

BAB III METODOLOGI PENELITIAN

3.1. Identifikasi Variabel dan Data yang Digunakan

Berdasarkan kajian literatur, penelitian ini akan menggunakan pendekatan kuantitatif deskriptif yang merupakan pengujian hipotesis dengan data yang terukur. Selanjutnya akan diperoleh parameter dari pengaruh perubahan suatu variabel ekonomi terhadap variabel ekonomi lainnya serta penjelasan dari asumsi ilmu ekonomi untuk mendapatkan suatu kesimpulan mengenai korelasi antar variabel dalam penelitian ini dengan menggunakan metodologi *time series* serta pendekatan *Granger Causality* dan VAR atau VECM sebagaimana yang pernah digunakan oleh Copelman (2000) serta Rousseau dan Xiao (2007). Pendekatan tersebut dipilih dengan pertimbangan bahwa secara spesifik *Granger Causality* digunakan untuk melakukan uji kausalitas antara variabel output dengan variabel sistem keuangan serta untuk melihat hubungan jangka panjangnya, sementara VAR atau VECM digunakan untuk melihat intensitas dan *speed of adjustment* atau respon dari masing-masing variabel dalam penelitian. Untuk menganalisa data yang telah dihimpun dalam penelitian ini, penulis akan menggunakan alat bantu berupa perangkat lunak E-views versi 5.0.

Bentuk dasar model VAR memperlakukan seluruh variabel secara simetris tanpa membedakan variabel bebas maupun terikat. Seluruh variabel dalam penelitian ini akan diperlakukan sebagai variabel endogen. Adapun variabel yang akan digunakan dalam penelitian ini adalah sebagai berikut:

1. Pertumbuhan Ekonomi.

Data Produk Domestik Bruto (PDB) Riil dengan harga konstan tahun 2000 yang diperoleh dari Statistik Ekonomi dan Keuangan Indonesia (SEKI) yang diterbitkan Bank Indonesia yang diolah dan akan dipergunakan sebagai *proxy* pertumbuhan ekonomi.

2. Sektor Perbankan.

Data volume penyaluran kredit oleh bank umum (KREDIT) kepada sektor swasta dalam Rupiah dan Valuta Asing yang juga diperoleh dari SEKI akan digunakan sebagai indikator perkembangan sektor perbankan. Pemilihan variabel ini didasarkan pada dugaan bahwa peningkatan volume kredit mengindikasikan peningkatan investasi yang memiliki hubungan positif dengan peningkatan pertumbuhan ekonomi.

3. Sektor Pasar Modal.

Data kapitalisasi saham dan obligasi dipasar modal (KAPSHM) yang merupakan akumulasi dari perkalian jumlah lembar saham beredar dengan harga saham di pasar dari seluruh perusahaan yang terdaftar di Bursa Efek Indonesia (BEI) akan digunakan sebagai indikator perkembangan sektor pasar modal. Data kapitalisasi saham dimaksud berhasil diperoleh dari langsung dari BEI. Pemilihan variabel ini didasarkan pada dugaan bahwa peningkatan kapitalisasi pasar mengindikasikan adanya peningkatan jumlah saham maupun emiten yang mencerminkan adanya aliran dana bagi investasi pada emiten-emiten tersebut yang secara agregat dapat meningkatkan pertumbuhan ekonomi.

4. Tingkat Suku Bunga.

Data tingkat suku Sertifikat Bank Indonesia (SBI) dengan tenor 1 (satu) bulan yang diperoleh dari SEKI merupakan variabel kontrol, yakni variabel sektor keuangan maupun sektor moneter yang dianggap turut memengaruhi pertumbuhan ekonomi. Variabel kontrol dimaksud mengacu pada penelitian yang dilakukan oleh Ingrid (2006) yang menginvestigasi peranan sektor keuangan dalam memicu pertumbuhan ekonomi di Indonesia.

Penelitian ini menggunakan variabel kontrol berupa tingkat suku bunga SBI tenor 1 (satu) bulan dengan pertimbangan bahwa suku bunga SBI merupakan salah satu alat kontrol bagi otoritas moneter dalam mengendalikan penawaran dan permintaan uang beredar dalam perekonomian Indonesia. Penggunaan variabel tingkat suku bunga dimaksud juga mengacu pada penelitian sebelumnya dengan

dugaan memiliki tingkat signifikansi yang baik dalam penerapan pada model yang akan disusun.

