*heavy tail*). Hal tersebut membuktikan keberadaan fenomena *leptokurtosis* yang sering ditemui pada data finansial.

Nilai *skewness*, dan kurtosis merupakan bagian terpenting dalam analisis statistik deskriptif ini, dimana kedua nilai tersebut akan mempengaruhi model volatilitas pada tahap selanjutnya. Berdasarkan kedua nilai tersebut, terdapat

indikasi bahwa keenam data *return* saham tidak terdistribusi secara normal, karena memiliki nilai *skewness* lebih dari nol dan nilai kurtosis yang lebih dari 3.

Dugaan tersebut dapat dibuktikan dengan uji normalitas Jarque-Bera, yang menunjukkan nilai p-value kurang dari tingkat signifikansi 5%. Sehingga hipotesis nol (H_0) yang menyatakan bahwa data terdistribusi normal dapat ditolak. Implikasi dari hasil tersebut adalah diperlukannya distribusi alternatif seperti *student-t* untuk mengestimasi parameter pada model GARCH.

4.1.2 Proses ARMA

4.1.2.1 Uji stasioneritas

Berdasarkan Gambar 4.1 dan 4.2, dapat dilihat bahwa *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA nilainya bergerak di sekitar nol. Hal tersebut mengindikasikan bahwa data *return* saham tersebut telah stasioner terhadap *mean* (rata-rata hitung). Untuk membuktikan hal tersebut, maka dilakukan pengujian stasioneritas menggunakan uji *Augmented Dickey-Fuller* (ADF) yang dikemukakan oleh Dickey dan Fuller (1981).

Uji ADF melihat kestasioneran data *time series* berdasarkan keberadaan *unit root*, istilah untuk tren stokastik pada data *time series*. Keberadaan *unit root* pada data *time series* akan melanggar asumsi dari model ARMA(p,q). Sehingga data *time series* yang tidak stasioner pada tingkat level perlu dilakukan *differencing*, dan menjadi proses integrasi (d) dari model ARIMA(p,d,q).

Tabel 4.2: Hasil Uji Stasioneritas

	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
<i>t</i> -statistic	-12.5764	-14.6233	-15.6250	-14.9776	-8.7639	-10.6276
Prob.	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000

Sumber: Hasil Pengolahan Data, 2021.



Berdasarkan Tabel 4.2, hasil uji ADF menyatakan bahwa data *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA tidak menunjukkan keberadaan *unit root*. Hal tersebut dapat dibuktikan dari nilai *Prob. (p-value)* yang lebih kecil dari tingkat signifikansi 5%. Oleh karena itu hipotesis alternatif (H_1) yang menyatakan bahwa tidak terdapat *unit root* pada data *return saham* dapat diterima.

Berdasarkan uji stasioneritas tersebut, dapat dikatakan bahwa data keenam *return* saham tersebut telah stasioner pada tingkat level. Oleh karena itu tidak perlu dilakukan *differencing* pada data *return* saham tersebut, sehingga ordo dari proses integrasi $I(0)$. Artinya model awal (tentatif) akan memiliki spesifikasi ARIMA($p,0,q$) atau setara dengan ARMA(p,q).

4.1.2.2 Identifikasi Autokorelasi


Proses identifikasi dilakukan untuk mendapatkan gagasan awal dari model ARMA yang layak untuk diselidiki lebih lanjut dan kemudian dilakukan estimasi parameter (Box dkk., 2016). Proses ini dapat dilakukan dengan membandingkan pola autokorelasi dan autokorelasi parsial pada ACF dan PACF empiris dari data sampel, dengan pola ACF dan PACF teoritis yang terkait dengan model ARMA. Hasil dari perbandingan tersebut dapat menjadi acuan untuk menentukan kombinasi ordo dari proses AR(p) dan MA(q) yang digunakan untuk membuat model awal (tentatif).

Berdasarkan Gambar 4.3, dapat dilihat bahwa sampel ACF dan PACF dari *return* saham dengan kode ICBP memiliki nilai korelasi yang signifikan pada *lag* 3 (keluar dari garis biru selang kepercayaan). Sampel ACF memiliki pola *cuts off* setelah *lag* 3, dimana nilai korelasi pada *lag* 4 menjadi nol (tidak signifikan) secara tiba-tiba, mengindikasikan proses *moving average*. Di sisi lain, sampel PACF juga memiliki pola *cuts off* setelah *lag* 3, yang mengindikasikan proses

autoregresif. Selain itu, tidak dapat interval tertentu pada *lag* yang signifikan, artinya model tentatif yang akan terbentuk tidak memiliki pola musiman.

Pola dari sampel ACF dan PACF tersebut kurang membantu dalam pembentukan model tentatif, karena tidak terdapat pola yang jelas seperti pola ACF dan PACF teoritis. Oleh karena itu, model tentatif yang perlu diselidiki lebih lanjut dapat mengikuti proses autoregresif (AR), *moving average* (MA), maupun gabungan keduanya (ARMA). Sehingga kombinasi $AR(p)$ dan $MA(q)$ yang memungkinkan adalah $p=3$ dan $q=0$, $p=0$ dan $q=3$, serta $p=3$ dan $q=3$. Namun karena *lag* awal pada sampel ACF dan PACF baru signifikan di *lag* 3, maka akan dibentuk model tentatif yang mengabaikan *lag* sebelumnya (*lag* 1 dan *lag* 2). Sehingga model tentatif yang terbentuk adalah $ARMA([3],0)$, $ARMA(0,[3])$, dan $ARMA([3],[3])$.

Gambar 4.3: Plot ACF dan PACF ICBP




Sumber: Hasil Pengolahan Data, 2021.

Selanjutnya pada Gambar 4.4, dapat dilihat bahwa sampel ACF dan PACF dari *return* saham dengan kode HMSP pada *lag* awal signifikan di *lag* 2 dan 4.

Baik sampel ACF maupun PACF menunjukkan pola *cuts off* setelah *lag* tersebut, namun tidak ada indikasi pola musiman. Sama seperti model tentatif ICBP, model tentatif HMSP juga dapat terdiri dari kombinasi ordo $AR(p)$ dan $MA(q)$

yang mengabaikan *lag* sebelumnya. Model tentatif tersebut adalah ARMA([2],0), ARMA(0,[2]), ARMA([2],[2]), ARMA([4],0), ARMA(0,[4]), serta ARMA([4],[4]).


Gambar 4.4: Plot ACF dan PACF HMSP



Sumber: Hasil Pengolahan Data, 2021.

Berdasarkan Gambar 4.5, dapat dilihat bahwa sampel ACF dan PACF dari *return* saham dengan kode KLBF pada *lag* awal memiliki nilai korelasi yang signifikan di *lag* 4 dan 6. Terlihat adanya pola *cuts off* setelah kedua *lag* tersebut, serta tidak terdapat indikasi pola musiman. Sama seperti model tentatif HMSP, model tentatif KLBF juga dapat terdiri dari kombinasi ordo AR(p) dan MA(q) yang mengabaikan *lag* sebelumnya. Sehingga terbentuk model tentatif ARMA([4],0), ARMA(0,[4]), ARMA([4],[4]), ARMA([6],0), serta ARMA(0,[6]).


Gambar 4.5: Plot ACF dan PACF KLBF



Sumber: Hasil Pengolahan Data, 2021.

Kemudian jika dilihat pada Gambar 4.6, sampel ACF dan PACF dari *return* saham dengan kode UNVR memiliki pola *tails off*, dimana nilai korelasinya menjadi nol (tidak signifikan) secara perlahan. Pada *lag* awal sampel ACF nilai korelasi yang signifikan hingga *lag* 3, sedangkan pada sampel PACF signifikan hingga *lag* 5. Pola tersebut sesuai dengan pola ACF dan PACF teoritis dari model ARMA, sehingga kombinasi AR(p) dan MA(q) yang memungkinkan adalah $p=1$ dan $q=1$. Namun sebagai pembandingan, akan digunakan kombinasi $p=5$ dan $q=0$ (berdasarkan PACF), serta $p=0$ dan $q=3$ (berdasarkan ACF). Oleh karena itu model tentatif yang terbentuk adalah ARMA(1,1), ARMA(5,0), dan ARMA(0,3).


Gambar 4.6: Plot ACF dan PACF UNVR



Sumber: Hasil Pengolahan Data, 2021.

Pada Gambar 4.7, dapat dilihat bahwa sampel ACF dan PACF dari *return* saham dengan kode WOOD pada *lag* awal memiliki nilai korelasi yang signifikan di *lag* 6. Terlihat adanya pola *cuts off* setelah *lag* tersebut, serta tidak terdapat indikasi adanya pola musiman. Karena *lag* awal pada sampel ACF dan PACF baru signifikan di *lag* 6, maka model tentatif WOOD juga dapat mengabaikan *lag* sebelumnya. Sehingga terbentuk model tentatif ARMA([6],0), ARMA(0,[6]), dan ARMA([6],[6]).


Gambar 4.7: Plot ACF dan PACF WOOD



Sumber: Hasil Pengolahan Data, 2021.

Kemudian pada Gambar 4.8, dapat dilihat bahwa sampel ACF dan PACF dari *return* saham dengan kode HRTA pada *lag* awal memiliki nilai korelasi yang signifikan di *lag* 5. Terlihat pola *cuts off* setelah *lag* 5 baik pada sampel ACF maupun PACF, dan tidak terdapat indikasi adanya pola musiman. Oleh karena itu model tentatif WOOD juga dapat mengabaikan *lag* sebelumnya. Sehingga terbentuk model tentatif ARMA([5],0), ARMA(0,[5]), dan ARMA([5],[5]).

Gambar 4.8: Plot ACF dan PACF HRTA



Sumber: Hasil Pengolahan Data, 2021.

4.1.2.3 Estimasi Parameter

Setelah mendapatkan model tentatif dari data *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA, tahap selanjutnya adalah melakukan estimasi parameter dari model tentatif yang telah terbentuk. Metode estimasi yang digunakan dalam penelitian ini adalah MLE (*Maximum Likelihood Estimation*), dimana metode tersebut berusaha menduga nilai parameter yang memaksimalkan *log likelihood*.

Tabel 4.3 menunjukkan hasil estimasi parameter dari model tentatif *return* saham dengan kode ICBP. Berdasarkan tabel tersebut, dapat dilihat bahwa parameter AR(3) dari model tentatif ARMA([3],0) dan MA(3) dari model tentatif ARMA(0,[3]) memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob. (p-value)* yang lebih kecil dari tingkat signifikansi 5%. Di sisi lain, parameter dari model tentatif ARMA([3],[3]) tidak memiliki pengaruh yang signifikan, karena nilai *Prob. (p-value)* lebih besar dari tingkat signifikansi 5%.

Tabel 4.3: Estimasi Parameter Model ARMA ICBP

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA([3],0)	C	0.0008	0.0004	2.0400	0.0414
	AR(3)	-0.0464	0.0170	-2.7314	0.0063
ARMA(0,[3])	C	0.0008	0.0004	2.0501	0.0404
	MA(3)	-0.0490	0.0174	-2.8135	0.0049
ARMA([3],[3])	C	0.0008	0.0004	2.0731	0.0382
	AR(3)	0.1955	0.1769	1.1052	0.2691
	MA(3)	-0.2451	0.1744	-1.4051	0.1600

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.4 menunjukkan hasil estimasi parameter dari model tentatif *return* saham dengan kode HMSP. Berdasarkan tabel tersebut, dapat dilihat bahwa parameter AR(2) dari model tentatif ARMA([2],0), MA(2) dari model tentatif ARMA(0,[2]), AR(4) dari model tentatif ARMA([4],0), serta MA(4) dari model

tentatif ARMA(0,[4]) memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob.* (*p-value*) yang lebih kecil dari tingkat signifikansi 5%. Di sisi lain, parameter dari model tentatif ARMA([2],[2]) dan ARMA([4],[4]) tidak memiliki pengaruh yang signifikan, karena nilai *Prob.* (*p-value*) lebih besar dari tingkat signifikansi 5%.

Tabel 4.4: **Estimasi Parameter Model ARMA H MSP**

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA([2],0)	C	0.0004	0.0003	1.2640	0.2062
	AR(2)	-0.0532	0.0170	-3.1265	0.0018
ARMA(0,[2])	C	0.0004	0.0003	1.2737	0.2028
	MA(2)	-0.0576	0.0176	-3.2699	0.0011
ARMA([2],[2])	C	0.0004	0.0003	1.3043	0.1921
	AR(2)	0.2355	0.1660	1.4189	0.1559
	MA(2)	-0.2942	0.1630	-1.8054	0.0710
ARMA([4],0)	C	0.0004	0.0003	1.2468	0.2125
	AR(4)	-0.0395	0.0170	-2.3203	0.0203
ARMA(0,[4])	C	0.0004	0.0003	1.2451	0.2131
	MA(4)	-0.0367	0.0164	-2.2405	0.0251
ARMA([4],[4])	C	0.0004	0.0003	1.2414	0.2145
	AR(4)	-0.3911	0.2176	-1.7977	0.0722
	MA(4)	0.3484	0.2212	1.5753	0.1152

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.5 menunjukkan hasil estimasi parameter dari model tentatif *return* saham dengan kode KLBF. Berdasarkan tabel tersebut, dapat dilihat bahwa parameter AR(4) dari model tentatif ARMA([4],0), MA(4) dari model tentatif ARMA(0,[4]), AR(6) dari model tentatif ARMA([6],0), serta MA(6) dari model tentatif ARMA(0,[6]) memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob.* (*p-value*) yang lebih kecil dari tingkat signifikansi 5%. Di sisi lain, parameter dari model tentatif ARMA([4],[4]) tidak memiliki pengaruh yang signifikan, karena nilai *Prob.* (*p-value*) lebih besar dari tingkat signifikansi 5%.

Tabel 4.5: Estimasi Parameter Model ARMA KLBF

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA([4],0)	C	0.0005	0.0004	1.3640	0.1726
	AR(4)	-0.0425	0.0170	-2.5055	0.0122
ARMA(0,[4])	C	0.0005	0.0004	1.3707	0.1705
	MA(4)	-0.0454	0.0175	-2.5959	0.0094
ARMA([4],[4])	C	0.0005	0.0004	1.4003	0.1614
	AR(4)	0.2684	0.2091	1.2839	0.1992
	MA(4)	-0.3153	0.2058	-1.5324	0.1254
ARMA([6],0)	C	0.0005	0.0004	1.3733	0.1697
	AR(6)	-0.0493	0.0170	-2.9040	0.0037
ARMA(0,[6])	C	0.0005	0.0004	1.3742	0.1694
	MA(6)	-0.0476	0.0166	-2.8638	0.0042

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.6 menunjukkan hasil estimasi parameter dari model tentatif *return* saham dengan kode UNVR. Berdasarkan tabel tersebut, dapat dilihat bahwa seluruh parameter AR dan MA memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob.* (*p-value*) yang lebih kecil dari tingkat signifikansi 5%.

Tabel 4.6: Estimasi Parameter Model ARMA UNVR

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA(1,1)	C	0.0005	0.0002	2.1093	0.0349
	AR(1)	0.6899	0.0560	12.3174	0.0000
	MA(1)	-0.7828	0.0480	-16.2987	0.0000
ARMA(5,0)	C	0.0005	0.0003	1.8671	0.0619
	AR(1)	-0.0887	0.0170	-5.2184	0.0000
	AR(2)	-0.0716	0.0170	-4.2028	0.0000
	AR(3)	-0.0495	0.0171	-2.8997	0.0037
	AR(4)	-0.0424	0.0170	-2.4908	0.0127
	AR(5)	-0.0398	0.0170	-2.3436	0.0191
ARMA(0,3)	C	0.0005	0.0003	1.8166	0.0693
	MA(1)	-0.0903	0.0170	-5.3082	0.0000
	MA(2)	-0.0694	0.0177	-3.9158	0.0001
	MA(3)	-0.0460	0.0173	-2.6638	0.0077

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.7 menunjukkan hasil estimasi parameter dari model tentatif *return* saham dengan kode WOOD. Berdasarkan tabel tersebut, dapat dilihat bahwa parameter AR(6) dari model tentatif ARMA([6],0), serta MA(6) dari model tentatif ARMA(0,[6]) memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob.* (*p-value*) yang lebih kecil dari tingkat signifikansi 5%.

