

Peramalan Volatilitas IHSG dan Estimasi Value-at-Risk Menggunakan Model Student APARCH

Najibullah¹, Ricky Ariansyah², Fitriani Rizky³

¹Politeknik Kutaraja, Banda Aceh, Aceh, email: najibullah@poltekkutaraja.ac.id

²Politeknik Kutaraja, Banda Aceh, Aceh, email: rickyariansyah@poltekkutaraja.ac.id

³Politeknik Kutaraja, Banda Aceh, Aceh, email: fitriani_rizky@yahoo.com

<p>Received Date. 10 Desember 2022 Revised Date. 16 Desember 2022 Accepted Date. 02 Januari 2023</p>	<p>ABSTRACT This study aim to find the best model to predict daily volatility of IHSG using APARCH model under student-t distribution, estimate value-at-risk measure based on the model and compare it with the value-at-risk measure estimated from GARCH. This study limits the search only on APARCH model class. The sample are IHSG dataset which is derived from yahoo finance, starting from Jan 1st, 2015 to Dec 31th, 2021. The result suggest that value-at-risk measure estimated using student APARCH are more adept to negatif shock than that of GARCH. Nevertheless, the result of value-at-risk back-testing do not show any significant differences between those two.</p>
<p><i>The Keywords:</i> Value-at-risk APARCH Student-t Distribution</p>	<p>ABSTRAK Penelitian ini bertujuan untuk menemukan model terbaik dalam memprediksi volatilitas harian dari IHSG menggunakan model APARCH dengan distribusi student-t, estimasi nilai value-at-risk berdasarkan model tersebut dan membandingkannya dengan ukuran value-at-risk yang dihasilkan oleh model GARCH. Penelitian ini membatasi pencarian model terbaik hanya pada kelas model APARCH. Sampel merupakan data IHSG yang diperoleh dari yahoo finance, dimulai dari 1 Januari 2015 hingga 31 Desember 2021. Hasil penelitian ini menemukan bahwa ukuran value-at-risk yang diestimasi menggunakan student APARCH bersifat lebih adaptif terhadap shock negatif dibandingkan dengan GARCH. Namun demikian, tidak terdapat perbedaan signifikan diantara keduanya jika ditinjau hasil back-testing.</p>

Pendahuluan

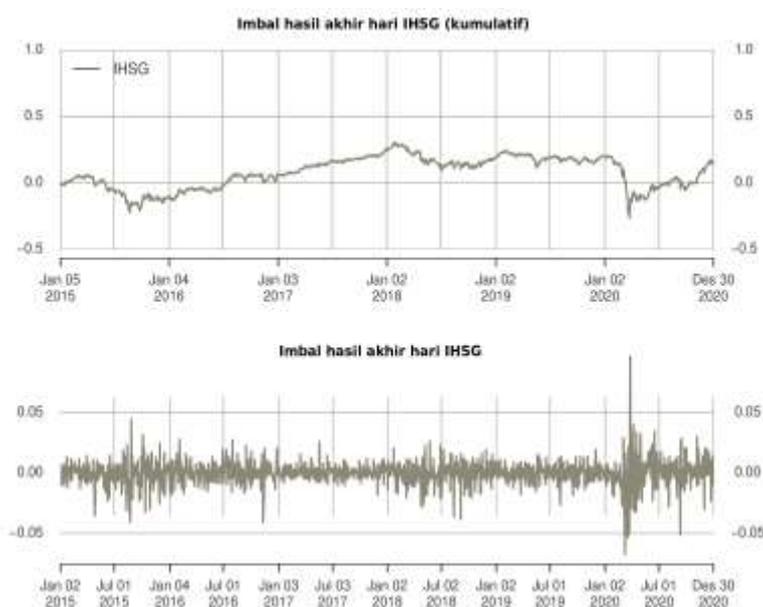
Sebagai salah satu instrument investasi, saham yang diperdagangkan di pasar modal, mampu memberikan imbal hasil yang lebih tinggi dibandingkan dengan bentuk investasi lainnya. Namun demikian, imbal hasil yang tinggi tersebut selalu diiringi dengan risiko yang relatif lebih tinggi pula. Risiko dan imbal hasil dalam trading/investasi umumnya selalu berubah-ubah, meningkat pada periode tertentu dan menurun periode lainnya (Tsay, 2010).

