

## BAB III

### METODOLOGI PENELITIAN

#### III.1 Periode dan Langkah Penelitian

Pada skripsi ini, penelitian yang dilakukan bertujuan untuk mengestimasi dan mengevaluasi volatilitas dalam kerangka *Value at Risk* (VaR) untuk mengukur tingkat risiko yang dapat terjadi pada institusi-institusi keuangan. Pengestimasian VaR dilakukan melalui pendekatan *Local-Valuation* dengan menggunakan metode *Delta Normal* (*Delta-Normal method*). Sedangkan pemodelan volatilitas dalam mengukur risiko dilakukan dengan menggunakan berbagai macam model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), seperti *Normal GARCH*, *Student GARCH*, dan *RiskMetrics* atau *Integrated GARCH* (I-GARCH). Pengukuran volatilitas dengan menggunakan beberapa model dalam penelitian kali ini bertujuan untuk mengukur tingkat risiko pada pasar modal Indonesia, yaitu khususnya pada sepuluh saham teraktif di Bursa Efek Indonesia pada periode observasi tanggal 2 Januari 2006 sampai dengan tanggal 18 Desember 2007, dan selanjutnya menunjukkan model mana yang paling baik digunakan bagi para *trader* dalam mengukur tingkat risiko yang mungkin mereka hadapi dalam melakukan perdagangan.

Dalam metodologi penelitian ini, ada beberapa langkah yang dilakukan. Langkah pertama yang dilakukan adalah pengumpulan data harga saham harian (*daily*) atas sepuluh saham teraktif di Bursa Efek Indonesia periode observasi tanggal 2 Januari 2006 sampai dengan tanggal 18 Desember 2007. Selanjutnya data harga saham tersebut diubah menjadi bentuk *return* untuk memperoleh data *time series* yang stasioner. Langkah kedua yaitu melakukan pengujian terhadap data *return* saham secara individual. Ada dua pengujian

yang dilakukan, yaitu pengujian pertama adalah pengujian stasioneritas data yang dilakukan untuk memastikan bahwa data *time series* dalam bentuk *return* tersebut sudah stasioner atau belum. Data *return* yang sudah stasioner selanjutnya dapat digunakan dalam pemodelan volatilitas. Pengujian kedua yang dilakukan adalah pengujian heteroskedastisitas yaitu untuk melihat apakah data *return* saham tersebut memiliki varians dari *error term* yang konstan ataukah berubah-ubah sepanjang waktu.

Selanjutnya langkah ketiga yang dilakukan adalah membentuk portofolio saham dari masing-masing saham teraktif yang diobservasi di atas. Pembentukan portofolio dilakukan dengan pemberian bobot diberikan berdasarkan berdasarkan persentase nilai aset atau saham. Setelah portofolio terbentuk, langkah keempat selanjutnya adalah melakukan pengujian stasioneritas dan heteroskedastisitas pula terhadap *return* portofolio. Berikutnya langkah kelima dilakukan pemodelan terhadap volatilitas heteroskedastis dari *return* portofolio dengan menggunakan model *Normal GARCH*, *Student GARCH*, dan *RiskMetrics* atau *Integrated GARCH (I-GARCH)*, untuk memperoleh peramalan (*forecast*) *conditional volatility* atas *return* dari portofolio. Namun sebelum melakukan pemodelan GARCH, dilakukan pemodelan ARIMA terlebih dahulu untuk memperoleh persamaan *conditional mean*.

Langkah keenam adalah perhitungan nilai VaR portofolio dengan menggunakan model VaR *normal GARCH*, VaR *student GARCH*, dan VaR *RiskMetrics* atau EWMA. Selanjutnya, langkah terakhir yang dilakukan adalah melakukan evaluasi atas kinerja tiap-tiap model volatilitas dengan menggunakan kerangka *Likelihood Ratio (LR test)* pada tingkat signifikansi atau alpha ( $\alpha$ ) sebesar 5%. Kemudian setelah melakukan evaluasi model dan diperoleh hasilnya, dilihat dan dipilih model VaR mana yang paling baik sesuai dengan kriteria yang telah ditentukan untuk mengukur tingkat risiko yang mungkin dihadapi oleh para *trader* di bursa. Pada akhirnya alur atas penelitian ini dapat dilihat pada

gambar 3.1 yang menggambarkan *flow chart* atas metodologi penelitian secara keseluruhan.

## **III.2 Pengumpulan Data**

### **III.2.1 Sampel Data**

Pada penelitian ini, dasar penentuan atas sepuluh saham teraktif ditentukan berdasarkan proses pemberian ‘rangking’ terlebih dahulu. Langkah pertama yang dilakukan adalah mendapatkan data atas daftar sepuluh saham teraktif (*ten most active stock*) setiap harinya dari mulai tanggal 2 Januari 2006 sampai dengan tanggal 18 Desember 2007 atau selama 512 hari kerja yang tercatat di Bursa Efek Indonesia. Data diperoleh penulis dari website Bursa Efek Indonesia ([www.bei.co.id](http://www.bei.co.id)). Data saham teraktif yang diperoleh selama periode tersebut secara kumulatif adalah sebanyak 1220 saham.

Kemudian langkah selanjutnya adalah memberikan rangking terhadap saham-saham yang menduduki posisi satu sampai dengan sepuluh selama periode tersebut, dan setelah itu dilihat saham mana yang memiliki frekuensi paling tinggi dalam menduduki posisi satu sampai sepuluh sebagai saham teraktif. Pada akhirnya sepuluh saham yang paling sering berada di posisi satu sampai sepuluh akhirnya ditentukan sebagai proksi atas sepuluh saham teraktif yang diperdagangkan selama periode tersebut. Adapun sepuluh saham teraktif yang akhirnya didapatkan selama periode observasi tanggal 2 Januari 2006 sampai dengan tanggal 18 Desember 2007 yang ditunjukkan pada tabel 3.1.

**Tabel 3.1**  
**Daftar Sepuluh Saham Teraktif di Bursa Efek Indonesia**  
**Periode 2 Januari 2006 sampai dengan 18 Desember 2007**

NO	KODE EFEK	NAMA EMITEN
1	BUMI	Bumi Resource Tbk
2	TLKM	Telekomunikasi Indonesia Tbk
3	BMRI	Bank Mandiri (Persero) Tbk
4	ANTM	Aneka Tambang (Persero) Tbk
5	PGAS	Perusahaan Gas Negara Tbk
6	ASII	Astra International Tbk
7	ELTY	Bakrieland Development Tbk
8	ENRG	Energi Mega Persada Tbk
9	BBRI	Bank Rakyat Indonesia Tbk
10	PTBA	Tambang Batubara Bukit Asam Tbk

Setelah daftar atas sepuluh saham teraktif di atas didapatkan, langkah selanjutnya adalah mendapatkan data harga saham harian (*daily price*) atas kesepuluh saham tersebut dengan periode yang sama yaitu tanggal 2 Januari 2006 sampai dengan tanggal 18 Desember 2007, yang kemudian akan digunakan dalam proses perhitungan. Sampel data tersebut nantinya akan dibagi menjadi dua bagian, yaitu sampel estimasi (*estimation sample*) atau disebut *in-the-sample*,  $S_E$ , dan sampel peramalan (*forecast sample*) atau disebut *out-of-sample*,  $S_F$ . *Estimation sample* nantinya akan digunakan dalam mengestimasi model volatilitas, sedangkan *forecast sample* digunakan untuk mengevaluasi atau mengukur kinerja VaR. Pada penelitian ini, ditentukan bahwa *estimation sample*, yaitu data harga saham harian mulai dari tanggal 2 Januari 2006 hingga tanggal 29 September

2006, sedangkan *forecast sample* yaitu data harga saham harian mulai dari tanggal 2 Oktober 2006 hingga 18 Desember 2007. Data harga saham harian yang merupakan data sekunder didapatkan dari situs Bursa Efek Indonesia, yaitu [www.bei.co.id](http://www.bei.co.id).

