

BAB III

METODOLOGI PENELITIAN

Pembahasan pada sub bab dari Bab III ini menguraikan metodologi penelitian yang dilakukan tahap demi tahap. Dalam tahap tersebut akan dimuat *flow chart* metodologi penelitian. Pendekatan data dilakukan dengan menggunakan *time series* yang dijelaskan dalam metodologi dengan menggunakan VAR.

3.1. Ruang Lingkup Penelitian

Penelitian ini akan mencoba melihat bagaimana pengaruh beberapa faktor internal dan eksternal terhadap kinerja keuangan khususnya likuiditas P.T. Bank muamalat Indonesia (BMI). Untuk melihat pengaruh perubahan kinerja keuangan sebagai variabel terikat akibat perubahan beberapa variabel bebas, maka model yang diajukan adalah model hubungan sebab akibat dengan menggunakan model regresi berganda. Periode pengamatan dimulai pada Januari 1997 sampai dengan Juli 2008.

3.2. Teknik Pengumpulan Data

Berdasarkan karakteristik data penelitian, data yang digunakan dalam penelitian ini memiliki beberapa kriteria, yaitu:

1. Menurut Cara Memperolehnya

Jenis data yang akan dipakai dalam penelitian ini adalah data sekunder, Data sekunder merupakan data-data yang diperoleh dalam bentuk yang sudah dikumpulkan dan diolah oleh pihak lain. Data sekunder meliputi data penelitian yang telah dipublikasikan, berbagai literatur yang berkaitan dengan topik penelitian seperti buku, majalah koran, dan internet, dan data yang berkaitan dengan variabel makro dan perbankan syariah.

2. Menurut Jenisnya

Penelitian ini berusaha untuk mengetahui pola hubungan variabel makro dan pertumbuhan perbankan syariah, sehingga bisa diketahui interaksi antara keduanya dan juga membantah *misperception* yang berkembang di sebagian masyarakat. Untuk itu, data yang diperlukan dalam penelitian ini

adalah data kuantitatif. Data kuantitatif merupakan data dalam bentuk angka. Dalam penelitian ini data yang digunakan adalah:

- a. Variabel ekonomi makro : Inflasi, suku bunga SBI, nilai tukar rupiah terhadap US\$.
- b. Perbankan Syariah : Net Performing Finance (NPF), Finance to Debt Ratio (FDR).

3. Menurut Waktu Perolehannya

Data dalam penelitian ini merupakan data berkala (*time series*), yaitu data yang dikumpulkan dari waktu ke waktu untuk memberikan gambaran tentang perkembangan suatu kegiatan selama periode spesifik yang diamati. Data tersebut diambil selama periode bulan (Januari 1997 sampai dengan Juli 2008) yang diperoleh dari :

1. Statistik Perbankan Syariah, Bank Indonesia periode Januari 1997 sampai dengan Juli 2008.
2. Indikator Moneter dan Keuangan Indonesia, Bank Indonesia periode Januari 1997 sampai dengan Juli 2008.
3. Situs Bank Indonesia (www.bi.go.id), Situs Bank Muamalat Indonesia (www.bmi.go.id) Badan Pusat Statistik (www.bps.go.id) dan CEIC.

Penulis mengambil data perbankan syariah dari Bank Indonesia karena Bank Indonesia adalah tempat dimana data secara keseluruhan perbankan syariah di Indonesia yang mana menggambarkan kondisi perbankan di Indonesia. Sedangkan data variabel makro, penulis mengambil Inflasi, suku bunga SBI, nilai tukar terhadap US\$, dimana variabel makro menggambarkan kondisi ekonomi Indonesia.

3.2. Pengujian Pra-Estimasi

Sebelum dilakukan estimasi dan analisa lebih lanjut maka dilakukan bentuk-bentuk pengujian pra-estimasi *Vector Autoregressive* (VAR) yaitu uji stasioneritas data, penentuan panjang lag yang optimum dan uji stabilitas. Salah satu bentuk jenis uji stasioner yang digunakan adalah Philip Perron. Sedangkan penentuan

panjang lag yang optimum akan menggunakan kriteria nilai yang paling minimum dari indikator *lag optimum* AIC dan SIC.