Data yang digunakan dalam penelitian ini adalah data sekunder dalam bentuk *time series* periode bulanan yang diperoleh dari Statistik Ekonomi Keuangan Indonesia (SEKI) yang diterbitkan oleh Bank Indonesia dan diperoleh langsung dari Bursa Efek Indonesia (BEI). Namun karena keterbatasan data yang tersedia maka penelitian ini hanya dilakukan dalam rentang waktu Januari 1997 s.d Juni 2009. Selain itu, mengingat periode data PDB yang tersedia bersifat triwulanan, maka khusus untuk data PDB dilakukan perubahan melalui metode intrapolasi guna memperoleh data PDB periode bulanan dengan bantuan aplikasi E-views versi 5.0.

3.2. Metode Pengolahan dan Analisis data

Penelitian ini akan menggunakan metodologi *time series* dengan pendekatan VAR jika data yang digunakan adalah stasioner dan tidak terdapat kointegrasi, atau pendekatan VECM jika data yang digunakan kemudian diketahui stasioner dan terdapat kointegrasi.

VAR dikembangkan oleh seorang ahli Ekonometrika, Christopher A. Sims, sebagai pendekatan alternatif model terhadap model persamaan ganda dengan pertimbangan meminimalkan pendekatan teori yang bertujuan agar mampu menangkap fenomena ekonomi dengan baik (Widarjono, 2007). Sims berpendapat bahwa jika terdapat hubungan simultan antar variabel yang diamati, maka variabel-variabel tersebut harus diperlakukan sama sehingga tidak ada lagi variabel endogen dan eksogen (Nachrowi, 2006). Berawal dari pemikiran inilah Sims memperkenalkan konsep VAR, yang ternyata juga menjawab tantangan kesulitan yang ditemui akibat model struktural yang tidak harus mengacu pada teori melainkan hanya perlu menentukan variabel yang saling berinteraksi dan perlu. Dengan kata lain, model VAR tidak banyak bergantung pada teori tetapi kita hanya perlu menentukan variabel yang saling berinteraksi dan perlu dimasukkan dalam sistem serta menentukan banyaknya jeda dan perlu diikutsertakan dalam model yang diharapkan dapat ‘menangkap’ keterkaitan antar variabel dalam model.

Keuntungan dari analisis VAR antara lain adalah metode yang sederhana dan tidak perlu membedakan mana variabel endogen dan eksogen, estimasi yang sederhana dimana metode *Ordinary Least Square* (OLS) biasa dapat diaplikasikan pada setiap persamaan secara terpisah, dan hasil estimasi yang diperoleh dengan menggunakan pendekatan VAR pada beberapa kasus lebih baik dibandingkan dengan hasil yang diperoleh dengan menggunakan model persamaan simultan yang kompleks sekalipun.

Meskipun banyak kelebihan, Gujarati (2003) mengemukakan beberapa kelemahan VAR sebagai berikut:

1. Lebih bersifat “a teoretik” mengingat pendekatan VAR tidak memanfaatkan informasi terlebih dahulu sehingga model menjadi tidak struktural.
2. Kurang sesuai untuk analisis kebijakan karena lebih menitikberatkan pada peramalan (*forecasting*).
3. Penentuan banyaknya *lag* yang dianggap optimal dapat menimbulkan permasalahan mengingat data yang diamati harus relatif banyak.
4. Semua variabel dalam VAR yang belum stasioner harus ditransformasikan terlebih dahulu agar stasioner.
5. Koefisien dalam estimasi VAR sulit untuk diinterpretasikan.