### III.2.2 Penghitungan *Return*

Menurut Jorion, suatu variabel acak (*random variable*) mengambil bentuk *return* dari suatu aset keuangan untuk mengukur suatu risiko pasar. Jenis utama dari *return* terbagi atas dua, yaitu *arithmetic return* dan *geometric return*. *Arithmetic return* diartikan sebagai *capital gain* yang ditambahkan dengan dividen atau kupon jika ada, dan diformulasikan sebagai berikut:

$$r_t = \frac{P_t + D_t - P_{t-1}}{P_{t-1}} \dots\dots\dots(3.1)$$

di mana  $r_t$  adalah imbal hasil (*return*) dari suatu saham pada periode  $t$ ;  $P_t$  adalah harga saham pada periode  $t$ ;  $P_{t-1}$  adalah harga saham pada periode  $t-1$ ; dan  $D_t$  adalah dividen pada periode  $t$ .

Selanjutnya *geometric return* didefinisikan sebagai bentuk logaritma natural dari rasio atas harga aset pada periode  $t$  yang ditambahkan dengan dividen ataupun kupon jika ada, terhadap harga aset pada periode  $t-1$ , yang dirumuskan sebagai berikut:

$$R_t = \ln \frac{P_t + D_t}{P_{t-1}} \dots\dots\dots(3.2)$$

Dalam penelitian kali ini, perhitungan *return* yang digunakan adalah pendekatan *geometric return* karena pendekatan ini fokus pada *return* yang memiliki horizon waktu tertentu. Selanjutnya data harga saham harian atas sepuluh saham yang tercatat paling aktif diperdagangkan tersebut di-*differencing* atau diturunkan sehingga data harga saham yang awalnya merupakan suatu data level pada suatu *series*, diubah menjadi data *return*. Data *return* atas sepuluh saham tersebut diasumsikan terdistribusi secara normal, di mana rerata

(*mean*) dari estimator adalah nol dan variansnya adalah  $\sigma^2 \sim N(0, \sigma^2)$ . Penelitian kali ini juga menggunakan *holding period* selama satu hari.

### III.2.3 Pembentukan Portofolio

Suatu portofolio merupakan penggabungan dua atau lebih atas aset-aset tunggal (*single asset*). Sebagai contoh suatu portofolio dapat dibentuk dengan mengkombinasikan dua atau lebih saham individual dengan maksud untuk mengurangi risiko dari sebuah saham individual. Menurut Jorion (2001: 148), portofolio juga dikatakan sebagai posisi atas sejumlah aset utama yang memiliki nominal tertentu. Jika posisi tersebut tetap selama periode waktu tertentu yang telah ditentukan, maka tingkat *return* merupakan kombinasi linear atas *return* aset yang mendasarinya dengan bobot yang diberikan berdasarkan jumlah relatif aset yang diinvestasikan pada awal periode.

Pembentukan portofolio dari suatu aset dilakukan dengan tujuan untuk mengurangi risiko dengan cara melakukan diversifikasi. Selanjutnya dari portofolio yang dibentuk, estimasi VaR portofolio tersebut dapat dibentuk atau dihitung berdasarkan kombinasi atas risiko-risiko sekuritas yang mendasarinya. Menurut Jorion (2001: 148), tingkat *return* dari suatu portofolio selanjutnya dihitung berdasarkan formula berikut:

$$R_{p,t+1} = \sum_{i=1}^N W_i R_{i,t+1} \dots \dots \dots (3.3)$$

di mana  $N$  merupakan jumlah aset,  $R_{i,t+1}$  adalah tingkat *return* suatu aset  $i$ , dan  $W_i$  adalah bobot dari suatu aset  $i$ .

Pembentukan portofolio dalam makalah ini kami lakukan dengan menggunakan pendekatan Markowitz.<sup>1</sup> Pada model Markowitz disebutkan bahwa seorang investor masih menanggung seluruh risiko atas kepemilikan suatu sekuritas, baik *systematic risk* maupun

---

<sup>1</sup> Bodie, Kane, dan Marcus menyatakan formula untuk menghitung risiko dari *two-risky-asset portfolio* sebagai berikut:  $\sigma^2_p = (W_b \sigma_b)^2 + (W_s \sigma_s)^2 + 2(W_b \sigma_b)(W_s \sigma_s) \rho_{bs}$

*unsystematic risk*. Namun, risiko ini dapat dikurangi dengan melakukan diversifikasi, yang salah satunya dengan membentuk portofolio. Kemudian *return* suatu portofolio diasumsikan akan mengikuti distribusi *return* dari aset individunya ( $R_i$ ). Jika suatu *return* atas aset-aset tunggal yang digunakan dalam pembentukan portofolio diasumsikan berdistribusi normal, dengan rerata nol dan varians  $\sigma_i^2$ , maka *return* portofolio-nya juga diasumsikan akan memiliki distribusi yang sama yaitu terdistribusi secara normal.

Varians dari suatu portofolio dapat dihitung berdasarkan persamaan berikut:

$$\sigma_p^2 = \sum_{i=1}^N w_i^2 \sigma_i^2 + 2 \sum_{i=1}^N \sum_{j<i}^N w_i w_j \rho_{ij} \sigma_i \sigma_j \dots \dots \dots (3.4)$$

Jika dilihat dari persamaan di atas, terlihat bahwa aset-aset yang menyusun suatu portofolio memiliki suatu hubungan linear satu sama lain, hubungan linear tersebut adalah korelasi antar dua aset. Koefisien korelasi,  $\rho$ , merupakan ukuran dependensi linear antar dua aset atau lebih dalam suatu portofolio dan tidak memiliki satuan. Koefisien korelasi terletak antara -1 dan +1 ( $-1 < \rho < +1$ ). Jika korelasi bernilai satu, maka dapat dikatakan bahwa dua atau lebih aset dalam portofolio berkorelasi sempurna atau bergerak bersama secara linear. Sedangkan jika korelasi bernilai sama dengan nol, maka dua atau lebih aset dalam portofolio dikatakan tidak berkorelasi satu sama lain.

. Pada penelitian kali ini, portofolio dibentuk dengan mengkombinasikan *return* sepuluh saham teraktif yang diobservasi yang kemudian akan terbentuk menjadi suatu *return* portofolio. Selanjutnya dari portofolio yang terbentuk, dilakukan penghitungan atas varians, yang selanjutnya digunakan untuk mengestimasi besarnya nilai VaR dalam mengukur tingkat risiko pasar yang terjadi.

