

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

JURNAL ILMIAH

Disusun oleh :

Kalis Rifo Irwandi

175020100111003



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

2021

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

Kalis Rifo Irwandi

Fakultas Ekonomi dan Bisnis Universitas Brawijaya

Email: kalis.rifo@gmail.com

ABSTRAK


Sejak awal Maret 2020, Indonesia tengah berjuang melawan penyebaran virus 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.

A. PENDAHULUAN

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.

Gambar 1. Perkembangan IHSG dan Indeks Sektoral Tahun 2020



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

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, Indeks Harga Saham Gabungan (IHSG) sempat turun 37.49% secara *year to date* pada 24

Maret 2020, dan menjadi harga penutupan terendah sepanjang tahun tersebut (PKSK, 2020). Di tengah sentimen negatif tersebut, performa sektor konsumen (*consumer goods industry*) di awal pandemi jauh lebih baik dari IHSG. Penurunan terendah indeks JAKCONS relatif lebih rendah dari IHSG, yaitu 32.98% (*ytd*) pada 19 Maret 2020 (PKSK, 2020). Kemudian selama beberapa bulan pandemi berlangsung, performa indeks JAKCONS secara *year to date* juga sempat memimpin indeks harga saham sektoral yang lain.

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 dalam sektor konsumen oleh BEI (Bursa Efek Indonesia) memproduksi barang konsumsi yang cenderung dibeli masyarakat karena tuntutan kebutuhan, terlepas dari kondisi perekonomian. Meskipun begitu, bukan berarti investasi saham dari sektor konsumen bebas dari risiko. Performa indeks JAKCONS 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 saham 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 Yoshida, 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 VaR meremehkan 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 Yoshida, 2005).

Terdapat dua metode umum yang digunakan untuk mengestimasi nilai VaR dan ES, yaitu pendekatan non parametrik dan parametrik (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.

Di sisi lain, pada data finansial seperti saham sering 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 yang 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.

Berdasarkan latar belakang tersebut, dapat diketahui bahwa untuk mengukur risiko investasi saham dari sektor konsumen menggunakan VaR dan ES dengan pendekatan parametrik, diperlukan model statistik yang mampu menggambarkan dinamika volatilitas *return* saham dengan baik. Model volatilitas tersebut perlu mengakomodasi fenomena leptokurtosis, *volatility clustering*, serta *leverage effect*. Oleh karena itu, penelitian ini memiliki beberapa bertujuan: menghitung estimasi risiko investasi saham, mengidentifikasi keberadaan fenomena leptokurtosis, *volatility clustering*, dan *leverage effect*, serta menggambarkan karakteristik volatilitas *return* saham perusahaan sektor konsumen.

B. TINJAUAN PUSTAKA

Risiko Investasi

Terdapat beberapa definisi risiko, namun sebagian besar merujuk pada peluang dari suatu kejadian yang tidak terduga (Fraser dkk., 2014). Risiko adalah variabel laten, yaitu variabel yang tidak dapat diukur dengan cara yang sama seperti mengukur suhu dengan termometer (Dañielsson, 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 VaR (*Value at Risk*).

Return Saham

Return merupakan salah satu faktor pendorong untuk berinvestasi, sekaligus imbalan atas keberanian investor untuk menanggung risiko investasi yang dilakukannya (Tandelilin, 2010). 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.

Menurut Tandelilin (2010), terdapat dua komponen pembentuk *return* saham: *capital gain* (laba/rugi modal) dan dividen. *Capital gain* diperoleh dari selisih harga jual dan harga beli saham. Sedangkan dividen diperoleh dari pembagian laba perusahaan kepada pemilik saham setiap periode tertentu. *Return* dari *capital gain* dapat dihitung menggunakan dua cara, yaitu *simple return* atau *log return*. Namun karena *return* terdistribusi secara *log-normal*, maka lebih tepat untuk didefinisikan menggunakan logaritma natural (Kissell, 2014). Secara matematis, *log return* (*continuously compounded return*) dapat didefinisikan sebagai berikut:

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

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

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. Salah satu konsep sederhana untuk menghitung volatilitas adalah *historical volatility*. *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

Model Volatilitas

Pendekatan model yang mengasumsikan residual konstan seperti *exponential smoothing*, maupun ARIMA (*Autoregressive Integrated Moving Average*) gagal untuk menangkap fenomena pada data finansial yang cenderung memiliki residual tidak konstan (Montgomery dkk., 2015). Jika data memiliki residual tidak konstan namun diasumsikan konstan, maka estimasi standar *error* bisa menjadi salah dan menghasilkan peramalan volatilitas yang kurang tepat (Brooks, 2008).

Permasalahan pada residual tersebut dapat diatasi oleh model ARCH (*Autoregressive Conditional Heteroskedasticity*) yang dikemukakan oleh Engle (1982). Model ini kemudian dikembangkan menjadi GARCH (*Generalized ARCH*) oleh muridnya Bollerslev (1986). Model tersebut mampu menangkap fenomena *volatility clustering*, yaitu kecenderungan tingkat volatilitas saat ini untuk berkorelasi positif dengan periode sebelumnya (Brooks, 2008).

Di sisi lain, model awal GARCH masih mengasumsikan respon simetris terhadap setiap efek guncangan pada harga aset. Oleh karena itu, model tersebut belum bisa mengakomodasi fenomena *leverage effect*. Fenomena tersebut pertama kali dikemukakan oleh Black (1976), yaitu kecenderungan peningkatan volatilitas ketika harga saham jatuh. Dimana peningkatan volatilitas ini tidak sebanding dengan peningkatan volatilitas ketika harga saham naik dengan besaran yang sama (Brooks, 2008).

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

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 Yoshida, 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*) menjadi satuan angka yang mudah dipahami (Jorion, 2007). Dimana potensi kerugian yang diukur dengan metode ini dapat dikonversikan ke satuan mata uang, sehingga mudah dipahami dan diaplikasikan sebagai acuan dalam pengambilan kebijakan.

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

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

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 tersebut terkait dengan fenomena *volatility clustering*, 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 (Dañielsson, 2011).

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 potensi kerugian dari penurunan ekstrem harga aset 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 tersebut dapat diatasi dengan *Conditional Value at Risk* (CVaR) atau sering disebut juga *Expected Shortfall* (ES). CVaR/ES adalah metode pengukuran risiko yang mengukur potensi kerugian di bagian ekor distribusi (Rockafellar dan Uryasev, 2002). Dimana informasi tentang besaran kerugian yang melampaui nilai VaR digambarkan sebagai ekspektasi bersyarat di bawah kuantil yang terkait dengan probabilitas (α) tertentu (Dañielsson, 2011).

Jika VaR dinyatakan 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.

C. METODE PENELITIAN

Penelitian ini merupakan penelitian kuantitatif yang menggunakan analisis *univariate*. 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). Keenam perusahaan tersebut mewakili setiap subsektor industri barang konsumsi, yang dipilih berdasarkan kapitalisasi pasar terbesar untuk setiap subsektor pada kuartal keempat di tahun 2020 (Indonesia Stock Exchange, 2020). Data *return* saham dari masing-masing perusahaan tersebut dihitung sebagai *continuously compounded return* dari seluruh data deret waktu (*time series*) harga saham harian hingga 30 Desember 2020. Data tersebut merupakan data sekunder yang diperoleh dari situs *finance.yahoo.com*.