3.2.1. Uji Stasioneritas Philip Peron

Uji stasioneritas data untuk mengetahui apakah data-data *time series* yang akan dipakai untuk keperluan analisis memiliki sifat stasioner atau tidak. Data yang tidak stasioner pada analisa *time series* harus dihindari karena akan menimbulkan regresi palsu yang tidak valid.

Alternatif uji stasioneritas selain ADF test stasioneritas yang juga biasa digunakan adalah *test stasioneritas Philip Perron* (PP-Test). Metode ini memodifikasi tes statistik yang digunakan ADF test sedemikian rupa sehingga tidak perlu ada tambahan *lag* variabel dependen untuk menghilangkan pengaruh serial korelasi yang ada pada *error term*-nya.

Pengujian dengan PP-test menggunakan metode non-parametrik untuk mengendalikan korelasi serial dalam suatu *time series*. PP-test merupakan proses AR (1) yang dapat dinyatakan sebagai berikut:

$$\Delta Y_t = \alpha + \beta Y_{t-1} + \epsilon_t \quad (3.1)$$

Hipotesis nol-nya adalah $\beta = 1$. Jika $\beta = 1$, maka variabel stokhastik Y_t memiliki *unit root* atau *random walk*, artinya data *non stasioner*. Untuk melakukan uji stasioner, PP-test dibandingkan dengan nilai *Critical Value MacKinnon*. Jika nilai *absolute PP statistic* lebih besar daripada nilai *Critical value MacKinnon*, maka hipotesis nol diterima, artinya data *time series* bersifat tidak stasioner.

Kelebihan metode ini adalah PP-test mengasumsikan bahwa proses terbentuknya *error term* dari suatu variabel tidak mengikuti suatu fungsi tertentu. Hal ini berarti prosedur PP-test dapat secara luas diterapkan sepanjang tidak ada keharusan mengasumsikan bahwa *error term* memiliki bentuk fungsional tertentu. Namun demikian, PP-test ternyata masih tergantung pada *asymptotic theory* yang berarti bahwa semakin besar sampel yang digunakan, validitas PP-test dalam mendeteksi stasioneritas pada data *time series* menjadi lebih kuat.

3.2.2. Penentuan Panjang Optimum Lag

Setelah melakukan uji stasioneritas, langkah selanjutnya menentukan panjang lag yang optimal. Dalam VAR, penentuan panjang lag penting karena lag yang terlalu panjang akan mengurangi banyaknya *degree of freedom*, sedangkan terlalu pendek akan mengarah pada kesalahan spesifikasi (Gujarati, 2003: hal 849). Indikator yang umumnya digunakan adalah *Akaike Information Criterion* (AIC) dan *Schwarz Information Criterion* (SIC) dimana nilai yang terendah merupakan nilai yang lebih disukai. Dengan demikian, dalam menentukan panjang lag yang dipilih adalah nilai *Akaike* atau *Schwarz* terkecil. AIC dan SIC masing-masing ditunjukkan oleh persamaan sebagaimana dinyatakan Enders (1995) sebagai berikut:

$$AIC(k) = T \ln \frac{SSR(k)}{T} + 2n \quad (3.2)$$

$$SIC(k) = T \ln \frac{SSR(k)}{T} + n \ln(T) \quad (3.3)$$

Dimana:

T : jumlah observasi yang digunakan

k : panjang lag

SSR : *sum square residual*

n : jumlah parameter yang diestimasi

Selain mempertimbangkan nilai AIC dan SIC yang terendah dalam menentukan panjang lag, banyaknya variabel yang tidak signifikan menjadi pertimbangan dalam menentukan panjang lag yang optimum. Karena semakin panjang lag, semakin banyak kehilangan observasi, sehingga dibutuhkan observasi yang panjang.

3.3. Model Estimasi *Vector Autoregressive* (VAR)

VAR dikembangkan oleh Christopher Sims tahun 1980 (Gujarati, 2003). Pengembangan model VAR ini diawali dengan kritik Sims terhadap permasalahan indentifikasi pada model persamaan simultan dimana seseorang dimungkinkan untuk mengasumsikan adanya variabel *predetermined* pada suatu persamaan. Menurutnya dalam analisis keseimbangan umum semua variabel ekonomi akan mempengaruhi variabel-variabel yang lain. Ini mengimplikasikan bahwa semua variabel bersifat *endogen* dan bahwa satu-satunya persamaan yang dapat diestimasi adalah persamaan *reduced form* dimana variabel *eksogen* merupakan *lag* dari variabel-variabel *endogen*.