### III.3 Pengujian Data

#### III.3.1 Pengujian Stasioneritas

Suatu data *series* secara umum dapat dikatakan stasioner secara lemah (*weakly stationary*) apabila dua momen pertamanya konstan seiring dengan berjalannya waktu, atau dengan kata lain *mean*, *variance*, dan *covarianceny*a bukan merupakan fungsi dari waktu. Adapun momen yang dimiliki oleh suatu data *series* diantaranya:

1. Momen pertama:  $E[X_t] = c$ , artinya rerata (*mean*) dari suatu data *series* adalah konstan.
2. Momen kedua:  $\text{Var}[X_t] = \sigma^2$ , artinya varians dari suatu data *series* tidak tergantung terhadap waktu.
3. Momen ketiga:  $\text{Cov}[X_t, X_{t-k}] = \sigma_k^2$ , artinya data *series* bersifat independen atau tidak ada hubungan antara data *series* yang satu dengan yang lainnya.

Kemudian secara informal, melalui pengamatan grafik, suatu *series* dapat dikatakan stasioner pada tingkat *mean* apabila tidak ada kecenderungan *mean* dari data *series* tersebut naik atau turun secara terus menerus. Sedangkan suatu data *series* dapat dikatakan stasioner pada tingkat varians apabila fluktuasi *series* tersebut stabil atau dengan kata lain tidak ada perbedaan range fluktuasi data.

Selanjutnya untuk mendapatkan suatu *series* yang stasioner, dapat dilakukan dengan cara *differencing* atau mencari nilai turunan dari suatu *series*. Proses *differencing* untuk mendapatkan suatu data *series* yang stasioner pada tingkat order tertentu dapat dikatakan sebagai proses *Integratedness* (I). Suatu data *series* dikatakan terintegrasi pada order 1, dinyatakan dengan I(1), apabila *series* tersebut dapat dirubah menjadi *series* yang stasioner pada perubahan (*differencing*) pertama. Umumnya pada data-data keuangan, proses diferensiasi atau perubahan hanya dilakukan sampai dengan order atau tingkat



pertama, namun dapat pula dilanjutkan pada tingkat yang lebih tinggi sampai diperoleh suatu *series* yang stasioner.

Secara statistik, pengujian untuk menentukan apakah suatu data *series* telah stasioner atau belum, dapat dilakukan dengan uji *unit root* (*unit root test*). Pengujian *unit root* dilakukan dengan pendekatan *Augmented Dickey-Fuller Test* yang dirumuskan sebagai berikut:

$$\Delta X_t = \alpha + \beta X_{t-1} + \delta_t + u_t \dots\dots\dots(3.5)$$

di mana:

$\Delta X_t = X_t - X_{t-1}$ , yaitu perbedaan nilai antara data *series* pada periode  $t$  dengan data *series* pada periode  $t-1$

$u_t =$  disturbance term

$t =$  komponen *trend*

Selanjutnya uji signifikansi parameter pada pengujian stasioneritas sama seperti pada uji-t, namun distribusi *test statistic* (*t-stat*) tidak mengikuti distribusi *student-t* melainkan mengikuti distribusi *Dickey-Fuller*. Dalam penelitian kali ini pengolahannya uji *Augmented Dickey-Fuller* dilakukan pada *Eviews*, sehingga *test critical values* (*t-critical*) mengikuti distribusi *Dickey-Fuller* yang disediakan oleh *Eviews* dan prosedur penghitungan *Mac Kinnon*.

Pengujian stasioneritas terhadap data *series* dilakukan terhadap *intercept* pada model. Adapun perumusan hipotesisnya adalah sebagai berikut:

**H0:**  $\beta = 0$  atau ada *unit root* pada data *series*

**H1:**  $\beta \neq 0$  atau tidak ada *unit root* pada data *series*

Kriteria penolakan terhadap perumusan hipotesis yaitu sebagai berikut:

1. Jika nilai absolut *Augmented Dickey-Fuller test statistic* < nilai absolut *test critical value*, maka keputusannya adalah **menerima H0** atau dengan kata lain menolak H1. Hal ini berarti data *series* dalam penelitian tidak stasioner
2. Jika nilai absolut *Augmented Dickey-Fuller test statistic* > nilai absolut *test critical value*, maka keputusannya adalah **menolak H0** atau dengan kata lain menerima H1.

Hal ini berarti data *series* dalam penelitian stasioner

### III.3.2 Pengujian Heteroskedastisitas

Faktor pengganggu (*error*) pada suatu model regresi biasanya memiliki masalah atas pelanggaran asumsi-asumsi pada *error*. Masalah heteroskedastisitas terjadi ketika variasi dari *error* tidak konstan untuk setiap observasi atau dengan kata lain melanggar asumsi  $\text{var}(u) = \sigma^2$ . Jika *error* dalam suatu model mengandung masalah heteroskedastisitas, maka konsekuensinya adalah (1) estimator yang dihasilkan tetap konsisten, tetapi tidak lagi efisien karena ada estimator lain yang memiliki varians lebih kecil daripada estimator yang memiliki *error* yang bersifat heteroskedastis, dan (2) standar *error* yang dihitung dari suatu OLS yang memiliki *error* yang bersifat heteroskedastis tidak lagi akurat, sehingga menyebabkan inferensi (uji hipotesis) yang menggunakan standar *error* tidak lagi akurat.

Untuk mendeteksi atau menguji terjadinya masalah heteroskedastisitas dapat dilakukan dengan metode informal maupun metode formal. Pengujian informal dilakukan dengan cara mem-*plot* residual kuadrat dengan salah satu variabel independen. Sedangkan untuk metode formal dapat dilakukan dengan menggunakan uji *white heteroscedasticity* (*white heteroscedasticity test*) atau sering disebut juga dengan uji *white*, yang digunakan

untuk menguji apakah *error* terdistribusi secara homoskedastis atau tidak. Adapun perumusan uji hipotesis pada uji *white* adalah:

**H0:** *no heteroscedasticity*, atau dengan kata lain residual (*error*) bersifat homoskedastis

**H1:** *heteroscedasticity*, atau dengan kata lain residual (*error*) bersifat heteroskedastis

Selanjutnya dalam kerangka uji *white* kriteria penolakan atau penerimaan pada uji hipotesis dilakukan dengan membandingkan antara nilai probabilitas (*p-value*) dari *Obs\*R-squared* dengan tingkat kepercayaan (*significance level*) sebesar 5%. Jika nilai *p-value* dari *Obs\*R-squared* lebih besar dari *significance level* 5%, maka **H0 diterima** atau dengan kata lain residual pada model bersifat homoskedastis. Namun sebaliknya jika nilai *p-value* dari *Obs\*R-squared* lebih kecil dari *significance level* 5%, maka **H0 ditolak** atau dengan kata lain residual pada model bersifat heteroskedastis.