Pengelompokan lonjakan volatilitas merupakan fenomena yang lazim ditemui pada data deret waktu keuangan. Dalam perspektif volatilitas pasar, hal tersebut merupakan cerminan

perilaku takut dan serakah dari partisipan pasar keuangan yang dapat menyebar dengan cepat. Fenomena tersebut umumnya terjadi pada saat terjadinya aksi jual (*sell off*) secara masif yang disebabkan karena meningkatnya kekhawatiran mengenai prospek ekonomi sebagaimana yang terjadi pada awal tahun 2020 akibat merebaknya pandemi Covid-19 diikuti pemberlakuan lockdown di berbagai negara. Hal tersebut juga dapat terjadi ketika market rally setelah rebound sebagai akibat dari bangkitnya optimisme trader/investor seperti yang terjadi pada akhir Q2-2020 dimana partisipan pasar menjadi optimis terkait kebijakan penanganan pandemi. Lonjakan volatilitas yang timbul dapat meningkatkan risiko yang harus dihadapi oleh investor secara mendadak sehingga diperlukan mekanisme untuk mengelola peningkatan risiko tersebut. Oleh sebab itu, ketersediaan model peramalan volatilitas IHSG diharapkan mampu menjadi alat bagi investor domestik, baik institusional ataupun retail, dalam mengelola risiko investasi.

Karakteristik pengelompokan volatilitas tersebut juga dimiliki oleh IHSG. Sebagaimana terlihat pada gambar 1, pengelompokan volatilitas yang sangat jelas terlihat pada periode viralnya isu covid-19 dan diumumkan rencana pemberlakuan lockdown untuk menghambat peningkatan jumlah kasus yang disinyalir akan turut memperlambat perekonomian oleh para trader/investor. Gambar 1 menyajikan imbal hasil harian kumulatif IHSG dan imbal hasil harian IHSG.

Gambar 1. Imbal Hasil Akhir Hari IHSG



Semenjak Auto Regressive Conditional Heteroskedasticity (ARCH) yang memodelkan *conditional variance* diperkenalkan oleh Engle(Engle, 1982), penelitian mengenai pengukuran volatilitas telah berkembang hingga menghasilkan beragam variasi kelas model ARCH lainnya. Ekstensi pertama, model tersebut diperluas menjadi GARCH dengan mengikutsertakan *conditional variance* ke dalam model sehingga memiliki fitur *adaptif learning*(Bollerslev, 1986). Namun, model tersebut mengasumsikan efek yang simetris dari *shock* negatif dan positif(Tsay, 2010). Sebaliknya, penurunan di pasar saham cenderung diiringi dengan volatilitas yang lebih tinggi jika dibandingkan dengan kenaikan harga saham. Kelas model *Threshold* GARCH (TGARCH), *Exponential* GARCH (EGARCH), Glosten-Jagannathan-Runkle GARCH (GJR-GARCH) merupakan model

yang memungkinkan volatilitas dapat bereaksi secara berbeda terhadap *shock* negative (Glosten dkk., 1993; Nelson, 1991; Zakoian, 1994). Asymmetric Power ARCH (APARCH), sebagai model omnibus, menambahkan fitur untuk menangkap efek dari sifat *long memory* pada harga saham (Taylor efek)(Ding dkk., 1993).

Model selanjutnya dapat diestimasi dengan menggunakan *quasi Maximum Likelihood*(MLE). Estimator ini memastikan estimasi tetap konsisten dan standar *error* tetap valid bahkan dalam keadaan *standardized innovation* tidak normal atau mengalami masalah serial korelasi, maupun keduanya(Francq & Thieu, 2019).

Hingga saat ini, terdapat banyak penelitian mengenai volatilitas indeks saham yang telah dilakukan. Beberapa penelitian fokus pada peramalan volatilitas indeks luar negeri seperti S&P500(Hafizah dkk., 2020; Megawati dkk., 2020). Sebagian penelitian lain berusaha untuk menelaah volatilitas saham individual(Husein & Lubis, 2022; Maulana, 2020; Sidadolog dkk., 2020), ataupun volatilitas pada sektor tertentu yang merupakan sub-komponen dari IHSG(Ridha & Wibowo, 2020). Selain pada pasar saham, penelitian mengenai peramalan volatilitas juga telah dilakukan pada pasar kripto(Warsito & Robiyanto, 2020). Ditinjau dari model yang digunakan, penelitian-penelitian tersebut menggunakan *Asymmetric Power ARCH* (APARCH)(Sidadolog dkk., 2020), IGARCH(Megawati dkk., 2020), *Threshold GARCH* (TGARCH)(Ridha & Wibowo, 2020), EGARCH(Husein & Lubis, 2022; Maulana, 2020), dan GJR-GARCH(Maulana, 2020). Hanya saja penelitian-penelitian tersebut tidak memprediksi volatilitas sebagai upaya untuk menghitung *value-at-risk* yang merupakan salah satu penerapan dari model prediksi volatilitas.

Penelitian untuk menentukan nilai *value-at-risk* berdasarkan hasil prediksi model peramalan volatilitas juga telah banyak dilakukan. Huang dan Lin mencoba untuk mengestimasi *value-at-risk* dari bursa berjangka Taiwan menggunakan model APARCH ketika distribusi *error* memiliki ekor distribusi yang lebar(Huang & Lin, 2004). Penelitian yang hampir serupa, dilakukan untuk mengestimasi *value-at-risk* satu hari kedepan atas pasar spot komoditas menggunakan GARCH-N, GARCH-t and GARCH-HT(Hung dkk., 2008). Dalam lingkup domestik, penelitian sejenis juga dilakukan untuk prediksi risiko imbal hasil harga saham bank BCA menggunakan ARIMAX-GARCHX(Arumningtyas dkk., 2021) Penelitian-penelitian tersebut menemukan bahwa distribusi *error* dari imbal hasil aset keuangan cenderung mengikuti distribusi student-t.

