

BAB 2

LANDASAN TEORI

Untuk menyelesaikan masalah-masalah yang diuraikan pada Bab I dalam karya akhir ini, maka digunakan teori-teori yang terkait dengan permasalahan tersebut yaitu metode-metode perhitungan dengan pendekatan VaR, dan metode perhitungan dengan pendekatan EVT. Selain itu karya akhir ini disusun dengan mengacu pada penelitian-penelitian yang sudah pernah dilakukan untuk pasar saham yang berbeda dan periode waktu yang berbeda pula.

2.1 Value at Risk

Untuk tingkat kepercayaan tertentu (α) yang mengambil nilai antara 0 dan 1, *Value at Risk (VaR)* dari suatu eksposur adalah nilai terkecil l sehingga probabilitas terjadinya kerugian sebesar L melewati nilai l tersebut lebih kecil atau sama dengan $(1-\alpha)$. Secara definisi VaR adalah jumlah kerugian finansial maksimum yang mungkin terjadi atas suatu portofolio dalam jangka waktu tertentu, dan tingkat keyakinan tertentu (Best, 1998).

Dalam bentuk yang lebih luas, VaR merupakan pengukuran risiko yang sederhana yang memberikan nilai kerugian finansial yang hanya akan melebihi $\alpha\%$ pada waktu tertentu dalam k hari perdagangan berikutnya. Dengan demikian:

$$\Pr(\text{Loss} > \text{VaR}) = \alpha$$

atau dalam bentuk *return*, persamaan di atas menjadi:

$$\Pr(r_{t+1} < \text{VaR}_{t+1}) = \alpha$$

VaR merupakan metode pengukuran risiko yang paling populer dalam pasar finansial, terutama bagi institusi keuangan yang harus tunduk pada peraturan dari *Basel Capital Accord*. Kelebihan utama VaR adalah metode ini merupakan pengukuran risiko yang dapat diterapkan pada seluruh instrumen *trading* (Best,1998), seperti tingkat bunga (*interest rates*), kurs (*foreign exchange rates*), komoditas, dan harga saham, termasuk indeks saham.

VaR mengukur volatilitas suatu aktiva finansial. Volatilitas adalah suatu ukuran seberapa besar harga atau nilai suatu aktiva berfluktuasi. Semakin besar volatilitasnya semakin besar potensi aktiva tersebut memberikan keuntungan atau kerugian yang signifikan. Semakin besar volatilitasnya semakin besar risiko yang dimiliki oleh aktiva tersebut. Karena VaR adalah metode pengukuran risiko maka VaR menggunakan volatilitas untuk mengestimasi kerugian maksimum atas penurunan harga atau nilai suatu aktiva. Perhitungan volatilitas dapat dilakukan dengan dua cara (Butler, 1999):

$$\sigma = \frac{\sqrt{\sum (x_i - x)^2}}{n} \dots\dots\dots (2.1)$$

atau

$$\sigma = \frac{\sqrt{\sum x_i^2 - (x)^2}}{n} \dots\dots\dots (2.2)$$

Perhitungan volatilitas membutuhkan data historis. Perbedaan sampel yang digunakan akan membuat perhitungan volatilitas juga menjadi berbeda. Namun secara umum, apabila sampel diperbesar maka perhitungan volatilitas akan semakin akurat.

Pemodelan volatilitas dapat dilakukan dengan beberapa cara diantaranya dengan menggunakan *Exponentially Weighted Moving Average (EWMA)* sebagaimana

diterapkan dalam *RiskMetrics* yang dikembangkan oleh JP Morgan dan GARCH (*Generalized Autoregressive Conditional Heteroskedasticity*).

Model GARCH semakin populer digunakan karena model ini mengakomodasi kenyataan bahwa *variance*, yang merupakan kuadrat dari volatilitas, bersifat tidak konstan. Penelitian menunjukkan bahwa dalam volatilitas terkandung sifat autoregresi, yang berarti bahwa volatilitas pada masa yang akan datang tergantung dari volatilitas yang terjadi sebelumnya.