#### III.4 Metode Pemodelan Volatilitas bagi Risiko Pasar

Dalam melakukan pemodelan secara ekonometrik terhadap volatilitas, pada umumnya diharapkan *error* ( $U_t$ ) yang dihasilkan dari suatu model regresi memenuhi asumsi-asumsi sebagai berikut:

1.  $E(U_t) = 0$ , yaitu nilai rata-rata dari *error* nol
2.  $\text{var}(U_t) = \sigma^2 < \infty$ , yaitu varians dari *error* bersifat konstan dan *finite* untuk setiap variabel yang diestimasi/diobservasi. Asumsi ini disebut juga homoskedastik.
3.  $\text{cov}(U_i, U_j) = 0$ , yaitu *error* bersifat independen secara statistik
4.  $\text{cov}(U_i, X_t) = 0$ , yaitu tidak ada hubungan antara *error* dengan variabel  $X_t$
5.  $U_t \sim N(0, \sigma^2)$ , yaitu *error* memiliki distribusi normal

Selanjutnya apabila asumsi-asumsi *error* di atas sebagai hasil dalam suatu model dapat dipenuhi, maka parameter yang diestimasi dapat dikatakan telah memiliki

karakteristik BLUE (*Best Linear Unbiased Estimators*)<sup>2</sup>. Namun, dalam kenyataannya sangat mungkin terjadi keadaan di mana asumsi dari *error* tidak terpenuhi seluruhnya. Adakalanya varians dari suatu *error* tidak konstan terhadap waktu (*time varying*). Keadaan ini menunjukkan bahwa ditemukan heteroskedastisitas di dalam *error*. Keadaan ini juga ditunjukkan oleh fenomena *volatility clustering* yang seringkali ditemukan pada data *time series* keuangan di mana adanya kecenderungan volatilitas yang tinggi pada suatu periode diikuti dengan volatilitas yang tinggi pula pada periode berikutnya.

Selain itu, seringkali juga *error* dalam suatu observasi memiliki korelasi antara satu parameter yang diobservasi dengan parameter lainnya. Hal ini menyebabkan timbulnya autokorelasi pada *error* sehingga menyebabkan parameter yang diestimasi tidak lagi efisien. Pada umumnya, perhitungan volatilitas dengan asumsi varians yang konstan terhadap waktu, biasanya dilakukan dengan menggunakan pemodelan standar deviasi yang normal. Sedangkan untuk melakukan perhitungan terhadap volatilitas yang memiliki varians yang tidak konstan terhadap waktu, maka dapat digunakan metode pemodelan lainnya.

Dalam penelitian kali ini penaksiran terhadap nilai volatilitas, khususnya volatilitas pada data harian (*daily volatility*), selanjutnya akan diukur dalam kerangka kerja *Value at Risk* (VaR). Volatilitas yang juga mencerminkan tingkat risiko akan diukur dengan menggunakan model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), baik model *normal* GARCH dan model *student* GARCH, dan model *Risk Metrics* atau disebut juga model *Integrated-GARCH*. Namun sebelum dilakukan pemodelan GARCH terlebih dahulu juga dilakukan pemodelan dengan metode *Autoregressive Integrated Moving Average* (ARIMA).

---

<sup>2</sup> Karakteristik ini berarti: *Best* artinya kuadrat kesalahan estimasi yang minimum (*Ordinary Least Square*) memiliki minimum varians, *Linear* artinya parameter yang diestimasi bersifat linear, dan *Unbiased* artinya nilai sesungguhnya dari parameter akan sama dengan nilai estimasinya.

### III.4.1 Model Autoregressive Integrated Moving Average (ARIMA)

Pada kenyataanya, data *time series* yang digunakan dalam pemodelan univariat kebanyakan tidak bersifat stasioner. Oleh karena itu, sebelum melakukan pemodelan *conditional variance* GARCH, pemodelan *conditional mean* dengan metode ARIMA juga harus dilakukan terlebih dahulu. Hal ini disebabkan karena spesifikasi model ARCH/GARCH terdiri atas *conditional mean* dan *conditional variance* sehingga terlebih dahulu diperlukan pemodelan ARIMA agar diperoleh model GARCH yang tepat. Untuk mendapatkan estimasi model yang optimal pada tingkat *mean*, pemodelan *conditional mean* harus dilakukan pada suatu observasi. Pemodelan ini hanya dapat dilakukan jika data *series* telah stasioner. Karena karakteristik data keuangan yang cenderung tidak stasioner, data *series* perlu di-*differencing* atau diturunkan terlebih dahulu untuk dapat stasioner. Selanjutnya setelah data *series* tersebut menjadi terintegrasi atau dengan kata lain telah stasioner, maka pemodelan *conditional mean* dilakukan dengan menggunakan metode *Box-Jenkins* atau dikenal juga sebagai metode ARIMA.

Metode ARIMA merupakan suatu pengembangan dari metode *Autoregressive Moving Average* (ARMA), yang mana di dalam metode ini harus dilakukan pula proses diferensiasi (*differencing*) untuk memperoleh suatu data *series* yang stasioner, di mana *mean* dan varians dari data *series* bersifat konstan dan kovariansnya tidak terpengaruh oleh waktu. Selanjutnya, dalam konsep ARIMA diasumsikan bahwa "*data speak for themselves*", yang artinya nilai data pada masa sekarang dipengaruhi oleh nilai data pada masa-masa sebelumnya. Selain itu, penekanan pada metode ARIMA yaitu metode ini tidak hanya membangun model persamaan tunggal atau persamaan simultan saja, tetapi juga menganalisis probabilistik atau stokastik. Model ARIMA juga disebut model *atheoretic* karena model ini tidak diturunkan dari beberapa teori ekonomi yang merupakan basis dari model persamaan simultan (Wing Wahyu, 2007:7.20).

Pemodelan ARIMA dilakukan dengan menggunakan perangkat antara lain sebagai berikut:

1. *Autoregressive (AR)*

Model AR mengasumsikan bahwa data periode sekarang dipengaruhi oleh data pada periode sebelumnya. Asumsi data yang mengikuti proses AR dapat dinyatakan sebagai berikut:

$$Y_t = \mu + \sum_{i=0}^p \Phi_i Y_{t-i} + u_t \dots \dots \dots (3.6)$$

di mana  $p$  menunjukkan order dari proses  $AR(p)$ ; variabel  $u_t$  adalah *residual random* yang tidak berkorelasi dengan rata-rata nol dan varian  $\sigma^2$  konstan (bersifat *white noise*), dan  $t-i$  menunjukkan selisih waktu (*lag*) sebanyak suatu periode tertentu. Apabila model tersebut mengandung *lag* sebanyak satu periode, maka model disebut *first-order autoregressive process* atau disingkat  $AR(1)$ .

2. *Integrated (I)*

Pada kenyataanya, data *time series* bersifat tidak stasioner. Seringkali data *time series* yang terintegrasi pada tingkat (order) pertama,  $I(1)$ , akan menjadi stasioner pada diferensiasi pertamanya, atau  $I(0)$ , yang berarti data tersebut telah stasioner. Demikian juga bila data *time series* tersebut terintegrasi pada order kedua atau  $I(2)$ , maka pada diferensiasi keduanya data *series* tersebut akan bersifat stasioner. Bila dirumuskan stasioneritas pada data *time series* dapat dituliskan dengan  $I(d)$ , yang berarti bahwa setelah didiferensiasikan sebanyak  $d$  kali, maka akan didapatkan data yang stasioner.