Pendekatan *structural model* persamaan simultan digunakan dalam teori ekonomi untuk menggambarkan hubungan antara beberapa variabel terkait. Model kemudian diestimasi dan digunakan untuk menguji teori ekonomi secara empiris. Namun demikian, teori ekonomi sering tidak mampu menjelaskan spesifikasi hubungan dinamis antar variabel tersebut. Hal ini memunculkan alternatif berupa model *non structural*, yaitu sebuah pendekatan untuk memodelkan hubungan antara beberapa variabel. Dalam hal ini digunakan analisis VAR.

VAR biasanya digunakan untuk menganalisis dampak dinamik variabel *random error* dalam sistem variabel serta untuk melakukan uji kausalitas. VAR tidak mementingkan persamaan. Pendekatan VAR merupakan permodelan setiap variabel endogen dalam sistem sebagai fungsi dari *lag* semua variabel endogen dalam sistem. Menurut Pyndick dan Rubinfeld (1991), terdapat dua hal khusus yang dibutuhkan dalam VAR, yaitu: (1) *set of variabel (endogenous dan eksogenous)* yang diyakini saling berinteraksi dan selanjutnya menjadi sebagai bagian dari sistem ekonomi yang mengusahakan model; (2) sejumlah besar *lag* yang dibutuhkan untuk menangkap sebagian besar pengaruh dari variabel-variabel satu sama lain.

Persamaan model *Vector Autoregressive* adalah sebagai berikut:

$$Y_t = \mu + \Gamma Y_{t-1} + \dots + \Gamma_p Y_{t-p} + \epsilon_t \quad (3.5)$$

Dimana: Y_t : matriks $n \times 1$ dari variabel *endogen*
 μ : matriks $m \times 1$ dari variabel *ekosgen*
 Γ : matriks koefisien yang diestimasi
 ϵ : matriks $n \times 1$ dari *error term*

Penelitian ini menggunakan enam variabel yang masing-masing bersifat *independent* atau *endogen* sesuai dengan karakteristik metode VAR, sehingga tidak ada variabel yang berkedudukan sebagai variabel *dependent* atau variabel terikat. Dengan demikian diantara variabel mempunyai kemungkinan adanya relasi satu sama lain. Maka terdapat enam model *Vector Autoregressive* dari enam variabel yang berkedudukan sama, seperti dijabarkan dibawah ini sebagai berikut:

- 1)
$$NPF_t = \beta_{10} + a_{11}(L)NPF_t + a_{12}(L)FDR_t + a_{13}(L)GDP_t + a_{14}(L)INFL_t + a_{15}(L)KURSt + a_{16}(L)SBI_t + \epsilon_t$$
- 2)
$$FDR_t = \beta_{20} + a_{21}(L)NPF_t + a_{22}(L)FDR_t + a_{23}(L)GDP_t + a_{24}(L)INFL_t + a_{25}(L)KURSt + a_{26}(L)SBI_t + \epsilon_t$$
- 3)
$$INFL_t = \beta_{40} + a_{41}(L)NPF_t + a_{42}(L)FDR_t + a_{43}(L)GDP_t + a_{44}(L)INFL_t + a_{45}(L)KURSt + a_{46}(L)SBI_t + \epsilon_t$$
- 4)
$$KURSt = \beta_{50} + a_{51}(L)NPF_t + a_{52}(L)FDR_t + a_{53}(L)GDP_t + a_{54}(L)INFL_t + a_{55}(L)KURSt + a_{56}(L)SBI_t + \epsilon_t$$
- 5)
$$SBI_t = \beta_{60} + a_{61}(L)NPF_t + a_{62}(L)FDR_t + a_{63}(L)GDP_t + a_{64}(L)INFL_t + a_{65}(L)KURSt + a_{66}(L)SBI_t + \epsilon_t$$

Keterangan :

NPF : Net Performing Finance
 FDR : Financing Deposit to Ratio
 INFL : inflasi
 KURS : nilai tukar Rupiah terhadap US \$
 SBI : tingkat suku bunga SBI
 L : *lag* atau periode
 ϵ : *error* atau penyimpangan

3.4. *Impulse Response Function (IRF)*

Impulse Response Function (IRF) adalah suatu prosedur yang dapat diterapkan untuk mengestimasi dan melihat pengaruh *shock* yang terjadi pada salah satu variabel dalam sistem VAR terhadap semua variabel *endogen* lainnya melalui struktur dinamis dalam sistem persamaan VAR. IRF juga mampu melacak pengaruh dari satu standar deviasi *shock* terhadap satu inovasi pada nilai sekarang dan nilai yang akan datang dari variabel *endogen*. *Shock* terhadap variabel ke-*i* langsung mempengaruhi variabel ke-*i* dan ditransmisikan ke semua variabel *endogen* melalui struktur dinamis dari VAR.