Berdasarkan volatilitas yang diprediksi dari beberapa metode di atas, maka VaR dapat dihitung. Beberapa metode penghitungan VaR dapat dijabarkan sebagai berikut:

2.1.1 Pendekatan Non Parametrik : *Historical Simulation* dan *Monte Carlo Simulation*

Pendekatan non parametrik menggunakan distribusi yang diasumsikan sebelumnya. Pendekatan non parametrik yang paling sederhana adalah dengan *Historical Simulation* karena hanya membutuhkan distribusi data empiris. Metode ini merupakan metode *unconditional* yang berasumsi bahwa distribusi *return* akan tetap sama, baik pada masa lampau maupun pada masa yang akan datang. Asumsi kunci yang digunakan dalam *Historical Simulation* ini adalah *data series* yang digunakan terdistribusi secara independen dan identik (*independently and identically distributed ~ iid*) yang pada kondisi yang sangat tidak stabil akan menjadi pengukuran risiko yang tidak tepat karena pada saat ini risiko dapat berubah secara signifikan. Selain itu kelemahan lainnya adalah metode ini mengesampingkan ketergantungan *return* dan ukuran data.

Historical Simulation menunjukkan bagaimana menghasilkan nilai VaR dengan melakukan simulasi perubahan penilaian portofolio yang dihasilkan dari penilaian kembali portofolio dengan menggunakan data historis perubahan harga aktiva yang benar-benar terjadi selama periode tertentu.

Cara paling sederhana menghitung VaR dengan menggunakan *Historical Simulation* adalah dengan melakukan penilaian ulang terhadap portofolio menggunakan harga historis tertentu. Nilai portofolio kemudian ditempatkan dalam *persentile*, dan nilai VaR dapat dibaca dari *persentile* yang sesuai dengan tingkat keyakinan yang diinginkan. Kelemahannya adalah apabila nilai portofolio berubah, persentase perubahan nilai dalam portofolio tidak lagi mengacu pada nilai portofolio awalnya.

Cara yang tepat untuk menghitung VaR dengan menggunakan *Historical Simulation* adalah dengan menggunakan nilai historis persentase perubahan harga dan mengimplementasikannya pada portofolio pada saat ini. Agar dapat digunakan secara efektif, *Historical Simulation* membutuhkan data historis yang cukup mewakili berbagai kondisi. Kesulitannya adalah apabila ternyata data yang ada hanya mewakili kondisi tertentu, misalnya kondisi pasar normal. Kesulitan ini yang kemudian dijawab dengan adanya metode lain dalam menghitung VaR yaitu dengan menggunakan pendekatan *Monte Carlo*. Pendekatan ini menggunakan *random number* untuk menghitung VaR dan menggunakan asumsi fundamental tentang perilaku pasar yaitu perubahan nilai aktiva yang membentuk portofolio terdistribusi secara normal.

Proses perolehan kumpulan *event* penilaian portofolio dilakukan dalam dua tahap. Tahap pertama adalah memperoleh suatu kumpulan perubahan harga yang terdistribusi

normal dengan volatilitas yang tepat untuk aktiva tertentu. Tahap selanjutnya adalah memperoleh perubahan harga aktiva yang saling berkorelasi, yang dapat diperoleh dengan menggunakan *eigenvalues* dan *eigenvectors*. *Eigenvalues* dan *eigenvectors* menjelaskan perilaku perubahan harga dari suatu kelompok faktor risiko yang bergerak secara terkait satu dengan yang lain. *Eigenvectors* merupakan komponen utama dari suatu matriks korelasi. Sedangkan *eigenvalues* memberikan bobot relatif untuk tiap *eigenvector*.

Asumsi distribusi normal untuk perubahan harga aset merupakan asumsi utama dalam sebagian besar model VaR. Asumsi ini mempermudah proses kuantifikasi volatilitas pada tingkat keyakinan tertentu, dengan secara sederhana mengalikan satu nilai standar deviasi volatilitas dengan faktor tertentu yang diinginkan. Asumsi normalitas juga berimplikasi bahwa perubahan harga aktiva saling bebas satu sama lain, dan kemungkinan harga akan naik akan sama besarnya dengan kemungkinan harga akan turun, dengan kata lain distribusi perubahan harga tersebut bersifat simetris di sekitar rata-ratanya (*symmetrical around the mean*), dan perubahan harga aktiva pada suatu saat tidak dipengaruhi oleh perubahan harga aktiva yang terjadi sebelumnya. Kedua implikasi ini ternyata tidak dapat terpenuhi pada data perubahan harga aktiva finansial. Berdasarkan penelitian yang dilakukan sebelumnya, perubahan harga aktiva ternyata tidak terdistribusi normal secara sempurna.