3.2.1. Model Umum *Vector Auto Regression* (VAR)

Metode VAR menganggap bahwa semua variabel adalah endogen. Dalam kasus dua variabel (y_t) dan (z_t); nilai sekarang (y_t) dipengaruhi oleh nilai sekarang dan nilai masa lalu (z_t), sedangkan nilai sekarang (z_t) dipengaruhi oleh nilai sekarang dan nilai masa lalu (y_t). Secara sederhana, Enders (1995) menuliskan sistem bivariat tersebut sebagai berikut:

$$\begin{aligned} y_t &= b_{10} - b_{12}z_t + \gamma_{11}y_{t-1} + \gamma_{12}z_{t-1} + \varepsilon_{yt} \\ z_t &= b_{20} - b_{22}z_t + \gamma_{21}y_{t-1} + \gamma_{22}z_{t-1} + \varepsilon_{zt} \end{aligned} \quad \dots \dots \dots (3.1)$$

Persamaan (3.1) di atas dikenal sebagai *first order* atau *primitive VAR* dengan asumsi:

1. y_t dan z_t adalah stasioner,
2. ε_{yt} dan ε_{zt} adalah proses *white noise* dengan standar deviasi α_y dan α_z , dan
3. ε_{yt} dan ε_{zt} tidak saling berkorelasi.

Selanjutnya, persamaan (3.1) tersebut diubah dalam bentuk matriks atau menjadi $Bx_t = \Gamma_0 + \Gamma_0 x_{t-1} + \varepsilon_t$ (3.2)

dan mengalikannya terhadap inverse matriks B (B^{-1}) sehingga diperoleh persamaan VAR dalam bentuk standar $x_t = A_0 + A_1 x_{t-1} + \ell_t$ (3.3)

dimana $A_0 = B^{-1}\Gamma_0$, $A_1 = B^{-1}\Gamma_0$ dan $\ell_t = B^{-1} \varepsilon_t$.

Jika α_{i0} didefinisikan sebagai elemen baris I dari vektor A_0 , α_{ij} sebagai elemen baris i dan kolom j dari matriks A_1 , ε_{it} sebagai elemen baris i dari ℓ_t maka persamaan VAR yang baru adalah :

$$\begin{aligned} y_t &= \alpha_{10} + \alpha_{11}y_{t-1} + \alpha_{12}z_{t-1} + \varepsilon_{1t} \\ z_t &= \alpha_{20} + \alpha_{21}y_{t-1} + \alpha_{22}z_{t-1} + \varepsilon_{2t} \end{aligned} \dots\dots\dots (3.4)$$

dari persamaan dasar tersebut dapat diturunkan beberapa macam bentuk estimasi, dimana salah satunya adalah respons terhadap inovasi.

3.2.2. Tahapan dan Prosedur Pembentukan VAR

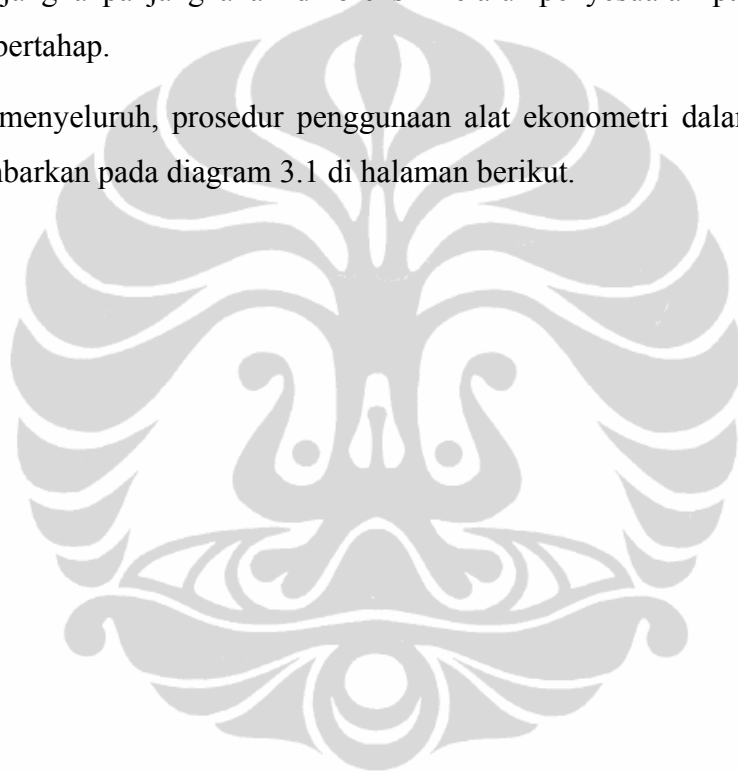
Model VAR merupakan model persamaan regresi yang menggunakan data time series yang berkaitan dengan masalah stasioneritas dan kointegrasi antar variabel di dalamnya. Pembentukan model VAR diawali dengan uji stasioneritas data, dimana model VAR biasa (*unrestricted VAR*) akan diperoleh apabila data telah stasioner pada tingkat level. Namun jika data tidak stasioner pada tingkat level tetapi stasioner pada proses diferensiasi yang sama, maka harus dilakukan uji kointegrasi untuk mengetahui apakah data tersebut mempunyai hubungan dalam jangka panjang atau tidak.