Pindyck dan Rubinfeld (1991) menyatakan bahwa *Impulse Response Function* adalah metode yang dapat digunakan untuk menentukan respons suatu variabel *endogen* terhadap *shock* variabel tertentu. Karena sebenarnya *shock* suatu variabel misalnya variabel ke-*i* tidak hanya berpengaruh terhadap variabel ke-*i* itu saja tetapi juga ditransmisikan kepada semua variabel *endogen* yang lainnya melalui struktur dinamik atau struktur *lag* dalam VAR. Jadi *Impulse Response Function* mengukur pengaruh *shock* pada suatu variabel kepada inovasi variabel *endogen* pada saat tersebut dan di masa yang akan datang.

Tingkat keseimbangan (*equilibrium*) dengan asumsi bahwa sistem persamaan stabil diperoleh melalui bentuk akhir dari sistem. Kita bisa melakukan langkah ini dengan pengulangan substitusi atau lebih sederhana dengan menggunakan *lag operator (L)*. Apabila dianggap ada injeksi *shock* pada sistem persamaan VAR (pers.1) di atas, maka akan terjadi fluktuasi respon. Selanjutnya respon akan bergerak kembali ke posisi seimbang (*equilibrium*). Suatu pergerakan yang berjalan dimana variabelnya kembali ke tingkat *equilibrium* disebut *Impulse Response Function VAR* (Green, 2003).

Bagaimana bekerjanya *Impulse Response Function* dapat diilustrasikan dalam model sederhana sebagai berikut:

$$Y_{1t} = a_{11}Y_{1t-1} - a_{12}Y_{2t-1} + \epsilon_{1t} \quad (3.6)$$

$$Y_{2t} = a_{21}Y_{1t-1} - a_{22}Y_{2t-1} + \epsilon_{2t} \quad (3.7)$$

Pada periode *t*, *shock* pada ϵ_{1t} mempunyai efek langsung dan penuh (*one for one*) terhadap Y_{1t} tetapi tidak mempunyai pengaruh terhadap Y_{2t} . Pada periode *t + 1*,

shock pada Y_{1t} tersebut akan berpengaruh terhadap variabel y_{1t+1} melalui persamaan 1 dan berpengaruh terhadap variabel y_{2t+1} melalui persamaan 2. Efek dari *shock* ϵ_{1t} tersebut akan terus bekerja pada periode $t-2$, kemudian $t+3$ dan seterusnya. Jadi efek suatu *shock* dalam VAR akan membentuk rantai reaksi sepanjang waktu terhadap semua variabel yang digunakan dalam model.

3.5. Variance Decomposition

Variance Decomposition merupakan salah satu metode untuk melihat dinamika sistem. *Variance Decomposition* melakukan dekomposisi terhadap variabel *endogen* ke dalam *shocks component* bagi variabel *endogen* dalam VAR. VAR biasa digunakan untuk melakukan peramalan dari data yang saling berhubungan untuk menganalisa dampak dari gangguan *random* terhadap sistem dari variabel. *Variance Decomposition* melakukan pemecahan terhadap varians dari *forecast error* dari setiap variabel ke dalam komponen yang dapat mempengaruhi variabel *endogen*.

Variance Decomposition memberikan pendekatan yang berbeda dengan IRF. Jika IRF dapat melacak sejauh mana pengaruh dari suatu *shock* yang terjadi pada *endogenous* VAR yang ada dalam sistem, maka *Variance Decomposition* memisahkan varian yang ada dalam variabel *endogen* menjadi komponen-komponen *shock* pada variabel *endogen* yang ada dalam VAR. Dengan demikian *Variance Decomposition* memberikan info tentang arti penting dari setiap *shocks* atau inovasi *random* terhadap variabel yang ada dalam VAR. Manakala *unrestricted* VAR adalah *overparameterized*, maka hal ini tidak berguna untuk *forecast* jangka pendek. Namun demikian, pengertian mengenai *properties* dari *forecast error* dapat membantu melihat hubungan timbal balik yang tidak tercakup diantara variabel-variabel dalam sistem.