3. *Moving Average (MA)*

Di dalam pemodelan univariat kita berasumsi bahwa rentet data akan mengikuti proses MA. Proses ini dibentuk dari proses *white noise*:

$$Y_t = \mu + \sum_{i=0}^q \theta_i U_{t-i} + U_t \dots \dots \dots (3.7)$$

Model MA mengasumsikan data periode sekarang dipengaruhi oleh nilai residual data periode sebelumnya. Model ini digunakan untuk meramalkan model ditingkat *error* menggunakan *lag values*. *First-order moving average* atau MA(1) artinya digunakan satu periode sebelumnya untuk meramalkan *error*, *second-order moving average* atau MA(2) artinya digunakan dua periode sebelumnya untuk meramalkan *error*, dan seterusnya.

Hal mendasar yang harus selalu diingat dalam pemodelan univariat dengan salah satunya menggunakan metode ARIMA adalah data yang digunakan haruslah stasioner terlebih dahulu. Hal ini untuk memastikan bahwa pemodelan yang dilakukan dapat konvergen. Implikasi lainnya adalah jika ada penambahan *lag* pada model bisa meminimumkan gangguan autokorelasi pada residual regresi. Selanjutnya, langkah pertama yang dilakukan adalah pertama membuat persamaan regresi dari *ordinary least square* (OLS) yang menggambarkan hubungan antara variabel dependen dan variabel independen pada Eviews. Selanjutnya langkah-langkah untuk menentukan order ARMA (p,q) adalah sebagai berikut:

#### 1. Identifikasi

Cara ini dilakukan dengan melihat *correlogram Q-statistic*-nya dari model dan pastikan pada *lag* ke berapa saja yang terlihat keluar dari *confidence interval 95%* atau dengan kata lain yang masih memiliki *spike*. Adanya *spike* menunjukkan bahwa masih terjadinya autokorelasi atau korelasi pada residual dari persamaan regresi yang diestimasi.

#### 2. Estimasi

Untuk meminimumkan gangguan autokorelasi tersebut, maka masukan rumus AR pada persamaan (3.6) dan rumus MA pada persamaan (3.7) ke dalam model, atau gabungkan keduanya. Untuk menentukan apakah menggunakan perangkat AR atau MA dalam meminimumkan gangguan autokorelasi, maka dilakukan proses *plotting autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF). Jika yang

memiliki *spike* adalah *autocorrelation function* (ACF), maka digunakan estimasi AR. Namun sebaliknya jika yang memiliki *spike* adalah *partial autocorrelation function* (PACF), maka digunakan estimasi MA. Sedangkan jika baik *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF) keduanya memiliki *spike*, maka dilakukan kombinasi yang terbaik dari perangkat ARMA.

### 3. Model Checking

Setelah dilakukan pemodelan ARIMA, maka lihat kembali apakah model yang dibuat sudah memenuhi syarat atau belum. Hal ini dapat dilakukan dengan dua cara. Cara yang pertama adalah dengan melakukan *overfitting*, yaitu menentukan model yang parameternya melebihi *lag* yang diidentifikasi pada langkah 1. Cara kedua dapat dilakukan dengan *residual diagnostic*, yaitu dengan mengecek residual dari model dan melihat apabila masih ada *lag* yang signifikan yang belum dimasukkan ke dalam model.

#### III.4.2 Model *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH)

Setelah sebelumnya dilakukan pemodelan *conditional mean* untuk memperoleh estimasi model yang optimal pada tingkat *mean*, selanjutnya pemodelan *conditional variance* juga dilakukan untuk memperoleh estimasi model yang optimal pada tingkat *variance*. Pemodelan ini dilakukan dengan menggunakan metode GARCH. Pemodelan ini dilakukan karena varians pada waktu  $t$  ( $\sigma^2_t$  atau  $h_t$ ) tergantung dari reratanya (*mean*), informasi pada periode sebelumnya yang tercermin pada *lag correlogram squared residual*, dan *error term* (GARCH term) pada periode sebelumnya. Estimasi yang paling umum dilakukan pada pemodelan *conditional variance* adalah dengan GARCH (1,1), namun dapat juga dilakukan pada orde atau tingkat yang lebih tinggi, GARCH (p,q). Umumnya, dalam pemodelan GARCH, pemodelan ARCH juga dimasukkan sehingga



menjadi persamaan ARCH/GARCH yang digunakan untuk mendapatkan estimasi model yang optimal baik di tingkat *mean* ataupun di tingkat *variance*.

### III.4.2.1 Model *Normal* GARCH

Salah satu asumsi yang mendasari estimasi dengan metode *Ordinary Least Square* (OLS) adalah residual dari suatu parameter yang diestimasi harus terbebas dari autokorelasi. Selain autokorelasi, asumsi lain yang sering digunakan adalah variabel pengganggu (*error*) atau residual yang bersifat konstan dari waktu ke waktu. Apabila residual tidak bersifat konstan, maka terkandung masalah heteroskedastisitas pada parameter yang diestimasi. Untuk mengatasi masalah ini, digunakan model khusus yang disebut model *Autoregressive Conditional Heteroscedasticity* (ARCH). Model ARCH dikembangkan oleh Robert Engle (1982) dan dimodifikasi oleh Mills (1999). Dalam model ARCH, varians residual dari data *time series* tidak hanya dipengaruhi oleh variabel independen, tetapi juga dipengaruhi oleh nilai residual variabel yang diteliti. Model ARCH menggunakan dua persamaan berikut:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \varepsilon_t \dots \dots \dots (3.8a)$$

$$\sigma^2_t = \alpha_0 + \alpha_1 \varepsilon^2_{t-1} \dots \dots \dots (3.8b)$$

di mana  $Y_t$  adalah variabel independen,  $X$  adalah variabel independen,  $\varepsilon$  adalah faktor pengganggu atau residual/*error*,  $\sigma^2_t$  adalah varians residual, dan  $\alpha_1 \varepsilon^2_{t-1}$  adalah yang disebut dengan komponen ARCH.

Varian residual memiliki dua komponen, yaitu konstanta dan residual dari periode sebelumnya. Itulah sebabnya model ARCH ini disebut model bersyarat (*conditional*), di mana periode sekarang dipengaruhi oleh periode sebelumnya. Pada kenyataannya, kondisi yang seringkali terjadi bahwa rata-rata saat ini sangat tergantung dari volatilitas beberapa periode di masa lalu (*conditional mean*)—ditunjukkan dalam persamaan 3.8a—ataupun

varians saat ini tergantung dengan volatilitas beberapa periode sebelumnya (*conditional variance*)—ditunjukkan dalam persamaan 3.8b. Hal ini akan menimbulkan banyaknya parameter dalam *conditional mean* atau *conditional variance* yang diestimasi. Pengestimasian parameter-parameter tersebut sulit dilakukan dengan presisi yang tepat. Untuk mengatasi masalah tersebut, tim Bollerslev (1986) mengembangkan model GARCH.