Tabel 4.7: Estimasi Parameter Model ARMA WOOD

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA([6],0)	C	0.0008	0.0011	0.7756	0.4380
	AR(6)	0.0855	0.0332	2.5716	0.0101
ARMA(0,[6])	C	0.0008	0.0011	0.7790	0.4360
	MA(6)	0.0880	0.0336	2.6146	0.0089

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.8 menunjukkan hasil estimasi parameter dari model tentatif *return* saham dengan kode HRTA. Berdasarkan tabel tersebut, dapat dilihat bahwa parameter AR(5) dari model tentatif ARMA([5],0), MA(5) dari model tentatif ARMA(0,[5]), serta parameter AR(5) dan MA(5) dari model tentatif ARMA([5],[5]) memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob.* (*p-value*) yang lebih kecil dari tingkat signifikansi 5%.

Tabel 4.8: Estimasi Parameter Model ARMA HRTA

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA([5],0)	C	-0.0003	0.0009	-0.3424	0.7321
	AR(5)	-0.0805	0.0334	-2.4118	0.0159
ARMA(0,[5])	C	-0.0003	0.0009	-0.3483	0.7276
	MA(5)	-0.0920	0.0357	-2.5781	0.0099
ARMA([5],[5])	C	-0.0003	0.0006	-0.5459	0.5851
	AR(5)	0.8006	0.0689	11.6270	0.0000
	MA(5)	-0.8819	0.0543	-16.2479	0.0000

Sumber: Hasil Pengolahan Data, 2021.



4.1.2.4 Pemeriksaan Diagnostik

Setelah melakukan estimasi parameter model tentatif, langkah selanjutnya adalah melakukan pemeriksaan diagnostik. Pemeriksaan diagnostik tersebut terdiri dari uji *white noise* dan perbandingan kriteria informasi. Uji *white noise* digunakan untuk memeriksa apakah model tentatif telah sesuai dengan perilaku data. Uji *white noise* dilakukan untuk memenuhi asumsi dari model ARMA yang memadai, yaitu memiliki residual dengan sifat *white noise* (bersifat independen dan tidak memiliki autokorelasi).

Tabel 4.9: Pemeriksaan Diagnostik Model ARMA

Return	Model	Uji White Noise		log likelihood	AIC	BIC	Keterangan
		Chi-squared	Prob.				
ICBP	ARMA([3],0)	8.6621	0.2778	8155.92	-16305.84	-16287.39	
	ARMA(0,[3])	8.2169	0.3139	8156.13	-16306.27	-16287.82	Model Terbaik
	ARMA([3],[3])	6.8825	0.1422	8156.63	-16305.26	-16280.66	
HMSP	ARMA([2],0)	18.9038	0.0154	8584.00	-17162	-17143.57	Tereliminasi
	ARMA(0,[2])	17.9074	0.0219	8584.42	-17162.84	-17144.41	Tereliminasi
	ARMA([2],[2])	15.6832	0.0156	8585.39	-17162.78	-17138.2	Tereliminasi
	ARMA([4],0)	22.7678	0.0009	8581.81	-17157.62	-17139.19	Tereliminasi
	ARMA(0,[4])	23.1298	0.0008	8581.62	-17157.25	-17138.81	Tereliminasi
	ARMA([4],[4])	20.2325	0.0000	8582.83	-17157.67	-17133.09	Tereliminasi
KLBF	ARMA([4],0)	18.7098	0.0047	8117.24	-16228.49	-16210.04	Tereliminasi
	ARMA(0,[4])	18.1529	0.0059	8117.46	-16228.92	-16210.48	Tereliminasi
	ARMA([4],[4])	15.9466	0.0003	8118.20	-16228.4	-16203.81	Tereliminasi
	ARMA([6],0)	16.8850	0.0020	8118.32	-16230.64	-16212.19	Tereliminasi
	ARMA(0,[6])	16.9623	0.0020	8118.18	-16230.36	-16211.91	Tereliminasi
UNVR	ARMA(1,1)	1.8392	0.9856	8614.15	-17220.3	-17195.7	Model Terbaik
	ARMA(5,0)	6.3969	0.2695	8612.07	-17210.14	-17167.09	
	ARMA(0,3)	12.0520	0.0989	8609.31	-17208.63	-17177.88	
WOOD	ARMA([6],0)	5.7460	0.2189	1882.09	-3758.186	-3743.792	
	ARMA(0,[6])	5.6777	0.2245	1882.19	-3758.377	-3743.983	Model Terbaik
HRTA	ARMA([5],0)	8.0877	0.1515	1926.81	-3847.625	-3833.231	
	ARMA(0,[5])	7.3464	0.1961	1927.22	-3848.444	-3834.05	Model Terbaik
	ARMA([5],[5])	4.4817	0.0000	1931.61	-3855.223	-3836.032	Tereliminasi

Sumber: Hasil Pengolahan Data, 2021.



Berdasarkan Tabel 4.9, dapat dilihat bahwa seluruh model tentatif dari *return* saham dengan kode HMSP dan KLBF, serta model tentatif ARMA([5],[5]) dari *return* saham HRTA memiliki residual yang tidak bersifat *white noise*. Hal tersebut dibuktikan dari nilai *Prob. (p-value)* yang lebih kecil dari tingkat signifikansi 5%. Sehingga terdapat bukti yang cukup untuk menolak H_0 (residual bersifat *white noise*), serta menerima H_1 (residual tidak bersifat *white noise*).

Berdasarkan hasil pengujian tersebut, model tentatif yang telah diuraikan diatas dapat dikatakan tidak layak. Karena memiliki *residual* yang tidak sesuai dengan perilaku data, sehingga dapat dieliminasi dari pemilihan model terbaik.

Di sisi lain, pada Tabel 4.9 telah didapatkan beberapa model tentatif dari *return* saham dengan kode ICBP, UNVR, WOOD, dan HRTA yang tidak tereliminasi. Hasil uji *white noise* pada model tentatif tersebut menunjukkan nilai *Prob. (p-value)* yang lebih besar dari tingkat signifikansi 5%. Sehingga terdapat bukti yang kurang kuat untuk menolak H_0 (residual bersifat *white noise*). Karena masih terdapat beberapa model tentatif yang layak, maka perlu ditentukan model terbaik diantara beberapa model tentatif tersebut.

Jika mengacu pada metode estimasi yang digunakan (MLE), seharusnya model tentatif terbaik adalah model yang memaksimalkan nilai *log likelihood*.

Namun pemilihan model terbaik tidak bisa dilakukan dengan hanya melihat nilai *log likelihood* saja. Nilai *log likelihood* cenderung meningkat seiring dengan jumlah parameter yang dimasukkan kedalam model, sehingga tingginya nilai *log likelihood* tidak serta-merta membuat model tersebut menjadi model terbaik.

Jumlah parameter yang terlalu banyak akan menghasilkan model yang terlalu kompleks, yang mengarah kepada suatu fenomena bernama *overfitting*.

Overfitting adalah fenomena ketika model terlalu sering “belajar” dari data sampel, sehingga performa *forecasting out-of-sample* cenderung lebih rendah dari performa *forecasting in-sample* (Grünwald, 2007). Oleh karena itu untuk

menentukan model terbaik, perlu diperhatikan *trade off* antara parameter yang memaksimalkan *log likelihood* dengan kompleksitas model. Hal tersebut bisa dilakukan dengan membandingkan nilai kriteria informasi, yaitu AIC dan BIC.

Pada Tabel 4.9 dapat dilihat bahwa model ICBP ARMA(0,[3]), UNVR ARMA(1,1), WOOD ARMA(0,[6]), serta HRTA ARMA(0,[5]) terpilih menjadi model terbaik. Model ICBP ARMA(0,[3]) terpilih menjadi model terbaik karena memiliki nilai AIC dan BIC yang relatif lebih kecil (negatif) dari model tentatif ICBP lainnya.

Selanjutnya, model UNVR ARMA(1,1) terpilih menjadi model terbaik karena memiliki nilai *log likelihood* yang relatif lebih besar, serta nilai AIC dan BIC yang juga relatif lebih rendah dari model tentatif UNVR lain. Sama seperti model UNVR ARMA(1,1), model WOOD ARMA(0,[6]) dan HRTA ARMA(0,[5]) juga terpilih menjadi model terbaik karena memiliki nilai *log likelihood* yang relatif lebih besar, serta nilai AIC dan BIC yang relatif lebih kecil.

Di sisi lain, seluruh model tentatif dari *return* saham dengan kode HMSP dan KLBF telah tereliminasi. Oleh karena itu perlu dibentuk model tentatif baru, dimana model tentatif tersebut tidak lagi mengabaikan *lag* sebelumnya. Sehingga untuk HMSP model tentatif yang terbentuk adalah ARMA(2,0), ARMA(0,2), ARMA(2,2), ARMA(4,0), ARMA(0,4), serta ARMA(4,4). Sedangkan untuk KLBF, model tentatif yang terbentuk adalah ARMA(4,0), ARMA(0,4), ARMA(4,4), ARMA(6,0), serta ARMA(0,6).

Tabel 4.10 merupakan hasil pemeriksaan diagnostik dari model tentatif baru *return* saham dengan kode HMSP serta KLBF. Berdasarkan hasil tersebut, terdapat beberapa model tentatif yang tidak tereliminasi. Artinya, hasil uji *white noise* pada model tentatif tersebut menunjukkan nilai *Prob. (p-value)* yang lebih besar dari tingkat signifikansi 5%. Sehingga hipotesis nol (residual bersifat *white noise*) dapat diterima.

Karena masih terdapat beberapa model tentatif yang tidak tereliminasi, maka perlu ditentukan model terbaik diantara beberapa model tentatif tersebut. Dimana model terbaik akan dipilih berdasarkan nilai *log likelihood* terbesar serta nilai kriteria informasi (AIC dan BIC) terkecil. Jika dilihat pada Tabel 4.9, model HMSP ARMA(4,4) dan KLBF ARMA(4,4) terpilih menjadi model terbaik karena memiliki nilai *log likelihood* yang relatif lebih besar, serta nilai AIC relatif lebih kecil dari model tentatif lain.

Tabel 4.10: Pemeriksaan Diagnostik Model ARMA HMSP dan KLBF

Return	Model	Uji White Noise		<i>log likelihood</i>	AIC	BIC	Keterangan
		<i>Chi-squared</i>	<i>Prob.</i>				
HMSP	ARMA(2,0)	18.5901	0.0172	8584.08	-17160.16	-17135.58	Tereliminasi
	ARMA(0,2)	17.7457	0.0232	8584.46	-17160.92	-17136.34	Tereliminasi
	ARMA(2,2)	15.4161	0.0173	8585.47	-17158.93	-17122.06	Tereliminasi
	ARMA(4,0)	10.4080	0.1085	8587.80	-17163.59	-17126.72	
	ARMA(0,4)	11.8073	0.0664	8587.09	-17162.17	-17125.3	
	ARMA(4,4)	3.1298	0.2091	8592.04	-17164.08	-17102.62	Model Terbaik
KLBF	ARMA(4,0)	16.8609	0.0098	8118.28	-16224.56	-16187.66	Tereliminasi
	ARMA(0,4)	16.9429	0.0095	8118.27	-16224.54	-16187.64	Tereliminasi
	ARMA(4,4)	5.2270	0.0733	8129.11	-16238.21	-16176.72	Model Terbaik
	ARMA(6,0)	8.3558	0.0794	8122.62	-16229.25	-16180.05	
	ARMA(0,6)	9.1641	0.0571	8122.01	-16228.02	-16178.83	

Sumber: Hasil Pengolahan Data, 2021.

Pada Tabel 4.11 dan 4.12, ditampilkan hasil estimasi parameter dari model terbaik *return* saham dengan kode HMSP dan KLBF yang telah didapatkan dari pemeriksaan diagnostik. Pada kedua tabel tersebut, dapat dilihat bahwa beberapa parameter AR dan MA memiliki pengaruh yang tidak signifikan.

Dimana parameter tersebut memiliki nilai *Prob.* (*p-value*) yang lebih besar dari tingkat signifikansi 5%. Namun karena model tersebut memiliki *residual* yang

sesuai dengan perilaku data serta terpilih menjadi model terbaik, maka model tersebut dapat dikatakan layak.

Tabel 4.11: **Estimasi Parameter Model ARMA HMSP**

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA(4,4)	C	0.0003	0.0003	1.0598	0.2892
	AR(1)	-0.4919	0.0846	-5.8159	0.0000
	AR(2)	0.0817	0.2030	0.4024	0.6874
	AR(3)	-0.1424	0.1023	-1.3917	0.1640
	AR(4)	-0.6064	0.1314	-4.6129	0.0000
	MA(1)	0.5026	0.1104	4.5511	0.0000
	MA(2)	-0.1325	0.2165	-0.6119	0.5406
	MA(3)	0.0943	0.0355	2.6528	0.0080
	MA(4)	0.5669	0.1358	4.1749	0.0000

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.12: **Estimasi Parameter Model ARMA KLBF**

Model	Parameter	Coef.	Std. Error	z-statistic	Prob.
ARMA(4,4)	C	0.0005	0.0004	1.4834	0.1380
	AR(1)	-0.4413	0.2417	-1.8263	0.0678
	AR(2)	0.8788	0.2358	3.7276	0.0002
	AR(3)	0.4419	0.1825	2.4220	0.0154
	AR(4)	-0.3746	0.1989	-1.8835	0.0596
	MA(1)	0.4512	0.2470	1.8269	0.0677
	MA(2)	-0.8679	0.2365	-3.6694	0.0002
	MA(3)	-0.4592	0.1891	-2.4281	0.0152
	MA(4)	0.3172	0.2023	1.5681	0.1168

Sumber: Hasil Pengolahan Data, 2021.

Berdasarkan hasil pemeriksaan diagnostik yang telah diuraikan sebelumnya, model ICBP ARMA(0,[3]), HMSP ARMA(4,4), KLBF ARMA(4,4), UNVR ARMA(1,1), WOOD ARMA(0,[6]), serta HRTA ARMA(0,[5]) akan dikombinasikan dengan model GARCH untuk memodelkan volatilitas *return* saham.

4.1.3 Proses GARCH

4.1.3.1 Uji Efek ARCH

Setelah mendapatkan model ARMA terbaik untuk setiap *return* saham, tahap selanjutnya adalah memastikan keberadaan fenomena *volatility clustering* pada data *return* saham tersebut. Untuk membuktikan fenomena ini, dapat dilakukan pengujian tertentu untuk melihat apakah residual kuadrat dari model ARMA bersifat *heteroscedastic* (memiliki efek ARCH). Pada penelitian ini, digunakan uji *Lagrange Multiplier* (LM) yang dikemukakan oleh Engle (1982) untuk menguji keberadaan efek ARCH (heteroskedastisitas) pada residual dari model ARMA.

Tabel 4.13: Hasil Uji Efek ARCH

Lag	ICBP	HMSF	KLBF	UNVR	WOOD	HRTA
4	3193 (0.0000)	8460 (0.0000)	3412 (0.0000)	3029 (0.0000)	969 (0.0000)	2299 (0.0000)
8	1213 (0.0000)	4024 (0.0000)	1494 (0.0000)	1463 (0.0000)	323 (0.0000)	1083 (0.0000)
12	709 (0.0000)	2639 (0.0000)	968 (0.0000)	970 (0.0000)	195 (0.0000)	706 (0.0000)
16	524 (0.0000)	1962 (0.0000)	696 (0.0000)	707 (0.0000)	142 (0.0000)	444 (0.0000)
20	419 (0.0000)	1560 (0.0000)	514 (0.0000)	561 (0.0000)	107 (0.0000)	347 (0.0000)
24	347 (0.0000)	1279 (0.0000)	425 (0.0000)	465 (0.0000)	82 (0.0000)	258 (0.0000)

Sumber: Hasil Pengolahan Data, 2021.

Keterangan: Angka dalam kurung menunjukkan nilai *p-value*.

Berdasarkan Tabel 4.13, dapat disimpulkan bahwa pada data *return* saham dengan kode ICBP, HMSF, KLBF, UNVR, WOOD, dan HRTA terdapat fenomena *volatility clustering*. Hal tersebut berdasar dari hasil uji LM pada residual dari model ARMA, yang menunjukkan nilai *p-value* lebih kecil dari tingkat signifikansi 5%. Artinya terdapat bukti kuat untuk menerima hipotesis alternatif (H_1), yaitu

terdapat efek ARCH pada residual dari model ARMA. Oleh karena itu, pendekatan model GARCH dapat digunakan untuk memodelkan *conditional heteroscedasticity* pada data *return* saham tersebut.