Non normalitas dapat dikarakteristikkan pada dua hal yaitu *kurtosis* dan *skewness*. *Kurtosis* menjelaskan bagaimana distribusi menjadi leptokurtik dan

mempunyai *fat tail*. *Skewness* menjelaskan bagaimana distribusi menjadi lebih menceng ke arah tertentu daripada simetris.

Fat tail mewakili sejumlah data perubahan harga aktiva yang berada di luar harapan (*outlier*). Apabila jumlah data tersebut sangat besar dibandingkan dengan yang diharapkan berada dalam suatu distribusi normal maka distribusi tersebut disebut memiliki *fat tail*. Pengaruh *fat tail* adalah meningkatnya volatilitas aktiva, dengan demikian *fat tail* mempunyai pengaruh yang signifikan dalam perhitungan VaR.

2.1.2 Pendekatan Parametrik : GARCH

Pendekatan paling populer yang sering digunakan untuk melakukan pemodelan volatilitas yang bersifat *conditional* atau tidak konstan adalah GARCH, yang sekaligus juga memasukkan pengaruh autoregresi *error* yang terjadi. Model ini dikembangkan oleh Bollerslev, dan merupakan proses generalisasi dari model ARCH (*Autoregressive Conditional Heteroskedasticity*) yang dikembangkan oleh Engle.

Perhatian utama dari pendekatan ini adalah sifat heteroskedastisitas dari suatu deret data *error* atau *residuals*. Heteroskedastis merupakan kondisi *variance* dari *error* yang bersifat tidak konstan, artinya besarnya *error* bisa berbeda atau lebih besar pada suatu periode data tertentu dibanding pada periode data yang lain.

Model GARCH menggunakan rata-rata tertimbang nilai kuadrat *residual* periode sebelumnya, namun bobotnya yang terus menurun tidak akan mencapai nol. Hal ini membuat model bisa menjadi *parsimonious* yang lebih mudah untuk diestimasi. Dengan GARCH, faktor utama yang paling mampu meramalkan *variance* pada masa mendatang

adalah rata-rata tertimbang dari rata-rata *variance* jangka panjang, *variance* yang diprediksi pada masa kini, dan informasi baru pada masa kini yang ditangkap dari kuadrat *residual* terkini. Model GARCH (p,q) dapat dijelaskan sebagai berikut (Bollerslev, 1986):

$$Y_t = X_t' \theta + \varepsilon_t \quad \dots\dots\dots (2.3)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \alpha_2 \sigma_{t-2}^2 + \dots + \alpha_p \sigma_{t-p}^2 + \beta_1 \varepsilon_{t-1}^2 + \beta_2 \varepsilon_{t-2}^2 + \beta_q \varepsilon_{t-q}^2 \quad \dots\dots (2.4)$$

Model *parsimonious GARCH* (1,1), yang hanya memiliki 1 *lag* untuk *squared error* dan satu *autoregressive term*, lebih tepat digunakan untuk berbagai tujuan karena model ini memiliki *infinite memory*. Model GARCH (1,1) didefinisikan sebagai berikut (Bollerslev, 1986):

$$Y_t = X_t' \theta + \varepsilon_t \quad \dots\dots\dots (2.5)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \sigma_{t-1}^2 + \beta_1 \varepsilon_{t-1}^2 \quad \dots\dots\dots (2.6)$$

Persamaan Y_t adalah *mean equation* yang ditulis sebagai fungsi *exogenous variables* dengan *error term* yaitu ε_t . Sedangkan persamaan σ_t^2 , yang merupakan peramalan *variance* satu periode ke depan berdasarkan informasi dari periode sebelumnya, disebut sebagai *conditional variance*. Persamaan *conditional variance* pada persamaan di atas merupakan fungsi dari tiga *term* (*Eviews 5 Users' Guide*) :

- *Constant term* : α_0
- Informasi volatilitas periode sebelumnya : ε_{t-1}^2 (*ARCH term*)
- Hasil peramalan *variance* periode sebelumnya : σ_{t-1}^2 (*GARCH term*)

Persamaan σ_t^2 menunjukkan orde pertama untuk masing-masing *GARCH term* dan *ARCH term* ($p=1, q=1$), sehingga dapat ditulis sebagai model GARCH (1,1).

