

ESTIMASI CVAR PADA PORTOFOLIO SAHAM MENGUNAKAN METODE GJR-EVT DENGAN PENDEKATAN D-VINE COPULA

Dery Maulana^{1§}, Komang Dharmawan², I Gusti Ayu Made Srinadi³

¹Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: derymaulana119@gmail.com]

²Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: k.dharmawan@unud.ac.id]

³Program Studi Matematika, Fakultas MIPA – Universitas Udayana [Email: srinadi@unud.ac.id]

[§]Corresponding Author

ABSTRACT

Risk measure using Conditional Value at Risk can be calculate if values that exceeds the p-quantile is known in VaR. The models used to accommodate characteristics of the stock portfolio in this research are EVT-GARCH-D-vine copula and EVT-GJR-D-vine copula so the performance of these two models can be compared. A comparison of the performance of the EVT-GARCH-D-vine copula and EVT-GJR-D-vine copula models can be seen from the Kupiec test backtesting process. Exceeded value Kupiec Test on CVaR 99% is 2, CVaR 95% is 6, and CVaR 90% is 13 for AR(1)-GARCH-t(1,1)-GPD and CVaR 99% is 3, CVaR 95% is 7, and CVaR 90% is 13 for AR(1)-GJR-t(1,1)-GPD. The Kupiec test describes the estimated risk value of CVaR running well with the value of the entire model above the significant level of $\alpha = 0.05$ so as to provide a conclusion of risk estimates considered feasible.

Keywords: CVaR, D-vine copula, EVT, GJR-GARCH

1. PENDAHULUAN

Manajemen risiko perlu dilakukan oleh investor dalam investasi saham. Nilai risiko dalam portofolio saham yang telah ditetapkan investor perlu diketahui secara mendalam. Hal ini bertujuan untuk menghindari risiko kerugian pada masa yang akan datang.

Terdapat istilah umum yang dikenal dalam finansial yaitu *high risk*, *high return*. Jika investor ingin memperoleh *return* yang tinggi maka semakin tinggi juga risiko yang muncul. Istilah tersebut juga berkaitan dengan pengertian volatilitas. Volatilitas dalam finansial berarti pergerakan yang tidak menentu suatu aset finansial. Semakin tinggi volatilitas maka semakin tinggi risiko ataupun *return* yang terjadi pada aset finansial tersebut.

Volatilitas asimetris, yaitu pergerakan volatilitas yang tidak searah dengan *return* terjadi pada beberapa kasus finansial. Pergerakan volatilitas turun ketika *return* naik, dalam contoh kasus disebut *leverage effect*. Metode kasus tersebut ialah metode *Glosten, Jagannathan, dan Runkle* GARCH (GJR-GARCH) (Brooks, 2008).

EVT dapat meramalkan terjadinya kejadian

ekstrem pada data berekor gemuk (*fat tail*) yang umum terjadi pada data finansial. Danielsson (2011) keberadaan ekor gemuk pada data dapat dilihat pada QQ plot yang mengikuti distribusi normal standar. Semakin banyak nilai *quantile* yang menjauh dari garis maka indikasi ekor gemuk pada data semakin besar.

Perilaku antaraset finansial dapat diketahui dengan melihat kebergantungan antaraset finansial sebagai langkah untuk melakukan diversifikasi. Kebergantungan antaraset finansial pada portofolio yang tersusun dari beberapa aset finansial harus dianalisis karena kebergantungan ini akan memberikan informasi terkait pengukuran risiko suatu portofolio. Data yang berdistribusi normal merupakan asumsi yang diperlukan untuk mengetahui kebergantungan antarpeubah acak yang diukur menggunakan korelasi linier. Danielsson (2011) sebagian besar data finansial tidak berdistribusi normal, terindikasi berekor gemuk pada distribusinya, serta memiliki kebergantungan taklinier. Kebergantungan antarpeubah acak pada data finansial kurang cocok jika menggunakan korelasi linier maka

salah satu alternatifnya pada kasus data finansial yaitu menggunakan pendekatan *copula*.

Value at risk (VaR) salah satu metode yang digunakan untuk mengukur risiko pada data finansial. Ukuran risiko menggunakan VaR dapat dikatakan baik jika kondisi kemonotonan, subaditivitas, positif homogen, invarian terhadap translasi terjaga. Jumlahan antara dua risiko tidak selalu kurang dari atau sama dengan dua risiko yang dijumlahkan atau biasa disebut subaditivitas dalam beberapa kasus estimasi risiko pada VaR tidak terjaga.

Conditional value at risk (CVaR) menjadi solusi karena dapat mengakomodasi masalah subaditivitas yang tidak dapat terjaga pada VaR. Sehingga CVaR dikatakan pengukuran risiko yang lebih koheren dari pada VaR (Alexander *et al*, 2006).

Prosedur pengujian validitas suatu model risiko adalah *Backtesting*. *Backtesting* merupakan suatu metode untuk menguji seberapa baik model risiko yang telah diestimasi. Uji *Kupiec* adalah metode yang menguji banyaknya frekuensi kerugian pada ekor kiri distribusi (Kichen, 2017).

Penelitian ini merupakan pengembangan penelitian Sudina (2019) dengan memperluas ruang lingkup melibatkan struktur dekomposisi *D-vine copula* dan membandingkan hasilnya dengan estimasi CVaR yang dilakukan Sudina (2019). Dalam membandingkan kinerja AR(1)-GARCH(1,1) dan AR(1)-GJR(1,1), Sudina (2019) menggunakan *backtesting* dengan metode *V-test*. Hasil yang diperoleh ialah model AR(1)-GJR(1,1) lebih baik karena secara umum nilai statistik V_1, V_2 , dan V model AR(1)-GJR(1,1) lebih kecil daripada model AR(1)-GARCH(1,1).

Pergerakan harga saham domestik *market* cenderung serupa karena dipengaruhi oleh *global market*. Portofolio saham yang baik salah satu cirinya memiliki pergerakan harga saham yang tidak saling memengaruhi. Penelitian ini menggunakan portofolio saham mencakup *global market* yang berada di Asia, yaitu indeks saham Dow Jones Jepang, Dow Jones Singapura, dan Dow Jones Taiwan.