4.1.3.2 Estimasi Parameter

Berdasarkan hasil analisis deskriptif yang telah dilakukan sebelumnya, data *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA tidak terdistribusi secara normal. Keenam data *return* saham tersebut mengalami fenomena leptokurtosis serta memiliki kecenderungan pada sebaran data untuk terdistribusi ke kanan (*long right tail*). Oleh karena itu digunakan distribusi *skewed student-t* untuk mengestimasi parameter pada kombinasi model ARMA-GARCH.

Tabel 4.14 menunjukkan hasil estimasi parameter model GARCH dari *return* saham dengan kode ICBP. Berdasarkan tabel tersebut, dapat dilihat bahwa seluruh parameter dari *mean equation* maupun *variance equation* memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *Prob. (p-value)* yang lebih kecil dari tingkat signifikansi 5%.

Tabel 4.14: Estimasi Parameter Model GARCH ICBP

Parameter	Coef.	Std. Error	t-statistic	Prob.
<i>Mean equation</i>				
C	0.0008	0.0003	2.9354	0.0033
MA(3)	-0.0599	0.0168	-3.5767	0.0003
<i>Variance equation</i>				
ω	0.0000	0.0000	3.6946	0.0002
α_1	0.1608	0.0210	7.6389	0.0000
β_1	0.8382	0.0182	46.1009	0.0000
$\alpha_1 + \beta_1$	0.9990			

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.15 menunjukkan hasil estimasi parameter model GARCH dari *return* saham dengan kode HMSP. Berdasarkan tabel tersebut, dapat dilihat bahwa nilai *Prob.* (*p-value*) dari seluruh parameter *variance equation* lebih kecil dari tingkat signifikansi 5%. Sedangkan pada *mean equation*, hanya konstanta (C) yang memiliki nilai *p-value* lebih besar dari tingkat signifikansi 5%.

Tabel 4.15: Estimasi Parameter Model GARCH HMSP

Parameter	Coef.	Std. Error	t-statistic	Prob.
<i>Mean equation</i>				
C	0.0002	0.0002	1.3544	0.1756
AR(1)	0.2677	0.0016	166.9304	0.0000
AR(2)	0.3881	0.0011	369.1657	0.0000
AR(3)	0.5819	0.0002	2489.1340	0.0000
AR(4)	-0.7657	0.0010	-755.9879	0.0000
MA(1)	-0.3080	0.0001	-4975.0277	0.0000
MA(2)	-0.4074	0.0010	-427.8756	0.0000
MA(3)	-0.5743	0.0002	-3258.2511	0.0000
MA(4)	0.8013	0.0001	6508.7992	0.0000
<i>Variance equation</i>				
ω	0.0000	0.0000	7.9074	0.0000
α_1	0.2669	0.0248	10.7477	0.0000
β_1	0.7321	0.0214	34.2869	0.0000
$\alpha_1 + \beta_1$	0.9990			

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.16 menunjukkan hasil estimasi parameter model GARCH dari *return* saham dengan kode KLBF. Berdasarkan tabel tersebut, dapat dilihat bahwa nilai *Prob.* (*p-value*) dari seluruh parameter *variance equation* lebih kecil dari tingkat signifikansi 5%. Sedangkan pada *mean equation*, hanya parameter AR(3), MA(3), serta konstanta (C) yang memiliki nilai *p-value* lebih besar dari tingkat signifikansi 5%.

Tabel 4.16: **Estimasi Parameter Model GARCH KLBF**

Parameter	Coef.	Std. Error	t-statistic	Prob.
Mean equation				
C	0.0004	0.0003	1.5636	0.1179
AR(1)	-0.8888	0.1276	-6.9643	0.0000
AR(2)	0.2130	0.0808	2.6380	0.0083
AR(3)	0.2439	0.2535	0.9620	0.3360
AR(4)	-0.2320	0.1020	-2.2743	0.0229
MA(1)	0.8061	0.1286	6.2701	0.0000
MA(2)	-0.3300	0.0257	-12.8351	0.0000
MA(3)	-0.2965	0.2367	-1.2529	0.2103
MA(4)	0.2187	0.0816	2.6788	0.0074
Variance equation				
ω	0.0000	0.0000	3.8136	0.0001
α_1	0.1997	0.0337	5.9305	0.0000
β_1	0.7648	0.0379	20.1702	0.0000
$\alpha_1 + \beta_1$	0.9645			

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.17 menunjukkan hasil estimasi parameter model GARCH dari *return* saham dengan kode UNVR. Berdasarkan tabel tersebut, dapat dilihat bahwa nilai *Prob.* (*p-value*) dari parameter AR(1) dan MA(1) pada *mean equation*, serta seluruh parameter *variance equation* lebih kecil dari tingkat signifikansi 5%.

Tabel 4.17: **Estimasi Parameter Model GARCH UNVR**

Parameter	Coef.	Std. Error	t-statistic	Prob.
Mean equation				
C	0.0003	0.0002	1.5269	0.1268
AR(1)	0.5857	0.0579	10.1219	0.0000
MA(1)	-0.7067	0.0503	-14.0478	0.0000
Variance equation				
ω	0.0000	0.0000	2.9472	0.0032
α_1	0.1509	0.0197	7.6558	0.0000
β_1	0.8379	0.0098	85.6300	0.0000
$\alpha_1 + \beta_1$	0.9888			

Sumber: Hasil Pengolahan Data, 2021.



Tabel 4.18 menunjukkan hasil estimasi parameter model ARMA-GARCH dari *return* saham dengan kode WOOD. Berdasarkan tabel tersebut, dapat dilihat bahwa nilai *Prob.* (*p-value*) dari seluruh parameter *variance equation* lebih kecil dari tingkat signifikansi 5%. Sedangkan nilai *p-value* dari seluruh parameter *mean equation* lebih besar dari tingkat signifikansi 5%.

Tabel 4.18: Estimasi Parameter Model GARCH WOOD

Parameter	Coef.	Std. Error	t-statistic	Prob.
<i>Mean equation</i>				
C	0.0016	0.0009	1.6409	0.1008
MA(6)	0.0182	0.0236	0.7691	0.4418
<i>Variance equation</i>				
ω	0.0002	0.0001	2.0645	0.0390
α_1	0.3114	0.1363	2.2853	0.0223
β_1	0.6876	0.0844	8.1500	0.0000
$\alpha_1 + \beta_1$	0.9990			

Sumber: Hasil Pengolahan Data, 2021.

Tabel 4.19 menunjukkan hasil estimasi parameter model ARMA-GARCH dari *return* saham dengan kode HRTA. Berdasarkan tabel tersebut, dapat dilihat bahwa nilai *Prob.* (*p-value*) dari seluruh parameter *mean equation* lebih besar dari tingkat signifikansi 5%. Sedangkan nilai *p-value* dari parameter ARCH (α_1) dan GARCH (β_1) pada *variance equation* lebih besar dari tingkat signifikansi 5%.

Tabel 4.19: Estimasi Parameter Model GARCH HRTA

Parameter	Coef.	Std. Error	t-statistic	Prob.
<i>Mean equation</i>				
C	-0.0001	0.0006	-0.0854	0.9320
MA(5)	-0.0495	0.0306	-1.6172	0.1058
<i>Variance equation</i>				
ω	0.0000	0.0000	1.6203	0.1052
α_1	0.1916	0.0724	2.6458	0.0082
β_1	0.8074	0.0763	10.5860	0.0000
$\alpha_1 + \beta_1$	0.9990			

Sumber: Hasil Pengolahan Data, 2021.



4.1.3.3 Pemeriksaan Diagnostik

Setelah melakukan estimasi parameter model ARMA-GARCH, tahap selanjutnya adalah memastikan residual dari model tersebut sudah tidak memiliki efek ARCH. Pada penelitian ini, digunakan uji *weighted* ARCH LM yang dikembangkan oleh Fisher dan Gallagher (2012). Berdasarkan Tabel 4.20, dapat dilihat bahwa residual terstandarisasi dari model ARMA-GARCH dari *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA sudah terbebas dari efek ARCH. Hal tersebut dapat dibuktikan dengan nilai *p-value* dari hasil uji *weighted* ARCH LM yang lebih besar dari tingkat signifikansi 5%. Artinya terdapat bukti yang kurang kuat untuk menolak hipotesis nol (H_0), yaitu tidak terdapat efek ARCH.

Tabel 4.20: Hasil Uji *Weighted* ARCH LM

Lag	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
3	0.0830 (0.7733)	0.3867 (0.5340)	1.3120 (0.2521)	0.0336 (0.8546)	0.2244 (0.6357)	0.3554 (0.5511)
5	2.0979 (0.4500)	0.7589 (0.8055)	1.6800 (0.5463)	1.1439 (0.6907)	0.9655 (0.7432)	0.6259 (0.8459)
7	4.3054 (0.3047)	0.9848 (0.916)	2.0400 (0.7089)	2.1542 (0.6847)	1.5822 (0.8047)	1.4084 (0.8395)

Sumber: Hasil Pengolahan Data, 2021.

Keterangan: Angka dalam kurung menunjukkan nilai *p-value*.

Setelah didapatkan model ARMA-GARCH yang telah terbebas dari efek ARCH, tahap selanjutnya adalah memastikan keberadaan fenomena *leverage effect*. Pada penelitian ini digunakan uji *sign and size bias* yang dikemukakan oleh Engle dan Ng (1993) untuk menguji keberadaan *leverage effect* serta menentukan apakah model GARCH asimetris perlu digunakan.

Pada Tabel 4.21, dapat dilihat hasil uji *sign and size bias* yang menunjukkan bahwa fenomena *leverage effect* tidak terjadi pada keenam data *return* saham tersebut. Hal ini dibuktikan oleh nilai *p-value* pada setiap pengujian yang lebih besar dari tingkat signifikansi 5%. Artinya terdapat bukti yang kurang kuat untuk menerima hipotesis alternatif (H_1), yaitu terdapat efek asimetris. Oleh karena itu, model GARCH asimetris tidak perlu digunakan untuk memodelkan volatilitas pada keenam *return* saham tersebut. Sehingga model yang digunakan sebagai *variance equation* adalah model GARCH simetris, yaitu GARCH(1,1).

Tabel 4.21: Hasil Uji *Sign and Size Bias*

Jenis Pengujian	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
<i>Sign Bias</i>	0.2198 (0.8260)	0.2122 (0.8319)	1.1337 (0.2570)	0.9173 (0.3590)	0.7840 (0.4332)	1.4488 (0.1477)
<i>Negative Sign Bias</i>	0.6735 (0.5007)	1.5484 (0.1216)	0.2085 (0.8348)	1.1631 (0.2449)	1.4188 (0.1563)	0.7002 (0.4840)
<i>Positive Sign Bias</i>	1.3555 (0.1753)	0.7832 (0.4335)	0.0911 (0.9274)	1.0192 (0.3082)	0.4522 (0.6512)	0.0708 (0.9436)
<i>Joint Effect</i>	3.4402 (0.3286)	3.0204 (0.3885)	2.1340 (0.5451)	2.4287 (0.4883)	2.2180 (0.5284)	2.3843 (0.4966)

Sumber: Hasil Pengolahan Data, 2021.

Keterangan: Angka dalam kurung menunjukkan nilai *p-value*.

4.1.4 Value at Risk

4.1.4.1 Backtesting

Setelah mendapatkan model ARMA-GARCH terbaik untuk setiap *return* saham, tahap selanjutnya adalah memeriksa apakah perkiraan kerugian maksimum (nilai VaR) yang dihasilkan dari estimasi model ARMA-GARCH sesuai dengan kerugian asli pada data historis. Pada penelitian ini, digunakan *backtesting* metode *rolling* dengan *ugarchroll* dari *package rugarch* dalam R yang dikembangkan oleh Ghalanos (2020b).

Tabel 4.22 merupakan hasil *backtesting* VaR pada tingkat kepercayaan 99% dari *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA. Berdasarkan tabel tersebut, seluruh estimasi nilai VaR pada keenam *return* saham dapat dinyatakan valid dan mampu memprediksi risiko dengan baik. Hal tersebut dibuktikan oleh nilai *Prob.* (*p-value*) dari uji *unconditional coverage* serta uji *conditional coverage* yang lebih besar dari tingkat signifikansi 5%. Sehingga terdapat bukti yang kurang kuat untuk menolak hipotesis nol (H_0) dari uji *unconditional coverage* (*correct exceedances*), serta H_0 dari uji *conditional coverage* (*correct exceedances dan independence of failures*).

Tabel 4.22: **Backtesting VaR (99%) 250 Observasi Terakhir**

Return	Exceedances		Unconditional Coverage		Conditional Coverage		Keterangan
	Actual	%	Statistic	Prob.	Statistic	Prob.	
ICBP	4	1.60%	0.7690	0.3800	0.9000	0.6380	Valid
HMSP	4	1.60%	0.7690	0.3800	0.9000	0.6380	Valid
KLBF	2	0.80%	0.1080	0.7420	0.1410	0.9320	Valid
UNVR	3	1.20%	0.0950	0.7580	0.1680	0.9190	Valid
WOOD	4	1.60%	0.7690	0.3800	0.9000	0.6380	Valid
HRTA	2	0.80%	0.1080	0.7420	0.1410	0.9320	Valid

Sumber: Hasil Pengolahan Data, 2021.

Visualisasi hasil *backtesting* VaR (99%) dari keenam *return* saham sektor konsumer ditampilkan pada Lampiran 43 hingga Lampiran 48. Grafik tersebut merupakan gabungan antara *scatter plot* dari *realized return*, serta diagram garis berwarna hitam yang menunjukkan pergerakan nilai VaR. *Scatter plot* dengan warna abu-abu merupakan *realized return* yang tidak melanggar nilai VaR. Sedangkan *scatter plot* yang berwarna merah merupakan *realized return* yang melanggar nilai VaR (*actual exceedances*).

Berdasarkan hasil uji *unconditional coverage* serta uji *conditional coverage* yang telah dilakukan sebelumnya, jumlah *actual exceedances* pada setiap *return*

saham masih bisa ditoleransi. Karena jumlahnya tidak berbeda jauh dari jumlah *exceedances* yang diharapkan, yaitu 2.5 atau 1% dari jumlah observasi *backtesting*. Selain itu, setiap pelanggaran VaR tersebut juga terbukti bersifat independen dan tidak terjadi pengelompokan (*clustered violations*).

4.1.4.2 Forecasting VaR

Setelah didapatkan VaR yang valid, selanjutnya dilakukan *forecasting VaR* dengan periode *holding* satu hari ke depan berdasarkan proyeksi *mean equation* dan *volatility equation* dari model ARMA-GARCH. Berlandaskan pada hasil estimasi parameter pada Tabel 4.14 hingga Tabel 4.19, maka secara matematis *mean equation* dan *volatility equation* dari *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA dapat dinyatakan sebagai berikut:

ICBP:

$$\mu_t = 0.000791 - 0.059947 \varepsilon_{t-3}$$

$$\sigma_t^2 = 0.000013 + 0.160763 \varepsilon_{t-1}^2 + 0.838237 \sigma_{t-1}^2$$

HMSP:

$$\mu_t = 0.000249 + 0.267732 r_{t-1} + 0.388118 r_{t-2} + 0.581882 r_{t-3} - 0.765733 r_{t-4} - 0.307961 \varepsilon_{t-1} - 0.40742 \varepsilon_{t-2} - 0.574341 \varepsilon_{t-3} + 0.801331 \varepsilon_{t-4}$$

$$\sigma_t^2 = 0.000017 + 0.266943 \varepsilon_{t-1}^2 + 0.732057 \sigma_{t-1}^2$$

KLBF:

$$\mu_t = 0.000402 + 0.888764 r_{t-1} + 0.213044 r_{t-2} + 0.243868 r_{t-3} + 0.231956 r_{t-4} + 0.806075 \varepsilon_{t-1} - 0.329993 \varepsilon_{t-2} - 0.296496 \varepsilon_{t-3} + 0.218685 \varepsilon_{t-4}$$

$$\sigma_t^2 = 0.000034 + 0.199652 \varepsilon_{t-1}^2 + 0.764822 \sigma_{t-1}^2$$

UNVR:

$$\mu_t = 0.000285 + 0.585652r_{t-1} - 0.70673\varepsilon_{t-1}$$

$$\sigma_t^2 = 0.000012 + 0.150914\varepsilon_{t-1}^2 + 0.837874\sigma_{t-1}^2$$

WOOD:

$$\mu_t = 0.001553 + 0.018168\varepsilon_{t-6}$$

$$\sigma_t^2 = 0.000217 + 0.311425\varepsilon_{t-1}^2 + 0.687575\sigma_{t-1}^2$$

HRTA:

$$\mu_t = -0.000053 - 0.049535\varepsilon_{t-3}$$

$$\sigma_t^2 = 0.000042 + 0.191573\varepsilon_{t-1}^2 + 0.807427\sigma_{t-1}^2$$

Keenam model tersebut selanjutnya digunakan untuk *forecasting* VaR, yang hasilnya ditampilkan pada Tabel 4.23. Berdasarkan tabel tersebut, dapat dilihat bahwa saham UNVR memiliki nilai VaR terendah (mendekati nol), sedangkan saham HRTA memiliki nilai VaR tertinggi (paling jauh dari nol).