Penelitian ini bertujuan menemukan model peramalan volatilitas IHSG menggunakan kelas model APARCH yang akan digunakan untuk menghitung nilai *Value-at-Risk* (VaR) satu periode kedepan. Selanjutnya, model APARCH tersebut akan dibandingkan dengan model GARCH standar terkait kemampuannya dalam memprediksi nilai *value-at-risk* satu periode kedepan dengan melakukan *backtesting*. *Backtesting* merupakan proses pengujian keandalan dari ukuran *value-at-risk*.

Kajian Literatur

Model peramalan yang digunakan dalam penelitian ini menggunakan model univariate dimana hanya terdiri dari satu variabel. Variabel tersebut adalah imbal hasil harian indeks IHSG ($R_{t,ihsg}$) yang dihitung sebagai imbal hasil geometrik, yaitu selisih dari log natural harga penutupan hari terkini, dan harga penutupan hari sebelumnya, P_{t-1} .

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

Sebagaimana dijelaskan oleh (Tsay, 2010), imbal hasil dari sebuah aset, R_t , diasumsikan tidak memiliki atau sedikit memiliki serial korelasi, namun tetap dependen dari lag-nya. sehingga R_t dapat dimodelkan sebagai ARMA(r,s):

$$R_t = \mu_t + a_t \tag{2}$$

$$\mu_t = \theta_0 + \sum_{i=1}^r \theta_i R_{t-i} - \sum_{i=1}^s \phi_i a_{t-i} \tag{3}$$

$$a_t = \sigma_t \epsilon_t, \epsilon_t \sim N(0,1) \tag{4}$$

dimana μ_t merupakan conditional mean yang dispesifikasikan sebagai ARMA (r,s), dan a_t adalah *shock* atau *mean-corrected* dari imbal hasil aset pada waktu t. Untuk student-t distribution, maka dimana v merupakan *degrees of freedom*(Huang & Lin, 2004). Selanjutnya, dispesifikasikan sebagai model APARCH mengikuti (Ding dkk., 1993) sehingga dapat dituliskan sebagai:

$$\sigma_t^\delta = \omega + \sum_{j=1}^q \alpha_j (|a_{t-j}| - \gamma_j a_{t-j})^\delta + \sum_{j=1}^p \beta_j \sigma_{t-j}^\delta \tag{5}$$

Sebagaimana dikemukakan oleh (Ding dkk., 1993), model APARCH mampu menangkap efek leverage dan efek taylor, dimana $\delta \in \mathbb{R}^+$, merupakan hasil tranformasi Box-Cox dari σ_t , dan γ_j merupakan koefisien dari efek leverage. σ_t^δ tetap sama untuk distribusi student-t.

Value-at-risk dari sebuah portofolio dapat didefinisikan sebagai probabilita turunnya nilai pasar melebihi penurunan maksimum yang diharapkan selama periode waktu tertentu(Duffie & Pan, 1997). Secara matematis, dibawah asumsi distribusi normal, *value-at-risk* dapat dihitung sebagai (Huang & Lin, 2004):

$$VaR_t = Z_\alpha \sqrt{\sigma_t^2} + \mu \tag{6}$$

Dimana Z_α merupakan quantil terendah α dari distribusi normal μ dengan interval kepercayaan tertentu dan merupakan rata-rata dari imbal hasil R_t . Sementara untuk distribusi student-t, *value-at-risk* dapat dihitung sebagai:

$$VaR_t = t_{\alpha,v} \sqrt{\sigma_t^2} + \mu \tag{7}$$

Dimana $t_{\alpha,v}$ merupakan quantile kiri pada interval kepercayaan α dan derajat kebebasan v .

Metode Penelitian

Data yang digunakan dalam penelitian ini merupakan data harian IHSG yang diperoleh dari basis data yahoo finance selama periode 1 Januari 2015 hingga 31 Desember

2021. Data mentah yang diperoleh sebanyak 1506 observasi. Setelah dilakukan pembersihan, didapatkan dataset dengan observasi sebanyak 1464.

Adapun langkah-langkah yang digunakan dalam penelitian ini meliputi: (1) pengujian serial korelasi, (2) pengujian efek ARCH atau keberadaan *volatility clustering* dengan ARCH-LM, (3) estimasi dan identifikasi model ARMA terbaik dengan nilai AIC terkecil sebagai spesifikasi mean (4) estimasi dan identifikasi model APARCH terbaik berdasarkan nilai AIC, (5) meramalkan nilai sigma satu periode kedepan menggunakan model APARCH terbaik dan GARCH, dan menghitung nilai *value-at-risk* untuk kedua model tersebut, dan (6) membandingkan hasil backtesting prediksi VaR untuk masing-masing model.