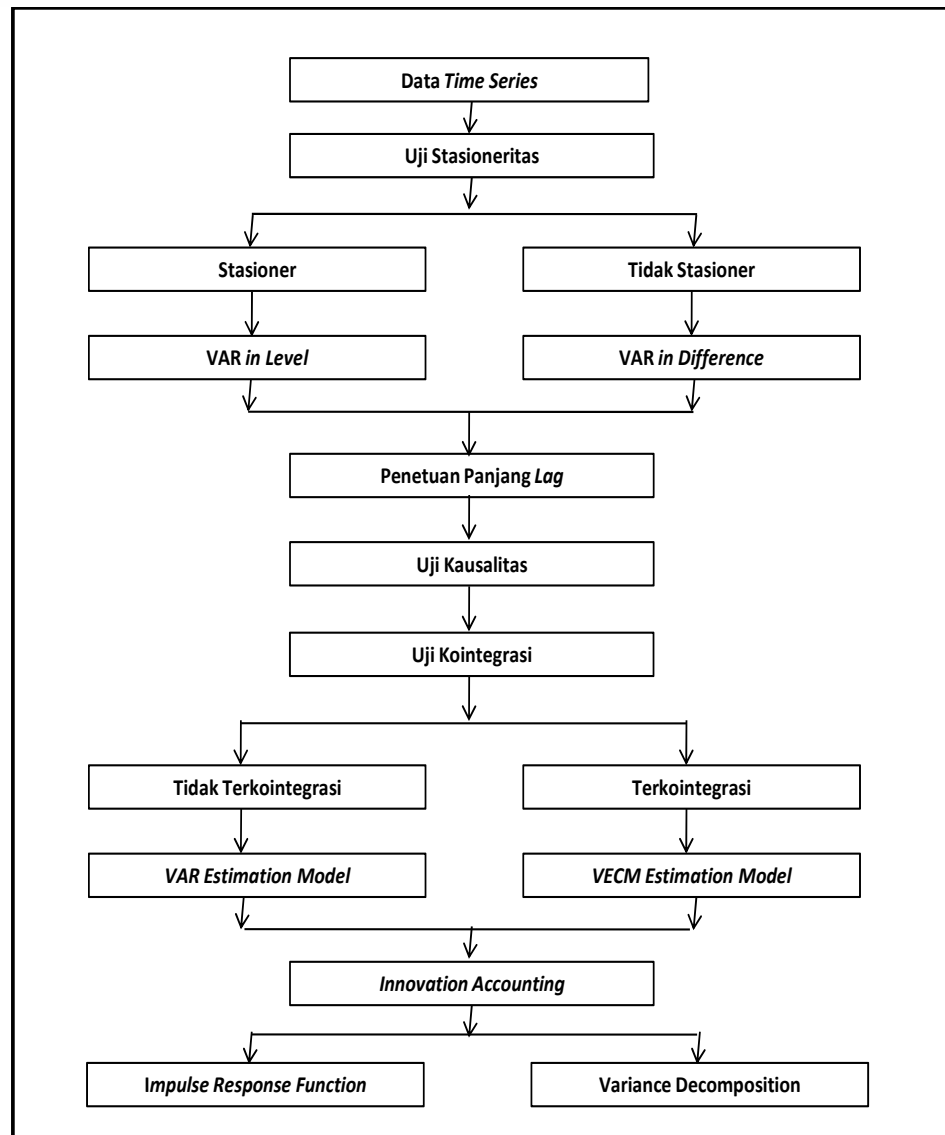
Dalam hal data stasioner pada proses diferensiasi namun tidak terkointegrasi, maka dapat dibentuk model VAR dengan data diferensiasi (*VAR in difference*). Namun apabila terdapat kointegrasi maka dibentuk *Vector Error Correction Model* (VECM), yang merupakan model VAR yang terkektriksi (*restricted VAR*) mengingat

adanya kointegrasi yang menunjukkan hubungan jangka panjang antar variabel dalam model VAR.