Tabel 4.23: **Forecasting VaR (99%) 1 Periode ke Depan**

ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
-0.0479	-0.0405	-0.0503	-0.0326	-0.0559	-0.1137

Sumber: Hasil Pengolahan Data, 2021.

4.1.5 Expected Shortfall

4.1.5.1 Backtesting

Setelah VaR dinyatakan valid, selanjutnya dapat dilakukan *backtesting* ES.

Pada penelitian ini, digunakan *backtesting* ES dengan metode *ESTest* dari *package rugarch* dalam R yang dikembangkan oleh (Ghalanos, 2020b). Metode ini merupakan implementasi *expected shortfall test* dari McNeil dan Frey

(2000) yang menguji apakah potensi risiko berdasarkan estimasi nilai ES lebih rendah dari potensi risiko yang sebenarnya.

Tabel 4.24 merupakan hasil *backtesting* ES pada tingkat kepercayaan 99% dari *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA.

Berdasarkan tabel tersebut, seluruh estimasi nilai ES pada keenam *return* saham dapat dinyatakan valid dan mampu memprediksi potensi risiko yang lolos dari VaR dengan baik. Hal tersebut dibuktikan oleh nilai *Prob.* (*p-value*) dari uji hipotesis satu arah (*one tailed t-test*) yang lebih besar dari tingkat signifikansi 5%. Sehingga terdapat bukti yang kurang kuat untuk menerima hipotesis alternatif (H_1), yaitu rata-rata *excess shortfall* lebih dari nol.

Tabel 4.24: **Backtesting ES (99%)**

	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
<i>Prob.</i>	0.7586	0.4597	0.9429	0.8968	0.9938	0.9984
Keterangan	Valid	Valid	Valid	Valid	Valid	Valid

Sumber: Hasil Pengolahan Data, 2021.

4.1.5.2 Forecasting ES

Setelah ES dinyatakan lolos *backtesting*, maka dapat dilakukan *forecasting* ES dengan periode *holding* satu hari ke depan berdasarkan proyeksi *mean equation* dan *volatility equation* yang telah dikemukakan sebelumnya. Hasil *forecasting* tersebut ditampilkan pada Tabel 4.25, yang menunjukkan bahwa nilai ES saham UNVR juga paling rendah (mendekati nol) sedangkan nilai ES saham HRTA juga paling tinggi (jauh dari nol).

Tabel 4.25: **Forecasting ES (99%) 1 Periode ke Depan**

ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
-0.0673	-0.0646	-0.0706	-0.0454	-0.0905	-0.1781

Sumber: Hasil Pengolahan Data, 2021.



4.2 Pembahasan

4.2.1 Karakteristik Volatilitas Return Saham

4.2.1.1 Volatility Clustering

Salah satu karakteristik volatilitas dari data finansial adalah terjadinya pengelompokan volatilitas pada periode tertentu, yang disebut sebagai fenomena *volatility clustering*. Fenomena ini memiliki implikasi bahwa volatilitas saat ini memiliki korelasi positif dengan periode sebelumnya (Brooks, 2008). Artinya volatilitas pada periode ini akan mempengaruhi ekspektasi volatilitas di periode ke depan. Fenomena ini diartikan oleh para ahli ekonometrika sebagai efek ARCH (*autoregressive conditional heteroskedasticity*) (Hanck, Arnold, Gerber, dan Schmelzer, 2020).

Dalam Box dkk. (2016), terdapat beberapa cara untuk menguji keberadaan efek ARCH, salah satunya adalah uji *Lagrange Multiplier* (LM) yang dikemukakan oleh Engle (1982). Uji LM dilakukan pada residual kuadrat dari data *time series* yang telah dimodelkan dengan model basis (model dasar) tertentu. Karena pada penelitian ini digunakan model ARMA sebagai model basis, maka yang perlu diuji adalah keberadaan efek ARCH pada residual kuadrat dari model ARMA.

Berdasarkan hasil uji LM yang ditampilkan pada Tabel 4.13, terdapat bukti yang kuat untuk mendukung keberadaan efek ARCH pada residual kuadrat model ARMA dari *return* saham dengan kode ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA. Oleh karena itu, diperlukan model GARCH untuk memanfaatkan *conditional heteroskedasticity* tersebut guna menjelaskan fenomena *volatility clustering*. Mengingat data keenam *return* saham tersebut tidak berdistribusi normal dan cenderung *leptokurtic* serta *long right tail* (berdasarkan Tabel 4.1), maka digunakan distribusi *skewed student-t* untuk mengestimasi parameter model GARCH.

Hasil estimasi parameter model GARCH yang ditampilkan pada Tabel 4.14 hingga tabel 4.19 menunjukkan pengaruh signifikan dari nilai koefisien *variance equation*. Koefisien ARCH (α_1) yang bernilai positif dan signifikan secara statistik mengisyaratkan bahwa volatilitas saat ini (t) dipengaruhi oleh ukuran dari guncangan volatilitas di periode sebelumnya ($t-1$). Sedangkan koefisien GARCH (β_1) yang bernilai positif dan signifikan secara statistik menunjukkan bahwa volatilitas di periode ini (t) dipengaruhi oleh perubahan volatilitas di periode sebelumnya ($t-1$).

Nilai koefisien ARCH (α_1) dapat diartikan sebagai reaksi volatilitas terhadap guncangan, sedangkan nilai koefisien GARCH (β_1) dapat diartikan sebagai persistensi (keberlangsungan) volatilitas setelah terjadi guncangan (Alexander, 2008a). Nilai koefisien ARCH (α_1) yang relatif tinggi pada *return* saham WOOD mengisyaratkan volatilitas yang lebih sensitif terhadap guncangan dibanding *return* saham lain. Namun nilai koefisien GARCH (β_1) yang relatif rendah pada *return* saham WOOD justru menunjukkan bahwa fluktuasi harga saham WOOD memerlukan waktu yang lebih cepat untuk kembali stabil. Di sisi lain, *return* saham UNVR dan ICBP memiliki volatilitas yang kurang sensitif terhadap guncangan, namun keduanya memerlukan waktu yang lebih lama untuk kembali stabil jika dibandingkan dengan *return* saham lain.

Persistensi volatilitas yang relatif rendah sering dikaitkan dengan sensitivitas terhadap guncangan yang relatif tinggi, mengindikasikan bahwa *return* saham WOOD memiliki volatilitas yang lebih "runcing" dan terkesan *jumpy*. Di sisi lain, sensitivitas terhadap guncangan yang relatif rendah pada *return* saham UNVR dan ICBP memang tidak terlalu mengejutkan. Mengingat bahwa kedua saham tersebut merupakan saham *Blue Chip*, yaitu saham perusahaan yang mapan dan sehat secara finansial serta memiliki kapitalisasi pasar yang besar.

Kapitalisasi pasar yang besar dari PT Unilever Indonesia Tbk (UNVR) dan PT Indofood CBP Sukses Makmur Tbk (ICBP) membuat sahamnya mampu meredam guncangan volatilitas, sehingga performanya cenderung stabil. Di sisi lain kedua perusahaan tersebut merupakan perusahaan multinasional, sehingga performanya dapat dipengaruhi oleh dinamika perekonomian global dan pergerakan mata uang asing. Hal tersebut menjelaskan tingginya tingkat persistensi volatilitas kedua *return* saham tersebut jika dibandingkan dengan *return* saham lain.

4.2.1.2 Efek Asimetris

Selain *volatility clustering*, volatilitas pada data finansial bisa jadi memiliki karakteristik efek asimetris. Efek asimetris adalah kondisi ketika volatilitas memiliki respon berbeda terhadap kenaikan atau penurunan harga saham (Tsay, 2010). Kondisi ini biasanya muncul ketika pasar saham sedang *crash*, yaitu ketika terjadi penurunan harga saham yang besar (Wu, 2001). *Financial leverage* adalah salah satu penjelasan dari fenomena ini, yang pertama kali dikemukakan oleh Black (1976). Dimana harga saham jatuh meningkatkan *financial leverage* dalam struktur modal perusahaan, kemudian peningkatan *leverage* dapat meningkatkan volatilitas harga saham.

Meskipun *financial leverage* bukan menjadi satu-satunya penjelasan dari fenomena efek asimetris, namun istilah *leverage effect* umumnya merujuk pada model volatilitas yang mampu merespon guncangan secara asimetris (Bollerslev, Patton, dan Quaedvlieg, 2020). Salah satu model volatilitas populer yang mampu menangkap fenomena tersebut adalah GJR-GARCH, yaitu pengembangan model GARCH yang dikemukakan oleh Glosten, Jagannathan, dan Runkle (1993).

Untuk menguji keberadaan efek asimetris (*leverage effect*) pada volatilitas, Brooks (2008) menyarankan penggunaan uji *sign and size bias* yang dikemukakan oleh Engle dan Ng (1993). Uji tersebut digunakan pada penelitian Aliyev dkk. (2020) untuk menentukan apakah model GARCH asimetris diperlukan untuk memodelkan volatilitas *return* indeks saham Nasdaq-100. Pada penelitian tersebut, hasil uji *sign and size bias* mendukung keberadaan fenomena *leverage effect*, sehingga diperlukan model GARCH asimetris.

Pada penelitian ini juga dilakukan uji *sign and size bias*, yang hasilnya ditunjukkan pada Tabel 4.21. Hasil tersebut menunjukkan nilai koefisien *sign bias* (ϕ_1) yang tidak signifikan, bukti dari tidak adanya bias pada dampak guncangan positif maupun negatif. Kemudian nilai koefisien *negative size bias* (ϕ_2) dan *positive size bias* (ϕ_3) yang tidak signifikan membuktikan bahwa tidak terdapat bias ukuran pada besaran guncangan positif maupun negatif. Sehingga dapat disimpulkan bahwa volatilitas *return* saham dari keenam perusahaan sektor konsumen tidak memiliki karakteristik untuk merespon guncangan secara asimetris.

4.2.2 Estimasi Risiko Investasi

Untuk meminimalisir risiko investasi, seorang investor dapat terlebih dahulu melakukan pengukuran risiko dengan metode VaR (*Value at Risk*) dan ES (*Expected Shortfall*). VaR mampu meringkas ukuran risiko pasar (*market risk*) ke dalam satuan angka yang mudah dipahami (Jorion, 2007). Risiko pasar yang dimaksud adalah potensi kerugian dari pergerakan harga pasar, sehingga dalam kasus investasi saham maka risiko yang diukur adalah risiko penurunan harga saham berdasarkan posisi harga saat ini.

Tabel 4.26: **Estimasi Risiko dengan VaR (99%) dan ES (99%) Tahun 2020**

		ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
VaR	<i>Mean</i>	-0.0553	-0.0692	-0.0664	-0.0530	-0.0798	-0.0799
	<i>Variance</i>	0.0008	0.0013	0.0011	0.0013	0.0011	0.0011
ES	<i>Mean</i>	-0.0781	-0.0718	-0.0811	-0.0692	-0.1069	-0.1113
	<i>Variance</i>	0.0012	0.0019	0.0014	0.0009	0.0013	0.0026

Sumber: Hasil Pengolahan Data, 2021.

Pada Tabel 4.26 ditampilkan *mean* dan *variance* dari estimasi risiko investasi saham enam perusahaan sektor konsumen dengan VaR (99%) dan ES (99%) sepanjang tahun 2020. Berdasarkan hasil tersebut, dapat diketahui bahwa sepanjang tahun 2020 saham WOOD dan HRTA memiliki potensi kerugian yang relatif lebih besar dibanding keempat saham sektor konsumen lain. Kedua saham tersebut masing-masing memiliki rata-rata risiko penurunan harga saham harian ketika kondisi normal (VaR) sebesar 7.98% dan 7.99%. Dengan rata-rata potensi penurunan harga saham harian ketika kondisi ekstrem (ES) sebesar 10.69% serta 11.13%. Jauh berbeda dengan empat saham lain (ICBP, HMSP, KLBF, dan UNVR) dengan rata-rata potensi penurunan harga saham harian ketika kondisi normal yang kurang dari 8%. Serta rata-rata potensi penurunan harga saham harian ketika kondisi ekstrem yang kurang dari 9%.

PT Integra Indocabinet Tbk (WOOD) dengan subsektor peralatan rumah tangga, memproduksi furnitur berbahan dasar kayu. Kinerja perusahaan ini cukup terpengaruh dengan adanya pandemi Covid-19 sepanjang tahun 2020. Pertumbuhan permintaan domestik tercatat menurun cukup signifikan hingga 25.1%, turun sebesar Rp182,4 miliar dibanding tahun 2019. Kemudian industri furnitur juga mengalami kontraksi, dimana pada kuartal I-2020 mengalami pertumbuhan negatif secara *year on year* hingga 7.28% (Integra Group, 2021).

PT Hartadinata Abadi Tbk (HRTA) dengan subsektor lainnya, memproduksi serta menjual perhiasan emas. Kinerja perusahaan ini pada kuartal I-2020 terdampak negatif oleh pandemi Covid-19, terutama pada penjualan perhiasan jelang Idul Fitri (Hartadinata Abadi, 2021). Pada momen Idul Fitri tersebut, banyaknya toko *offline* yang tutup akibat pemberlakuan Pembatasan Sosial Berskala Besar (PSBB) di berbagai daerah sempat membuat transaksi emas perusahaan menurun sekitar 40% (yoy) (Fitri, 2020).

PT Indofood CBP Sukses Makmur Tbk (ICBP) dengan subsektor makanan dan minuman, memproduksi mi instan hingga minuman kemasan. Kinerja beberapa lini bisnis perusahaan ini pada tahun 2020 justru mengalami dampak positif dari pandemi Covid-19. Dimana penjualan produk yang ideal untuk konsumsi rumahan mengalami peningkatan. Segmen penyedap makanan mengalami pertumbuhan penjualan yang signifikan hingga 21.9% (yoy). Disusul oleh segmen mi instan yang masih menjadi penopang penjualan perusahaan hingga Rp31,97 triliun, meningkat 15.4% secara *year on year* (Indofood CBP, 2021).

PT H.M. Sampoerna Tbk (HMSP) dengan subsektor rokok, memproduksi beragam segmen rokok. Kinerja perusahaan ini mengalami dampak negatif dari pandemi Covid-19, serta kenaikan cukai rokok di awal tahun 2020. Kedua faktor tersebut menyebabkan penurunan permintaan seiring dengan menurunnya daya beli masyarakat. Sehingga volume penjualan perusahaan di tahun 2020 turun 19.3% (yoy) menjadi 79.5 miliar unit (Sampoerna, 2021).

PT Kalbe Farma Tbk (KLBF) dengan subsektor farmasi, memproduksi obat-obatan hingga suplemen. Kinerja beberapa lini bisnis perusahaan ini juga mengalami dampak positif dari pandemi Covid-19. Sepanjang tahun 2020, segmen produk kesehatan mencatatkan penjualan bersih Rp3633 miliar, tumbuh 4.7% (yoy) (Kalbe, 2021). Dalam segmen ini, produk suplemen serta produk

preventif lainnya mengalami peningkatan permintaan. Hal ini diakibatkan oleh meningkatnya kesadaran masyarakat untuk memperkuat kekebalan tubuhnya selama masa pandemi.