3.6. Pengujian Asumsi Klasik

Untuk mendapatkan hasil estimasi yang baik dan memenuhi asumsi yang disyaratkan, maka dilakukan pengujian atas asumsi yang digunakan. Pengujian akan dilakukan pada tiga asumsi utama yaitu multikolinieritas (*multicollinearity*), heteroskedastisitas dan otokorelasi (*autocorrelation*).

3.6.1. Multikolinearitas

Metode estimasi yang menghasilkan pendugaan yang memiliki ciri BLUE mensyaratkan tidak adanya hubungan linier antara variabel bebas atau tidak ada multikolinieritas. Sebaliknya, jika diantara variabel bebas memiliki korelasi linier yang tinggi, maka model pendugaan tersebut dikatakan terdapat multikolinieritas yang serius.

Multikolinieritas yang serius akan berdampak pada:

- Variansi besar (dari taksiran OLS)
- Interval kepercayaan lebar (Variansi besar - SE besar - Interval kepercayaan lebar).
- Uji t (t rasio) tidak signifikan, nilai t statistik menjadi lebih kecil sehingga variabel bebas tersebut menjadi tidak signifikan pengaruhnya. Pengaruh lebih lanjutnya adalah bahwa koefisien regresi yang dihasilkan tidak mencerminkan nilai yang sebenarnya dimana sebagian koefisien cenderung *overestimate* dan yang lainnya *underestimate*.

Terkadang taksiran koefisien yang didapat akan mempunyai nilai yang tidak sesuai dengan substansi, sehingga dapat menyesatkan interpretasi. Pelanggaran terhadap masalah multikolinieritas akan menimbulkan masalah jika tujuan kita melakukan regresi adalah untuk menafsirkan nilai koefisien regresi. Namun jika hanya kita gunakan untuk peramalan maka multikolinieritas ini bisa diabaikan.

Beberapa cara bisa digunakan untuk mengidentifikasi ada tidaknya multikolinieritas pada model regresi yang dihasilkan diantaranya:

- (i) Jika hasil regresi menunjukkan nilai R^2 yang tinggi dan F statistik yang sangat signifikan (*goodness of fit* terpenuhi) namun sebagian besar variabel bebas tidak signifikan pengaruhnya (t hitung kecil),
- (ii) Terdapat korelasi yang tinggi ($r > 0.8$) antara satu pasang atau lebih variabel bebas dalam model,
- (iii) Mencari nilai *Condition Index*. *Condition Index* yang bernilai lebih dari 30 mengidentifikasi adanya multikolinieritas

- (iv) Mencari nilai *VIF* (*Variance Inflation Factor*) yang terdapat pada *print out* Eviews. Nilai $VIF > 10$ mengindikasikan adanya multikolinieritas dan harus ditanggulangi.

Proses identifikasi terhadap pelanggaran asumsi multikolinieritas ini dilakukan secara bertahap yaitu dari

- (i) Identifikasi apakah ada kecenderungan multikolinieritas,
- (ii) Menentukan tingkat keseriusan multikolinieritas tersebut dan
- (iii) Menentukan bentuk atau sifat alamiah dari multikolinieritas yang terjadi.

Dalam mengatasi masalah multikolinieritas yang terjadi pada model regresi, langkah umum yang ditempuh adalah dengan membuang salah satu variabel dari pasangan variabel yang mengalami multikolinieritas, mengubah bentuk model atau menambah data.

3.6.2. Heteroskedastisitas

Heteroskedastisitas adalah pelanggaran terhadap asumsi regresi yang menyatakan bahwa varian dari ε_i adalah konstan. Heteroskedastisitas ini muncul jika varians dari ε_i berubah-ubah pada setiap observasi data, yang biasanya muncul pada data observasi yang bersifat *cross section*. Pelanggaran asumsi heteroskedastisitas ini berdampak pada:

1. Akibat tidak konstannya variansi, maka salah satu dampak yang ditimbulkan adalah lebih besarnya variansi dari taksiran. Hal ini tentunya akan berpengaruh pada uji hipotesis yang dilakukan (Uji F dan Uji t). Karena kedua uji tersebut menggunakan besaran variansi taksiran. Akibatnya kedua uji hipotesis itu menjadi kurang akurat. Selain itu SE (standar error) taksiran juga akan lebih besar sehingga interval kepercayaan menjadi sangat besar.
2. Akibatnya, kesimpulan yang diambil dari persamaan regresi ini dapat menyesatkan.