Metode Analisis

Penelitian ini menggunakan gabungan metode analisis statistik deskriptif dan statistik inferensia. 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	: <i>Return</i>
μ_t	: <i>Mean</i>
ε_t	: <i>Error</i>
σ_t	: Standar deviasi
z_t	: Proses <i>white noise</i>
μ	: Konstanta <i>mean equation</i> (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	: <i>Conditional variance</i>
ω	: Konstanta <i>variance equation</i> (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)

Model ARMA dan GARCH merupakan model empiris, sehingga pendekatan terbaik untuk memodelkannya adalah melalui prosedur iteratif tiga tahap berdasarkan identifikasi, estimasi, dan pemeriksaan diagnostik (Box dkk., 2016). Prosedur identifikasi dilakukan untuk menentukan model awal (tentatif) yang layak untuk diselidiki lebih lanjut. Model tentatif yang didapatkan dari prosedur identifikasi kemudian diestimasi parameternya. Selanjutnya dilakukan pemeriksaan diagnostik untuk menguji kesesuaian model dengan perilaku data serta memilih model terbaik diantara beberapa model tentatif tersebut.

Pada penelitian ini, proses pemodelan ARMA mencakup prosedur identifikasi (uji stasioneritas dan identifikasi model), prosedur estimasi parameter (*Maximum Likelihood Estimation*), serta prosedur pemeriksaan diagnostik (uji *white noise* dan perbandingan kriteria informasi). Sedangkan proses pemodelan GARCH mencakup prosedur identifikasi (uji efek ARCH), prosedur estimasi parameter (MLE), serta prosedur pemeriksaan diagnostik (uji *weighted ARCH LM*, uji *sign and size bias*, serta perbandingan kriteria informasi).

Dalam proses pemodelan GARCH, dipertimbangkan penggunaan model GARCH asimetris untuk mengakomodasi fenomena *leverage effect*. Pada penelitian ini, digunakan model GJR-GARCH(1,1) sebagai model pembanding, yang secara matematis dapat didefinisikan sebagai 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.

Setelah memodelkan volatilitas dengan ARMA-GARCH, tahap selanjutnya adalah menghitung nilai VaR dan ES. 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:

$$VaR_t(\alpha) = \mu_t + \sigma_t F^{-1}(\alpha)$$

Dimana,

α	: Probabilitas kerugian yang melampaui nilai VaR
μ_t	: <i>Mean equation (conditional mean)</i> dari ARMA
σ_t	: <i>Volatility equation (conditional volatility)</i> dari GARCH
F^{-1}	: <i>Inverse cumulative distribution function</i>

Sedangkan dengan 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):

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

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

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

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*)


Pengukuran risiko dengan metode VaR dan ES hanya berguna jika model dapat mengestimasi risiko dengan baik. Oleh karena itu, penerapan metode ini perlu disertai dengan proses validasi, yang 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, metode *backtesting* yang digunakan untuk menguji estimasi nilai VaR yang dihasilkan dengan pendekatan ARMA-GARCH adalah *rolling analysis*. Metode *backtesting* ini dilakukan dengan *ugarchroll* dari *package rugarch* yang dikembangkan oleh Ghalanos (2020b) dalam R (R Core Team, 2013). Sedangkan metode *backtesting* yang digunakan untuk menguji estimasi nilai ES adalah *expected shortfall test* yang dikemukakan oleh McNeil dan Frey (2000), yang kemudian diimplementasikan dalam Ghalanos (2020b) menjadi *ESTest* dari *package rugarch* dalam R.

D. HASIL DAN PEMBAHASAN

Analisis Statistik Deskriptif


Gambar 2: Harga dan Return Saham ICBP (A), HMSP (B), dan KLBF (C)



Sumber: Output R, 2021 (data diolah).

Berdasarkan pergerakan harga saham beserta *return* saham yang ditunjukkan pada Gambar 2 dan 3, terlihat 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 3: Harga dan Return Saham UNVR (D), WOOD (E), dan HRTA (F)



Sumber: Output R, 2021 (data diolah).

Kemudian berdasarkan Tabel 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. 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.

Tabel 1. Statistik Deskriptif Return Saham

Ukuran Statistik	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
Mean	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
Skewness	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
Jarque-Bera statistic	3535	33686.9	10638.6	5629.7	2021.0	6290.3
Jarque-Bera p-value	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
Observasi	3459	3446	3460	3460	895	895

Sumber: Output R, 2021 (data diolah).