PT Unilever Indonesia Tbk (UNVR) dengan subsektor kosmetik dan keperluan rumah tangga, memproduksi beragam barang konsumsi. Kinerja lini bisnis utama perusahaan ini pada tahun 2020 mengalami dampak positif dari pandemi Covid-19. Segmen kebutuhan rumah tangga dan perawatan tubuh mencatatkan penjualan bersih Rp29,99 triliun, tumbuh 0.4% (yoy) (Unilever Indonesia, 2021). Pertumbuhan pada segmen ini dipengaruhi oleh peningkatan permintaan produk pada kategori pembersih dan cairan pencuci piring, seiring dengan meningkatnya kesadaran masyarakat terhadap kebersihan permukaan rumah dan peralatan makan.

Jika dilihat dari nilai kapitalisasi pasarnya, saham WOOD dan HRTA tergolong sebagai saham lapis dua (*second liner*), yang memiliki nilai kapitalisasi pasar antara Rp500 Miliar hingga Rp10 Triliun. Sedangkan saham ICBP, HMSP, KLBF, dan UNVR tergolong sebagai saham lapis satu (*Blue Chip*), yang memiliki nilai kapitalisasi pasar lebih dari Rp10 Triliun (Indonesia Stock Exchange, 2020).

Kapitalisasi pasar yang besar serta kinerja perusahaan yang cukup tangguh membuat saham ICBP, KLBF dan UNVR cenderung lebih mampu meredam guncangan volatilitas akibat pandemi Covid-19. Sehingga estimasi rata-rata potensi kerugian hariannya sepanjang tahun 2020 relatif lebih rendah dari saham WOOD dan HRTA. Sedangkan untuk saham HMSP, kinerja perusahaan yang menurun selama pandemi membuat rata-rata potensi kerugian hariannya pada tahun 2020 lebih tinggi dibanding ketiga saham *Blue Chip* lain. Meskipun nilainya masih relatif lebih rendah dari saham WOOD dan HRTA.

Berdasarkan *forecasting* VaR dan ES yang telah dilakukan sebelumnya (Tabel 4.23 dan Tabel 4.25), jika seorang investor mempunyai modal sebesar

Rp100 Juta maka estimasi risiko yang perlu ditanggung oleh investor tersebut adalah sebagai berikut.

Tabel 4.27: Peramalan Risiko dengan VaR (99%) dan ES (99%) (Rp)

	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
VaR	4,789,778	4,047,947	5,030,944	3,257,948	5,586,313	11,369,900
ES	6,725,151	6,460,669	7,057,714	4,542,092	9,045,901	17,813,508

Sumber: Hasil Pengolahan Data, 2021.

Berdasarkan Tabel 4.27, jika seorang investor menanamkan seluruh modalnya pada saham ICBP pada 30 Desember 2020, maka pada hari perdagangan selanjutnya (4 Januari 2021) investor tersebut berpotensi mendapatkan kerugian maksimum sebesar Rp4.789.778,00 (VaR). Estimasi kerugian tersebut memiliki tingkat kepercayaan 99%, artinya hanya terdapat 1% kemungkinan investor tersebut mengalami kerugian yang lebih besar dari Rp4.789.778,00. Seandainya terjadi kondisi ekstrem (misalnya terjadi *market crash*), maka ekspektasi kerugian yang dapat diderita oleh investor tersebut adalah Rp6.725.151,00 (ES).

Dari hasil peramalan risiko pada Tabel 4.27, dapat diketahui bahwa pada 4 Januari 2021 saham *second liner* (HRTA dan WOOD) masih memiliki potensi kerugian yang relatif lebih besar dari saham *Blue Chip* (ICBP, HMSP, dan UNVR). Saham HRTA memiliki potensi kerugian terbesar, yaitu sejumlah Rp11.369.900,00 (VaR) dan Rp17.813.508,00 (ES). Disusul oleh saham WOOD dengan potensi kerugian sebesar Rp5.586.313,00 (VaR) dan Rp9.045.901,00 (ES). Uniknya, posisi tersebut disusul oleh saham KLBF yang merupakan saham *Blue Chip*, dengan potensi kerugian senilai RP5.030.944,00 (VaR) dan Rp7.057.714,00 (ES). Sedangkan tiga saham *Blue Chip* lain (ICBP, HMSP, dan UNVR) memiliki potensi kerugian maksimum yang relatif lebih rendah, yaitu di bawah Rp5 Juta (VaR) dan di bawah Rp7 Juta (ES).

BAB V

KESIMPULAN, IMPLIKASI, DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah diuraikan sebelumnya, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Keenam *return* saham dari perusahaan sektor konsumen pada penelitian ini mengalami fenomena *volatility clustering* dan leptokurtosis, namun tidak mengalami fenomena *leverage effect*. Sehingga dinamika volatilitas keenam *return* saham tersebut dapat digambarkan oleh model GARCH simetris dengan penggunaan distribusi *student-t*.
2. Dari seluruh *return* saham sektor konsumen pada penelitian ini, WOOD memiliki volatilitas yang paling sensitif terhadap guncangan, sedangkan *return* saham UNVR dan ICBP paling tidak sensitif. Di sisi lain, volatilitas *return* saham WOOD paling cepat untuk kembali stabil, sedangkan volatilitas *return* saham UNVR dan ICBP memerlukan waktu yang paling lama untuk kembali stabil.
3. Nilai VaR dengan tingkat kepercayaan 99% untuk saham ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA pada tanggal 4 Januari 2021 masing-masing sebesar -5%, -4%, -5%, -3%, -6%, serta -11%. Sedangkan nilai ES dengan tingkat kepercayaan 99% untuk masing-masing *return* saham tersebut sebesar -7%, -6%, -7%, -5%, -9%, dan -18%.
4. Hasil estimasi risiko investasi dengan VaR dan ES menunjukkan bahwa sepanjang tahun 2020 dan 4 Januari 2021, saham second liner (HRTA dan

WOOD) memiliki potensi kerugian yang relatif lebih besar dibanding saham Blue Chip (ICBP, HMSP, dan UNVR).

5.2 Implikasi

5.2.1 Implikasi Teoritis

Hasil penelitian ini menunjukkan bahwa keenam *return* saham tidak mengalami fenomena *leverage effect*. Sehingga pelaku investasi pada keenam saham tersebut tidak mudah terpengaruh oleh sentimen negatif (*bad news*) yang ada di pasar. Hal tersebut menarik karena umumnya fenomena tersebut sering terjadi pada aset finansial, hingga dianggap sebagai fakta empiris. Hasil penelitian ini sedikit berbeda dengan hasil penelitian sebelumnya yang dilakukan oleh Aliyev dkk. (2020), yang membuktikan keberadaan fenomena tersebut pada *return* indeks saham Nasdaq-100. Perbedaan hasil temuan ini membuktikan bahwa perbedaan variabel penelitian dapat mengakibatkan hasil yang berbeda.

5.2.1 Implikasi Praktis

Hasil penelitian ini secara praktis dapat digunakan sebagai pertimbangan bagi investor agar lebih memperhatikan dinamika volatilitas *return* saham, serta guncangan yang terjadi pada periode sebelumnya. *Return* saham harian yang cenderung menunjukkan pengelompokan volatilitas dapat disimulasikan dengan pendekatan model ARMA-GARCH. Model tersebut dapat menghasilkan peramalan volatilitas yang lebih akurat, yang diikuti oleh hasil estimasi risiko dengan VaR dan ES yang semakin akurat. Sehingga akan membantu investor dalam menetapkan kebijakan berinvestasi.

5.3 Saran

1. Penelitian ini memodelkan volatilitas (*conditional variance*) menggunakan model *univariate* GARCH. Pada penelitian selanjutnya dapat digunakan

model *multivariate* GARCH dengan menambahkan variabel yang terkait dengan volatilitas *return* saham.

2. Penelitian ini menghitung VaR dan ES dengan pendekatan parametrik berbasis model statistik untuk menggambarkan dinamika volatilitas *return* saham. Pada penelitian selanjutnya, dapat digunakan pendekatan model volatilitas yang berbasis *deep learning* seperti model *Artificial Neural Network* (ANN).



DAFTAR PUSTAKA

- Adamko, P., Spuchlakova, E., & Valaškova, K. (2015). The History and Ideas Behind VaR. *Procedia Economics and Finance*, 24(July), 18–24. [https://doi.org/10.1016/s2212-5671\(15\)00607-3](https://doi.org/10.1016/s2212-5671(15)00607-3)
- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*. <https://doi.org/10.1109/TAC.1974.1100705>
- Alexander, C. (2008a). *Market Risk Analysis, Volume III: Pricing, Hedging and Trading Financial Instruments*. John Wiley & Sons.
- Alexander, C. (2008b). *Market Risk Analysis Volume IV: Value at Risk Models*.
- Aliyev, F., Ajayi, R., & Gasim, N. (2020). Modelling asymmetric market volatility with univariate GARCH models: Evidence from Nasdaq-100. *Journal of Economic Asymmetries*. <https://doi.org/10.1016/j.jeca.2020.e00167>
- Ang, R. (1997). *Buku Pintar Pasar Modal Indonesia (The Intelligent Guide to Indonesia Capital Market)*.
- Angelidis, T., Benos, A., & Degiannakis, S. (2004). The use of GARCH models in VaR estimation. *Statistical Methodology*. <https://doi.org/10.1016/j.stamet.2004.08.004>
- Black, F. (1976). Studies of Stock Price Volatility Changes. *Journal of the American Statistical Association*.
- Bollerslev, T. (1986). Generalized Autogressive Conditional Heteroscedasticity. *Journal of Econometrics*.
- Bollerslev, T., Patton, A. J., & Quaedvlieg, R. (2020). Multivariate leverage effects and realized semicovariance GARCH models. *Journal of Econometrics*, 217(2), 411–430. <https://doi.org/10.1016/j.jeconom.2019.12.011>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2016). *Time Series Analysis: Forecasting and Control*. Wiley.
- Brooks, C. (2008). *Introductory Econometrics for Finance* (2nd ed.). Cambridge University Press.
- Cai, Y. (2020). Estimating Expected Shortfall Using a Quantile Function Model. *International Journal of Finance and Economics*, (December 2019), 1–29. <https://doi.org/10.1002/ijfe.2017>
- Chen, J. (2020). Defensive Stock. Retrieved December 7, 2020, from <https://www.investopedia.com/terms/d/defensivestock.asp>
- Christoffersen, P. F. (1998). Evaluating Interval Forecasts. *International Economic Review*, 39(4).

- Dañielsson, J. (2011). *Financial Risk Forecasting: The Theory and Practice of Forecasting Market Risk with Implementation in R and Matlab*. Chichester: John Wiley & Sons.
- Dickey, D. A., & Fuller, W. A. (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica*, 49(4), 1057–1072.
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*. <https://doi.org/10.2307/1912773>
- Engle, R. F., & Ng, V. K. (1993). Measuring and testing the impact of news on volatility. *The Journal of Finance*.
- Erginbay, U., Thalassinos, E., & Muratoglu, Y. (2014). Modeling Volatility in the Stock Markets using GARCH Models: European Emerging Economies and Turkey. *International Journal of Economics and Business Administration*. <https://doi.org/10.35808/ijeba/49>
- Fisher, T. J., & Gallagher, C. M. (2012). New weighted portmanteau statistics for time series goodness of fit testing. *Journal of the American Statistical Association*. <https://doi.org/10.1080/01621459.2012.688465>
- Fitri, A. N. (2020). Hartadinata Abadi (HRTA) catat penurunan penjualan di momen Lebaran tahun ini. Retrieved from KONTAN.CO.ID website: <https://industri.kontan.co.id/news/hartadinata-abadi-hrta-catat-penurunan-penjualan-di-momen-lebaran-tahun-ini>
- Fraser, J. R. S., Simkins, B., & Narvaez, K. (2014). *Implementing Enterprise Risk Management: Case Studies and Best Practices*. Wiley.
- Ghalanos, A. (2020a). Introduction to the rugarch package. (Version 1.4-3). Retrieved November 11, 2020, from https://cran.r-project.org/web/packages/rugarch/vignettes/Introduction_to_the_rugarch_package.pdf
- Ghalanos, A. (2020b). *rugarch: Univariate GARCH models*.
- Gitman, L. J. (2006). *Principle of Managerial Finance*. Pearson.
- Glosten, L. R., Jagannathan, R., & Runkle, D. E. (1993). On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. *The Journal of Finance*, 48(5), 1779–1801. <https://doi.org/10.1111/j.1540-6261.1993.tb05128.x>
- Grünwald, P. (2007). *The Minimum Description Length Principle (Adaptive Computation and Machine Learning)*. The MIT Press.

- Gujarati, D. N., & Porter, D. C. (2008). *Basic Econometrics* (5th ed.). McGraw-Hill.
- Hanck, C., Arnold, M., Gerber, A., & Schmelzer, M. (2020). Introduction to Econometrics with R. Retrieved from <https://www.econometrics-with-r.org>
- Hansen, P. R., & Lunde, A. (2005). A forecast comparison of volatility models: Does anything beat a GARCH(1,1)? *Journal of Applied Econometrics*. <https://doi.org/10.1002/jae.800>
- Hartadinata Abadi. (2021). *Annual Report 2020*. Retrieved from <https://www.hartadinataabadi.co.id/storage/app/uploads/public/60d/c68/62a/60dc6862ace12540023645.pdf>
- Ho, R. (2013). *Handbook of Univariate and Multivariate Data Analysis with IBM SPSS* (2, Ed.). <https://doi.org/10.1080/02664763.2015.1015811>
- Holton, G. A. (2014). Value-at-Risk: Theory and Practice. Retrieved July 10, 2021, from www.value-at-risk.net
- Hull, J. C. (2018). *Risk Management and Financial Institutions* (5th ed.). Hoboken: John Wiley & Sons.
- Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: principles and practice. Retrieved November 6, 2020, from OTexts.com/fpp2
- Indofood CBP. (2021). *Annual Report 2020*. Retrieved from http://www.indofoodcbp.com/uploads/annual/ICBP - AR 2020 Preview_web version.pdf
- Indonesia Stock Exchange. (2020). *IDX Statistics 2020*.
- Integra Group. (2021). *Annual Report 2020*. Retrieved from https://www.integragroup-indonesia.com/wp-content/uploads/2021/06/INTEGRA02_Annual-Report_2020_JUNE_28_hiress.pdf
- Jogiyanto, H. M. (2010). *Teori portofolio dan analisis investasi*. Yogyakarta: BPFÉ.
- Jorion, P. (2007). *Value at Risk The New Benchmark for Managing Financial Risk* (3rd ed.). McGraw-Hill.
- Juanda, B., & Junaidi. (2012). *Ekonometrika Deret Waktu: Teori dan Aplikasi*. Bogor: IPB Press.
- Kalbe. (2021). *2020 Annual Report*. Retrieved from <http://www.kalbe.co.id/Portals/0/pdf/annual-report/AR Kalbe 2020.pdf>
- Kissell, R. (2014). *The Science of Algorithmic Trading and Portfolio Management*. <https://doi.org/10.1016/C2012-0-00818-6>

- Kupiec, P. H. (1995). Techniques for Verifying the Accuracy of Risk Measurement Models. *The Journal of Derivatives*, 3(2), 73–84.
<https://doi.org/10.3905/jod.1995.407942>
- Levendis, J. D. (2018). Time Series Econometrics: Learning Through Replication. In *Springer Texts in Business and Economics*. <https://doi.org/10.1007/978-3-319-98282-3>
- Li, W. K., Ling, S., & McAleer, M. (2002). Recent theoretical results for time series models with GARCH errors. *Journal of Economic Surveys*.
<https://doi.org/10.1111/1467-6419.00169>
- Mann, P. S. (2016). *Introductory Statistics* (9, Ed.). Wiley.
- Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77–91.
<https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- 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*, 7(3–4), 271–300. [https://doi.org/10.1016/S0927-5398\(00\)00012-8](https://doi.org/10.1016/S0927-5398(00)00012-8)
- Miron, D., & Tudor, C. (2010). Asymmetric conditional volatility models: Empirical estimation and comparison of forecasting accuracy. *Romanian Journal of Economic Forecasting*.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction Time Series Analysis and Forecasting (2nd ed.)*.
- Muijs, D. (2004). *Quantitative research*.
<https://doi.org/10.7748/ns.29.31.44.e8681>
- Natenberg, S. (2007). *Option Volatility Trading Strategies*. Wiley.
- PKSK. (2020). *IHSG - Sektoral*.
- Putra. (2020). Bak "Tahu Bulat Digoreng Dadakan", 14 Saham Kena Auto Reject. Retrieved from CNBC Indonesia website:
<https://www.cnbcindonesia.com/market/20201208045123-17-207520/bak-tahu-bulat-digoreng-dadakan-14-saham-kena-auto-reject>
- R Core Team. (2013). *R: A language and environment for statistical computing*. Retrieved from <http://www.r-project.org/>
- Roccioletti, S. (2016). *Backtesting Value at Risk and Expected Shortfall*. Springer Gabler.
- Rockafellar, R. T., & Uryasev, S. (2002). Conditional value-at-risk for general loss distributions. *Journal of Banking and Finance*, 26(7), 1443–1471.
[https://doi.org/10.1016/S0378-4266\(02\)00271-6](https://doi.org/10.1016/S0378-4266(02)00271-6)