Beberapa langkah bisa ditempuh dalam mengidentifikasi terjadinya pelanggaran asumsi Heteroskedastisitas. Pengujian yang bersifat

informal bisa dilakukan dengan memeriksa pola residual apakah varians dugaan berbeda dari satu observasi ke observasi lainnya. Langkahnya, misalnya dengan melihat polanya melalui plot grafik.

3.6.3. Autokorelasi

Autokorelasi adalah pelanggaran terhadap asumsi ε_i independent secara statistik atau terjadi korelasi antar ε_i dan ε_j pada observasi yang berbeda (biasanya berdekatan). Otokorelasi cenderung terjadi pada penggunaan data *time-series* dalam membuat model regresi karena gangguan-gangguan (*errors*) yang berkaitan dengan observasi pada periode waktu tertentu terbawa ke dalam periode waktu yang berikutnya. Otokorelasi tidak berpengaruh terhadap sifat *unbiased* hasil dugaan namun mempengaruhi efisiensinya.


Dampak yang timbul dari adanya otokorelasi, taksiran yang diperoleh dengan menggunakan OLS tidak lagi BLUE, namun masih tak bias dan konsisten. Oleh karenanya interval kepercayaan menjadi lebar, uji signifikansi menjadi kurang kuat, Akibatnya uji t dan uji F bila dilakukan hasilnya tidak akan baik (R^2 nya rendah)

Dalam menentukan ada atau tidaknya *Autocorrelation*, penulis menggunakan skala *Durbin Watson* (DW test), untuk dibandingkan antara t_{tabel} dan t_{hitung} . Nilai t_{hitung} diperoleh dari *output* regresi. Sedangkan nilai t_{tabel} diperoleh dari dari tabel *Durbin-Watson Statistic* berupa nilai d_L (d_{Lower}) dan D_U (d_{upper}).

Untuk uji DW ini dapat dibuat batasan daerah penolakan secara praktis, yaitu jika nilai d dekat dengan 2, maka tidak ada korelasi dalam suatu variabel. Untuk uji yang spesifik, aturannya adalah sebagai berikut (Nachrowi dan Usman, 2002, hal.144) :

1. Bila $d < d_L \rightarrow$ tolak H_0 , berarti ada korelasi yang positif atau kecenderungannya $\rho = 1$.
2. Bila $d_L \leq d \leq d_U \rightarrow$ tidak dapat mengambil keputusan apa-apa.
3. Bila $d_U < d < 4 - d_U \rightarrow$ tidak ada alasan untuk menolak H_0 . Artinya tidak ada korelasi positif maupun negatif.

4. Bila $4 - d_U \leq d \leq 4 - d_L \rightarrow$ tidak dapat mengambil kesimpulan apa-apa.
5. Bila $d > 4 - d_L \rightarrow$ tolak H_0 , berarti ada korelasi negatif.



Gambar 3.1. Skala Durbin-Watson d Statistic

3.7 Tahap-tahap Penelitian dan Alur Proses Analisis VAR

Sekaran (2000) menguraikan tahap-tahap dalam penelitian meliputi observasi mengumpulkan data awal, merumuskan masalah, membentuk kerangka teori, membuat hipotesis, mendesain riset ilmiah, mengumpulkan data, menganalisis dan menginterpretasikan serta yang terakhir adalah menyimpulkan hasil analisis apakah hipotesis sesuai dengan realitas atau substansi atau pertanyaan penelitian terjawab. Jika terjawab, hasil penelitian ditulis, lalu dipresentasikan selanjutnya dapat digunakan untuk membuat keputusan manajerial.