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 mengatasi leptokurtosis. Hal tersebut sesuai dengan saran Box dkk. (2016), yaitu penggunaan distribusi *student-t* dalam mengestimasi parameter model GARCH.

Uji Stasioneritas

Berdasarkan Gambar 2 dan 3, dapat dilihat bahwa keenam *return* saham 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 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 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
<i>Prob.</i>	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000

Sumber: Output R, 2021 (data diolah).

Berdasarkan Tabel 2, hasil uji ADF menyatakan bahwa tidak terdapat *unit root* pada keenam *return* saham. 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. Artinya keenam *return* saham tersebut telah stasioner pada tingkat level, sehingga tidak perlu dilakukan *differencing*. Oleh karena itu, model awal (tentatif) akan memiliki spesifikasi ARIMA($p,0,q$) atau setara dengan ARMA(p,q).

Identifikasi Model ARMA

Identifikasi model 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 hasil perbandingan pola ACF dan PACF yang telah dilakukan, terbentuk beberapa model tentatif sebagai berikut.

Tabel 3: Model Tentatif ARMA

<i>Return Saham</i>	Model Tentatif
ICBP	ARMA([3],0), ARMA(0,[3]), ARMA([3],[3])
HMSP	ARMA([2],0), ARMA(0,[2]), ARMA([2],[2]), ARMA([4],0), ARMA(0,[4]), ARMA([4],[4])
KLBF	ARMA([4],0), ARMA(0,[4]), ARMA([4],[4]), ARMA([6],0), ARMA(0,[6])
UNVR	ARMA(1,1), ARMA(5,0), ARMA(0,3)
WOOD	ARMA([6],0), ARMA(0,[6]), ARMA([6],[6])
HRTA	ARMA([5],0), ARMA(0,[5]), ARMA([5],[5])

Sumber: Output R, 2021 (data diolah).

Estimasi Parameter dan Pemeriksaan Diagnostik Model ARMA

Model tentatif yang telah terbentuk kemudian akan diestimasi parameternya. Metode estimasi yang digunakan dalam penelitian ini adalah MLE (*Maximum Likelihood Estimation*). Metode tersebut berusaha menduga nilai parameter yang memaksimalkan *log likelihood* (Hyndman dan Athanasopoulos, 2018). Setelah melakukan estimasi parameter model tentatif, langkah selanjutnya adalah melakukan pemeriksaan diagnostik.

Pemeriksaan diagnostik model ARMA terdiri dari uji *white noise* dan perbandingan kriteria informasi. Uji *white noise* digunakan untuk memeriksa apakah model tentatif telah sesuai dengan perilaku data. Dimana model ARMA yang memadai akan memiliki residual dengan sifat *white noise* (bersifat independen) (Montgomery dkk., 2015).

Jika terdapat lebih dari satu model yang lolos uji *white noise*, maka dapat dipilih model terbaik dengan perbandingan kriteria informasi. Diantaranya adalah AIC yang diusulkan oleh Akaike (1974) atau 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.

Tabel 4 menampilkan hasil pemeriksaan diagnostik dari model tentatif keenam *return* saham dengan koefisien yang signifikan. Berdasarkan tabel tersebut, beberapa model tentatif dari *return* saham ICBP, UNVR, WOOD, dan HRTA tidak tereliminasi dari pemilihan model terbaik. 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 dalam pemilihan model terbaik, nilai kriteria informasi (AIC dan BIC) juga perlu diperhatikan untuk menghindari model

yang terlalu kompleks (*overfitting*). *Overfitting* merupakan 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).