Untuk menjamin bahwa data mempunyai *variance* yang stasioner, pada kasus GARCH (1,1) ada restriksi untuk parameter-parameternya. Disyaratkan bahwa $\alpha_0 > 0$; $\alpha_1, \beta \geq 0$; dan jumlah dari koefisien ARCH dan GARCH, $(\alpha_1 + \beta) < 1$. Apabila jumlah tersebut semakin mendekati 1, hal ini menunjukkan bahwa *volatility shocks* bersifat *persistent*. Hal semacam ini sering dihasilkan oleh data finansial dengan frekuensi tinggi.

Model GARCH (1,1) hanya digunakan untuk melakukan *forecast* untuk satu periode ke depan, namun langkah *forecast* dapat diulangi untuk memperoleh *forecast* dua periode ke depan, demikian seterusnya untuk periode waktu *forecast* yang lebih panjang.

2.2 Extreme Value Theory

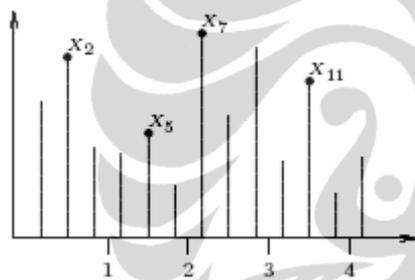
Kerugian yang jarang terjadi dan mempunyai nilai kerugian yang sangat besar tidak dapat dimodelkan dengan pendekatan biasa. Kerugian seperti ini dapat dimodelkan dengan *Extreme Value Theory (EVT)*. Metode ini digunakan untuk mengestimasi nilai kerugian yang melampaui suatu tingkat probabilitas tertentu. EVT pada dasarnya memodelkan *tail* dari suatu distribusi karena EVT berkaitan dengan kuantil 1% atau 5% yang merupakan batas VaR.

Secara umum, nilai-nilai ekstrem (*extreme values*) dapat dimodelkan dalam dua jenis pendekatan. *Block Maxima Models (BMM)*, yang digunakan untuk data-data kerugian tertinggi dari suatu bagian atau blok waktu tertentu, dan *Peaks over*

Thresholds (POT) yang menggunakan data-data kerugian yang nilainya melebihi batas tinggi tertentu yang sudah ditetapkan sebelumnya.

2.2.1 Block Maxima Model

Metode *Block Maxima Model (BMM)* adalah pendekatan tradisional yang digunakan untuk menganalisis data yang bersifat musiman. Dalam pendekatan ini data kerugian yang dimasukkan dalam sampel adalah data yang paling tinggi nilainya (maksimum kerugian) dalam suatu periode (minggu, bulan, tiga bulan) tertentu.



Gambar 2.1

Dari gambar 2.1 sumbu horizontal menggambarkan periode tertentu, misalnya bulanan, sedangkan sumbu vertikal menggambarkan nilai kerugian yang terjadi. Untuk periode atau bulan pertama, nilai kerugian tertinggi adalah sebesar x_2 , bulan kedua nilai kerugian tertinggi adalah x_5 , bulan ketiga nilai kerugian tertinggi adalah x_7 dan pada bulan keempat nilai kerugian tertinggi adalah x_{11} . Nilai kerugian yang dimasukkan sebagai data dalam melakukan pemodelan adalah x_2, x_5, x_7 dan x_{11} . Data kerugian yang bukan merupakan kerugian maksimum pada setiap bulannya tidak dimasukkan sebagai data sampel pemodelan.

Dari penelitian yang telah ada sebelumnya, distribusi dari *extreme values* dengan pendekatan BMM menunjukkan kecenderungan untuk mengikuti distribusi Gumbel, Frechet, atau Weibull (Fisher and Tippett (1928), Gnedenko (1943)). Bentuk standar dari ketiga distribusi ini disebut sebagai distribusi *Generalized Extreme Value (GEV)*.