- Sampoerna. (2021). *Annual Report 2020*. Retrieved from https://www.sampoerna.com/resources/docs/default-source/sampoerna-market-documents/annual-reports---en/annual-report-2020.pdf?sfvrsn=c0cf95b4_2
- Sari, L. K., Achsani, N. A., & Sartono, B. (2017). Pemodelan Volatilitas Return Saham: Studi Kasus Pasar Saham Asia. *Jurnal Ekonomi Dan Pembangunan Indonesia*. <https://doi.org/10.21002/jepi.v18i1.717>
- Sarykalin, S. (2008). *Value-at-Risk vs. Conditional Value-at-Risk in Risk Management and Optimization*. <https://doi.org/10.1287/educ.1080.0052>
- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*.
- Spierdijk, L. (2016). Confidence intervals for ARMA–GARCH Value-at-Risk: The case of heavy tails and skewness. *Computational Statistics and Data Analysis*, 100, 545–559. <https://doi.org/10.1016/j.csda.2014.08.011>
- Tandelilin, E. (2010). *Portofolio dan Investasi: Teori dan aplikasi*. Kanisius.
- Trochim, W. M. K. (2006). Research Methods Knowledge Base. Retrieved December 11, 2020, from <https://conjointly.com/kb/descriptive-statistics/>
- Tsay, R. S. (2010). *Analysis of Financial Time Series* (3rd ed.). John Wiley & Sons.
- Unilever Indonesia. (2021). *2020 Annual Reports*. Retrieved from https://www.unilever.co.id/id/Images/ar_uli_2020_270421_dv_19.51_comple-te-with-lk_compressed_tags_tcm1310-561142_1_id.pdf
- Uryasev, S., & Rockafellar, R. T. (2001). Conditional Value-at-Risk: Optimization Approach. In S. Uryasev & P. M. Pardalos (Eds.), *Stochastic Optimization: Algorithms and Applications* (pp. 411–435). https://doi.org/10.1007/978-1-4757-6594-6_17
- Wu, G. (2001). The Determinants of Asymmetric Volatility. *Review of Financial Studies*. <https://doi.org/10.1093/rfs/14.3.837>
- Yamai, Y., & Yoshiba, T. (2005). Value-at-risk versus expected shortfall: A practical perspective. *Journal of Banking and Finance*, 29(4), 997–1015. <https://doi.org/10.1016/j.jbankfin.2004.08.010>
- Zivot, E., & Wang, J. (2005). *Modelling Financial Time Series with S-PLUS*. https://doi.org/10.1111/j.1467-985x.2007.00506_20.x

LAMPIRAN

Lampiran 1: **Harga Penutupan Saham Harian 6 Perusahaan Sektor Konsumer**

No	Tanggal	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
1	02/01/2007	690.00	365.53	248.00	1,330.00	-	-
2	03/01/2007	695.00	363.64	250.00	1,300.00	-	-
3	04/01/2007	690.00	361.76	250.00	1,270.00	-	-
4	05/01/2007	700.00	361.76	250.00	1,290.00	-	-
5	08/01/2007	710.00	367.41	252.00	1,270.00	-	-
...
...
3458	22/12/2020	9,600.00	1,520.00	1,505.00	7,475.00	580.00	270.00
3459	23/12/2020	9,525.00	1,505.00	1,465.00	7,425.00	580.00	258.00
3460	28/12/2020	9,475.00	1,505.00	1,500.00	7,450.00	570.00	266.00
3461	29/12/2020	9,300.00	1,515.00	1,490.00	7,350.00	560.00	258.00
3462	30/12/2020	9,575.00	1,505.00	1,480.00	7,350.00	560.00	244.00

Sumber: *finance.yahoo.com*.

Lampiran 2: **Return Saham Harian 6 Perusahaan Sektor Konsumer**

No	Tanggal	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
1	03/01/2007	0.0072	-0.0052	0.0080	-0.0228	-	-
2	04/01/2007	-0.0072	-0.0052	0.0000	-0.0233	-	-
3	05/01/2007	0.0144	0.0000	0.0000	0.0156	-	-
4	08/01/2007	0.0142	0.0155	0.0080	-0.0156	-	-
5	09/01/2007	-0.0071	0.0153	0.0079	-0.0402	-	-
...
...
3457	22/12/2020	-0.0181	-0.0066	-0.0262	-0.0199	-0.0339	-0.0292
3458	23/12/2020	-0.0078	-0.0099	-0.0269	-0.0067	0.0000	-0.0455
3459	28/12/2020	-0.0053	0.0000	0.0236	0.0034	-0.0174	0.0305
3460	29/12/2020	-0.0186	0.0066	-0.0067	-0.0135	-0.0177	-0.0305
3461	30/12/2020	0.0291	-0.0066	-0.0067	0.0000	0.0000	-0.0558

Sumber: *finance.yahoo.com*, telah diolah kembali.



Lampiran 3: Sintaks R - Persiapan Data

```

# library yang digunakan
library(quantmod)
library(tidyverse)
library(gridExtra)
library(psych)
library(tseries)
library(urca)
library(lmtest)
library(aTSA)
library(rugarch)

# kode saham yang ingin dianalisis
kode ← c("ICBP.JK", "HMSP.JK", "KLBF.JK", "UNVR.JK", "WOOD.JK", "HRTA.JK")

# menarik data harga saham harian
data_saham ← NULL
for (k in kode) {
  data_saham[[k]] ←
    getSymbols.yahoo(k, to="2020-12-31", auto.assign=FALSE)
  data_saham[[k]] ←
    data_saham[[k]][,4] %>% setNames(., "price")
  data_saham[[k]] ←
    data.frame(date=index(data_saham[[k]]), coredata(data_saham[[k]]))
}

# menghitung continuously compounded return
data_saham ← lapply(setNames(kode, kode), function(x) {
  data_saham[[x]] = data_saham[[x]] %>% na.omit()
  return = diff(log(data_saham[[x]]$price))
  data_saham[[x]] = data_saham[[x]][-1,]
  data_saham[[x]]$return = return
  data_saham[[x]]
})

```

Lampiran 4: Sintaks R - Grafik Harga dan Return Saham

```

# membuat object grafik harga dan return saham
plot ← sapply(setNames(kode, kode), function(x) {
  plot ← NULL
  plot$harga ←
    qplot(date, price, data=data_saham[[x]], geom="line", xlab="") +
    theme_bw()
  plot$return ←
    qplot(date, return, data=data_saham[[x]], geom="line", xlab="") +
    theme_bw()
  plot
})

# plot harga & return saham 1
do.call('grid.arrange', c(plot[1:6], list(nrow=3, top="")))

# plot harga & return saham 2
do.call('grid.arrange', c(plot[7:12], list(nrow=3, top="")))

```


Lampiran 5: Sintaks R - Statistik Deskriptif

```
# statistik deskriptif
statistik_deskriptif ← NULL
for (k in kode) {
  statistik ← data.frame(describe(data_saham[[k]]$return))
  statistik_deskriptif ← cbind(statistik_deskriptif, t(statistik))
}
colnames(statistik_deskriptif) ← kode

uji_normalitas ← NULL
for (k in kode) {
  jb_test ← data.frame(c(jarque.bera.test(data_saham[[k]]$return)))
  uji_normalitas = rbind(uji_normalitas, jb_test[,c(1,3)])
}
colnames(uji_normalitas) ← c("jb_statistic", "jb_pvalue")

statistik_deskriptif ←
  round(rbind(statistik_deskriptif, t(uji_normalitas)),4)

(statistik_deskriptif ←
  statistik_deskriptif[c(3,5,8,9,4,11,12,14,15,2),])
```

Lampiran 6: Sintaks R - Uji Stasioneritas

```
# uji stasioneritas
uji_satsioneritas ← NULL
for (k in kode) {
  h ← trunc((length(data_saham[[k]]$return)-1)^(1/3))
  adf ←
    ur.df(data_saham[[k]]$return, lags=h)@ttestreg$coefficients
  uji_satsioneritas ←
    rbind(uji_satsioneritas, round(adf[1,c(3,4)], 4))
}

(uji_satsioneritas ←
  data.frame(t(uji_satsioneritas)) %>% setNames(.,kode))
```

Lampiran 7: Sintaks R - Plot ACF dan PACF

```
# membuat plot acf dan pacf
for (k in kode) {
  par(mfrow=c(1, 2), mar=c(3, 4, 2, 1), mgp=c(2.5,1,0))
  Acf(data_saham[[k]]$return, main="", xlab="")
  Pacf(data_saham[[k]]$return, main="", xlab="", ylab="PACF")
  # title(paste0("Plot ACF dan PACF ",k),outer=TRUE,line=-1.25)
}
```

Lampiran 8: Sintaks R - Fungsi ARMA

```
# fungsi untuk mengestimasi parameter model ARMA
ARMA ← function (data, order_list, fixed_par = FALSE) {
  estimasi ← NULL
  for (order in order_list) {
    if (fixed_par == TRUE) {

      fixed ← append(rep(0, length.out = sum(order)), NA)

      fixed[c(order[1], sum(order[-2]))] ← NA

      model ←
        arima(data, order, fixed=fixed, transform.pars=FALSE, method="ML")
    }
    else {
      model ← arima(data, order, method="ML")
    }
    ljung_box ←
      Box.test(
        residuals(model),
        lag = min(10, length(data)/5),
        type = "Ljung-Box",
        fitdf = sum(order[-2])
      )
    diagnostik ←
      as.data.frame(
        list(
          "Order" = toString(order),
          "Chi-squared" = ljung_box$statistic,
          "Prob." = ljung_box$p.value,
          "log likelihood" = logLik(model),
          "AIC" = AIC(model),
          "BIC" = BIC(model)
        ),
        row.names = NULL
      )
    estimasi$parameter ←
      rbind(estimasi$parameter, round(coeftest(model),4))

    estimasi$diagnostik ←
      rbind(estimasi$diagnostik, diagnostik)
  }
  return(estimasi)
}
```


Lampiran 9: Sintaks R - Estimasi Parameter ARMA

```

# estimasi parameter model ARMA return ICBP
model_arma ← NULL
icbp_order ← list(c(3,0,0), c(0,0,3), c(3,0,3))
model_arma$ICBP.JK ←
  ARMA(data_saham$ICBP.JK$return, icbp_order, fixed_par=TRUE)

# estimasi parameter model ARMA return Hmsp
hmsp_order ←
  list(c(2,0,0), c(0,0,2), c(2,0,2), c(4,0,0), c(0,0,4), c(4,0,4))
model_arma$Hmsp.JK ←
  ARMA(data_saham$Hmsp.JK$return, hmsp_order, fixed_par=TRUE)

# estimasi parameter model ARMA return KLBf
klbf_order ← list(c(4,0,0), c(0,0,4), c(4,0,4), c(6,0,0), c(0,0,6))
model_arma$KLBf.JK ←
  ARMA(data_saham$KLBf.JK$return, klbf_order, fixed_par=TRUE)

# estimasi parameter model ARMA return UNVR
unvr_order ← list(c(1,0,1), c(5,0,0), c(0,0,3))
model_arma$UNVR.JK ← ARMA(data_saham$UNVR.JK$return, unvr_order)

# estimasi parameter model ARMA return WOOD
wood_order ← list(c(6,0,0), c(0,0,6))
model_arma$WOOD.JK ←
  ARMA(data_saham$WOOD.JK$return, wood_order, fixed_par=TRUE)

# estimasi parameter model ARMA return HRTA
hrta_order ← list(c(5,0,0), c(0,0,5), c(5,0,5))
model_arma$HRTA.JK ←
  ARMA(data_saham$HRTA.JK$return, hrta_order, fixed_par=TRUE)

```

Lampiran 10: Sintaks R - Pemeriksaan Diagnostik Model ARMA

```

# fungsi untuk melakukan pemeriksaan diagnostik model ARMA
pemeriksaan_diagnostik ← function (diagnostik) {
  diagnostik ← diagnostik %>%
    mutate(skor1=if_else(log.likelihood==max(diagnostik[4]),1,0)) %>%
    mutate(skor2 = if_else(AIC == min(diagnostik[5]), 1, 0)) %>%
    mutate(skor3 = if_else(BIC == min(diagnostik[6]), 1, 0)) %>%
    rowwise() %>% mutate(skor_total = sum(c_across(skor1:skor3))) %>%
    mutate(Keterangan = case_when(
      Prob. ≥ 0.05 & skor_total ≥ 2 ~ "Model Terbaik",
      Prob. < 0.05 ~ "Tereliminasi")) %>%
    select(-starts_with("skor"))
}

# pemeriksaan diagnostik model ARMA
for (k in kode) {
  model_arma[[k]]$diagnostik ←
    pemeriksaan_diagnostik(model_arma[[k]]$diagnostik)
  cat("\nPemeriksaan diagnostik return ", k)
  print(model_arma[[k]]$diagnostik)
}

```

Lampiran 11: **Sintaks R - Estimasi Parameter ARMA Ke-2**

```
# estimasi parameter model ARMA return HMSP ke-2
hmsp_order ←
  list(c(2,0,0), c(0,0,2), c(2,0,2), c(4,0,0), c(0,0,4), c(4,0,4))
model_arma$HMSP.JK ← ARMA(data_saham$HMSP.JK$return, hmsp_order)

# estimasi parameter model ARMA return KLBK ke-2
klbf_order ←
  list(c(4,0,0), c(0,0,4), c(4,0,4), c(6,0,0), c(0,0,6))
model_arma$KLBK.JK ← ARMA(data_saham$KLBK.JK$return, klbf_order)

# estimasi parameter model ARMA return HRTA ke-2
hrta_order ← list(c(5,0,0), c(0,0,5))
model_arma$HRTA.JK ←
  ARMA(data_saham$HRTA.JK$return, hrta_order, fixed_par=TRUE)

# pemeriksaan diagnostik model ARMA ke-2
for (k in c("HMSP.JK", "KLBK.JK", "HRTA.JK")) {
  model_arma[[k]]$diagnostik ←
    pemeriksaan_diagnostik(model_arma[[k]]$diagnostik)
  cat("\nPemeriksaan diagnostik return ", k)
  print(model_arma[[k]]$diagnostik)
}
```

Lampiran 12: **Sintaks R - Kombinasi Ordo ARMA Terbaik**

```
# kombinasi ordo terbaik dari model ARMA
ordo_terbaik ← NULL
for (k in kode) {
  ordo_terbaik[[k]] ← model_arma[[k]]$diagnostik %>%
    filter(Keterangan = "Model Terbaik") %>% select(Order)
  ordo_terbaik[[k]] ←
    as.numeric(unlist(str_split(ordo_terbaik[[k]], ", ")))
}
print(ordo_terbaik)
```

Lampiran 13: **Output R - Kombinasi Ordo ARMA Terbaik**

```
$ICBP.JK
[1] 0 0 3

$HMSP.JK
[1] 4 0 4

$KLBK.JK
[1] 4 0 4

$UNVR.JK
[1] 1 0 1

$WOOD.JK
[1] 0 0 6

$HRTA.JK
[1] 0 0 5
```


Lampiran 14: Sintaks R - Uji Efek ARCH

```

# uji LM (efek arch)
uji_arch_lm ← NULL
fixed_model ← c("ICBP.JK", "WOOD.JK", "HRTA.JK")
for (k in kode) {
  if (k %in% fixed_model) {
    fixed ←
      append(rep(0, length.out = sum(ordo_terbaik[[k]])), NA)

    fixed[c(ordo_terbaik[[k]][1],
            sum(ordo_terbaik[[k]][-2]))] ← NA
    model ←
      arima(data_saham[[k]]$return, ordo_terbaik[[k]],
            fixed=fixed, transform.pars=FALSE, method="ML")
  }
  else {
    model ←
      arima(data_saham[[k]]$return,
            ordo_terbaik[[k]], method = "ML")
  }
  uji_arch_lm[[k]] ←
    data.frame(round(arch.test(model, output=FALSE)), 4)[-2:-3]
}
print(uji_arch_lm)