Metode *backtesting* yang digunakan dalam penelitian ini terdiri dari dua jenis pengujian. Pertama, Kupiec’s “*proportion of failures*” (PF) *coverage test* merupakan pengujian atas jumlah pelanggaran ukuran *value-at-risk* dimana hipotesis nol adalah jumlah pelanggaran ukuran *value-at-risk* berada dalam interval yang diharapkan (Kupiec, 1995). Kedua, *unconditional coverage test* yang mengukur jumlah pelanggaran beruntun dan tidak biasa atas ukuran *value-at-risk*. Hipotesis nol dari uji tersebut adalah tidak terdapat jumlah pelanggaran beruntun yang signifikan (Christoffersen, 1998).

Hasil Penelitian dan Pembahasan

Analisis Deskriptif

Berdasarkan data penutupan harian IHSG selama periode 2015-2020 sebagaimana disajikan pada Gambar 1, pergerakan indeks telah menunjukkan tren kenaikan, tren penurunan, maupun *sideways* (periode dimana tidak terdapat arah tren yang jelas). Oleh sebab itu, periode yang digunakan dalam penelitian ini seharusnya telah cukup mewakili keseluruhan dataset IHSG. Lebih lanjut, terdapat sebanyak kurang lebih 1464 observasi deret waktu yang siap untuk digunakan dalam analisis deret waktu setelah dilakukan pembersihan. Tabel 1 dibawah ini menampilkan nilai statistik deskriptif untuk setiap variabel yang digunakan dalam penelitian ini.

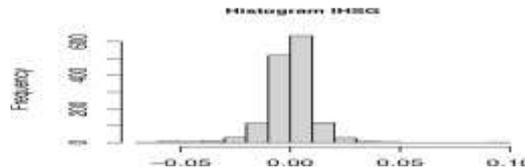
Tabel 1. Ringkasan Statistik

Ukuran	$r_{t,IHSG}$
N	1.464
Min	-0.0681
Mean	0.0001
Median	0.0006
Max	0.0970
Skewness	-0.1737
Kurtosis	12.7851

Untuk menguji apakah variabel terdistribusi secara normal atau tidak dapat ditentukan dari nilai kurtosis dan skewness. Kurtosis mengukur ketajaman dari tanjakan pada distribusi data. Distribusi data dikatakan normal jika berbentuk *mesokurtic*, terjadi jika nilai *kurtosis* sama dengan atau mendekati tiga, sehingga *excess kurtosis* ($K-3$) menjadi nol. *Skewness* mengukur kesimetrisan dari distribusi data. Distribusi data dikatakan simetris (memiliki ekor kiri dan kanan sama) jika nilai *skewness* sama dengan atau mendekati nol. Berdasarkan tabel 1, terlihat bahwa variabel imbal hasil harian IHSG memiliki *skewness* mendekati nol yang berarti distribusi dari variabel imbal hasil harian IHSG memiliki ekor yang simetris. Selanjutnya nilai kurtosis lebih besar dari tiga sehingga *excess kurtosis*

menjadi lebih besar dari nol yang mengindikasikan bahwa variabel tidak terdistribusi normal. Disisi lain, variabel imbal hasil harian S&P500 juga tidak terdistribusi normal, dimana koefisien *skewness* sebesar -1,0382 mengindikasikan bahwa data terdistribusi condong ke sebelah kanan nilai mean dan nilai koefisien *kurtosis* yang lebih besar dari 0 membuktikan bahwa data tidak terdistribusi secara normal. Gambar 2 berikut menunjukkan distribusi imbal hasil IHSG.

Gambar 2. Histogram imbal hasil harian IHSG



Dikarenakan tujuan akhir dari penelitian ini adalah menguji keandalan hasil prediksi model volatilitas APARCH dalam menentukan nilai *value-at-risk* yang *robust*, oleh sebab itu, estimasi model volatilitas dalam penelitian ini akan menggunakan distribusi *student-t* yang memiliki ekor yang lebih tebal dibandingkan distribusi normal sehingga dapat menghasilkan perhitungan *value-at-risk* yang lebih akurat (Huang & Lin, 2004; Hung dkk., 2008).

Uji unit root

Uji *unit root* atau sering disebut juga uji stationeritas dilakukan untuk mengidentifikasi keberadaan *unit root* pada variabel univariate. *unit root* akan menyebabkan hasil estimasi parameter menjadi menyesatkan. Uji ini dapat dilakukan dengan menggunakan uji *augmented dickey fuller* (ADF).