Log return merupakan salah satu model yang umum digunakan dalam analisis data finansial. Menurut Danielsson (2011) *return* adalah perubahan relatif pada harga aset finansial pada interval waktu tertentu. Berikut penjabaran dari *log return* :

Definisi 1 Return (Danielsson, 2011) Jika S_t menyatakan *log return* aset pada periode ke- t didefinisikan sebagai berikut:

$$r_t = \log\left(\frac{S_t}{S_{t-1}}\right) = \log S_t - \log S_{t-1} \quad (1)$$

r_t merupakan *return* pada waktu ke- t , S_t merupakan nilai aset pada periode waktu ke- t , S_{t-1} merupakan nilai aset pada periode waktu ke- $(t-1)$

Secara matematis model GARCH(p, q) dapat ditulis sebagai berikut:

$$\varepsilon_t = \sigma_t z_t$$

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (2)$$

ω adalah komponen konstanta, ε_t merupakan galat/eror pada waktu ke- t , σ_t merupakan deviasi standar pada waktu ke- t , z_t adalah variabel peubah acak IID dengan rata-rata nol dan varians satu, α_i adalah parameter ARCH, ε_{t-i}^2 merupakan kuadrat galat/eror pada waktu $t-1, i = 1, 2, \dots, p$, β_j adalah parameter GARCH, σ_{t-j}^2 adalah varians dari kuadrat galat pada waktu $t-j, j = 1, 2, \dots, q$.

McNeil (2005) menyatakan pemodelan volatilitas pada *return* akan bersifat stasioner jika *return* dari aset mengikuti proses autoregresif orde pertama atau AR(1) dengan

$$R_t = \phi R_{t-1} + \varepsilon_t, \quad |\phi| < 1 \quad (3)$$

Parameter ϕ merupakan parameter AR(1) yang mana jika $\phi = 1$ maka proses mengikuti *random walk* yang menyebabkan nilai *return* tidak stasioner sehingga nilai dari ϕ harus tetap kurang dari satu.

Zivot (2008) menghitung efek asimetris pada *return* dengan cara menghitung korelasi antara kuadrat *return* dan *return* aset pada periode sebelumnya. Secara matematis dapat ditulis sebagai berikut

$$\text{cor}(r_t^2, r_{t-1}) = \frac{\sum_{t=1}^n r_t^2 r_{t-1}}{\sqrt{(\sum_{t=1}^n (r_t^2)^2 r_{t-1}^2)}} \quad (4)$$

Salah satu contoh efek asimetris adalah ketika nilai korelasi pada Persamaan (4) mengarah bernilai negatif. Nilai yang negatif pada korelasi *return* kuadrat dan *return* akan menyebabkan nilai volatilitas berkurang. Prinsip memodelkan volatilitas yang baik ialah

Secara matematis model GJR-GARCH(p, q) dapat ditulis sebagai berikut:

$$\varepsilon_t = \sigma_t z_t$$

$$\sigma_t^2 = \omega + \sum_{i=1}^p (\alpha_i \varepsilon_{t-i}^2 + \gamma_i \varepsilon_{t-i}^2 L_{t-i}) + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (5)$$

$$L = \begin{cases} 1, & \varepsilon_{t-1} < 0 \\ 0, & \varepsilon_{t-1} > 0 \end{cases}$$

Sesuai dengan parameter GARCH(p, q) parameter pembeda pada model GJR-GARCH(p, q) adalah γ_i sebagai parameter efek asimetris.

Definisi 2 Ekor Gemuk (Danielsson, 2011) *Peubah acak dikatakan memiliki ekor gemuk apabila terdapat titik ekstrem yang lebih banyak daripada peubah acak yang mengikuti distribusi normal standar.*

Identifikasi awal pada EVT ialah melihat keberadaan nilai ekstrem pada QQ plot. Nilai yang menjauh dari garis bantu pada QQ plot diasumsikan sebagai nilai ekstrem pada data. Langkah selanjutnya dilakukan metode *Peak Over Threshold* (POT). POT diawali dengan menentukan ambang batas μ . Ambang batas μ adalah batas yang ditentukan dari fungsi distribusi peubah acak. POT mengasumsikan peubah acak berdistribusi IID. Chaves-Demoulin (1999) dalam Zuhara *et al* (2012) menyarankan untuk memilih ambang batas μ sebesar 10% dari total data amatan. Karena fungsi distribusi yang tidak diketahui pada Y_x dari $\{x_1, x_2, \dots, x_n\}$, maka akan sulit mengestimasi $Y_\mu(x)$ secara langsung. Kesulitan ini dapat diatasi dengan menggunakan pendekatan GPD.

Definisi 3 Fungsi Distribusi Generalized Pareto Distribution (GPD) (Franke *et al.*, 2011) menyatakan GPD sebagai berikut:

$$G_{\xi, \beta}(y) = 1 - \left(1 + \xi \frac{y}{\beta}\right)^{-\frac{1}{\xi}}$$

untuk $\begin{cases} y > 0, & \text{jika } \xi > 0, \\ \left[0 \leq y \leq -\left(\frac{\beta}{\xi}\right)\right], & \text{jika } \xi < 0, \end{cases}$ (6)

dan

$$G_{\xi, \beta}(y) = 1 - e^{-\left(\frac{y}{\beta}\right)}$$

untuk $y = 0$, jika $\xi = 0$. (7)

ξ merupakan skala bentuk dan β skala parameter > 0

Definisi 4 Copula (Franke, 2011) *Copula berdimensi n adalah fungsi distribusi berdimensi n dengan fungsi marginal uniform standar $[0,1]$.*

Pada analisis data finansial, memodelkan kebergantungan tak linier antarpeubah acak penyusun portofolio harus ditransformasikan menjadi distribusi uniform standar $[0,1]$ seperti Definisi 4. Dalam proses transformasi distribusi

uniform standar $[0,1]$ dapat menggunakan metode *probability integral transformation*. Danielsson (2011) menyatakan bahwa metode *probability integral transformation* dapat mengidentifikasi kebergantungan antarpeubah acak dari hasil transformasinya. Sehingga data *return* aset saham yang sudah ditransformasi ke bentuk distribusi uniform standar $[0,1]$ dapat digunakan untuk memodelkan struktur kebergantungan antarpeubah acak menggunakan fungsi *copula*.

Definisi 5 Archimedean Copula (Cherubini *et al.*, 2004) *Fungsi archimedean copula $C: [0,1]^d \rightarrow [0,1]$ diberikan oleh*

$$C(x_1, \dots, x_n; \varphi) = \varphi^{-1}(\varphi(x_1) + \dots + \varphi(x_n)), \quad (8)$$

$x_i \in [0,1]^d$

Generator *copula* C adalah fungsi $\varphi(x_i)$, dengan $i = 1, \dots, n$ yang dipetakan pada rentangan $[0,1]$ pada $[0, \infty]$ sedemikian sehingga $\varphi(1) = 0$ dan $\varphi(0) = \infty$. Nilai generator $\varphi(x_i)$ pada setiap jenis *archimedean copula* berbeda. Berikut tabel yang menjelaskan perbedaan antara Clayton *copula*, Gumbel *copula*, dan Frank *copula*.

D-vine copula merupakan bagian dari reguler *vine copula* yang terbentuk dari *vine copula*.