Teori Fisher, Tippet dan Gnedenko menyatakan bahwa dari suatu sampel observasi yang *i.i.d.* atas suatu distribusi probabilitas yang tidak diketahui, jika jumlah sampel ditambah sampai mencapai tidak terhingga, maka nilai standardisasi terbesar dari suatu interval waktu akan menjadi salah satu dari distribusi tersebut (Muslich, 2007):

$$1. \text{ Gumbel} \quad f(x) = \exp\left(-\exp\left(\frac{x-\mu}{\sigma}\right)\right) \quad \text{dengan } \xi = 0 \quad \dots\dots\dots (2.7)$$

$$2. \text{ Frechet} \quad f(x) = \begin{cases} 0 & \\ \exp\left[-\frac{(x-\mu)^{-\alpha}}{\sigma}\right] & \begin{matrix} x < \mu \\ x \geq \mu \end{matrix} \end{cases} \quad \text{dengan } \xi > 0 \quad \dots\dots\dots (2.8)$$

$$3. \text{ Weibull} \quad f(x) = \begin{cases} 0 & \\ \exp\left[-\frac{(x-\mu)^\alpha}{\sigma}\right] & \begin{matrix} x > \mu \\ x \leq \mu \end{matrix} \end{cases} \quad \text{dengan } \xi < 0 \quad \dots\dots\dots (2.9)$$

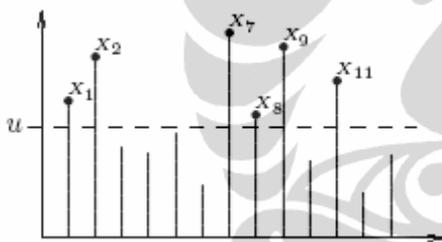
Di mana μ , $\sigma > 0$, dan $\alpha > 0$ adalah parameter distribusinya yang masing-masing menunjukkan *location (mean)*, *scale* (standar deviasi) dan parameter *tail index*.

Dalam GEV, sebagaimana distribusi untuk *extreme values*, maka parameter yang memainkan peranan penting adalah *tail index* (ξ) yang menunjukkan ketebalan *tail* distribusi. Semakin besar nilai *tail index*, semakin besar ketebalan *tail* distribusi tersebut. Apabila nilai *tail index* sama dengan nol maka distribusi dari *extreme values*

tersebut adalah Gumbel; bila positif maka distribusinya adalah Frechet; dan bila negatif maka distribusinya adalah Weibull.

2.2.2 Peaks Over Threshold (POT)

Model *Peaks over Threshold (POT)* dapat digunakan untuk mengestimasi *excess distribution* berdasarkan tingkat level *threshold* tertentu u , dan untuk mengestimasi *tail shape* dari distribusi asalnya. Penentuan *threshold* sangat tergantung pada data yang ada. *Threshold* u biasanya dipilih dengan menggunakan *mean excess plot* yang mempertimbangkan adanya *trade off* antara *bias* dalam melakukan estimasi fungsi *excess distribution* dengan *variance* hasil samplinya.



Gambar 2.2

Dari gambar 2.2 sumbu vertikal menggambarkan nilai kerugian, u adalah batas atau *threshold* yang dipilih. Nilai-nilai x_1 , x_2 , x_7 , x_8 , x_9 dan x_{11} merupakan nilai kerugian di atas *threshold* dan menjadi data nilai ekstrem sebagai anggota distribusi.

Dalam model POT terdapat dua jenis analisis, yaitu model *semi-parametric* yang dibangun berdasarkan *Hill estimator* dan yang terkait (Beirlant et al. 1996, Danielsson, Hartmann & de Vries 1998), dan model *fully-parametric* yang dibangun berdasarkan *Generalized Pareto Distribution* atau *GPD* (Embrechts, Resnick & Samorodnitsky

1998). Distribusi GPD pertama kali diperkenalkan oleh Pickands (1975) dan kemudian dikembangkan diantaranya oleh Davidson (1983) dan Hosking dan Wallis (1987).