Hipotesis nol didefinisikan bahwa terdapat unit root (*structural breaks*). Oleh sebab itu, penolakan terhadap hipotesis nol berarti bahwa variabel stationer atau tidak memiliki unit root. Tabel 2 berikut menyajikan hasil uji ADF untuk setiap variabel.

Tabel 2. Hasil uji unit root

Uji	N	Maks. Lag	t Statistik	t kritis
DF	146 3	11	-27.7753	-1.96
ADF	146 3	11	-11.536	-1.96

Dari tabel 2 diatas, terlihat bahwa nilai t-hitung untuk setiap variabel melebihi nilai t kritis pada $\alpha = 95\%$, yaitu -1.96. Hal tersebut membuktikan bahwa variabel imbal hasil

harian IHSG yang dihitung sebagai *diff-in-log* menolak hipotesis nol pada uji ADF yang berarti bahwa data tidak memiliki struktural break.

Uji Korelasi Serial

Uji Ljung-Box dilakukan untuk menguji hipotesis nol bahwa data deret waktu independen dari lag-nya. Hipotesis nol berarti bahwa data tidak memiliki korelasi serial. Tabel 3 berikut menampilkan hasil uji Ljung-Box atas variabel imbal hasil harian IHSG.

Tabel 3. Hasil uji Ljung-Box

Maks.lag	N	X-squared	p-value
1	1463	4.3171	0.0377
5	1463	13.962	0.0158
10	1463	19.000	0.0403

Dari hasil uji Ljung-Box sebagaimana ditampilkan pada tabel 3 tersebut, didapatkan bahwa data variabel imbal hasil IHSG tidak mampu menolak hipotesis alternatif yang berarti bahwa data tidak independen dari lag-nya. Hal tersebut mengindikasikan bahwa spesifikasi persamaan mean berupa ARMA(r,s) dapat digunakan untuk memitigasi permasalahan auto-korelasi yang dimiliki oleh dataset.

Uji ARCH-LM

Uji ARCH-LM diperlukan untuk memastikan bahwa terdapat pengelompokan volatilitas pada variabel deret waktu. Hipotesis nol berarti tidak terdapat pengelompokan volatilitas. Tabel 4 berikut menyajikan hasil pengujian ARCH-LM pada vektor imbal hasil harian IHSG.

Tabel 4. Hasil uji ARCH-LM

N	Maks. lag	Chi-Squared	p-value
146 3	10	314.92	<2.2e-16
146 3	15	360.25	<2.2e-16

Sebagaimana terlihat pada tabel 4, dataset menolak hipotesis nol yang mengindikasikan bahwa terdapat pengelompokan volatilitas sehingga memungkinkan penerapan kelas model GARCH dan variannya.

Uji Sign-bias

Uji sign-bias dilakukan untuk mengidentifikasi adanya perbedaan efek (asimetris) dari sentimen positif dan sentimen negatif terhadap volatilitas. Hipotesis nol adalah tidak terdapat perbedaan efek antara sentimen positif dan sentimen positif terhadap volatilitas. Tabel 5 berikut menyajikan hasil uji sign-bias.

Tabel 5. Hasil uji *sign-bias*

Statistik	t-value	p-value
<i>sign-bias</i>	1.1166	0.2643
<i>Sign-bias</i> negatif	2.0093	0.045**
<i>Sign-bias</i> positif	0.6476	0.5173
<i>Joint effect</i>	14.782	0.0020***
	0	

Hasil uji menunjukkan bahwa dataset menolak hipotesis nol bahwa efek bersifat simetris atau tidak terdapat perbedaan efek yang signifikan antara sentimen negatif dan sentimen positif terhadap volatilitas. Hasil ini mengindikasikan bahwa penggunaan varian model GARCH yang mampu memperhitungkan efek leverage seperti EGARCH, TGARCH, GJR-GARCH dan APARCH lebih sesuai. Namun demikian, penelitian ini hanya fokus pada penggunaan model APARCH untuk memprediksi nilai sigma satu hari kedepan dan menggunakan nilai sigma tersebut dalam menghitung nilai *value-at-risk*.

Estimasi Parameter

Pemilihan jumlah lag pada spesifikasi model ARMA akan dilakukan secara otomatis dengan menggunakan AIC sebagai kriteria. Model terbaik merupakan model yang menghasilkan nilai AIC terkecil. Tabel 6 berikut menyajikan empat model dengan nilai AIC terkecil yang diurutkan dari yang terkecil.