Definisi 6 D-vine dan C-vine (Kurowicka & Cooke, 2007)

- D-vine* memenuhi syarat pada saat masing-masing *node* pada *tree* T_j memiliki drajat paling banyak dua.
- C-vine* memenuhi syarat pada saat masing-masing *node* pada *tree* T_j memiliki *node* unik yang disebut akar (*root*).

Pada penelitian ini selanjutnya penulis akan memakai struktur *D-vine copula* karena memiliki struktur yang lebih sederhana.

Langkah simulasi *return* ini perlu dilakukan untuk mengestimasi nilai CVaR pada subbab berikutnya. Data simulasi x_1, x_2, x_3 diperoleh dari invers fungsi distribusi kumulatif sehingga diperoleh kembali komponen barisan independen dengan *mean* nol dan varians satu (z_{it}) dengan $i = 1, 2, 3$. Selanjutnya z_{it} digunakan pada Persamaan (3) yang merupakan proses AR(1) sehingga diperoleh *return* hasil simulasi *D-vine copula* yang stasioner.

Definisi 7 (VaR) dan (CVaR) (Klugman *et al.*, 2008 dalam Sudina, 2019)

Diberikan $F(X)$ adalah fungsi distribusi

kerugian dari peubah acak X , sehingga berlaku $F(\pi_p) = \Pr(X \leq \pi_p) = p$. Invers dari fungsi distribusi D adalah $F^{-1}(p) = \inf(\pi_p \in \mathbb{R}: F(\pi_p) \geq p)$, $0 < p < 1$ atau disebut juga sebagai fungsi kuantil dari distribusi F . VaR dan CVaR didefinisikan sebagai:

1. Value at Risk (VaR) dari peubah acak X pada tingkat kepercayaan $100p\%$ adalah p -kuantil dari fungsi distribusi F dan dapat dinyatakan sebagai

$$VaR_p(X) = \pi_p = F^{-1}(p) \quad (9)$$

2. Conditional Value at Risk (CVaR) dari peubah acak X pada tingkat kepercayaan $100p\%$ merupakan ekspektasi kerugian apabila diketahui besar kerugian yang melebihi p -kuantil dari distribusi F .

$$CVaR_p(X) = E\left(X \mid X > VaR_p(X)\right) \quad (10)$$

Berdasarkan 2 definisi tersebut, Conditional Value at Risk (CVaR) merupakan metode untuk menghitung risiko yang melebihi VaR.

Backtesting merupakan metode untuk menguji suatu model risiko yang terbentuk. *Backtesting* mampu melihat pergerakan estimasi risiko secara riil pada data return sehingga pengujian dapat terlihat secara langsung. Salah satu metode turunan dari *backtesting* yang umum digunakan pada data finansial adalah uji *Kupiec* yang dapat menguji banyaknya frekuensi kerugian pada ekor kiri distribusi (Kichen, 2017).

2. METODE PENELITIAN

Jenis data yang digunakan pada penelitian ini adalah data kuantitatif, merupakan data sekunder berupa harga penutupan harian yaitu indeks saham Dow Jones Jepang (DJJP), Dow Jones Singapura (DJSG), dan Dow Jones Taiwan (DJTA) dalam mata uang USD periode 22 April 2013 hingga 10 Februari 2021 sebanyak 2039 data saham harian. Data tersebut dapat diakses melalui situs *website* www.investing.com.

Langkah-langkah dalam mengestimasi nilai CVaR portofolio menggunakan metode GJR-EVT dengan pendekatan *D-vine copula* yaitu sebagai berikut :

1. Menghitung *return* indeks saham DJJP, DJSG, dan DJTA.
2. Melihat karakteristik data pada statistik deskriptif *return* indeks saham DJJP, DJSG, dan DJTA.
3. Memeriksa stasioneritas pada masing-masing *return* indeks saham menggunakan

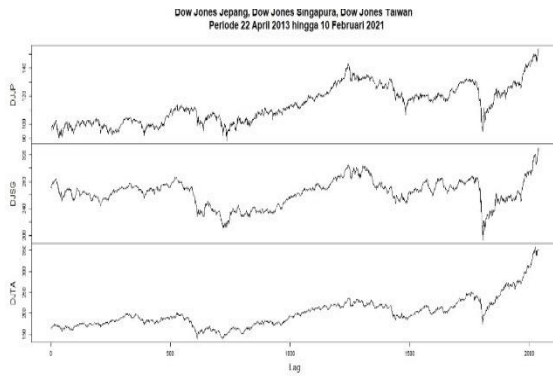
uji formal *augmented* Dickey-Fuller (ADF).

4. Melakukan uji Ljung-Box untuk mengetahui keberadaan sifat autokorelasi pada residual data *return*.
5. Melakukan uji ARCH *Lagrange multiplier* untuk mengetahui sifat heteroskedastisitas pada residual *return*.
6. Memodelkan volatilitas portofolio indeks saham menggunakan model GARCH(1,1).
7. Memeriksa efek autokorelasi dan heteroskedastisitas pada data residual.
8. Plot kuantil-kuantil (Plot QQ) untuk mengetahui keberadaan ekor gemuk pada data residual model GARCH(1,1).
9. Menentukan *threshold* sebesar 10% dari keseluruhan data sebagai data ekstrem.
10. Mengestimasi parameter *Generalized Pareto Distribution* (GPD) menggunakan *maximum likelihood estimator*.
11. Melakukan transformasi seragam [0,1] pada masing-masing marginal menggunakan *probability integral transformation*.
12. Memodelkan distribusi seragam [0,1] dari residual GARCH(1,1) dengan pendekatan *D-vine copula*.
13. Melakukan estimasi parameter *D-vine copula*.
14. Melakukan simulasi *return* menggunakan dekomposisi *D-vine copula*.
15. Menghitung CVaR 90%, CVaR 95%, dan CVaR 99%.
16. Mengulangi langkah 6 sampai 15 menggunakan model GJR(1,1).
17. Melakukan validasi model EVT-GJR(1,1)-*Dvine copula* dengan Uji Kupiec.

3. HASIL DAN PEMBAHASAN


3.1 Identifikasi Data

Identifikasi data meliputi pergerakan data historis, perhitungan nilai *return*, dan uji asumsi klasik pada data *return*. Secara visual yang terlihat pada Gambar 1 bahwa pergerakan harga indeks saham DJJP, DJSG, dan DJTA memiliki fluktuasi perubahan harga yang cukup signifikan.



Gambar 1. Plot *Closing Price* Indeks Saham DJJP, DJSG, dan DJTA

Plot pada waktu awal hingga menuju tahun 2015 menunjukkan tren naik pada harga saham. Kemudian turun secara drastis hingga menyentuh titik terendah pada akhir 2015 hingga pergerakan nilai saham kembali naik dan menyentuh *all time high* pada kisaran tahun 2021.