Model GARCH merupakan perbaikan terhadap model ARCH yang sebenarnya merupakan penjabaran lebih lanjut dari model ARCH yang memiliki *conditional information*. Seiring dengan meningkatnya *lag(p)* yang diestimasi pada model ARCH, maka akan menjadi lebih sulit untuk mengestimasi suatu parameter karena *likelihood function* akan menjadi sangat *flat* atau dengan kata lain ketepatan (presisi) dari estimator menjadi berkurang. Oleh karena itu, model GARCH biasanya direkomendasikan untuk dipergunakan dalam mengestimasi volatilitas. Hal ini karena model GARCH memungkinkan perhitungan volatilitas yang bervariasi terhadap waktu (*time-varying volatility*) dan *volatility clustering*, serta merupakan model yang sangat fleksibel dan berkinerja dengan baik dengan batasan-batasan yang beralasan pada koefisiennya dan menggunakan hanya sedikit parameter.

Model GARCH (p,q) dapat diformulasikan sebagai berikut:

$$y_i = \mu + e_i \dots\dots\dots(3.9a)$$

$$e_i = \epsilon_i \sqrt{h_i} \dots\dots\dots(3.9b)$$

di mana  $\mu$  adalah *expected return*,  $\epsilon_i$  digambarkan dari suatu distribusi *independent and identically distributed* (IID)  $N(0,1)$ , dan  $h_i$  dirumuskan sebagai berikut:

$$h_i = \omega + \alpha_1 e_{i-1}^2 + \beta_1 h_{i-1} \dots\dots\dots(3.10)$$

di mana  $\omega > 0$ ,  $\alpha_1 \geq 0$ , dan  $\beta_1 \geq 0$ .

Persamaan (3.10) merupakan model GARCH yang paling umum digunakan, yaitu GARCH (1,1). Kemudian untuk  $\omega$ ,  $\alpha$ , dan  $\beta$  diestimasi menggunakan metode *maximum likelihood* dan adapun restriksi parameter yang harus dipenuhi yaitu:

1. Syarat agar varians positif, yaitu :  $\omega > 0$  dan  $\alpha_1 \geq 0, \beta_1 \geq 0$
2. Syarat stasioneritas, yaitu:  $\alpha_1 + \beta_1 < 1$

Dari persamaan (3.10) atas, dapat dikatakan bahwa model GARCH mengasumsikan bahwa varians bersyarat (*conditional variance*) dari *error* ( $h_i$ ) saat ini terdiri dari tiga bagian, yaitu: (1) varians yang konstan,  $\omega$ , (2) volatilitas pada periode sebelumnya yang diukur sebagai *lag* dari residual kuadrat *mean* satu periode sebelumnya atau disebut juga *ARCH-term*,  $e^2_{i-1}$ , dan (3) peramalan varians periode sebelumnya atau *GARCH-term*,  $h_{i-1}$ . Model GARCH pada persamaan (3.10) disebut juga model GARCH (1,1).

Pada penelitian kali ini, model GARCH yang digunakan adalah model *Normal GARCH*. Model ini pada dasarnya sama dengan model GARCH pada umumnya yang memiliki formula seperti pada persamaan (3.9a) dan persamaan (3.9b), namun diasumsikan bahwa model dari residual atau *error*-nya mengikuti distribusi normal-Gaussian (*Gaussian error distribution*).

Selanjutnya untuk memasukkan suatu korelasi serial (*serial autocorrelation*) pada *return*, maka persamaan *return* (3.9a) disubstitusi menjadi:

$$y_i = \mu + \delta y_{i-1} + e_i \dots\dots\dots(3.11)$$

Pemodelan *normal GARCH* dilakukan untuk memodelkan residual pada model yang masih memiliki heteroskedastisitas. Pemodelan dilakukan dengan menggunakan persamaan (3.10), namun dengan menggunakan asumsi bahwa *error* atau residual digambarkan sebagai suatu distribusi yang *independent and identically distributed* (IID)  $N(0,1)$ , atau dengan kata lain residual dari model diasumsikan memiliki distribusi normal

(Gaussian). Pemodelan ini dihitung dengan menggunakan sampel estimasi (*estimation sample*) atau disebut juga *in-the-sample*,  $S_E$ . Setelah diperoleh *output* estimasi, maka persamaan *mean* yang tidak signifikan ( $p\text{-value} > 5\%$ ) harus dikeluarkan dari model dan variabel ARCH yang tidak signifikan harus dihilangkan atau diganti dengan orde lain.

Selanjutnya dengan menggunakan sampel peramalan (*forecast sample*) atau disebut juga *out-of-sample*,  $S_F$ , dilakukan pengestimasi terhadap model VaR dengan menggunakan *original return* ( $Y_i$ ) yang diformulasikan sebagai berikut:

$$VaR_{G(j)} = \hat{\mu} + \hat{\delta}Y_{j-1} + Z_{\alpha} \sqrt{\hat{h}_j} \phi(t_j) \dots\dots\dots (3.12)$$

#### III.4.2.2 Model *Student* GARCH (t-GARCH)

Model *student* GARCH disebut juga model *t*-GARCH. Seperti yang telah dibahas sebelumnya bahwa model GARCH (1,1) secara empiris telah berkinerja cukup baik untuk mengatasi masalah heteroskedastisitas ataupun autokorelasi di dalam residual. Namun, pada kenyataannya model tersebut tidak secara penuh berkinerja dengan baik pada distribusi *return* yang 'fat tails'. Sesungguhnya, model GARCH mengizinkan sebuah koefisien kurtosis yang lebih dari 3 (tiga) dalam modelnya, tetapi data empiris harian (*daily*) atau *intradaily* menunjukkan koefisien kurtosis yang masih jauh lebih besar dari tiga. Untuk mengatasi masalah tersebut, *student* GARCH atau *t*-GARCH dikembangkan. Model ini mengasumsikan bahwa residual pada model mengikuti distribusi *t* secara statistik, di mana  $e_i$  pada persamaan (3.9a) dan (3.9b) menggambarkan suatu distribusi  $t(0,1,\nu)$ . Selanjutnya untuk menghitung nilai VaR dalam digunakan formula:

$$VaR_{(j)} = \hat{\mu} + \hat{\delta}y_{j-1} + t_{\alpha, \nu} \sqrt{\hat{h}_j} \phi(t_j) \dots\dots\dots (3.13)$$

Pemodelan *conditional variance* dengan model *t*-GARCH dilakukan dengan menggunakan persamaan yang sama dengan model *normal* GARCH pada persamaan (3.10), hanya saja asumsi distribusi residualnya diubah dengan mengikuti distribusi *t* secara statistik. Sama seperti model *normal* GARCH sebelumnya, pemodelan residual dengan *t*-GARCH ini juga menggunakan sampel estimasi (*estimation sample*) pada prosesnya. Sedangkan pengestimasi terhadap model VaR-nya dilakukan dengan menggunakan sampel peramalan (*forecast sample*).