Distribusi dari kerugian yang melebihi batas tinggi tertentu dapat didefinisikan sebagai (Rossignolo, 2008):

$$F_u(y) = P\{X - u \leq y | X > u\}, \dots\dots\dots (2.10)$$

untuk $0 \leq y < x_0 - u$ dimana $x_0 \leq \infty$ adalah sisi paling kanan dari F, dapat diterangkan sebagai berikut. Distribusi nilai di atas batas mewakili probabilitas suatu kerugian melebihi batas u maksimum sebesar y , berdasarkan informasi bahwa kerugian tersebut berada di atas batas u . Fungsi distribusi di atas dapat dituliskan kembali sebagai (Rossignolo, 2008):

$$F_u(y) = \frac{F(y+u) - F(u)}{1 - F(u)} \dots\dots\dots (2.11)$$

Aplikasi EVT memiliki beberapa tantangan. Analisis data awal memainkan peranan penting dalam menentukan apakah suatu *data series* memiliki *fat tail* yang diperlukan dalam aplikasi EVT. Selain itu estimasi parameter dari suatu distribusi tergantung dari jumlah observasi data ekstrem yang digunakan. Pemilihan *threshold* yang cukup tinggi diperlukan untuk memenuhi kondisi ini namun jumlah observasi juga harus cukup banyak agar dapat dilakukan estimasi yang lebih akurat. Untuk mengetahui distribusi *data series* dari hasil observasi data ekstrem dapat digunakan beberapa metode, di antaranya adalah dengan menggunakan *Q-Q Plots*.

Biasanya pengujian distribusi dapat menggunakan histogram berdasarkan data yang dimiliki. Kebanyakan data finansial memiliki *fat tail*. Grafik kuantil dapat

digunakan untuk melakukan pengujian apakah data cocok dengan model parametrik yang diasumsikan.

Misalkan X_1, \dots, X_n merupakan suatu deret *random variable iid*, dan $X_{n,n} < \dots < X_{1,n}$ merupakan urutan statistik, F_n merupakan distribusi empiris. $F_n(X_{k,n}) = (n-k+1)/n$ dan F merupakan distribusi parametrik yang diestimasi dari data. Maka grafik kuantil (*Q-Q plots*) didefinisikan sebagai set dari titik-titik:

$$\left\{ X_{k,n}, F^{-1}\left(\frac{n-k+1}{n}\right), k = 1, \dots, n \right\}$$

Apabila model parametrik cocok dengan data, grafik tersebut harus linear, sehingga grafik ini dapat digunakan untuk membandingkan berbagai model estimasi dan memilih model yang terbaik. Semakin linear *Q-Q plots*, berarti model tersebut semakin cocok dengan data. Selain itu apabila distribusi data telah diketahui sebelumnya, *Q-Q plots* dapat digunakan untuk mendeteksi *outliers* (Embrechts, Kluppelberg, and Mikosch (1997)).

Q-Q plots juga dapat digunakan untuk mengevaluasi kecocokan model dengan *tail* dari *empirical distribution*. Misalnya apabila *data series* tersebut cocok dengan distribusi normal dan data empiris memiliki *fat tail*, grafik akan menunjukkan garis yang naik ke arah kanan.

Pemilihan *threshold* menjadi *trade-off* antara *variance* dan bias. Dengan menambah jumlah observasi data maksimum (dengan demikian menetapkan *threshold* yang rendah), *tail index* menjadi lebih akurat namun menjadi bias. Di lain pihak, menetapkan *threshold* tinggi (dengan demikian menurunkan jumlah observasi data

maksimum) menurunkan bias namun membuat estimator menjadi lebih *volatile*. Beberapa penelitian seperti Resnick dan Starica (1996) menyarankan menggunakan observasi yang distandardisasi untuk mencocokkan berbagai parameter untuk mengatasi permasalahan tersebut.