Spesifikasi VECM merestriksi hubungan perilaku jangka panjang antar variabel agar konvergen ke dalam hubungan kointegrasi namun tetap membiarkan perubahan dinamis dalam jangka pendek. Terminologi kointegrasi ini dikenal sebagai koreksi kesalahan (*error correction*) karena bila terjadi deviasi terhadap keseimbangan jangka panjang akan dikoreksi melalui penyesuaian parsial jangka pendek secara bertahap.

Secara menyeluruh, prosedur penggunaan alat ekonometri dalam penelitian ini dapat digambarkan pada diagram 3.1 di halaman berikut.





Sumber : Agus Widarjono (2007), diolah.

Diagram 3.1
Prosedur Penggunaan Alat Ekonometri dalam Pendekatan VAR

Adapun tahapan dalam melakukan analisis dengan pendekatan VAR adalah sebagai berikut:

3.2.2.1. Uji Stasioneritas

Uji stasioneritas merupakan langkah pertama dalam membangun model VAR guna memastikan bahwa data yang digunakan adalah data yang stasioner sehingga hasil regresi yang dihasilkan tidak menggambarkan hubungan variabel yang nampaknya signifikan secara statistik namun dalam kenyataannya tidak demikian

(*spurious*). Stasioneritas data dilihat dengan menggunakan uji formal, yakni Uji Akar Unit (*unit root test*) yang diperkenalkan oleh David Dickey dan Wayne Fuller, dengan tujuan untuk mengetahui apakah data *time series* stasioner atau tidak, mengingat studi terhadap data yang tidak stasioner hanya dapat dilakukan pada waktu yang bersangkutan saja.

Gujarati (2003) mengemukakan bahwa data *time series* dapat dikatakan stasioner jika rata-rata dan variannya konstan sepanjang waktu serta kovarian antara dua runtut waktunya hanya tergantung dari kelambanan (*lag*) antara dua periode waktu tersebut. Secara statistik pernyataan Gujarati dimaksud dapat dituliskan sebagai berikut:

$$\begin{aligned} \text{Rata-rata} & : E(Y_t) = \mu \\ \text{Varian} & : \text{Var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \\ \text{Kovarian} & : \gamma_k = E[(Y_t - \mu)(Y_{t-k} - \mu)] \end{aligned}$$

dimana γ_k , kovarian pada *lag* k, merupakan kovarian antara nilai Y_t dan Y_{t-k} yakni antara nilai Y pada interval k periode.

Pemikiran uji stasioneritas data dengan pengujian akar unit dapat dijelaskan melalui model sebagai berikut:

$$Y_t = \rho Y_{t-1} + \mu_t \dots \dots \dots (3.5)$$

dimana $-1 \leq \rho \leq 1$ dan μ_t adalah variabel gangguan yang bersifat random atau stokastik dengan rata-rata nol, varian yang konstan dan tidak saling berhubungan. Jika $\rho=1$ maka variabel Y_t mempunyai akar unit, yang bergerak secara random (*random walk*) tanpa *trend* dimana varian Y_t tidak stasioner. Hal ini menunjukkan bahwa Y_t merupakan data yang tidak stasioner karena memiliki *unit root*.

Bila persamaan (3.5) dikurangi dengan Y_{t-1} pada kedua sisinya, maka akan diperoleh persamaan sebagai berikut:

$$Y_t - Y_{t-1} = \rho Y_{t-1} - Y_{t-1} + \mu_t \dots \dots \dots (3.6)$$

$$\Delta Y_t = (\rho-1)Y_{t-1} + \mu_t$$

$$\text{atau dapat ditulis dalam bentuk } \Delta Y_t = \delta Y_{t-1} + \mu_t \dots \dots \dots (3.7)$$

dimana $\delta = (\rho-1)$ dan Δ merupakan *first difference operator*.