Gambar 2. Plot *return* Indeks Saham DJJP, DJSG, DJTA

Gambar 2 menunjukkan plot *return* indeks saham DJJP, DJSG, dan DJTA sebanyak 2037 data. Nilai *return* tersebut diperoleh dari perhitungan sesuai pada Persamaan (1). Selanjutnya nilai *return* tersebut digunakan untuk proses estimasi risiko. Identifikasi data dilanjutkan pada tahap uji asumsi klasik pada Tabel 1. Kondisi stasioner, autokorelasi, dan heteroskedastisitas pada data finansial harus dipenuhi agar dapat dilanjutkan pada tahanan pemodelan volatilitas pada subbab selanjutnya.

Tabel 1. Uji Asumsi Klasik pada Data *Return*

Tarf Signifikan $\alpha = 0,05$	p-value <i>Return</i>		
	DJJP	DJSG	DJTA
Uji ADF	0,01	0,01	0,01
Uji Ljung-Box	$4,106 \times 10^{-7}$	$2,861 \times 10^{-7}$	0,001414
Uji ARCH-LM	$< 2,2 \times 10^{-16}$	$< 2,2 \times 10^{-16}$	$< 2,2 \times 10^{-16}$

Identifikasi data stasioner pada *return* indeks saham menggunakan uji ADF dengan hipotesis nol terdapat akar unit pada residual data *return* menunjukkan nilai yang kurang dari taraf signifikan $\alpha = 0,05$. Nilai *p-value* = 0,01 pada ketiga data *return*. Sehingga cukup bukti untuk menolak hipotesis nol yang mengartikan bahwa *return* DJJP, DJSG, dan DJTA tidak memiliki akar unit pada residual sehingga *return* DJJP, DJSG, dan DJTA stasioner.

Hasil dari uji ADF ini sejalan dengan pernyataan Tsay (2013) *differencing* ordo pertama atau log *return* sering kali bersifat stasioner daripada harga saham itu sendiri. Sehingga log *return* baik digunakan untuk analisis deret waktu yang memerlukan asumsi stasioner. Selanjutnya akan diidentifikasi sifat autokorelasi pada data. Korelasi antaramatan pada periode waktu sekarang dan waktu sebelumnya disebut Autokorelasi. Asumsi autokorelasi pada data finansial sangat

diperlukan untuk mengetahui seberapa acak data amatan. Efek Autokorelasi dapat dideteksi dengan uji Ljung-Box pada Tabel 1.

Nilai *p-value* indeks saham DJJP, DJSG, dan DJTA berturut-turut $4,106 \times 10^{-7}$, $2,861 \times 10^{-7}$, 0,001414 menunjukkan *p-value* ketiga indeks saham DJJP, DJSG, dan DJTA kurang dari taraf signifikan $\alpha = 0,05$ dengan hipotesis nol residual data tidak memiliki korelasi sehingga dalam hal ini cukup bukti untuk menolak hipotesis nol yang berarti terdapat autokorelasi pada *return* indeks saham DJJP, DJSG, dan DJTA.

Kemudian akan diidentifikasi sifat heteroskedastisitas pada data indeks saham DJJP, DJSG, dan DJTA. Suatu keadaan yang terdapat perbedaan varians pada residual data amatan disebut heteroskedastisitas. Pada Tabel 1 sifat heteroskedastisitas diuji dengan uji ARCH-LM. Hasil dari uji tersebut menunjukkan *p-value* DJJP, DJSG, dan DJTA berturut-turut $< 2,2 \times 10^{-16}$, $< 2,2 \times 10^{-16}$,

dan $< 2,2 \times 10^{-16}$ kurang dari taraf signifikan $\alpha = 0,05$ dengan hipotesis nol residual data tidak terdapat efek ARCH sehingga cukup bukti untuk menolak hipotesis nol yang berarti indeks saham DJJP, DJSG, dan DJTA bersifat heteroskedastisitas.

Tabel 2. Korelasi *Return* Kuadrat Periode ke-t dan *Return* Pada Periode t-1

	DJJP	DJSG	DJTA
$cor(r_t^2, r_{t-1})$	-0,1270446	-0,04969777	-0,175283

Nilai $cor(r_t^2, r_{t-1})$ yang negatif mengindikasikan terdapat efek asimetris pada indeks saham DJJP, DJSG, dan DJTA. Hal ini bersesuaian dengan penjelasan pada tinjauan pustaka GJR. Sehingga *leverage effect* perlu diestimasi pada pemodelan volatilitas pada

subbab berikutnya menggunakan GJR-GARCH.

3.2 Pemodelan Volatilitas

Karena GARCH(1,1) tidak dapat mengestimasi keberadaan *leverage effect* maka pada pemodelan volatilitas akan menggunakan model tambahan sebagai pembanding yaitu GJR-GARCH(1,1) karena pada perhitungannya GJR-GARCH(1,1) dapat mengestimasi nilai *leverage effect*. Danielsson (2011) menggunakan inovasi distribusi normal dan *student-t* pada galat model heteroskedastisitas. Tetapi berdasarkan identifikasi data pada Subbab sebelumnya yang mengindikasikan data tidak berdistribusi normal maka pemodelan volatilitas akan menggunakan inovasi distribusi *student-t*.

Tabel 3. Estimasi Parameter Model AR(1) GARCH-t(1,1)

Parameter Optimal ($\alpha = 0,05$)	AR(1)-GARCH-t(1,1)					
	DJJP		DJSG		DJTA	
	Estimasi	Galat baku	Estimasi	Galat Baku	Estimasi	Galat baku
μ	0,000537	0,000162	0,000313	0,000131	0,000777	0,000180
ϕ_1	-0,136856	0,022443	0,060357	0,022630	0,035587	0,021261
ω	0,000005	0,000004	0,000001	0,000001	0,000002	0,000002
α_1	0,114901	0,018998	0,090766	0,013633	0,049026	0,023194
β_1	0,852918	0,030963	0,899398	0,012727	0,930946	0,029119
<i>shape</i>	5,160093	0,673173	5,947752	0,683992	4,934189	0,500964
<i>LogLikelihood</i>	6553,233		7344,827		6718,311	
Kriteria Informasi						
<i>AIC</i>	-6,4283		-7,2055		-6,5904	
<i>BIC</i>	-6,4118		-7,1890		-6,5738	

Tabel 4. Estimasi Parameter Model AR(1)-GJR-t(1,1)