Salah satu cara menentukan besarnya *threshold* adalah dengan menggunakan pendekatan *sample mean excess function*. *Sample mean excess function* merupakan ukuran kelebihan nilai di atas *threshold* dibagi dengan jumlah data yang nilainya melebihi *threshold*, atau dapat dijabarkan sebagai berikut (Gilli and K llezi,2003) :

$$e_n(u) = \frac{\sum_{i=k}^n (x_i^n - u)}{n - k + 1}, \quad k = \min\{i \mid x_i^n > u\}, \quad \dots \dots \dots (2.12)$$

di mana $n-k+1$ adalah jumlah observasi yang nilainya melebihi *threshold* u . *Sample mean excess function* merupakan suatu estimasi dari *mean excess function* $e(u)$. Untuk GPD, *mean excess function* dengan parameter $\xi < 1$ adalah (Gilli and K llezi,2003):

$$e(z) = E(X - z \mid X > z) = \frac{\sigma + \xi z}{1 - \xi}, \quad \sigma + \xi z > 0. \quad \dots \dots \dots (2.13)$$

Mean excess function untuk GPD adalah linear. Berdasarkan hasil penelitian Picklands, Balkema-in Haan, untuk *threshold* yang tinggi, kelebihan di atas *threshold* dari suatu *data series* mendekati distribusi GPD. *Threshold* dipilih dengan cara mendeteksi suatu area di mana terdapat suatu bentuk linear pada grafik.

Estimasi GPD dilakukan dengan dua tahap:

1. Memilih *threshold* u . Grafik dari *mean excess* dapat digunakan dimana u dipilih sehingga $e(x)$ linear untuk $x > u$ ($e(u)$ linear untuk suatu distribusi GPD).

2. Estimasi parameter untuk ξ dan β atau σ , dilakukan dengan *Maximum Likelihood Estimation (MLE)*.

Apabila distribusi telah diestimasi, aproksimasi dari distribusi data asli (yang menghasilkan observasi data ekstrem) dan estimasi dari kuantil ke- p dari distribusi tersebut dapat digunakan untuk mengestimasi VaR ekstrem (*extreme VaR*).

Misalnya telah dipilih u sebagai *threshold*, X_1, \dots, X_n adalah *random variable* yang nilainya melebihi *threshold* dan Y_1, \dots, Y_n adalah *data series* dengan nilai sebesar selisih kelebihan dengan *threshold* ($Y_i = X_i - u$). Distribusi dari nilai yang lebih tinggi dari *threshold* u adalah sebagai berikut (Bensalah, 2000):

$$F_u(y) = P(X - u \leq y | X > u) = P(Y \geq y | X > u), y \geq 0 \quad \dots \quad (2.14)$$

$F(u)$ dapat diestimasi dari distribusi empiris hasil observasi (Bensalah, 2000):

$$(\widehat{F}(u)) = \frac{1}{n} \sum_{i=1}^n I_{\{X_i > u\}} = \frac{N_u}{n} \quad \dots \quad (2.15)$$

dan (Bensalah, 2000):

$$(\widehat{F}(u + y)) = \frac{N_u}{n} \left(1 + \frac{\xi y}{\beta} \right)^{-1/\xi} \quad \dots \quad (2.16)$$

Dengan demikian estimasi nilai VaR dari kuantil ke- p untuk *threshold* tertentu, u , dengan menggunakan distribusi tersebut adalah (Bensalah, 2000):

$$\widehat{x}_p = u + \frac{\widehat{\beta}}{\widehat{\xi}} \left[\left(\frac{n}{N_u} (1-p) \right)^{-\widehat{\xi}} - 1 \right] \quad \dots \quad (2.17)$$

2.3 Hipotesa Penelitian

Beberapa penelitian yang telah dilakukan sebelumnya pada beberapa bursa efek di dunia menunjukkan kurang akuratnya metode VaR yang menggunakan asumsi normalitas distribusi, pada kondisi pasar yang bergejolak. Dengan kata lain, pada saat kondisi pasar normal metode VaR memang dapat digunakan untuk memprediksi risiko pasar pada bursa efek tersebut, namun ketika terjadi krisis, ternyata banyak terjadi kerugian di atas nilai VaR yang diprediksi.

Berdasarkan kondisi tersebut maka ditetapkan hipotesa penelitian sebagai berikut:

1. Hipotesis I:

$$H_0 : \text{VaR-GARCH} < -R$$

$$H_1 : \text{VaR-GARCH} \geq -R$$

VaR-GARCH merupakan estimasi potensi terjadinya *negative return* pada tingkat keyakinan tertentu berdasarkan penghitungan dengan GARCH, dan $-R$ merupakan *actual negative return* IHSG.