### III.4.2.3 Model *Risk Metrics* atau *Integrated* GARCH

Model *Risk Metrics* diperkenalkan pertama kali oleh JP Morgan pada tahun 1994 sebagai sebuah pemodelan risiko yang sederhana yang hampir tidak membutuhkan perhitungan empiris. *Risk Metrics model* ekuivalen dengan model *Intergrated* GARCH (I-GARCH). Model I-GARCH digunakan ketika peramalan dari suatu volatilitas tidak bersifat *mean reverting*, yang berarti *unconditional variance* tidak ditemukan dan peramalan *term structure* juga menjadi tidak konvergen (Carol:2001, 75). Adapun model umum dari I-GARCH memiliki formula sebagai berikut:

$$\sigma_t^2 = \omega + (1-\lambda)\varepsilon_{t-1}^2 + \lambda\sigma_{t-1}^2 \dots \dots \dots (3.14)$$

Dari formula di atas, dapat dijelaskan bahwa:

- a. ketika  $\alpha + \beta = 1$ , yang mana berarti estimator dari suatu data *time series* bersifat stasioner), maka  $\beta$  dapat digantikan dengan  $\lambda$  ( $\beta = \lambda$ ), di mana *range* untuk  $\lambda$  yaitu  $0 \leq \lambda \leq 1$ .  $\lambda$  adalah suatu parameter faktor peluruh (*decay factor*) yang menunjukkan skala bobot dari pengamatan data terbaru dengan data sebelumnya. Semakin tinggi nilai  $\lambda$  maka akan semakin kecil reaksinya terhadap suatu volatilitas, tetapi semakin *persistence* terhadap volatilitas. Secara teoritis,  $\lambda$  dapat diperoleh dengan cara memaksimalkan fungsi *likelihood*. JP Morgan telah mengadakan penelitian yang

menemukan bahwa *decay factor* ( $\lambda$ ) yang paling optimal untuk suatu data *time series* adalah 0.94 yang digunakan pada data harian ( $\lambda = 0.94$ ).

- b.  $\lambda\sigma^2_{t-1}$  merupakan suatu parameter yang menunjukkan persistensi dalam suatu volatilitas, di mana apabila nilai suatu volatilitas relatif tinggi pada periode sebelumnya maka volatilitas tersebut akan tetap tinggi pada saat ini.
- c. Selanjutnya  $(1-\lambda)\varepsilon^2_{t-1}$  menunjukkan suatu intensitas reaksi terhadap suatu volatilitas yang dipengaruhi oleh kondisi pasar. Jika nilai  $\lambda$  semakin kecil, maka dapat dikatakan bahwa semakin reaktif volatilitas terhadap informasi pasar pada *return* hari sebelumnya.

Kemudian apabila  $\omega$  pada persamaan (3.14) bernilai sama dengan nol ( $\omega = 0$ ), maka model I-GARCH akan menjadi model EWMA (*Exponentially Weighted Moving Average*). Model EWMA dapat dikatakan sebagai suatu model GARCH yang sederhana tanpa adanya suatu varians yang konstan ( $\omega$ ) dan dengan *term structure* yang konstan. Pada penelitian kali ini, model I-GARCH yang mengasumsikan bahwa varians,  $\omega$ , sama dengan nol atau konstan, parameter *autoregressive*,  $\beta_1$ , dinotasikan sebagai  $\lambda$  dan koefisien dari ARCH-term,  $\alpha_1$ , dinotasikan sebagai  $(1-\lambda)$ , sehingga model GARCH pada persamaan (3.10) dirumuskan menjadi:

$$h_t = \lambda\varepsilon^2_{t-1} + (1-\lambda)h_{t-1} \dots\dots\dots(3.15)$$

Selanjutnya langkah terakhir adalah menghitung nilai VaR dengan model *Risk Metrics* atau I-GARCH yang diformulasikan sebagai berikut:

$$VaR_{RM(j)} = \hat{\mu} + \hat{\delta}Y_{j-1} + z_{\alpha}\sqrt{\hat{h}_j\phi(t_j)} \dots\dots\dots(3.16)$$

Pemodelan volatilitas selanjutnya dilakukan dengan menggunakan model *RiskMetrics* atau disebut juga *Integrated GARCH* (I-GARCH). Pada penelitian kali ini, diasumsikan bahwa varians pada persamaan *conditional variance*,  $\omega$ , bernilai sama dengan

nol (0), sehingga model *RiskMetrics* atau I-GARCH disebut juga dengan model *Exponentially Weighted Moving Average* (EWMA) yang ditunjukkan pada persamaan (3.15). Model EWMA ini selanjutnya menggunakan *decay factor* ( $\lambda$ ) sebesar 0.94. Nilai  $\lambda$  tersebut sesuai dengan penelitian yang dilakukan JP.Morgan, di mana berdasarkan penelitian pada model *RiskMetrics* dinyatakan bahwa nilai *decay factor* tersebut adalah yang paling optimal. Pengestimasian *conditional variance* dengan menggunakan model *RiskMetrics* atau model EWMA ini menggunakan sampel estimasi dalam pemodelannya dan sampel peramalan (*forecast sample*) untuk mengestimasi nilai VaR-nya.

### III.5 Penghitungan VaR Portofolio

Setelah dilakukan pembentukan atas portofolio dari sepuluh saham teraktif, berikutnya dilakukan pemodelan volatilitas atas *return* portofolio yang memiliki masalah heteroskedastisitas dengan model *normal GARCH*, *student GARCH*, dan *RiskMetrics* atau EWMA, untuk memperoleh nilai *conditional variance*. Nilai *variance* portofolio dibentuk berdasarkan persamaan (3.4) yang selanjutnya digunakan untuk mengestimasi nilai VaR portofolio dengan menggunakan model VaR *normal GARCH* pada persamaan (3.12), model VaR *student GARCH* pada persamaan (3.13), dan model VaR *RiskMetrics* atau EWMA pada persamaan (3.16).

Estimasi nilai VaR portofolio dengan menggunakan ketiga model di atas, didapatkan dengan mengalikan standar deviasi portofolio atau volatilitas portofolio yang didapatkan dari hasil pemodelan volatilitas sebelumnya, dengan nilai alpha ( $\alpha$ ) distribusi normal yang sesuai dengan tingkat keyakinan yang digunakan, kemudian dikalikan pula dengan nilai akar dari *holding period* ( $\sqrt{t}$ ). Dalam penelitian kali ini, perhitungan estimasi nilai VaR portofolio dilakukan tanpa mengalikan lagi nilai estimasi VaR dengan posisi portofolionya ( $V_0$ ) karena nilai estimasi VaR disini berfungsi sebagai *forecast return*, yang

akan dibandingkan langsung dengan *actual return* dari portofolio saham, sehingga pada akhirnya perhitungan nilai VaR tidak memerlukan posisi dari portofolio itu sendiri (Bredin dan Hyde, 2004). Perhitungan VaR portofolio pada penelitian ini menggunakan tingkat keyakinan sebesar 95% dan *holding period* selama 1 hari, yang mana ketentuan ini didasarkan dengan sistem yang ada pada *RiskMetrics*.