Parameter Optimal ($\alpha = 0,05$)	AR(1)-GJR-t(1,1)					
	DJJP		DJSG		DJTA	
	Estimasi	Galat baku	Estimasi	Galat baku	Estimasi	Galat baku
μ	0,000379	0,000163	0,000219	0,000130	0,000680	0,000183
ϕ_1	-0,125362	0,022460	0,058855	0,022604	0,041968	0,021580
ω	0,000005	0,000001	0,000001	0,000000	0,000003	0,000001
α_1	0,018947	0,007585	0,027164	0,003391	0,009360	0,001750
β_1	0,850119	0,014270	0,919073	0,009589	0,923510	0,009634
γ_1	0,167759	0,028957	0,085149	0,017185	0,067750	0,015101
<i>shape</i>	5,502333	0,622112	6,322190	0,805663	5,218537	0,603388
<i>LogLikelihood</i>	6570,853		7355,325		6726,714	
Kriteria Informasi						
<i>AIC</i>	-6,4446		-7,2149		-6,5977	
<i>BIC</i>	-6,4253		-7,1955		-6,5783	

Untuk menjaga kondisi stasioner pada pemodelan volatilitas, model AR(1) juga digunakan pada data *return* dengan perhitungan yang bersesuaian pada Persamaan (3). Model volatilitas akan bernilai baik jika kondisi stasioner dapat terjaga dan varians bernilai

positif.. Estimasi parameter AR(1)-GARCH(1,1) dan AR(1)-GJR(1,1) dengan inovasi distribusi *student-t* disingkat AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) digunakan *maximum likelihood estimator*. Tabel 4 dan Tabel 5 berikut secara berturut-

turut menjelaskan estimasi parameter GARCH-t(1,1) dan AR(1)-GJR-t(1,1) menggunakan aplikasi R 4.0.3.

Tabel 3 menjelaskan estimasi parameter dari AR(1)-GARCH-t(1,1) yang menunjukkan bahwa kondisi stasioner tetap terjaga. Hal ini dapat ditunjukkan oleh penjumlahan parameter ARCH (α) dan parameter GARCH (β) untuk masing-masing indeks saham berlaku $\alpha_1 + \beta_1 < 1$. Selanjutnya kondisi positif pada varians model AR(1)-GARCH-t(1,1) juga dapat dipertahankan. Hal ini dapat dilihat dari sifat GARCH-t(1,1) jika $\omega > 0$, $\alpha_1 > 0$, dan $\beta_1 > 0$ maka varians model positif. Kondisi stasioner juga dapat terjaga pada estimasi parameter model AR(1)-GJR-t(1,1) pada Tabel 4 dengan penjelasan yang sama pada model AR(1)-GARCH-t(1,1). Hal yang menjadi pembeda ialah kondisi positif varians pada model AR(1)-GJR-t(1,1) dapat tercapai jika $\omega > 0$, $\alpha_1 > 0$, dan $\beta_1 > 0$, dan $\alpha_1 + \gamma_1 \geq 0$. Terlihat pada

Tabel 4 seluruh sifat yang menjadi syarat model AR(1)-GJR-t(1,1) memiliki kondisi varians yang positif terpenuhi. Karena model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) dapat menjaga kondisi stasioner dan varians positif maka secara karakteristik estimasi parameter model volatilitas berjalan dengan baik.

Estimasi parameter dari model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) juga dapat dilihat pada kriteria informasi yang menampilkan nilai dari Akaike *Information Criterion* (AIC) dan Bayesian *Information Criterion* (BIC). Kriteria informasi ini menunjukkan hasil yang kecil pada seluruh indeks saham sehingga dapat dikatakan estimasi parameter memiliki kinerja yang baik.

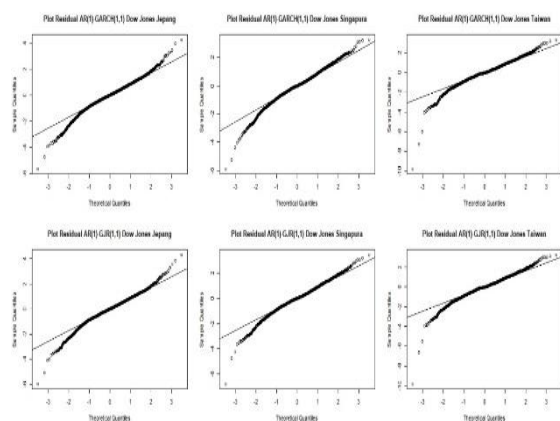
Lebih lanjut akan dilakukan uji formal pada residual model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) untuk mengetahui seberapa efektif model bekerja. Uji autokorelasi, uji heteroskedastisitas akan dilakukan kembali pada standar residual AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1).

Tabel 5. Uji Formal Ljung-Box dan ARCH-LM pada Standar Residual AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1)

Tarf signifikan $\alpha = 0,05$	p-value residual					
	AR(1)-GARCH-t(1,1)			AR(1)-GJR-t(1,1)		
	DJJP	DJSG	DJTA	DJJP	DJSG	DJTA
Uji Ljung-Box	0,7631	0,07773	0,05874	0,8045	0,1486	0,05417
Uji ARCH-LM	0,547	0,1785	0,9877	0,3556	0,5031	0,9946

Hasil uji formal pada Tabel 5 menunjukkan uji Ljung-Box dengan $p - value$ untuk seluruh indeks saham lebih dari taraf signifikan $\alpha = 0,05$ dengan hipotesis nol terdapat korelasi pada data. Sehingga tidak cukup bukti untuk menolak hipotesis nol yang berarti model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) untuk seluruh indeks saham tidak bersifat autokorelasi.

Selanjutnya untuk uji ARCH-LM menunjukkan $p - value$ untuk seluruh indeks saham melebihi taraf signifikan $\alpha = 0,05$ dengan hipotesis nol tidak terdapat efek ARCH. Sehingga cukup bukti untuk menolak hipotesis nol yang memiliki arti terdapat efek ARCH pada residual data. Hasil ini menunjukkan bahwa efek heteroskedastisitas telah diatasi dengan baik pada model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1).



Gambar 3. QQ Plot Residual Model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1)

Residual model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) yang terlihat pada Gambar 3 masih terdapat masalah yang muncul. Pada Gambar 3 ada beberapa data *quantile* yang bergerak keluar dari garis bantu. Data *quantile* yang bergerak tidak sesuai dengan distribusi normal ini dinamakan sebagai nilai ekstrem yang mengindikasikan keberadaan ekor gemuk pada data.

3.3 Pemodelan Nilai Ekstrem

Keberadaan nilai ekstrem penyebab ekor gemuk yang terindikasi pada Gambar 3 perlu dimodelkan agar estimasi risiko tidak *underestimated*. *Extreme Value Theorm* (EVT) akan digunakan untuk memodelkan ekor gemuk pada residual AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1). Langkah awal untuk memodelkan ekor gemuk adalah identifikasi menggunakan metode POT diawali dengan menentukan ambang batas μ . Sebanyak 203 data ekor kiri residual GARCH-t(1,1) diambil sebagai data ekstrem yang diperoleh dari 10% dari 2038 total data. Dua ratus tiga data ekor kiri residual AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) akan dimodelkan menggunakan GPD sebagai solusi pemodelan ekor gemuk. Estimasi parameter GPD menggunakan *likelihood estimator* (MLE) diberikan pada Tabel 6.