Tabel 6. Hasil estimasi parameter ARMA

Spesifikasi	Log likelihood	AIC
ARMA(1,1)	4620.23	-9232.46
ARMA(2,1)	4620.52	-9231.04
ARMA(1,2)	4620.5	-9231.0
ARMA(3,1)	4620.76	-9229.51

Setelah spesifikasi mean terbaik didapatkan, sebagaimana disajikan pada tabel 6. Estimasi parameter selanjutnya dilakukan secara manual untuk mengidentifikasi model ARMA(1,1)-APARCH(q,p) terbaik berdasarkan nilai AIC. Pilihan model ARMA(1,1)-APARCH(q,p) dibatasi pada spesifikasi dimana jumlah lag q dan p tidak lebih dari 2. di Selanjutnya, model ARMA(1,1)-APARCH(q,p) akan dibandingkan dengan model GARCH dalam hal kemampuannya menghasilkan prediksi satu hari kedepan nilai *value-at-risk* yang *robust*. Baik estimasi parameter ataupun peramalan satu hari kedepan secara bergilir dilakukan dengan menggunakan paket/librari rugarch dari bahasa pemrograman R. Hasil estimasi parameter model APARCH(q,p) pada berbagai spesifikasi disajikan pada Tabel 7.

Tabel 7. Hasil estimasi parameter

Parameter	Model			
	ARMA(1,1)- APARCH(1,1)	ARMA(1,1)- APARCH(1,2)	ARMA(1,1)- APARCH(2,1)	ARMA(1,1)- ARCH(2,2)
μ	0.0003(0.0002)*	0.0003(0.0002)*	0.0003(0.0002)*	0.0003(0.0002)*
θ_1	- 0.8529(0.0187)***	-0.8431(0.0278)***	- 0.8529(0.0188)** *	- 0.8431(0.0279)** *
φ_1	0.8815(0.0143)***	0.8757(0.022)***	0.8815(0.0144)** *	0.8757(0.0221)** *
ω	0(0.0001)	0(0.0001)	0(0.0001)	0(0.0001)
α_1	0.0737(0.0529)	0.1236(0.0552)**	0.0735(0.0525)	0.1235(0.0551)**
α_2			0(0)	0(0)
β_1	0.9128(0.0543)***	0.232(0.1557)	0.9128(0.0541)** *	0.232(0.1557)
β_2		0.6239(0.1654)***		0.6239(0.1654)** *
γ_1	0.6377(0.2621)**	0.591(0.1923)***	0.6371(0.2639)**	0.5908(0.1929)** *
γ_2			0.3383(0.3796)	-0.8516(2.1964)
δ	1.3981(0.2824)***	1.4031(0.2582)***	1.4032(0.2703)** *	1.4062(0.2561)** *
shape	4.9207(0.5773)***	5.0655(0.641)***	4.9215(0.5773)** *	5.065(0.6409)***
Likelihood	4928.747	4933.386	4928.746	4933.386
AIC	-6.7256	-6.7305	-6.7228	-6.7278
BIC	-6.693	-6.6944	-6.6831	-6.6844
SIC	-6.7256	-6.7306	-6.7229	-6.7279

Sumber: diolah, Keterangan: *, **, ***, secara berurutan mengindikasikan signifikansi pada level alpha 10%, 5% dan 1%.

Sebagaimana terlihat pada tabel 7, hasil estimasi parameter model ARMA(1,1)-APARCH(1,2) menunjukkan nilai AIC/BIC/SIC yang terkecil. Parameter omega(ω), sebagaimana pada model lainnya, tidak menunjukkan signifikansi pada seluruh model yang diestimasi. Parameter α_1 yang mengukur seberapa besar volatilitas saat ini akan berpengaruh pada volatilitas periode berikutnya menunjukkan nilai sebesar 0,12 dan signifikan. Parameter β yang mengukur persistensi dari volatilitas bernilai 0,62 dan hanya signifikan pada β_2 . Parameter γ yang mengukur efek leverage hanya menunjukkan signifikansi yang diharapkan pada koefisien γ_1 sehingga mengkonfirmasi hasil uji *sign-bias* bahwa terdapat perbedaan efek antara sentimen negatif dan sentimen positif terhadap

volatilitas. Parameter δ yang merupakan pangkat dari fungsi heteroskedastisitas kondisional bernilai 1,40 yang secara signifikan membuktikan bahwa fungsi tersebut non-linear.

Pada tahap berikutnya, dilakukan perbandingan atas model ARMA(1,1)-APARCH(1,2) sebagai model terbaik untuk meninjau seberapa baik model APARCH tersebut dalam memprediksi nilai *value-at-risk* satu periode kedepan jika dibandingkan dengan GARCH. *Backtesting* atas nilai *value-at-risk* dilakukan menggunakan uji *unconditional coverage* dan *conditional coverage*. Tabel 8 berikut menunjukkan hasil *backtesting value-at-risk* pada masing-masing model.