### III.6 Pengujian Validasi Model VaR

#### III.6.1 Backtesting

Untuk menguji validasi dari suatu model VaR, banyak metode yang dapat digunakan, salah satunya adalah metode *backtesting*. Metode ini merupakan kerangka kerja statistik yang terdiri dari proses memastikan bahwa kerugian actual (*actual loss*) sesuai dengan kerugian yang diprediksi (Jorion, 2001: 129). Metode ini dilakukan dengan membandingkan estimasi nilai VaR dengan asosiasi *return* suatu aset. Model VaR dapat dikatakan sempurna ketika jumlah observasi yang melebihi nilai estimasi VaR sesuai dengan tingkat keyakinan dari model tersebut. Misalnya jika tingkat kepercayaan yang digunakan dalam model sebesar 99%, maka jumlah observasi yang melebihi nilai estimasi VaR seharusnya kurang dari 1%.

Jika jumlah observasi melebihi nilai estimasi VaR, maka dapat dikatakan model tersebut memiliki suatu *exceptions*. Model VaR yang memiliki terlalu banyak *exceptions*, maka konsekuensinya adalah model tersebut akan menaksir risiko terlalu kecil (*underestimate*). Pengestimasian yang terlalu kecil atas modal minimum yang dibutuhkan, menyebabkan modal tersebut tidak mampu menjadi penahan (*buffer*) yang optimal dalam menghadapi risiko pasar yang mungkin terjadi. Sebaliknya, jika jumlah *exceptions* dalam model juga terlalu sedikit, maka akan menyebabkan adanya kelebihan modal minimum atau pengalokasian modal menjadi tidak efisien (Jorion, 2001: 130).



Kupiec (1995) mengembangkan suatu aproksimasi jumlah *exceptions* yang dapat diterima dalam suatu model VaR yang digunakan, yang ditunjukkan pada tabel 3.2 di bawah ini:

**Tabel 3.2**  
**Area Penerimaan *Exceptions* pada Beberapa Tingkat Keyakinan**

Significance Level ( $\alpha$ )	VaR confidence level ( $1-\alpha$ )	<i>Non-rejection Region for Number of Failures (N)</i>		
		T = 255 days	T = 510 days	T = 1000 days
1%	99%	$N < 7$	$1 < N < 11$	$4 < N < 17$
2.50%	97.50%	$2 < N < 12$	$6 < N < 21$	$15 < N < 36$
<b>5%</b>	<b>95%</b>	<b><math>6 &lt; N &lt; 21</math></b>	<b><math>16 &lt; N &lt; 36</math></b>	<b><math>37 &lt; N &lt; 65</math></b>
7.50%	92.50%	$11 < N < 28$	$27 < N < 51$	$59 < N < 92$
10%	90%	$16 < N < 36$	$38 < N < 65$	$81 < N < 120$

Catatan: N adalah jumlah *exceptions* yang dapat diamati pada sampel T

Sumber: Kupiec (1995)

Pada penelitian kali ini, metode pengujian *backtesting* juga akan disajikan dalam secara grafis untuk memperlihatkan apakah estimasi dari model VaR yang ada mampu menangkap *swing* atau *shock* dari data *return* saham yang disebabkan dari adanya reaksi pasar terhadap suatu kejadian di pasar (*market event*)

Setelah memperoleh hasil atau *output* dari masing-masing model estimasi VaR tersebut, selanjutnya dilakukan pengujian terhadap model mana yang berkinerja paling baik. Salah satu metode pengujian yang dilakukan adalah *backtesting*. Metode ini digunakan untuk melihat *exceptions* yang ada pada model VaR yang telah diestimasi sebelumnya. *Exceptions* merupakan banyak data *return* aktual yang melebihi estimasi nilai VaR. Jika *exceptions* berada pada area penerimaan menurut Kupiec (disajikan pada tabel 3.2) pada tingkat signifikansi yang telah ditentukan sebelumnya, maka model VaR tersebut dapat dikatakan valid atau akurat. Pada penelitian kali ini, tingkat signifikansi yang digunakan untuk menguji validasi model adalah pada tingkat 5%.

### III.6.2 Kupiec's Likelihood Ratio Test

Penelitian kali ini menguji validasi dari model VaR yang digunakan dengan menggunakan kerangka *Likelihood Ratio (LR-test)*. Kupiec (1995) melakukan pengujian untuk menganalisis kinerja dari suatu model VaR dengan menghitung persentase kegagalan (*percentage of failures*), yang lebih dikenal dengan *Kupiec's likelihood ratio test*. Dalam metode ini, kita menghitung *failure rate* empiris ( $\hat{f}$ ) sebagai suatu persentase dari berapa kali *return* aktual ( $y_k$ ) yang melebihi daripada estimasi VaR. Jika estimasi VaR akurat, maka *failure rate* seharusnya sama dengan nilai tingkat signifikansi ( $\alpha$ ). Pengujian Kupiec juga melihat apakah *failure rate* yang diobservasi konsisten dengan jumlah *exceptions* yang diprediksi dengan menggunakan model VaR. *Kupiec's likelihood ratio test* secara statistik memiliki formula sebagai berikut:

$$LR = 2 \left[ \ln(\hat{\alpha}^m (1 - \hat{\alpha})^{n-m}) - \ln(\alpha^m (1 - \alpha)^{n-m}) \right] \dots \dots \dots (3.17)$$

di mana  $\alpha$  adalah *p-value* atau tingkat signifikansi,  $m$  adalah jumlah *exception*, dan  $n$  adalah jumlah sampel. *Likelihood ratio* didistribusikan sebagai *chi-square*  $\chi^2(1)$  pada hipotesis nol-nya.

Selanjutnya, pengujian ini dilakukan dengan menggunakan persamaan (3.17) di atas, dengan perumusan hipotesis adalah sebagai berikut:

**H0:**  $f = \alpha$ , atau dengan kata lain tingkat kegagalan (*failure rate*) dari estimasi VaR adalah sebesar tingkat signifikansi yang ditentukan

**H1:**  $f \neq \alpha$ , atau dengan kata lain tingkat kegagalan (*failure rate*) dari estimasi VaR tidak sama atau berbeda dengan tingkat signifikansi yang ditentukan

Pengujian ini menggunakan distribusi *chi-square* dengan derajat kebebasan sebesar 1 atau  $\chi^2(1)$ . Oleh karena itu, kriteria penolakan hipotesis adalah jika uji  $LR < \chi^2_{df=1}$ , maka keputusannya adalah kita **menerima H0** atau dengan kata lain tingkat kegagalan

(*failure rate*) dari estimasi VaR adalah sebesar tingkat signifikansi yang ditentukan, dan berarti dengan begitu dapat dikatakan model VaR yang diestimasi adalah valid. Sebaliknya, jika uji  $LR > \chi^2_{df : 1}$ , maka keputusannya adalah kita **menolak  $H_0$**  atau dengan kata lain tingkat kegagalan (*failure rate*) dari estimasi VaR tidak sama atau berbeda dengan tingkat signifikansi yang ditentukan. Ini berarti model VaR yang diestimasi tidak akurat dibandingkan dengan model yang lainnya. Penelitian kali ini menguji validasi dari model VaR di uji dengan level signifikansi ( $\alpha$ ) sebesar 5%.



**Gambar 3.1 Flow Chart Metodologi Penelitian**