Tabel 6. Estimasi Parameter Model GPD

Parameter	AR(1)-GARCH-t(1,1)			AR(1)-GJR-t(1,1)		
	DJJP	DJSG	DJTA	DJJP	DJSG	DJTA
μ	-1,21404	-1,2518	-1,2154	-1,22323	-1,235	-1,2182
Excess	203	203	203	203	203	203
β	0,79428	0,66533	0,61991	0,76676	0,66428	0,6063
ξ	-0,05251	0,04322	0,17491	-0,03366	0,03374	0,1654


Hasil estimasi parameter GPD pada Tabel 6 menunjukkan nilai ξ residual data DJJP model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1) memiliki nilai yang negatif. Hal ini menunjukkan bahwa residual model dari data DJJP dengan nilai di bawah μ akan mengikuti distribusi Pareto II. Selanjutnya nilai ξ lebih besar dari nol ditunjukkan pada residual sisanya sehingga data residual yang memiliki nilai lebih kecil dari μ akan mengikuti distribusi Pareto.

Perbedaan antara distribusi Pareto II dan distribusi Pareto adalah karakteristik distribusi Pareto memiliki nilai ekor yang lebih gemuk.

3.4 Copula




Gambar 4. Plot Pencar Residual Model AR(1)-GARCH-t(1,1)




Gambar 5. Plot Pencar Residual Model AR(1)-GJR-t(1,1)

Pada analisis data finansial, memodelkan kebergantungan tak linier antarpeubah acak penyusun portofolio dengan metode *copula* harus ditransformasikan menjadi distribusi uniform standar [0,1] seperti Definisi 2.9. Metode *probability integral transformation* digunakan pada proses transformasi distribusi uniform standar [0,1] dapat menggunakan. Berikut Plot distribusi uniform standar [0,1] dari model AR(1)-GARCH-t(1,1)-GDP dan AR(1)-GJR-t(1,1)-GDP.



Gambar 6. Plot Pencar residual Transformasi Uniform [0,1] AR(1)-GARCH-t(1,1)-GDP



Gambar 7. Plot Pencar residual Transformasi Uniform [0,1] AR(1)-GJR-t(1,1)-GDP

Karena plot pencar pada Gambar 6 dan Gambar 7 hanya menampilkan kebergantungan data antarsaham secara visual maka diperlukan analisis lebih lanjut guna mengetahui aset saham yang paling berpengaruh pada portofolio. Nilai Kendall (τ) dan Spearman (ρ) akan digunakan untuk mengetahui aset saham yang memiliki nilai kebergantungan terkecil yang selanjutnya akan digunakan sebagai *node* penyusun *copula* multivariat.


Tabel 7. Nilai Kendall (τ) Residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1] dan Residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]

Nilai Kendall (τ)	Residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1]			Residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]		
	DJJP	DJSG	DJTA	DJJP	DJSG	DJTA
DJJP	1	0,1905755	0,2152622	1	0,2001470	0,2071134
DJSG	0,1905755	1	0,2833870	0,2001470	1	0,2765248
DJTA	0,2152622	0,2833870	1	0,2071134	0,2765248	1

Tabel 8. Nilai Spearman (ρ) Residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1] dan Residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]

Spearman (ρ)	Residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1]			Residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]		
	DJJP	DJSG	DJTA	DJJP	DJSG	DJTA
DJJP	1	0,2781294	0,3134437	1	0,2920061	0,3012252
DJSG	0,2781294	1	0,4071472	0,2920061	1	0,3975560
DJTA	0,3134437	0,4071472	1	0,3012252	0,3975560	1

Tabel 7 dan Tabel 8 menunjukkan nilai Kendall (τ) dan Spearman (ρ) secara bivariat pada setiap aset indeks saham. Nilai terkecil ditunjukkan DJJP dengan nilai Kendall (τ) dan 0,1905755 pada DJSG dan 0,2152622 pada DJTA untuk residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1]. Hasil serupa ditunjukkan pada residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]. Nilai terkecil berada pada DJJP dengan nilai Kendall (τ) 0,2920061 pada DJSG dan 0,3012252 pada DJTA. Nilai Spearman (ρ) pada Tabel 8 juga menunjukkan nilai terkecil berada pada DJJP. Nilai residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1] dan AR(1)-GJR-t(1,1)-GPD Uniform [0,1] DJJP yang kecil pada kebergantungan bivariat pada DJSG dan DJTA menjadikan data DJJP sebagai *node* penyusun *copula* multivariat.



Gambar 8. Dekomposisi D-vine Copula Indeks saham DJJP, DJSG, dan DJTA

Tabel 9. Estimasi Parameter D-vine Copula pada Residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1] dan Residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]

Residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1]				Residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]			
Tree	Edge	Family	Parameter	Tree	Edge	Family	Parameter
1	DJSG,DJJP	Clayton	0,49 (0,04)	1	DJSG,DJJP	Clayton	0,51 (0,04)
	DJJP,DJTA	Clayton	0,74 (0,04)		DJJP,DJTA	Clayton	0,75 (0,04)
2	DJSG,DJTA DJJP	Clayton	0,29 (0,03)	2	DJSG,DJTA DJJP	Clayton	0,25 (0,03)
Type: D-vine	logLik: 314,76	AIC: -623,52	BIC: -606,66	Type: D-vine	logLik: 321,27	AIC: -636,53	BIC: -619,67
Tree	Edge	Family	Parameter	Tree	Edge	Family	Parameter
1	DJSG,DJJP	Gumbel	1,36 (0,03)	1	DJSG,DJJP	Gumbel	1,37 (0,03)
	DJJP,DJTA	Gumbel	1,56 (0,03)		DJJP,DJTA	Gumbel	1,54 (0,03)
2	DJSG,DJTA DJJP	Gumbel	1,22 (0,02)	2	DJSG,DJTA DJJP	Gumbel	1,20 (0,02)
Type: D-vine	logLik: 403,3	AIC: -800,6	BIC: -783,74	Type: D-vine	logLik: 391,78	AIC: -777,56	BIC: -760,7
Tree	Edge	Family	Parameter	Tree	Edge	Family	Parameter
1	DJSG,DJJP	Frank	2,46 (0,17)	1	DJSG,DJJP	Frank	2,53 (0,16)
	DJJP,DJTA	Frank	3,64 (0,17)		DJJP,DJTA	Frank	3,53 (0,16)
2	DJSG,DJTA DJJP	Frank	1,96 (0,16)	2	DJSG,DJTA DJJP	Frank	1,82 (0,16)
Type: D-vine	logLik: 391,62	AIC: -777,23	BIC: -760,37	Type: D-vine	logLik: 382,3	AIC: -758,6	BIC: -741,74

Berdasarkan struktur dekomposisi D-vine copula pada Gambar 8, selanjutnya akan dilakukan estimasi parameter D-vine copula menggunakan *maximum likelihood estimator* (MLE). Hasil estimasi parameter D-vine copula disajikan pada Tabel 9.