Dengan kata lain, hipotesis nol yang diajukan adalah metode VaR dengan GARCH memberikan prediksi risiko yang lebih kecil terhadap eksposur risiko pasar pada *return* indeks saham Bursa Efek Indonesia.

2. Hipotesis II:

$$H_0 : \text{VaR-EVT} \geq -R$$

$$H_1 : \text{VaR-EVT} < -R$$

VaR-EVT merupakan estimasi potensi terjadinya *negative return* pada tingkat keyakinan tertentu berdasarkan penghitungan dengan EVT, dan $-R$ merupakan *actual negative return* IHSG.

Dengan kata lain, hipotesis nol yang diajukan adalah metode VaR berbasis EVT memberikan prediksi risiko yang mampu menutup eksposur risiko pasar pada *return* indeks saham Bursa Efek Indonesia.

2.4 Penelitian Sebelumnya

Terhadap tema karya akhir ini, yang mengangkat mengenai perbandingan kinerja antara *VaR approach* dengan *EVT approach* terhadap *return* indeks saham, telah beberapa kali dilakukan penelitian, di antaranya adalah yang dilakukan oleh Ramazan Gençay dan Faruk Selçuk (2004), yang menilai *performance* model VaR pada *return* harian indeks saham di sembilan bursa yang baru berkembang (*emerging markets*) dan EVT pada data yang sama untuk *percentile* 0.999 dan tingkat kepercayaan (*confidence level*) 95% untuk keperluan *stress testing*. Hasil penelitian menunjukkan bahwa pendekatan EVT dalam mengestimasi VaR memberikan perhitungan yang lebih akurat pada kuantil yang lebih tinggi.

Penelitian lain mengenai *EVT approach* pada indeks saham dilakukan oleh Adrian F. Rosignolo pada Februari 2009 yang menggunakan pendekatan EVT untuk menghitung VaR pada enam indeks saham pada negara berkembang dan negara maju melalui dua cara yang berbeda: *Unconditional* EVT pada *raw return* dan *conditional* EVT, yang menggabungkan *Quasi-Maximum-Likelihood* dari *GARCH model* untuk

mengestimasi volatilitas dinamis pada masa sekarang dan EVT untuk mengestimasi tail dari distribusi *GARCH residuals*. *Backtesting* EVT dilakukan dengan menggunakan data gejolak pasar modal tahun 2008. Hasil penelitian menunjukkan bahwa pendekatan EVT dapat membantu institusi keuangan dalam menghindari kerugian yang besar akibat gejolak pasar.

Khusus untuk pasar saham Indonesia, penelitian pernah dilakukan oleh Johny Harianto pada tahun 2008, yang hasilnya dituangkan dalam thesis untuk mencapai gelar Magister Manajemen pada Universitas Indonesia tahun 2008, dengan judul Pengukuran dan Perbandingan Risiko Pasar Menggunakan *Extreme Value Theory* dan *Historical Simulation* (Studi Kasus pada Saham LQ-45). Metode penghitungan VaR yang digunakan adalah *Historical Simulation*, dan pendekatan EVT yang digunakan adalah *Generalized Pareto Distribution (GPD)*, dengan penerapan penghitungan pada 14 saham LQ-45. Kesimpulan yang diperoleh untuk metode VaR *Historical Simulation* adalah, dari ke-14 saham tersebut, 6 saham tidak *valid* di *confidence level* 95% dan 4 saham tidak *valid* di *confidence level* 99%. Sedangkan metode VaR-GPD *valid* untuk seluruh saham pada kedua *confidence level* tersebut.

Dari seluruh teori yang telah diuraikan diatas, dalam karya akhir ini penghitungan VaR dibatasi dengan menggunakan pendekatan GARCH yang mengakomodasi kondisi heteroskedastisitas dari *residual data return*, dan membatasi penghitungan *EVT approach* dengan menggunakan *Peaks Over Threshold (POT)* dengan asumsi distribusi *Generalized Pareto Distribution (GPD)*.