```

Lampiran 15: Sintaks R - Fungsi GARCH

```

# fungsi untuk mengestimasi parameter model GARCH
GARCH ← function(data, ordo_arma=c(0,0),
                 model="sGARCH",
                 ordo_garch=c(1,1),
                 dist="sstd",
                 fixed_par=NULL) {
  spesifikasi ←
    ugarchspec(
      variance.model = list(model=model, garchOrder=ordo_garch),
      mean.model = list(armaOrder = ordo_arma),
      fixed.pars = fixed_par,
      distribution.model = dist
    )
  df ← ugarchfit(spesifikasi, data = data)
}

```

Lampiran 16: Sintaks R - Estimasi GARCH dan Pemeriksaan Diagnostik

```
# estimasi parameter model ARMA-GARCH return ICBP
model_garch ← NULL
model_garch$ICBP.JK ←
  GARCH(data_saham$ICBP.JK$return, ordo_terbaik$ICBP.JK[-2],
        fixed_par=list(ma1=0,ma2=0))
# estimasi parameter model ARMA-GARCH return HMSP
model_garch$HMSP.JK ←
  GARCH(data_saham$HMSP.JK$return, ordo_terbaik$HMSP.JK[-2])
# estimasi parameter model ARMA-GARCH return KLBF
model_garch$KLBF.JK ←
  GARCH(data_saham$KLBF.JK$return, ordo_terbaik$KLBF.JK[-2])
# estimasi parameter model ARMA-GARCH return UNVR
model_garch$UNVR.JK ←
  GARCH(data_saham$UNVR.JK$return, ordo_terbaik$UNVR.JK[-2])
# estimasi parameter model ARMA-GARCH return WOOD
model_garch$WOOD.JK ←
  GARCH(data_saham$WOOD.JK$return, ordo_terbaik$WOOD.JK[-2],
        fixed_par=list(ma1=0,ma2=0,ma3=0,ma4=0,ma5=0))
# estimasi parameter model ARMA-GARCH return HRTA
model_garch$HRTA.JK ←
  GARCH(data_saham$HRTA.JK$return, ordo_terbaik$HRTA.JK[-2],
        fixed_par=list(ma1=0,ma2=0,ma3=0,ma4=0))

# pemeriksaan dignostik garch
sapply(model_garch, print)
```

Lampiran 17: Output R - Estimasi GARCH ICBP

```
*-----*
```

* GARCH Model Fit *

```
*-----*
```

Conditional Variance Dynamics

```
-----
```

GARCH Model : sGARCH(1,1)
Mean Model : ARFIMA(0,0,3)
Distribution : sstd

Conditional Variance Dynamics

```
-----
```

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000791	0.00027	2.9354	0.003332
ma1	0	NA	NA	NA
ma2	0	NA	NA	NA
ma3	-0.059947	0.01676	-3.5767	0.000348
omega	1.3E-05	4E-06	3.6946	0.00022
alpha1	0.160763	0.021045	7.6389	0
beta1	0.838237	0.018183	46.1009	0
skew	1.068087	0.021466	49.7568	0
shape	3.860592	0.341241	11.3134	0



Lampiran 18: **Output R – Uji Weighted ARCH LM ICBP**

Weighted ARCH LM Tests					

		Statistic	Shape	Scale	P-Value
ARCH	Lag[3]	0.08296	0.5	2	0.7733
ARCH	Lag[5]	2.09789	1.44	1.667	0.45
ARCH	Lag[7]	4.30543	2.315	1.543	0.3047

Lampiran 19: **Output R – Uji Sign Bias ICBP**

Sign Bias Test			

	t-value	prob	sig
Sign Bias	0.2198	0.826	
Negative Sign Bias	0.6735	0.5007	
Positive Sign Bias	1.3555	0.1753	
Joint Effect	3.4402	0.3286	

Lampiran 20: **Output R - Estimasi GARCH HMSP**

* GARCH Model Fit *				

Conditional Variance Dynamics				

GARCH Model	: sGARCH(1,1)			
Mean Model	: ARFIMA(4,0,4)			
Distribution	: sstd			
Conditional Variance Dynamics				

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000249	0.000184	1.3544	0.1756
ar1	0.267732	0.001604	166.9304	0
ar2	0.388118	0.001051	369.1657	0
ar3	0.581882	0.000234	2489.134	0
ar4	-0.765733	0.001013	-755.9879	0
ma1	-0.307961	6.2E-05	-4975.028	0
ma2	-0.40742	0.000952	-427.8756	0
ma3	-0.574341	0.000176	-3258.251	0
ma4	0.801331	0.000123	6508.7992	0
omega	1.7E-05	2E-06	7.9074	0
alpha1	0.266943	0.024837	10.7477	0
beta1	0.732057	0.021351	34.2869	0
skew	1.048548	0.017395	60.2789	0
shape	2.741259	0.081205	33.7572	0



Lampiran 21: **Output R – Uji Weighted ARCH LM HMSP**

Weighted ARCH LM Tests					

		Statistic	Shape	Scale	P-Value
ARCH	Lag[3]	0.3867	0.5	2	0.534
ARCH	Lag[5]	0.7589	1.44	1.667	0.8055
ARCH	Lag[7]	0.9848	2.315	1.543	0.916

Lampiran 22: **Output R – Uji Sign Bias HMSP**

Sign Bias Test			

	t-value	prob	sig
Sign Bias	0.2122	0.8319	
Negative Sign Bias	1.5484	0.1216	
Positive Sign Bias	0.7832	0.4335	
Joint Effect	3.0204	0.3885	

Lampiran 23: **Output R - Estimasi GARCH KLBF**

* GARCH Model Fit *				

Conditional Variance Dynamics				

GARCH Model	: sGARCH(1,1)			
Mean Model	: ARFIMA(4,0,4)			
Distribution	: sstd			
Conditional Variance Dynamics				

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000402	0.000257	1.56355	0.117923
ar1	-0.888764	0.127618	-6.96425	0
ar2	0.213044	0.08076	2.63798	0.00834
ar3	0.243868	0.253489	0.96204	0.336028
ar4	-0.231956	0.101991	-2.27427	0.022949
ma1	0.806075	0.128558	6.27013	0
ma2	-0.329993	0.02571	-12.8351	0
ma3	-0.296496	0.236655	-1.25286	0.210257
ma4	0.218685	0.081637	2.67876	0.00739
omega	3.4E-05	9E-06	3.81364	0.000137
alpha1	0.199652	0.033666	5.93046	0
beta1	0.764822	0.037918	20.17022	0
skew	1.025822	0.021484	47.74856	0
shape	3.911261	0.290549	13.4616	0



Lampiran 24: **Output R – Uji Weighted ARCH LM KLBF**

Weighted ARCH LM Tests					

		Statistic	Shape	Scale	P-Value
ARCH	Lag[3]	1.312	0.5	2	0.2521
ARCH	Lag[5]	1.68	1.44	1.667	0.5463
ARCH	Lag[7]	2.04	2.315	1.543	0.7089

Lampiran 25: **Output R – Uji Sign Bias KLBF**

Sign Bias Test			

	t-value	prob	sig
Sign Bias	1.13368	0.257	
Negative Sign Bias	0.20851	0.8348	
Positive Sign Bias	0.09109	0.9274	
Joint Effect	2.13397	0.5451	

Lampiran 26: **Output R - Estimasi GARCH UNVR**

* GARCH Model Fit *				

Conditional Variance Dynamics				

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

	Estimate	Std. Error	t value	Pr(> t)
mu	0.000285	0.000187	1.5269	0.126793
ar1	0.585652	0.05786	10.1219	0
ma1	-0.70673	0.050309	-14.0478	0
omega	1.2E-05	4E-06	2.9472	0.003207
alpha1	0.150914	0.019712	7.6558	0
beta1	0.837874	0.009785	85.63	0
skew	1.033286	0.02191	47.1597	0
shape	4.175541	0.320711	13.0196	0



Lampiran 27: **Output R – Uji Weighted ARCH LM UNVR**

Weighted ARCH LM Tests					

		Statistic	Shape	Scale	P-Value
ARCH	Lag[3]	0.03356	0.5	2	0.8546
ARCH	Lag[5]	1.14394	1.44	1.667	0.6907
ARCH	Lag[7]	2.15418	2.315	1.543	0.6847

Lampiran 28: **Output R – Uji Sign Bias UNVR**

Sign Bias Test			

	t-value	prob	sig
Sign Bias	0.9173	0.359	
Negative Sign Bias	1.1631	0.2449	
Positive Sign Bias	1.0192	0.3082	
Joint Effect	2.4287	0.4883	

Lampiran 29: **Output R - Estimasi GARCH WOOD**

* GARCH Model Fit *				

Conditional Variance Dynamics				

GARCH Model	: sGARCH(1,1)			
Mean Model	: ARFIMA(0,0,6)			
Distribution	: sstd			
Conditional Variance Dynamics				

	Estimate	Std. Error	t value	Pr(> t)
mu	0.001553	0.000946	1.64086	0.100827
ma1	0	NA	NA	NA
ma2	0	NA	NA	NA
ma3	0	NA	NA	NA
ma4	0	NA	NA	NA
ma5	0	NA	NA	NA
ma6	0.018168	0.023622	0.76909	0.441838
omega	0.000217	0.000105	2.06445	0.038975
alpha1	0.311425	0.136276	2.28525	0.022298
beta1	0.687575	0.084365	8.14999	0
skew	1.280126	0.054639	23.42872	0
shape	2.536426	0.294259	8.61971	0



Lampiran 30: **Output R – Uji Weighted ARCH LM WOOD**

Weighted ARCH LM Tests					

		Statistic	Shape	Scale	P-Value
ARCH	Lag[3]	0.2244	0.5	2	0.6357
ARCH	Lag[5]	0.9655	1.44	1.667	0.7432
ARCH	Lag[7]	1.5822	2.315	1.543	0.8047

Lampiran 31: **Output R – Uji Sign Bias WOOD**

Sign Bias Test			

	t-value	prob	sig
Sign Bias	0.784	0.4332	
Negative Sign Bias	1.4188	0.1563	
Positive Sign Bias	0.4522	0.6512	
Joint Effect	2.218	0.5284	

Lampiran 32: **Output R - Estimasi GARCH HRTA**

* GARCH Model Fit *				

Conditional Variance Dynamics				

GARCH Model	: sGARCH(1,1)			
Mean Model	: ARFIMA(0,0,5)			
Distribution	: sstd			
Conditional Variance Dynamics				

	Estimate	Std. Error	t value	Pr(> t)
mu	-0.000053	0.000624	-0.085392	0.93195
ma1	0	NA	NA	NA
ma2	0	NA	NA	NA
ma3	0	NA	NA	NA
ma4	0	NA	NA	NA
ma5	-0.049535	NA	NA	NA
omega	0.000042	0.000026	1.620327	0.105162
alpha1	0.191573	0.072408	2.645753	0.008151
beta1	0.807427	0.076273	10.586046	0
skew	1.050811	0.039208	26.800698	0
shape	2.873431	0.2792	10.291646	0



Lampiran 33: **Output R – Uji Weighted ARCH LM HRTA**

Weighted ARCH LM Tests					

		Statistic	Shape	Scale	P-Value
ARCH	Lag[3]	0.3554	0.5	2	0.5511
ARCH	Lag[5]	0.6259	1.44	1.667	0.8459
ARCH	Lag[7]	1.4084	2.315	1.543	0.8395

Lampiran 34: **Output R – Uji Sign Bias HRTA**

Sign Bias Test			

	t-value	prob	sig
Sign Bias	1.44879	0.1477	
Negative Sign Bias	0.70021	0.484	
Positive Sign Bias	0.07077	0.9436	
Joint Effect	2.38433	0.4966	

Lampiran 35: **Sintaks R - Backtesting VaR (99%)**

```
# fungsi untuk backtesting
rolling <- function(data, model_garch, alpha,
                    forecast_length, reestimasi) {
  df <- NULL
  for (k in kode) {
    data_xts <- xts(data[[k]]$return, order.by=data[[k]]$date)
    df[[k]] <- ugarchroll(
      spec=getspec(model_garch[[k]]), data=data_xts,
      forecast.length=forecast_length, refit.every=reestimasi,
      n.ahead=1, refit.window="moving", calculate.VaR=TRUE,
      VaR.alpha=alpha, keep.coef=TRUE
    )
  }
  return(df)
}

# backtesting
alpha <- 0.01
forecast_length <- 250
reestimasi <- 50
backtesting <- rolling(data_saham, model_garch, alpha,
                      forecast_length, reestimasi)

# reporting
for (k in kode) {
  cat("\n- ", k, "- ")
  report(backtesting[[k]], type="VaR", VaR.alpha=alpha)
}
```



Lampiran 36: **Output R - ICBP VaR Backtest Report**

Model:		sGARCH-sstd
Backtest Length:	250	
Data:	=====	
alpha:		1.00%
Expected Exceed:	2.5	
Actual VaR Exceed:	4	
Actual %:		1.60%
Unconditional Coverage (Kupiec)		
Null-Hypothesis:	Correct Exceedances	
LR.uc Statistic:	0.769	
LR.uc Critical:	3.841	
LR.uc p-value:	0.38	
Reject Null:	NO	
Conditional Coverage (Christoffersen)		
Null-Hypothesis:	Correct Exceedances and Independence of Failures	
LR.cc Statistic:	0.9	
LR.cc Critical:	5.991	
LR.cc p-value:	0.638	
Reject Null:	NO	

Lampiran 37: **Output R - HMSP VaR Backtest Report**

Model:		sGARCH-sstd
Backtest Length:	250	
Data:	=====	
alpha:		1.00%
Expected Exceed:	2.5	
Actual VaR Exceed:	4	
Actual %:		1.60%
Unconditional Coverage (Kupiec)		
Null-Hypothesis:	Correct Exceedances	
LR.uc Statistic:	0.769	
LR.uc Critical:	3.841	
LR.uc p-value:	0.38	
Reject Null:	NO	
Conditional Coverage (Christoffersen)		
Null-Hypothesis:	Correct Exceedances and Independence of Failures	
LR.cc Statistic:	0.9	
LR.cc Critical:	5.991	
LR.cc p-value:	0.638	
Reject Null:	NO	



Lampiran 38: **Output R - KLBF VaR Backtest Report**

Model:		sGARCH-sstd
Backtest Length:	250	
Data:	=====	
alpha:		1.00%
Expected Exceed:	2.5	
Actual VaR Exceed:	2	
Actual %:		0.80%
Unconditional Coverage (Kupiec)		
Null-Hypothesis:	Correct Exceedances	
LR.uc Statistic:	0.108	
LR.uc Critical:	3.841	
LR.uc p-value:	0.742	
Reject Null:	NO	
Conditional Coverage (Christoffersen)		
Null-Hypothesis:	Correct Exceedances and Independence of Failures	
LR.cc Statistic:	0.141	
LR.cc Critical:	5.991	
LR.cc p-value:	0.932	
Reject Null:	NO	

Lampiran 39: **Output R - UNVR VaR Backtest Report**

Model:		sGARCH-sstd
Backtest Length:	250	
Data:	=====	
alpha:		1.00%
Expected Exceed:	2.5	
Actual VaR Exceed:	3	
Actual %:		1.20%
Unconditional Coverage (Kupiec)		
Null-Hypothesis:	Correct Exceedances	
LR.uc Statistic:	0.095	
LR.uc Critical:	3.841	
LR.uc p-value:	0.758	
Reject Null:	NO	
Conditional Coverage (Christoffersen)		
Null-Hypothesis:	Correct Exceedances and Independence of Failures	
LR.cc Statistic:	0.168	
LR.cc Critical:	5.991	
LR.cc p-value:	0.919	
Reject Null:	NO	