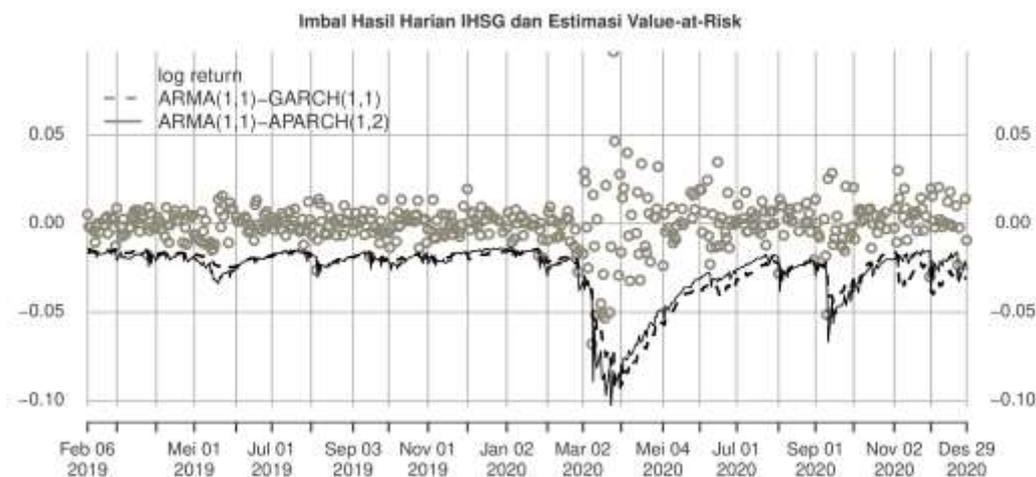
Tabel 8. Hasil *Backtesting Value-at-Risk*

Model	ARMA(1,1)- GARCH(1,1)	ARMA(1,1)- APARCH(1,2)
N	462	462
<i>Expected Shortfall</i>	4,6	4,6
<i>Actual Shortfall</i>	10	9
<i>Unconditional coverage LR</i>	4.747 (6.635)**	3,286(6.635)*
<i>Conditional coverage LR</i>	5,191 (9.21)*	3,643 (9.21)

*Sumber: diolah, Keterangan: *,**,***, secara berurutan mengindikasikan signifikansi pada level alpha 10%, 5% dan 1%. Hasil uji backtesting, baik unconditional ataupun conditional disajikan dalam format “t hitung LR (t tabel LR)”. Tolak H0 jika LR hitung > LR kritis.*

Tabel 8 menunjukkan bahwa tidak terdapat perbedaan kinerja yang signifikan diantara kedua model dalam hal meramalkan nilai *value-at-risk*. Namun demikian, hasil *backtesting* membuktikan bahwa kedua model tersebut tidak mampu menolak hipotesis nol dari kedua pengujian yang berarti bahwa kedua ukuran *value-at-risk* dapat diterima. Namun demikian, sebagaimana ditunjukkan oleh Gambar 2, terdapat perbedaan karakteristik antara ukuran *value-at-risk* yang dihasilkan oleh model ARMA(1,1)-GARCH (1,1) dan ARMA(1,1)-APARCH(1,2). Model ARMA(1,1)-APARCH(1,2) mampu menghasilkan ukuran *value-at-risk* yang lebih adaptif terhadap perubahan volatilitas harian terutama untuk efek negatif jika dibandingkan dengan ARMA(1,1)-GARCH(1,1). Sebagai hasilnya, model ARMA(1,1)-APARCH(1,2) mampu mengurangi jumlah pelanggaran aktual sebanyak 1 kasus jika dibandingkan model ARMA(1,1)-GARCH(1,1). Gambar 2 berikut ini menampilkan perbedaan antara ukuran *value-at-risk* yang dihasilkan oleh ketiga model.

Gambar 3. Imbal Hasil Harian IHSG dan Estimasi Value-at-risk



Kesimpulan

Hasil pemilihan model peramalan terbaik untuk kelas model ARMA(r,s)-APARCH(q,p) dilakukan berdasar nilai AIC sebagai patokan utama. Berdasarkan nilai AIC dan juga konsisten dengan nilai BIC/SIC didapatkan model terbaik adalah ARMA(1,1)-APARCH(1,2) dengan persamaan:

$$\mu_t = -0,8431R_{t-1} + 0,8757a_{t-1}$$

$$\sigma_t^\delta = 0,0003 + 0,1236(|\epsilon_{t-1}| - 0,591\epsilon_{t-1})^{1,403} + 0,232\sigma_{t-1}^{1,403} + 0,6239\sigma_{t-2}^{1,403}$$

Selanjutnya nilai sigma satu periode kedepan yang diramalkan oleh model tersebut digunakan untuk menghitung *value-at-risk* dan dibandingkan dengan ukuran *value-at-risk* yang dihasilkan oleh model ARMA-GARCH. Hasil dalam penelitian ini menunjukkan bahwa kelas model APARCH mampu menghasilkan nilai *value-at-risk* yang lebih adaptif dibanding kelas model GARCH. Hal tersebut sesuai dengan keunggulan model APARCH yang mampu memperhitungkan efek negatif dan positif secara asimetris.