Tabel 4: Pemeriksaan Diagnostik Model ARMA

Return	Model	Uji <i>White Noise</i>		<i>log likelihood</i>	AIC	BIC	Keterangan
		<i>Chi-squared</i>	<i>Prob.</i>				
ICBP	ARMA([3],0)	8.6621	0.2778	8155.92	-16305.84	-16287.39	Model Terbaik
	ARMA(0,[3])	8.2169	0.3139	8156.13	-16306.27	-16287.82	
	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	Model Terbaik
	ARMA(0,[6])	5.6777	0.2245	1882.19	-3758.377	-3743.983	
HRTA	ARMA([5],0)	8.0877	0.1515	1926.81	-3847.625	-3833.231	Model Terbaik
	ARMA(0,[5])	7.3464	0.1961	1927.22	-3848.444	-3834.05	
	ARMA([5],[5])	4.4817	0.0000	1931.61	-3855.223	-3836.032	

Sumber: Output R, 2021 (data diolah).

Pada Tabel 4 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. Di sisi lain, seluruh model tentatif dari *return* saham HMSP dan KLBF telah tereliminasi, sehingga perlu dibentuk model tentatif baru. 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).

Hasil pemeriksaan diagnostik dari model tentatif baru *return* saham HMSP dan KLBF ditampilkan pada Tabel 5. 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. Oleh karena itu perlu dilakukan pemilihan model terbaik berdasarkan nilai *log likelihood* dan kriteria informasi. 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 5: Pemeriksaan Diagnostik Model ARMA HMSP dan KLBF

Return	Model	Uji White Noise		log likelihood	AIC	BIC	Keterangan
		Chi-squared	Prob.				
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: Output R, 2021 (data diolah).

Uji Efek ARCH

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. Namun sebelum melakukan pemodelan GARCH, perlu dipastikan keberadaan fenomena *volatility clustering* pada masing-masing data *return* saham tersebut.

Keberadaan pengelompokan volatilitas memang sudah terlihat dari grafik pergerakan *return* saham pada Gambar 2 dan 3. Namun untuk membuktikan fenomena ini, dapat diuji apakah residual kuadrat dari model ARMA memiliki efek ARCH (bersifat *heteroscedastic*). Pada penelitian ini, keberadaan efek ARCH dibuktikan dengan uji LM (*Lagrange Multiplier*) yang dikemukakan oleh Engle (1982).

Tabel 6: Hasil Uji Efek ARCH

Lag	ICBP	HMSP	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: Output R, 2021 (data diolah).

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

Berdasarkan Tabel 6, dapat disimpulkan bahwa pada keenam data *return* saham terdapat fenomena *volatility clustering*. Hal tersebut berdasar dari hasil uji LM pada residual kuadrat 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.

Estimasi Parameter Model GARCH

Menurut Brooks (2008), model simetris GARCH(1,1) sudah cukup untuk mengakomodasi fenomena *volatility clustering* pada data finansial. Sehingga pada penelitian ini GARCH(1,1) dipilih sebagai kombinasi ordo dari proses GARCH(p,q). Kemudian untuk prosedur estimasi parameter, metode estimasi yang digunakan sama seperti model ARMA yaitu MLE.

Berdasarkan hasil analisis deskriptif yang telah dilakukan sebelumnya, keenam data *return* saham 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, dalam penelitian ini digunakan distribusi *skewed student-t* untuk mengestimasi parameter model GARCH.

Tabel 7: Hasil Estimasi Parameter Model GARCH (*Variance Equation*)

	ICBP	HMSF	KLBF	UNVR	WOOD	HRTA
ARMA(<i>p,q</i>)	(0,[3])	(4,4)	(4,4)	(1,1)	(0,[6])	(0,[5])
ω	0.0000 (0.0002)	0.0000 (0.0000)	0.0000 (0.0001)	0.0000 (0.0032)	0.0002 (0.0390)	0.0000 (0.1052)
α_1	0.1608 (0.0000)	0.2669 (0.0000)	0.1997 (0.0000)	0.1509 (0.0000)	0.3114 (0.0223)	0.1916 (0.0082)
β_1	0.8382 (0.0000)	0.7321 (0.0000)	0.7648 (0.0000)	0.8379 (0.0000)	0.6876 (0.0000)	0.8074 (0.0000)

Sumber: Output R, 2021 (data diolah).