Lampiran 40: **Output R - WOOD VaR Backtest Report**

Model:		sGARCH-sstd
Backtest Length:	250	
Data:	=====	
alpha:		1.00%
Expected Exceed:	2.5	
Actual VaR Exceed:	4	
Actual %:		1.60%
Unconditional Coverage (Kupiec)		
Null-Hypothesis:	Correct Exceedances	
LR.uc Statistic:	0.769	
LR.uc Critical:	3.841	
LR.uc p-value:	0.38	
Reject Null:	NO	
Conditional Coverage (Christoffersen)		
Null-Hypothesis:	Correct Exceedances and Independence of Failures	
LR.cc Statistic:	0.9	
LR.cc Critical:	5.991	
LR.cc p-value:	0.638	
Reject Null:	NO	

Lampiran 41: **Output R - HRTA VaR Backtest Report**

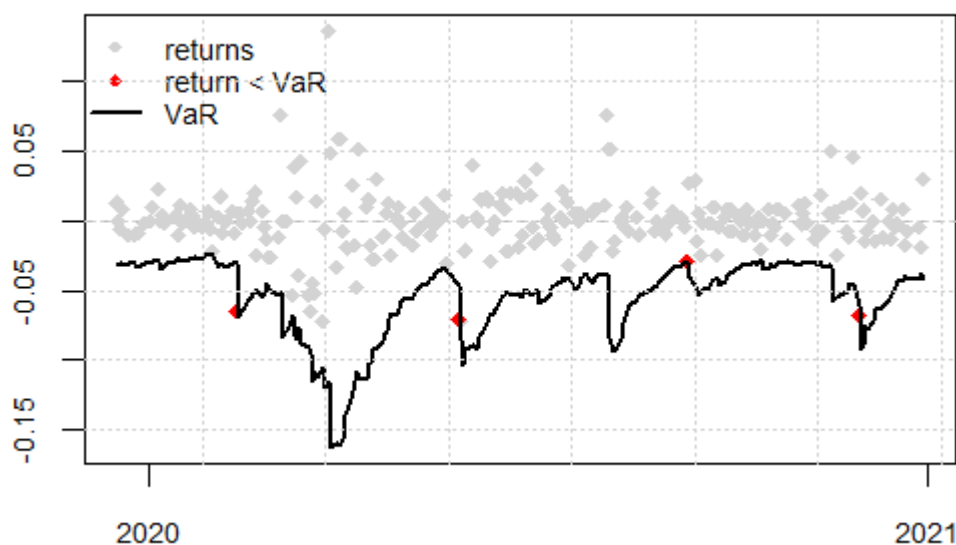
Model:		sGARCH-sstd
Backtest Length:	250	
Data:	=====	
alpha:		1.00%
Expected Exceed:	2.5	
Actual VaR Exceed:	2	
Actual %:		0.80%
Unconditional Coverage (Kupiec)		
Null-Hypothesis:	Correct Exceedances	
LR.uc Statistic:	0.108	
LR.uc Critical:	3.841	
LR.uc p-value:	0.742	
Reject Null:	NO	
Conditional Coverage (Christoffersen)		
Null-Hypothesis:	Correct Exceedances and Independence of Failures	
LR.cc Statistic:	0.141	
LR.cc Critical:	5.991	
LR.cc p-value:	0.932	
Reject Null:	NO	



Lampiran 42: Sintaks R - Grafik Return Saham dengan VaR (99%)

```
# VaR Plot
for (k in kode) {
  par(mfrow=c(1, 1), mar=c(2.5, 2, 2, 1), mgp=c(2.5,1,0), cex=1.5)
  plot(backtesting[[k]], which=4, VaR.alpha=alpha)
  title(main=paste0("Backtesting ",
                    str_replace(k, ".JK", ""), " VaR 99%"))
}
```

Lampiran 43: Output R – Grafik Return ICBP dengan VaR (99%)




Sumber: Hasil Pengolahan Data, 2021.






Lampiran 44: **Output R - Grafik Return HMSP dengan VaR (99%)**



Sumber: Hasil Pengolahan Data, 2021.


Lampiran 45: **Output R - Grafik Return KLBF dengan VaR (99%)**



Sumber: Hasil Pengolahan Data, 2021.

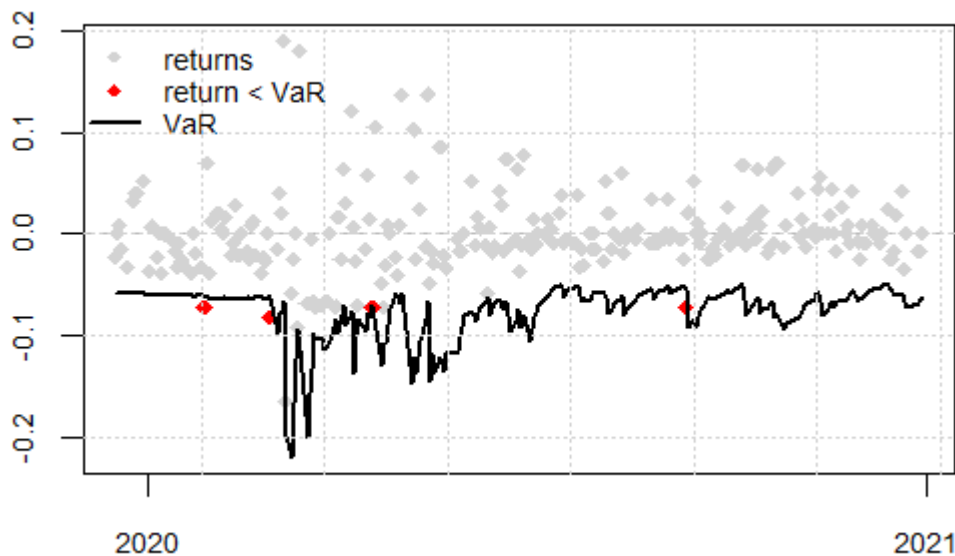


Lampiran 46: **Output R - Grafik Return UNVR dengan VaR (99%)**



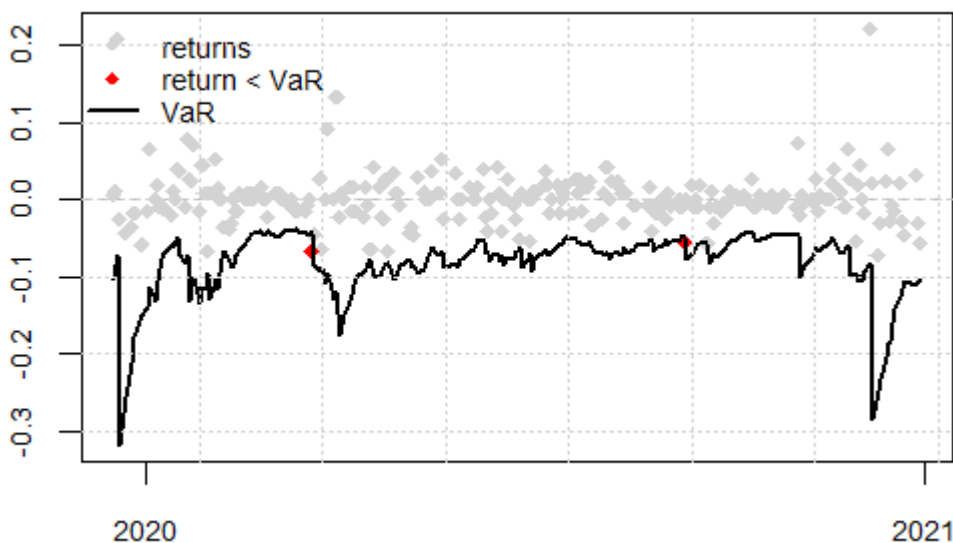
Sumber: Hasil Pengolahan Data, 2021.

Lampiran 47: **Output R - Grafik Return WOOD dengan VaR (99%)**



Sumber: Hasil Pengolahan Data, 2021.

Lampiran 48: **Output R - Grafik Return HRTA dengan VaR (99%)**



Sumber: Hasil Pengolahan Data, 2021.

Lampiran 49: **Sintaks R - Forecasting VaR (99%) 1 Periode ke Depan**

```
# fungsi untuk menghitung nilai VaR
VaR <- function(model_garch, alpha, forecast=FALSE, n_ahead=1) {
  VaR = NULL
  if (forecast = FALSE) {
    for (k in kode) {
      shape <- coef(model_garch[[k]])["shape"]
      skew <- coef(model_garch[[k]])["skew"]
      icdf <- qdist("sstd", alpha, shape=shape, skew=skew)
      mu <- fitted(model_garch[[k]])
      sigma <- sigma(model_garch[[k]])
      VaR[[k]] <- mu + sigma * icdf
      time(VaR[[k]]) <- data_saham[[k]]$date
    }
  }
  else {
    for (k in kode) {
      garch_forecast <-
        ugarchforecast(model_garch[[k]], n.ahead=n_ahead)
      shape <- coef(model_garch[[k]])["shape"]
      skew <- coef(model_garch[[k]])["skew"]
      icdf <- qdist("sstd", alpha, shape=shape, skew=skew)
      mu <- fitted(garch_forecast)[1:n_ahead]
      sigma <- sigma(garch_forecast)[1:n_ahead]
      VaR[[k]] <- mu + sigma * icdf
    }
  }
  return(VaR)
}
#forecasting VaR
VaR99_forecast <- VaR(model_garch, alpha, forecast=TRUE)
sapply(VaR99_forecast, print)
```

Lampiran 50: Sintaks R - *Backtesting ES (99%)*

```

# fungsi untuk menghitung nilai ES
ES ← function(model_garch, alpha, forecast=FALSE, n_ahead=1) {
  ES = NULL
  fungsi_kuantil ←
  function(q) {qdist("sstd", p=q, skew=skew, shape=shape)}
  if (forecast = FALSE) {
    for (k in kode) {
      shape ← coef(model_garch[[k]])["shape"]
      skew ← coef(model_garch[[k]])["skew"]
      mu ← fitted(model_garch[[k]])
      sigma ← sigma(model_garch[[k]])
      ES[[k]] ← mu + sigma * integrate(fungsi_kuantil,
                                      0, alpha)$value/alpha
      time(ES[[k]]) ← data_saham[[k]]$date
    }
  }
  else {
    for (k in kode) {
      garch_forecast ←
      ugarchforecast(model_garch[[k]], n.ahead=n_ahead)
      shape ← coef(model_garch[[k]])["shape"]
      skew ← coef(model_garch[[k]])["skew"]
      mu ← fitted(garch_forecast)[1:n_ahead]
      sigma ← sigma(garch_forecast)[1:n_ahead]
      ES[[k]] ← mu + sigma * integrate(fungsi_kuantil,
                                      0, alpha)$value/alpha
    }
  }
  return(ES)
}

# menghitung nilai VaR
VaR99 ← VaR(model_garch, alpha)

# menghitung nilai ES
ES99 ← ES(model_garch, alpha)

# backtesting ES
ES_backtesting ← NULL
for (k in kode) {
  ES_backtesting[[k]] ←
  ESTest(alpha, data_saham[[k]]$return, ES99[[k]], VaR99[[k]])
}
ES_backtesting

```

Lampiran 51: Sintaks R - *Forecasting ES (99%) 1 Periode ke Depan*

```

#forecasting ES
ES99_forecast ← VaR(model_garch, alpha, forecast=TRUE)
sapply(ES99_forecast, print)

```


Lampiran 52: Hasil *Backtesting* ES (99%) ICBP

\$ICBP.JK	
\$ICBP.JK\$expected.exceed	[1] 34
\$ICBP.JK\$actual.exceed	[1] 31
\$ICBP.JK\$H1	[1] "Mean of Excess Violations of VaR is greater than zero"
\$ICBP.JK\$boot.p.value	[1] NA
\$ICBP.JK\$p.value	[1] 0.7586353
\$ICBP.JK\$Decision	[1] "Fail to Reject H0"



Lampiran 53: Hasil *Backtesting* ES (99%) HMSP

\$HMSP.JK	
\$HMSP.JK\$expected.exceed	[1] 34
\$HMSP.JK\$actual.exceed	[1] 49
\$HMSP.JK\$H1	[1] "Mean of Excess Violations of VaR is greater than zero"
\$HMSP.JK\$boot.p.value	[1] NA
\$HMSP.JK\$p.value	[1] 0.4596605
\$HMSP.JK\$Decision	[1] "Fail to Reject H0"



Lampiran 54: Hasil *Backtesting* ES (99%) KLBF

\$KLBF.JK	
\$KLBF.JK\$expected.exceed	[1] 34
\$KLBF.JK\$actual.exceed	[1] 31
\$KLBF.JK\$H1	[1] "Mean of Excess Violations of VaR is greater than zero"
\$KLBF.JK\$boot.p.value	[1] NA
\$KLBF.JK\$p.value	[1] 0.9429252
\$KLBF.JK\$Decision	[1] "Fail to Reject H0"



Lampiran 55: Hasil *Backtesting* ES (99%) UNVR

\$UNVR.JK	
\$UNVR.JK\$expected.exceed	[1] 34
\$UNVR.JK\$actual.exceed	[1] 27
\$UNVR.JK\$H1	[1] "Mean of Excess Violations of VaR is greater than zero"
\$UNVR.JK\$boot.p.value	[1] NA
\$UNVR.JK\$p.value	[1] 0.8968121
\$UNVR.JK\$Decision	[1] "Fail to Reject H0"



Lampiran 56: Hasil *Backtesting* ES (99%) WOOD

\$WOOD.JK	
\$WOOD.JK\$expected.exceed	[1] 8
\$WOOD.JK\$actual.exceed	[1] 6
\$WOOD.JK\$H1	[1] "Mean of Excess Violations of VaR is greater than zero"
\$WOOD.JK\$boot.p.value	[1] NA
\$WOOD.JK\$p.value	[1] 0.9937894
\$WOOD.JK\$Decision	[1] "Fail to Reject H0"



Lampiran 57: Hasil *Backtesting* ES (99%) HRTA

\$HRTA.JK	
\$HRTA.JK\$expected.exceed	[1] 8
\$HRTA.JK\$actual.exceed	[1] 6
\$HRTA.JK\$H1	[1] "Mean of Excess Violations of VaR is greater than zero"
\$HRTA.JK\$boot.p.value	[1] NA
\$HRTA.JK\$p.value	[1] 0.9983589
\$HRTA.JK\$Decision	[1] "Fail to Reject H0"

Lampiran 58: Hasil Estimasi VaR (99%)

No	Tanggal	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
1	03/01/2007	-0.0568	-0.0486	-0.0601	-0.0515	-	-
2	04/01/2007	-0.0568	-0.0486	-0.0601	-0.0504	-	-
3	05/01/2007	-0.0568	-0.0486	-0.0601	-0.0513	-	-
4	08/01/2007	-0.0548	-0.0486	-0.0601	-0.0516	-	-
5	09/01/2007	-0.0520	-0.0477	-0.0560	-0.0494	-	-
...
...
3457	22/12/2020	-0.0399	-0.0723	-0.0470	-0.0357	-0.0678	-0.1309
3458	23/12/2020	-0.0422	-0.0647	-0.0474	-0.0361	-0.0722	-0.1172
3459	28/12/2020	-0.0413	-0.0567	-0.0564	-0.0346	-0.0653	-0.1186
3460	29/12/2020	-0.0377	-0.0506	-0.0574	-0.0337	-0.0627	-0.1122
3461	30/12/2020	-0.0415	-0.0464	-0.0535	-0.0337	-0.0605	-0.1094

Lampiran 59: Hasil Estimasi ES (99%)

No	Tanggal	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
1	03/01/2007	-0.0795	-0.0778	-0.0842	-0.0707	-	-
2	04/01/2007	-0.0795	-0.0778	-0.0842	-0.0703	-	-
3	05/01/2007	-0.0795	-0.0778	-0.0842	-0.0722	-	-
4	08/01/2007	-0.0766	-0.0778	-0.0842	-0.0715	-	-
5	09/01/2007	-0.0730	-0.0759	-0.0781	-0.0690	-	-
...
...
3457	22/12/2020	-0.0561	-0.1162	-0.0651	-0.0486	-0.1093	-0.2022
3458	23/12/2020	-0.0593	-0.1033	-0.0678	-0.0502	-0.1158	-0.1837
3459	28/12/2020	-0.0577	-0.0911	-0.0799	-0.0483	-0.1048	-0.1853
3460	29/12/2020	-0.0533	-0.0806	-0.0809	-0.0466	-0.1007	-0.1755
3461	30/12/2020	-0.0583	-0.0733	-0.0752	-0.0472	-0.0975	-0.1700