Secara praktis, peramalan volatilitas sering digunakan untuk menghitung nilai *value-at-risk* satu periode atau beberapa periode kedepan. Penelitian selanjutnya dapat mengikutsertakan kelas model yang berbeda seperti TGARCH, EGARCH, dan GJR-GARCH dalam menentukan spesifikasi yang terbaik dalam peramalan nilai *value-at-risk*. Ketiganya mampu memperhitungkan *leverage effect* sehingga sangat relevan untuk diperbandingkan.

Daftar Pustaka

- Aryati, T., & Walansendouw, Y. C. (2013). Analisis Pengaruh Diversifikasi Arumningtyas, F., Prahutama, A., & Kartikasari, P. (2021). Value-At-Risk Analysis Using ARIMAX-GARCHX Approach For Estimating Risk Of Bank Central Asia Stock Returns. *Jurnal Varian*, 5(1), 71–80. <https://doi.org/10.30812/varian.v5i1.1474>

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, 31(3), 307–327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Christoffersen, P. F. (1998). Evaluating Interval Forecasts. *International Economic Review*, 39(4), 841. <https://doi.org/10.2307/2527341>
- Ding, Z., Granger, C. W. J., & Engle, R. F. (1993). A long memory property of stock market returns and a new model. *Journal of Empirical Finance*, 1(1), 83–106. [https://doi.org/10.1016/0927-5398\(93\)90006-D](https://doi.org/10.1016/0927-5398(93)90006-D)
- Duffie, D., & Pan, J. (1997). An Overview of Value at Risk. *The Journal of Derivatives*, 4(3), 7–49. <https://doi.org/10.3905/jod.1997.407971>
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987. <https://doi.org/10.2307/1912773>
- Francq, C., & Thieu, L. Q. (2019). QML Inference For Volatility Models With Covariates. *Econometric Theory*, 35(1), 37–72. <https://doi.org/10.1017/S0266466617000512>
- 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>
- Hafizah, S. Z., Kusnandar, D., & Martha, S. (2020). Model Generalized Autoregressive Conditional Heteroscedasticity in Mean Untuk Meramalkan Volatilitas Return Saham. *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 9(1).
- Huang, Y. C., & Lin, B.-J. (2004). Value-at-Risk Analysis for Taiwan Stock Index Futures: Fat Tails and Conditional Asymmetries in Return Innovations. *Review of Quantitative Finance and Accounting*, 22(2), 79–95. <https://doi.org/10.1023/B:REQU.0000015851.78720.a9>
- Hung, J.-C., Lee, M.-C., & Liu, H.-C. (2008). Estimation of value-at-risk for energy commodities via fat-tailed GARCH models. *Energy Economics*, 30(3), 1173–1191. <https://doi.org/10.1016/j.eneco.2007.11.004>
- Husein, I., & Lubis, A. I. D. (2022). Egarch Model Prediction for Sale Stock Price. *Jurnal Varian*, 6(1), 49–60. <https://doi.org/10.30812/varian.v6i1.1975>
- 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>
- Maulana, Y. (2020). Analisis Volatilitas Return Saham PT Antam (Persero) Tbk dan PT Adaro Energy Tbk Dengan Garch, Egarch Dan GJR. *Jurnal Akuntansi dan Pajak*, 20(2), 197–200. <https://doi.org/10.29040/jap.v20i2.859>
- Megawati, S. M., Kusnandar, D., & others. (2020). Pemodelan dan peramalan volatilitas saham menggunakan model integrated generalized autoregressive conditional heteroscedasticity. *Bimaster: Buletin Ilmiah Matematika, Statistika dan Terapannya*, 9(1).
- Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, 59(2), 347. <https://doi.org/10.2307/2938260>

- Ridha, R., & Wibowo, A. (2020). Analisis Volatilitas Return indeks saham sektor barang konsumsi di Indonesia: Aplikasi metode Treshold-garch (TGARCH). *VARIANCE: Journal of Statistics and Its Applications*, 2(1), 35–43. <https://doi.org/10.30598/variancevol2iss1page35-43>
- Sidadolog, J. H., Sumarjaya, I. W., & Tastrawati, N. K. T. (2020). Peramalan Volatilitas Return Saham Menggunakan Metode Asymmetric Power Arch (APARCH). *E-Jurnal Matematika*, 9(3), 157–164. <https://doi.org/10.24843/MTK.2020.v09.i03.p293>
- Tsay, R. S. (2010). *Analysis of Financial Time Series: Tsay/Financial Time Series 3E*. John Wiley & Sons, Inc. <https://doi.org/10.1002/9780470644560>
- Warsito, O. L. D., & Robiyanto, R. (2020). Analisis Volatilitas Cryptocurrency, Emas, Dollar, Dan Indeks Harga Saham (IHSG). *International Journal of Social Science and Business*, 4(1). <https://doi.org/10.23887/ijssb.v4i1.23887>
- Zakoian, J.-M. (1994). Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*, 18(5), 931–955. [https://doi.org/10.1016/0165-1889\(94\)90039-6](https://doi.org/10.1016/0165-1889(94)90039-6)