Pengujian *unit root* dilakukan terhadap persamaan $\Delta Y_t = \delta Y_{t-1} + \mu_t$ dengan melakukan regresi *first difference* dari Y_t terhadap Y_{t-1} dengan hipotesa $H_0 : \delta = 0$ dan $H_1 : \delta \neq 0$. Jika $\delta = 0$ maka $\rho = 1$, menunjukkan bahwa data *time series* memiliki *unit root* dimana Y_t tidak stasioner. Sedangkan apabila $\delta \neq 0$ maka Y_t adalah stasioner.

Model-model di atas mengasumsikan μ_t tidak berkorelasi, sehingga Dickey-Fuller mengembangkan suatu pengujian *Augmented Dickey-Fuller Test (ADF test)* untuk mengantisipasi adanya korelasi dimaksud. Estimasi untuk *ADF test* dilakukan melalui persamaan sebagai berikut:

$$\Delta Y_t = \beta_1 + \beta_2 + \delta Y_{t-1} + \sum_{i=1}^m \Delta Y_{t-i} + \mu_t \dots \dots \dots (3.8)$$

dimana $\Delta Y_t =$ bentuk *first difference*,
 $\beta_1 =$ intersep,
 $Y =$ variabel yang sedang diuji,
 $m =$ panjang *lag* yang digunakan, dan
 $\mu =$ *error term*.

Prosedur untuk menentukan apakah data stasioner atau tidak adalah dengan cara membandingkan nilai statistik *ADF test* dengan nilai kritis distribusi statistik MacKinnon, dimana nilai statistik *ADF test* ditunjukkan oleh nilai t statistik koefisien δY_{t-1} pada persamaan (3.8). Jika nilai absolut statistik *ADF test* lebih besar dari nilai kritis distribusi statistik MacKinnon maka H_0 ditolak, dalam arti data *time series* yang diamati telah stasioner. Dan sebaliknya, jika nilai absolut statistik *ADF test* lebih kecil dari nilai kritis distribusi statistik MacKinnon, maka H_0 diterima, yang berarti data *time series* tidak stasioner.

Dalam hal hasil *ADF test* menunjukkan bahwa data *time series* yang diamati tidak stasioner dalam bentuk *level*, maka perlu dilakukan transformasi melalui proses *differencing* agar data menjadi stasioner. Data dalam bentuk *difference* merupakan data yang telah diturunkan dengan periode sebelumnya, dimana bentuk derajat pertama (*first difference*) dapat dinotasikan dengan $I(1)$ dengan fungsi

$$\Delta Y_t = (Y_t - Y_{t-1}) \dots \dots \dots (3.9)$$

Prosedur ADF *test* kembali dilakukan apabila data *time series* yang diamati masih belum stasioner pada derajat pertama sehingga kembali dilakukan *differencing* yang kedua (*second difference*) untuk memperoleh data yang stasioner.

3.2.2.2. Penentuan Panjang *Lag* Optimal

Penentuan kelambanan (*lag*) optimal merupakan tahapan yang sangat penting dalam model VAR mengingat tujuan membangun model VAR adalah untuk melihat perilaku dan hubungan dari setiap variabel dalam sistem. Untuk kepentingan tersebut, dapat digunakan beberapa kriteria sebagai berikut:

Akaike Information Criterion (AIC): $-2 (\hat{J} / T) + 2 (k + T)$

Schwartz Information Criterion (SIC): $-2 (\hat{J} / T) + k \log (T) / T$

Hannan-Quinn Information Criterion (HQ): $-2 (\hat{J} / T) + 2k \log (\log(T)) / T$

dimana \hat{J} = Sum of Squared Residual,
 T = Jumlah Observasi,
 k = Parameter yang Diestimasi.

Penentuan *lag* optimal dengan menggunakan kriteria informasi tersebut diperoleh dengan memilih kriteria yang mempunyai nilai paling kecil di antara berbagai *lag* yang diajukan. Sangat dimungkinkan untuk membangun model VAR sebanyak n persamaan yang mengandung kelambanan sebanyak p *lag* dan n variabel ke dalam model VAR mengingat seluruh variabel yang relevan dan memiliki pengaruh ekonomi dapat dimasukkan kedalam persamaan model VAR. Karena itu *lag* optimal yang digunakan dalam model VAR bisa jadi sangat panjang (Sucahyo, 2008).