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

Tabel 7 menunjukkan hasil estimasi parameter model GARCH dari keenam *return* saham. Berdasarkan tabel tersebut, dapat dilihat bahwa seluruh koefisien *variance equation* memiliki pengaruh yang signifikan. Hal tersebut dibuktikan dari nilai *p-value* yang lebih kecil dari tingkat signifikansi 5%.

Pemeriksaan Diagnostik Model GARCH

Setelah melakukan estimasi parameter model 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 8, dapat dilihat bahwa residual terstandarisasi model GARCH dari keenam *return* saham 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 8: Hasil Uji *Weighted ARCH LM*

Lag	ICBP	HMSF	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: Output R, 2021 (data diolah).

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

Setelah didapatkan model 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 9, 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 9: 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: Output R, 2021 (data diolah).

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

Backtesting Value at Risk

Setelah mendapatkan model ARMA-GARCH terbaik untuk setiap *return* saham, tahap selanjutnya adalah *backtesting* VaR. Dengan metode *ugarchroll* dari *package rugarch* dalam R, 250 observasi terakhir dari masing-masing data *return* saham pada penelitian ini digunakan untuk memvalidasi model VaR pada tingkat kepercayaan 99%.

Hasil *backtesting* tersebut ditampilkan pada Tabel 10, yang menunjukkan bahwa seluruh estimasi nilai VaR pada keenam *return* saham dapat dinyatakan valid. 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 10: 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: Output R, 2021 (data diolah).

Berdasarkan hasil pengujian tersebut, 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*).

Backtesting Expected Shortfall

Setelah VaR dinyatakan valid, selanjutnya dapat dilakukan *backtesting* ES. Pada Tabel 11 ditampilkan hasil *backtesting* ES pada tingkat kepercayaan 99% dari keenam *return* saham. 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 11: 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: Output R, 2021 (data diolah).

Karakteristik Volatilitas *Return* Saham

Hasil estimasi parameter model GARCH yang ditampilkan pada Tabel 7 menunjukkan pengaruh signifikan dari 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 yang relatif tinggi serta nilai koefisien GARCH yang relatif rendah pada *return* saham WOOD mengisyaratkan volatilitas yang lebih sensitif terhadap guncangan namun 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 rendah sering dikaitkan dengan sensitivitas terhadap guncangan yang relatif tinggi, mengindikasikan bahwa *return* saham WOOD memiliki volatilitas yang lebih “runcing”. 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.

Saham PT Unilever Indonesia Tbk (UNVR) dan PT Indofood CBP Sukses Makmur Tbk (ICBP) memiliki kapitalisasi pasar yang tergolong besar. Oleh karena itu, kedua saham tersebut mampu meredam guncangan volatilitas dan performanya cenderung stabil. Di sisi lain, 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.

Risiko Investasi Sepanjang Tahun 2020

Tabel 12: 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: Output R, 2021 (data diolah).

Pada Tabel 12 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.

Kinerja PT Integra Indocabinet Tbk (WOOD) memang cukup terpengaruh dengan adanya pandemi Covid-19 sepanjang tahun 2020. Pertumbuhan permintaan domestik menurun hingga 25.1% dibanding tahun 2019 (Integra Group, 2021). Begitu pula dengan kinerja PT Hartadinata Abadi Tbk (HRTA), dimana pada kuartal I-2020 terdampak negatif oleh pandemi Covid-19. Terutama pada penjualan perhiasan jelang Idul Fitri (Hartadinata Abadi, 2021).