Kolom *tree* dan *edge* pada Tabel 9 merupakan susunan dekomposisi D-vine copula berdasarkan Gambar 8. *Edge* menunjukkan copula bivariat yang memodelkan kebergantungan penyusun dari D-vine copula. *Tree* dua menjelaskan copula bivariat bersyarat yang memodelkan copula bivariat DJSG, DJJP dengan DJTA, DJJP.

Nilai *log likelihood* pada setiap *family* estimasi parameter D-vine copula menjadi penentu jenis *family copula* terbaik dalam memodelkan kebergantungan antarsaham DJJP, DJSG, DJTA yang selanjutnya diterapkan pada kriteria AIC dan BIC. Nilai AIC dan BIC terkecil dapat dilihat pada *family Gumbel copula* dengan nilai $AIC = -800,6$, $BIC = -783,74$ pada residual AR(1)-GARCH-t(1,1)-GPD Uniform [0,1] dan $AIC = -777,56$, $BIC = -760,7$ pada residual AR(1)-GJR-t(1,1)-GPD Uniform [0,1]. Nilai karakteristik

Gumbel copula baik digunakan untuk mengetahui kebergantungan antaraset finansial penyusun portofolio. Karakteristik Gumbel copula yang berfokus pada *uppertail copula* mengindikasikan kebergantungan copula pada risiko keuntungan. Semakin besar parameter pada Gumbel copula maka semakin besar kebergantungan risiko keuntungan pada aset finansial. Parameter Gumbel copula yang telah diestimasi selanjutnya digunakan sebagai struktur kebergantungan pada portofolio indeks saham DJJP, DJSG, dan DJTA untuk mengestimasi risiko menggunakan CVaR.

3.5 Simulasi Return

Setelah mengakomodasi sifat dan karakteristik pada data return indeks saham DJJP, DJSG, dan DJTA menggunakan AR(1)-GARCH-t(1,1)-GPD Uniform [0,1] dan AR(1)-GJR-t(1,1)-GPD Uniform [0,1], simulasi perlu data return perlu dilakukan dengan pendekatan D-vine copula. Hal ini dilakukan untuk memperoleh data return DJJP, DJSG, dan DJTA dengan struktur D-vine copula.

Tabel 10. Estimasi *Value at Risk* dan *Conditional Value at Risk* pada Simulasi *Return* AR(1)- GARCH-t(1,1) dan AR(1)-GJR-t(1,1)

Tingkat Kepercayaan (1 - α)	Family Copula	VaR		CVaR	
		Sim Return AR(1)-GARCH-t(1,1)-GPD	Sim Return AR(1)-GJR-t(1,1)-GPD	Sim Return AR(1)-GARCH-t(1,1)-GPD	Sim Return AR(1)-GJR-t(1,1)-GPD
90%	Gumbel	0,01098082	0,009845107	0,01729718	0,01546754
95%	Gumbel	0,01429846	0,01341453	0,02209712	0,01956534
99%	Gumbel	0,02502447	0,02208237	0,03780831	0,03052013

Tabel 11. Estimasi Kerugian Maksimum Satu Hari ke Depan Menggunakan CVaR

Tingkat Kepercayaan (1 - α)	Family Copula	CVaR (%)	
		Sim Return AR(1)-GARCH-t(1,1)-GPD	Sim Return AR(1)-GJR-t(1,1)-GPD
90%	Gumbel	\$ 1729	\$ 1546
95%	Gumbel	\$ 2221	\$ 1956
99%	Gumbel	\$ 3780	\$ 3052

Tabel 12. Uji Kupiec pada Estimasi Risiko *Value at Risk*

1 - α	Family Copula	CVaR (%)					
		Sim Return AR(1)-GARCH-t(1,1)-GPD	Exceeded value	p-value $\alpha = 0,05$	Sim Return AR(1)-GJR-t(1,1)-GPD	Exceeded value	p-value $\alpha = 0,05$
90%	Gumbel	0,01729718	13	0,9999742	0,01546754	13	0,999963
95%	Gumbel	0,02209712	6	1	0,01956534	7	1
99%	Gumbel	0,03780831	2	1	0,03052013	3	1

Langkah pertama yang dilakukan ialah membangkitkan bilangan acak sebanyak 2037 data berdasarkan estimasi parameter *D-vine copula* pada Tabel 9. Bilangan acak yang berjumlah 2037 tersebut kemudian ditransformasikan ke bentuk *invers* model AR(1)-GARCH-t(1,1)-GPD dan AR(1)-GJR-t(1,1)-GPD sehingga diperoleh bilangan acak IID z_{it} dengan mean nol dan varians satu. Galat baku (ε_{it}) pada simulasi *return* berdasarkan Persamaan (2) diperoleh dari z_{it} dikalikan dengan standar deviasi σ_{it} dari model AR(1)-GARCH-t(1,1) dan AR(1)-GJR-t(1,1). Setelah mendapat nilai galat baku (ε_{it}), langkah selanjutnya dapat dilanjutkan untuk simulasi *return* berdasarkan Persamaan (3) untuk mendapatkan nilai simulasi *return* yang stasioner.

3.6 Estimasi Risiko

Berdasarkan Tabel 10 terlihat setiap CVaR bernilai lebih besar dari nilai VaR. Hal ini menandakan setiap estimasi risiko pada CVaR

memiliki tingkat kerugian yang lebih dari VaR. Hal ini bersifat baik dalam berinvestasi karena model CVaR dikatakan memiliki kinerja yang lebih baik dalam mengestimasi risiko. Nilai CVaR pada simulasi *return* AR(1)-GJR-t(1,1) berturut-turut pada tingkat kepercayaan sebesar 90%, 95%, dan 99% adalah 0,01546754, 0,01956534, 0,03052013. Hal ini mengartikan jika seorang investor menginvestasikan uangnya sebesar \$ 100.000 pada indeks saham DJJP, DJSG, dan DJTA menggunakan model simulasi *return* AR(1)-GJR-t(1,1) dengan pendekatan *D-vine copula* maka kerugian maksimum yang akan timbul pada satu hari perdagangan ke depan ialah 1,54% pada tingkat kepercayaan 90%, 1,95% pada tingkat kepercayaan 95%, dan 3,05% pada tingkat kepercayaan 99% dari total nilai investasi. Berikut Tabel 11 dapat menggambarkan kerugian maksimum menggunakan CVaR.