Dalam penelitian ini penulis akan menggunakan *Schwartz Information Criterion* (SIC) untuk menentukan panjang *lag* optimal. Model VAR akan diestimasi dengan tingkat *lag* yang berbeda-beda dan selanjutnya nilai SIC terkecil akan digunakan sebagai nilai *lag* yang optimal.

3.2.2.3. Uji Kausalitas

Tahapan selanjutnya dalam model VAR setelah menentukan panjang *lag* optimal adalah melakukan uji kausalitas Granger guna mengetahui apakah terdapat hubungan yang saling mempengaruhi antar variabel endogen sehingga spesifikasi model VAR menjadi tepat untuk digunakan mengingat sifatnya yang non struktural. Uji kausalitas Granger melihat pengaruh masa lalu terhadap kondisi sekarang sehingga uji ini memang tepat dipergunakan untuk data *time series*.

Dalam konsep kausalitas Granger, dua perangkat data *time series* yang linier berkaitan dengan variabel X dan Y diformulasikan dalam dua bentuk model regresi. Hasil-hasil regresi pada kedua bentuk model regresi linier tersebut akan menghasilkan empat kemungkinan mengenai nilai koefisien regresi masing-masing sebagai berikut:

1. $\sum_{i=1}^n \beta \neq 0$ dan $\sum_{i=1}^n \delta = 0$, terdapat kausalitas satu arah dari Y ke X.
2. $\sum_{i=1}^n \beta = 0$ dan $\sum_{i=1}^n \delta \neq 0$, terdapat kausalitas satu arah dari X ke Y.
3. $\sum_{i=1}^n \beta \neq 0$ dan $\sum_{i=1}^n \delta \neq 0$, terdapat kausalitas dua arah dari X ke Y.
4. $\sum_{i=1}^n \beta \neq 0$ dan $\sum_{i=1}^n \delta = 0$, tidak terdapat kausalitas antara X dan Y.

3.2.2.4. Uji Kointegrasi

Tahapan selanjutnya dalam estimasi VAR adalah melakukan uji kointegrasi guna mengetahui keberadaan hubungan jangka panjang antar variabel. Pada tahapan ini akan diketahui apakah model yang akan digunakan merupakan model VAR tingkat diferensiasi, jika tidak terdapat kointegrasi, atau model VECM, jika terdapat kointegrasi. Engle Granger menyatakan bahwa kombinasi linier dari dua atau lebih variabel *time series* yang tidak stasioner dapat menjadi stasioner. Jika kombinasi dari variabel-variabel yang tidak stasioner menghasilkan residual yang stasioner maka variabel tersebut dikatakan terkointegrasi atau memiliki hubungan jangka panjang antar variabel di dalam sistem VAR.

Mengingat penelitian ini akan menggunakan pendekatan VAR maka metode kointegrasi yang akan digunakan untuk memperoleh hubungan jangka panjang antar variabel dalam penelitian ini adalah metode kointegrasi Johansen. Metode kointegrasi Johansen untuk beberapa persamaan agak berbeda dengan metode Engle Granger yang lazim digunakan untuk satu persamaan saja.

3.2.2.5. Spesifikasi Model

Secara teoretis, variabel pertumbuhan ekonomi, perkembangan perbankan, pasar modal dan tingkat suku bunga mempunyai hubungan sehingga keempat variabel tersebut merupakan variabel endogen, yang kemudian dapat dianalisis dengan menggunakan metode VAR.

Adapun model yang akan digunakan dalam mengamati hubungan kausalitas antara pertumbuhan ekonomi, perkembangan perbankan, pasar modal dan tingkat suku bunga pada penelitian ini adalah mengacu pada model yang pernah dikembangkan oleh Rousseau dan Xiao (2007), Jennifer Lee (2005) serta Rousseau dan Watchel (1998) sebagai berikut:

$$\begin{aligned}
 X_{1,t} &= a_{1,0} + \sum_{i=1}^k a_{1,i} X_{1,t-i} + \sum_{i=1}^k b_{1,i} X_{2,t-i} + \sum_{i=1}^k c_{1,i} X_{3,t-i} + \sum_{i=1}^k d_{1,i} X_{4,t-i} + \mu_{1,t} \\
 X_{2,t} &= a_{2,0} + \sum_{i=1}^k a_{2,i} X_{1,t-i} + \sum_{i=1}^k b_{2,i} X_{2,t-i} + \sum_{i=1}^k c_{2,i} X_{3,t-i} + \sum_{i=1}^k d_{2,i} X_{4,t-i} + \mu_{2,t} \\
 X_{3,t} &= a_{3,0} + \sum_{i=1}^k a_{3,i} X_{1,t-i} + \sum_{i=1}^k b_{3,i} X_{2,t-i} + \sum_{i=1}^k c_{3,i} X_{3,t-i} + \sum_{i=1}^k d_{3,i} X_{4,t-i} + \mu_{3,t} \\
 X_{4,t} &= a_{4,0} + \sum_{i=1}^k a_{4,i} X_{1,t-i} + \sum_{i=1}^k b_{4,i} X_{2,t-i} + \sum_{i=1}^k c_{4,i} X_{3,t-i} + \sum_{i=1}^k d_{4,i} X_{4,t-i} + \mu_{4,t}
 \end{aligned}$$

dimana:

X_1 adalah Produk Domestik Bruto

X_2 adalah Volume Penyaluran Kredit oleh Perbankan

X_3 adalah Nilai Kapitalisasi Pasar Modal,

X_4 adalah Tingkat Suku Bunga SBI tenor 1 (satu) bulan.

Seluruh variabel akan dinyatakan dalam bentuk logaritma, kecuali variabel tingkat suku bunga SBI yang dinyatakan dalam prosentase.

3.2.2.6. Innovation Accounting

Model VAR menghasilkan *Impulse Response Function* (IRF) dan *Variance Decomposition* (VD) yang digunakan untuk mengamati struktur dinamis data *time series* dari sistem variabel yang dicerminkan melalui *innovation accounting*.

a. Impulse Response Function (IRF)

Respon terhadap adanya inovasi (*shock*) merupakan salah satu metode pada VAR yang digunakan untuk melihat respon variabel endogen terhadap pengaruh inovasi variabel endogen lain yang ada dalam model. Analisis IRF mampu melacak respon dari variabel endogen dalam model VAR akibat adanya suatu *shock* atau perubahan di dalam variabel gangguan (e), yang selanjutnya dapat melihat lamanya pengaruh dari *shock* suatu variabel terhadap variabel lain hingga pengaruhnya hilang dan kembali konvergen. Fungsi *impulse response* didapat melalui model VAR yang diubah menjadi vektor rata-rata bergerak (*vector moving average*) dimana koefisien merupakan respon terhadap adanya inovasi (Enders, 1995).

Adanya *shock* variabel gangguan (e_{1t}) pada persamaan variabel endogen ke-1 dalam model VAR, misalnya e_{1t} mengalami kenaikan sebesar satu standar deviasi, maka akan mempengaruhi variabel endogen ke-1 itu sendiri untuk saat ini maupun di masa yang akan datang. Mengingat variabel endogen tersebut juga muncul dalam persamaan variabel endogen yang lain, maka *shock* variabel gangguan e_{1t} tersebut juga akan menjalar ke variabel endogen lainnya melalui struktur dinamis VAR. Dengan demikian, *shock* atas suatu variabel dengan adanya informasi baru akan mempengaruhi variabel itu sendiri dan variabel lainnya dalam model.

b. Variance Decomposition (VD)

Analisis *Variance Decomposition* (VD) atau dikenal sebagai *forecast error variance decomposition* merupakan alat analisis pada model VAR yang akan memberikan informasi mengenai proporsi dari pergerakan pengaruh *shock* pada satu variabel terhadap variabel lainnya pada saat ini dan periode ke depannya.

VD menggambarkan relatif pentingnya setiap variabel dalam model VAR karena adanya *shock* atau seberapa kuat komposisi dari peranan variabel tertentu terhadap variabel lainnya. Berbeda dengan IRF, VD berguna untuk memprediksi kontribusi prosentase varian setiap variabel karena adanya perubahan variabel tertentu, sedangkan IRF digunakan untuk melacak dampak *shock* dari satu variabel endogen terhadap variabel lainnya dalam model VAR.