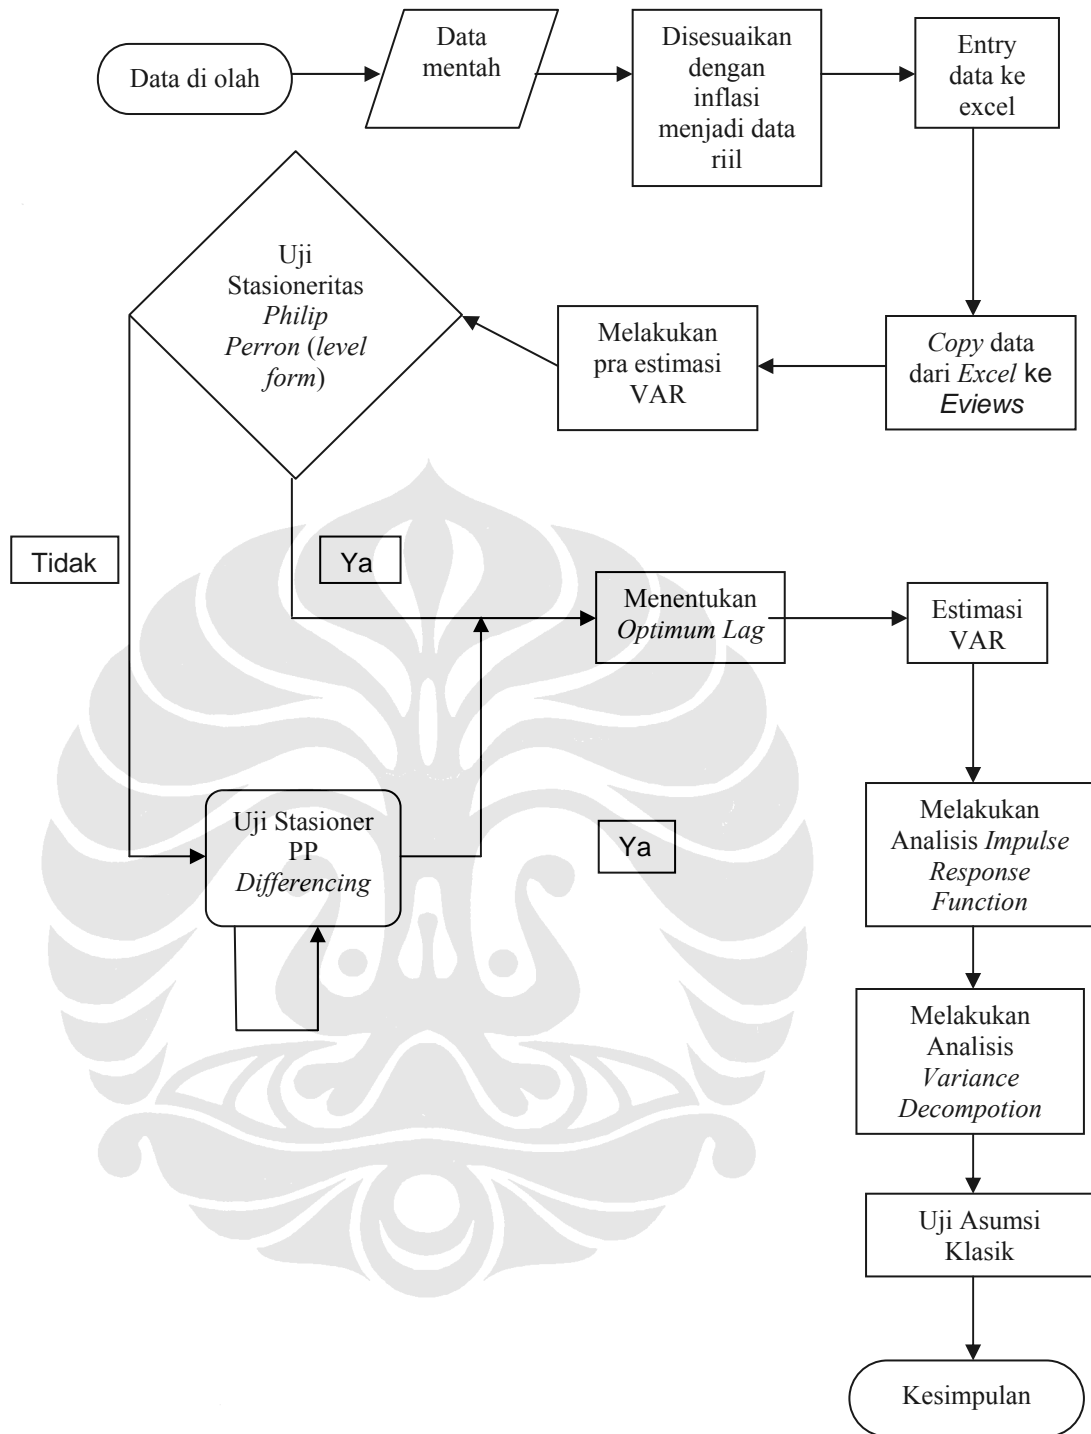
Tahap pertama adalah melakukan analisis data dengan menggunakan program *Eviews*. Data di-copy dari *Excel* ke *Eviews*. Proses selanjutnya adalah pra-estimasi VAR yaitu;