Kemudian kinerja PT H.M. Sampoerna Tbk (HMSP) yang sejak awal tahun 2020 telah mengalami dampak negatif dari kenaikan cukai rokok, juga diperparah dengan dampak negatif dari pandemi Covid-19. Kedua faktor tersebut menyebabkan penurunan permintaan seiring dengan menurunnya daya beli masyarakat. Sehingga volume penjualan perusahaan di tahun 2020 turun sebesar 19.3% (*yoy*) (Sampoerna, 2021).

Di sisi lain, kinerja beberapa lini bisnis PT Indofood CBP Sukses Makmur Tbk (ICBP) pada tahun 2020 justru mengalami dampak positif dari pandemi Covid-19. Dimana segmen penyedap makanan dan mi instan masing-masing mengalami pertumbuhan penjualan sebesar 21.9% (*yoy*) dan 15.4% (*yoy*) (Indofood CBP, 2021). Hal tersebut serupa dengan kinerja beberapa lini bisnis PT Kalbe Farma Tbk (KLBF). Dimana segmen produk kesehatan tumbuh sebesar 4.7% (*yoy*) akibat meningkatnya kesadaran masyarakat untuk memperkuat kekebalan tubuhnya selama masa pandemi (Kalbe, 2021). Begitu pula dengan kinerja lini bisnis utama PT Unilever Indonesia Tbk

(UNVR). Dimana segmen kebutuhan rumah tangga dan perawatan tubuh mengalami pertumbuhan penjualan bersih sebesar 0.4% (yoy) akibat meningkatnya kesadaran masyarakat terhadap kebersihan permukaan rumah dan peralatan makan (Unilever Indonesia, 2021).

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.

Peramalan Risiko Investasi

Jika seorang investor menanamkan modalnya pada saham ICBP, HMSP, KLBF, UNVR, WOOD, dan HRTA di 30 Desember 2020, maka potensi risiko yang perlu ditanggung oleh investor tersebut pada hari perdagangan selanjutnya (4 Januari 2021) adalah sebagai berikut.

Tabel 13: Peramalan Risiko dengan VaR (99%) dan ES (99%)

	ICBP	HMSP	KLBF	UNVR	WOOD	HRTA
VaR	-0.0479	-0.0405	-0.0503	-0.0326	-0.0559	-0.1137
ES	-0.0673	-0.0646	-0.0706	-0.0454	-0.0905	-0.1781

Ketika investor tersebut memiliki modal sebesar Rp100 Juta dan menanamkan seluruh modalnya pada saham ICBP, maka terdapat potensi 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).

Tabel 14: 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: Output R, 2021 (data diolah).

Dari hasil peramalan risiko pada Tabel 13, 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).

E. KESIMPULAN DAN SARAN

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 saham 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).

Saran

1. Bagi para investor, khususnya yang ingin berinvestasi pada saham dari sektor konsumen, perlu 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 dan hasil estimasi risiko dengan VaR dan ES yang akurat. Sehingga dapat membantu investor dalam menetapkan kebijakan berinvestasi, yang menghindarkan investor dari kerugian finansial yang besar.
2. 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.

DAFTAR PUSTAKA

- 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*.
- 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*.
- 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>
- Danielsson, 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>
- Fraser, J. R. S., Simkins, B., & Narvaez, K. (2014). *Implementing Enterprise Risk Management: Case Studies and Best Practices*. Wiley.
- Ghalanos, A. (2020). *rugarch: Univariate GARCH models*.
- 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.
- Hartadinata Abadi. (2021). *Annual Report 2020*. Retrieved from <https://www.hartadinataabadi.co.id/storage/app/uploads/public/60d/c68/62a/60dc6862ace12540023645.pdf>
- 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: BPFE.
- 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>
- 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>
- 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.).
- PKSK. (2020). *IHSG - Sektoral*.
- 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.
- Unilever Indonesia. (2021). *2020 Annual Reports*. Retrieved from https://www.unilever.co.id/id/Images/ar_uli_2020_270421_dv_19.51_complete-with-lk_compressed_tags_tcm1310-561142_1_id.pdf
- Yamai, Y., & Yoshida, 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>