3.7 Backtesting Model Estimasi Risiko

Tabel 12 menjelaskan Uji Kupiec pada estimasi risiko CVaR 99%, 95%, dan 90% dengan nilai *exceeded value* berturut-turut 2, 6, 13 untuk simulasi *Return AR(1)-GARCH-t(1,1)-GPD* dan 3, 7, 13 untuk simulasi *Return AR(1)-GJR-t(1,1)-GPD*. Semakin banyak nilai yang melewati ambang batas (*exceeded value*) pada uji Kupiec mengindikasikan buruknya model estimasi risiko. Sebaliknya, jika *exceeded value* pada uji Kupiec sedikit maka estimasi risiko dapat dikatakan baik. Hasil dari uji Kupiec juga dapat dilihat dari nilai p -value untuk seluruh uji Kupiec bernilai kurang dari taraf signifikan $\alpha = 0,05$. Hal ini mengartikan bahwa CVaR baik digunakan dalam mengestimasi risiko.

4 SIMPULAN DAN SARAN

4.1 Simpulan

VaR dan CVaR dapat mengestimasi risiko pada portofolio saham DJJP, DJSG, dan DJTA. Estimasi risiko menggunakan CVaR memiliki nilai yang lebih baik daripada VaR dengan nilai berturut-turut pada tingkat kepercayaan sebesar 90% sebesar 0.01546754, 95% sebesar 0.01956534, dan 99% sebesar 0.03052013 dengan periode perdagangan satu hari ke depan.

Uji Kupiec untuk CVaR digunakan pada proses *backtesting* guna mengetahui kelayakan estimasi risiko. *Exceeded value* Uji Kupiec pada CVaR 99% bernilai 2, CVaR 95% bernilai 6, dan CVaR 90% bernilai 13 untuk simulasi *Return AR(1)-GARCH-t(1,1)-GPD* dan CVaR 99% bernilai 3, CVaR 95% bernilai 7, dan CVaR 90% bernilai 13 untuk simulasi *Return AR(1)-GJR-t(1,1)-GPD*. Uji Kupiec menjelaskan estimasi nilai risiko CVaR berjalan baik dengan nilai seluruh model berada di atas taraf signifikan $\alpha = 0,05$ sehingga memberikan simpulan estimasi risiko dinilai layak digunakan. Penelitian ini diharapkan dapat menjadi referensi dalam mengestimasi portofolio aset saham.

4.2 Saran

Penelitian struktur kebergantungan Penelitian struktur kebergantungan dengan *D-vine copula* yang dilakukan pada penelitian ini hanya pada kasus triviat dengan 3 data saham.

Pada penelitian selanjutnya diharapkan memiliki contoh kasus pada data saham yang lebih dari 3 data saham. Pemodelan risiko pada penelitian ini hanya menggunakan CVaR dan VaR. Penelitian selanjutnya diharapkan dapat memperluas estimasi risiko menggunakan model lain contohnya LVaR dan TVaR.

DAFTAR PUSTAKA

- Aas, K., Czado, C., Frigessi, A., & Bakken, H. (2009). Pair-copula constructions of multiple dependence. *Insurance: Mathematics and economics*, 44(2), 182-198.
- Alexander, S., Coleman, T. F., & Li, Y. (2006). Minimizing CVaR and VaR for a portfolio of derivatives. *Journal of Banking & Finance*, 30(2), 583-605.
- Brockwell, P. J., Davis, R. A., & Calder, M. V. (2002). *Introduction to time series and forecasting* (Vol. 2, pp. 3118-3121). New York: springer.
- Brooks, C. (2008). *RATS Handbook to accompany introductory econometrics for finance*. 3rd ed. Cambridge Books.
- Cherubini, U., Luciano, E., & Vecchiato, W. (2004). *Copula methods in finance*. 2nd ed. John Wiley & Sons.
- Danielsson, J. (2011). *Financial risk forecasting: The theory and practice of forecasting market risk with implementation in R and Matlab* (Vol. 588). John Wiley & Sons.
- Duan, J., Gauthier, G., Simonato, J., & Sasseville, C. (2006). Approximating the GJR-GARCH and EGARCH option pricing models analytically. *Journal of Computational Finance*, 9(3), 41.
- Franke, J., (2011). *Statistics of Financial Markets: An Introduction*. Third Edition. London: Springer-VerlagBerlin Heidelberg.
- Hastaryta, R., & Effendie, A. R. (2006). Estimasi Value-At-Risk dengan Pendekatan Extreme Value Theory-Generalized Pareto Distribution (Studi Kasus IHSG 1997-2004). *BIMIPA*, 16(2), 1-6.
- Kichen, N. N. (2017). *Estimasi Value at Risk (VaR) Portofolio Multivariat Menggunakan Metode GARCH Student t-EVT-Vine*

Copula (Doctoral dissertation, Universitas Gadjah Mada).

- Klugman, S. A., Panjer, H. H., & E. Willmot, G. (2008). *Loss Models from Data to Decisions*. Third Edition. Canada: John Wiley & Sons, Inc.
- Kurowicka, D., & Cooke, R. M. (2007). Sampling algorithms for generating joint uniform distributions using the vine-copula method. *Computational statistics & data analysis*, 51(6), 2889-2906.
- McNeil, A. J. (2005). Estimating value-at risk: a point process approach. *Quantitative Finance*, 5(2), 227-234.
- Pintari, H. O., & Subekti, R. (2018). Penerapan Metode GARCH-Vine Copula untuk Estimasi Value at Risk (VaR) pada Portofolio. *Jurnal Fourier*, 7(2), 63-77.
- Sudina, N. W. U. Y. A., Dharmawan, K., & Sumarjaya, I. W. (2019). Estimasi Nilai Conditional Value at Risk (CVaR) Portofolio Menggunakan Metode EvtGJR-Vine Copula. *E-Jurnal Matematika* 8(1), pp.15-26
- Sugiyarto. (2019). *Jurnal Matematika* (Vol. 6) Yogyakarta: Universitas Ahmad Dahlan.
- Sumarjaya, I. W. (2013). Memodelkan Ketergantungan dengan Kopula. *Jurnal Matematika*, 3(1), 34-42.
- Tsay, R. S. (2013). *Multivariate time series analysis: with R and finansial applications*. 3rd ed. John Wiley & Sons.
- Tsay, R. S. (2014). *An introduction to analysis of financial data with R*. 3rd ed. John Wiley & Sons.
- Zivot, E. (2009). Practical issues in the analysis of univariate GARCH models. In *Handbook of financial time series* (pp. 113-155). Springer, Berlin, Heidelberg.
- Zuhara, U., Akbar, M. S., & Haryono, H. (2012). Penggunaan Metode VaR (Value at Risk) dalam Analisis Risiko Investasi Saham dengan Pendekatan Generalized Pareto Distribution (GPD). *Jurnal Sains dan Seni ITS*, 1(1), D56-D61.