- (1) Uji Stasioneritas Philip Peron, Uji ini dilakukan untuk mengetahui apakah data yang akan digunakan untuk estimasi lebih lanjut bersifat stasioner atau tidak, karena data yang tidak stasioner akan menghasilkan analisis yang tidak valid. Pada pengujian tingkat level semua data tidak stasioner, oleh karena itu dilanjutkan tahapan *first differencing*, supaya dapat digunakan untuk estimasi lebih lanjut. Dari hasil pengujian tahap lanjut diketahui bahwa semua data bersifat stasioner pada level yang sama, kecuali GDP stasioner pada level 10%. Karena semua data telah stasioner pada 1st *diffrencing*, dengan demikian data yang digunakan telah memiliki sifat rata-rata konstan, seimbang, sehingga data tersebut dapat digunakan untuk tahap estimasi dan analisis VAR tingkat lanjut.

- (2) Penentuan Panjang Optimum *Lag*, pada analisis *time series*, *lag* memegang fungsi penting dan sensitif karena metode VAR bersifat dinamis, juga karena ada faktor masa lalu yang turut menjadi variabel. Dengan demikian metode VAR sangat sensitif terhadap jumlah *lag*. Pemilihan panjang *lag* yang tepat merupakan sesuatu hal yang kritis, karena disamping mempertimbangkan standar kriteria nilai yang paling rendah, juga mempertimbangkan keterbatasan *series* yang ada. Untuk menentukan panjang *lag*, dimulai dengan panjang *lag* terpanjang yang masuk akal atau panjang *lag* terpanjang yang fisibel dengan mempertimbangkan derajat kebebasan. Kriteria yang digunakan untuk menentukan optimum *lag* pada penelitian ini adalah kriteria AIC. Alasan digunakan indikator AIC sebagai penentu *lag* optimum yang paling baik dibandingkan dengan SIC adalah:
- a. AIC mengandung penalti yang meningkatkan fungsi dari sejumlah parameter yang diestimasi.
 - b. Penalti parameter-parameter bebas AIC sedikit lebih kuat daripada kriteria SIC (*Schwartz Information Criterion*).
 - c. Metode AIC berusaha untuk menemukan model yang terbaik yang mampu menjelaskan data dengan parameter-parameter bebas yang minimum.
 - d. Metode maksimum (*log likelihood*) pada AIC bisa digunakan untuk mengestimasi nilai-nilai parameter.
- (3) Estimasi VAR, metode VAR melibatkan faktor *lag* atau waktu untuk menilai hubungan diantara periode-periode yang telah lalu terhadap suatu variabel di masa sekarang. Berdasarkan hasil *output* terlihat ada hubungan periode yang lalu terhadap beberapa variabel. Semua variabel memiliki keberhubungan dengan periode-periode yang telah lalu.
- (4) Analisis *Impulse Response Function*, analisis ini berguna untuk mengetahui dampak dari suatu variabel apabila terjadi *shock* terhadap suatu variabel yang lain. Masing-masing variabel memberikan respon yang berbeda apabila terjadi *shock* pada variabel tertentu.

- (5) Analisis *Variance Decomposition*, analisis ini digunakan untuk mengetahui *shock* mana yang paling besar pengaruhnya terhadap NPF dan FDR.
- (6) Tahap terakhir adalah pengujian asumsi klasik, dimana data yang digunakan dan diolah sudah dipastikan tidak bermasalah dan tidak mempunyai penyakit autokorelasi, multikolinearitas dan heteroskedasticity.





Gambar 3.1. Flow Chart Analisis VAR