

BAB II

TINJAUAN PUSTAKA

2.1. Definisi Indeks Harga Saham Gabungan

Indeks Harga Saham Gabungan atau Composite Stock Price Index (IHSG) merupakan suatu nilai yang berfungsi untuk mengukur kinerja gabungan dari seluruh saham yang tercatat di suatu Bursa Efek Indonesia (Sunariyah, 2000). Menurut Samsul (2015:136) Indeks Harga Saham Gabungan (IHSG) merupakan indeks gabungan dari seluruh jenis saham yang tercatat di bursa efek. IHSG berubah setiap hari dikarenakan : (1) perubahan harga pasar setiap hari, (2) adanya saham tambahan. Jumlah tambahan saham yang beredar berasal dari emisi baru, yaitu datangnya emiten baru yang tercatat di bursa efek. Naiknya IHSG tidak berarti seluruh jenis saham mengalami kenaikan harga, tetapi hanya sebagian yang mengalami kenaikan sementara sebagian lagi mengalami penurunan. Turunnya IHSG dapat diartikan bahwa sebagian saham mengalami penurunan dan sebagian lagi mengalami kenaikan. Jika suatu jenis saham naik harganya ketika IHSG naik, berarti saham tersebut mempunyai korelasi positif dengan kenaikan IHSG. Sebaliknya, jika suatu jenis saham naik harganya ketika IHSG turun, berarti saham tersebut berkorelasi negatif dengan IHSG.

Menurut Hartono (2015:151), Indeks Harga Saham Gabungan (IHSG) di Bursa Efek Indonesia (BEI) meliputi pergerakan-pergerakan harga untuk saham biasa dan saham preferen. Indeks Harga Saham Gabungan (IHSG) dianggap sebagai dasar analisis yang paling sering dipakai oleh para analis untuk melihat kondisi saham di pasar modal Indonesia, karena IHSG memperhatikan dan mengamati secara intensif seluruh pergerakan saham yang terdapat di pasar,

(Fahmi, 2014).IHSG mulai dikenalkan pertama kali pada tanggal 1 April 1983 dengan menggunakan landasan dasar (*baseline*) tanggal 10 Agustus 1982.Jumlah saham yang tercatat pada waktu itu adalah sebanyak 13 saham. Rumus yang digunakan untuk menghitung IHSG adalah sebagai berikut :

$$IHSG_t = \frac{Nilai\ Pasar_t}{Nilai\ Dasar} \times 100$$

Dengan :

IHSG_t : Indeks Harga Saham Gabungan hari ke-t

Nilai Pasar : Rata-rata tertimbang nilai pasar (jumlah lembar tercatat dibursa dikalikan dengan harga pasar perlembaranya) dari saham umum dan saham preferen pada hari ke-t

Nilai Dasar : Sama dengan nilai dasar (harga pada waktu dasar)

2.2. Definisi Inflasi

Menurut Ebert dan Griffin (2003, hal. 19) dalam Murhadi (2012), inflasi merupakan suatu keadaan dimana jumlah barang yang beredar lebih sedikit dari jumlah permintaan sehingga akan mengakibatkan terjadinya kenaikan harga yang meluas dalam sistem perekonomian secara keseluruhan. Kenaikan inflasi yang signifikan akan mempengaruhi daya beli konsumen berupa penurunan kemampuan daya beli. Berdasarkan penyebabnya menurut Boediono (1988) inflasi terbagi menjadi 2 yaitu:

1. Demand inflation, yaitu inflasi yang timbul karena permintaan masyarakat akan berbagai barang terlalu kuat.
2. Cost inflation, yaitu inflasi yang timbul karena kenaikan biaya produksi.

Besarnya inflasi sangat tergantung pada besarnya kenaikan harga dan bobot barang dan jasa yang masuk dalam perhitungan inflasi tersebut. Dengan

demikian, sumbangan inflasi dari suatu jenis barang dan jasa atau kelompok barang dan jasa terhadap inflasi secara umum akan berbeda-beda. Laju inflasi dapat dihitung dengan cara sebagai berikut :

$$LI_t = \frac{IHK_t - IHK_{t-1}}{IHK_{t-1}} \times 100$$

Dengan :

1 : Laju Inflasi pada periode ke-t

IHK_t : Indeks Harga Konsumen periode ke-t

IHK_{t-1} : Indeks Harga Konsumen periode t-1

2.3. Pengaruh Inflasi terhadap Indeks Harga Saham

Menurut Samsul (2015:211), tingkat inflasi dapat berpengaruh positif maupun negatif tergantung derajat inflasi itu sendiri. Inflasi yang berlebihan dapat merugikan perekonomian secara keseluruhan, dalam arti banyak perusahaan yang akan mengalami kebangkrutan. Hal ini berarti, inflasi yang tinggi akan menurunkan harga saham dipasar, inflasi yang sangat rendah akan berakibat pertumbuhan ekonomi yang sangat lamban, yang pada akhirnya mengakibatkan harga saham bergerak secara lamban pula. Menurut Tandelilin (2010:343), peningkatan inflasi secara relatif merupakan sinyal negatif bagi pemodal dipasar modal. Tingginya tingkat inflasi erat kaitannya dengan keadaan ekonomi yang semakin buruk. Permintaan atas produk yang melebihi penawaran, mengakibatkan harga suatu barang cenderung naik. Tingginya tingkat inflasi mengakibatkan menurunnya daya beli masyarakat dan mengurangi pendapatan riil yang diterima oleh investor (Tandelilin, 2001).

Inflasi merupakan faktor utama yang mempengaruhi pasar saham (Patel, 2012). Inflasi akan cenderung meningkatkan biaya produksi dari perusahaan,

sehingga margin keuntungan dari perusahaan menjadi lebih rendah. Dampak lanjutan dari hal ini adalah menjadikan harga saham di bursa menjadi turun. Apabila hal ini dialami oleh banyak perusahaan di pasar modal maka kinerja IHSG juga akan menurun. Setiawan (2012) dan Sangmi (2013) dalam penelitiannya menunjukkan bahwa inflasi berpengaruh positif dan signifikan terhadap IHSG, sedangkan Appa (2014) dalam penelitiannya menunjukkan bahwa inflasi tidak berpengaruh signifikan terhadap IHSG.

2.4. Pentingnya Peramalan pada Indeks Harga Saham Gabungan

Peramalan memiliki peranan penting, karena dengan peramalan maka kita akan mengetahui apa yang akan terjadi di masa yang akan datang, sehingga dapat mengambil keputusan dan tindakan yang lebih baik (Nainggolan, 2008). Saat ini di tengah wabah Covid-19 yang menyebar diseluruh Negara, perkembangan harga saham mengalami penurunan drastis di beberapa Negara tak terkecuali di Indonesia yang mengalami kenaikan dan penurunan yang tak menentu sehingga berpengaruh besar terhadap perekonomian global. Dengan adanya kenaikan dan penurunan Harga Saham yang tak menentu, maka diperlukan adanya peramalan Indeks Harga Saham pada periode yang akan datang. Hal ini diperlukan sebagai gambaran untuk mengambil tindakan yang tepat sehingga nantinya para investor bisa mengambil keputusan dalam perubahan Harga Saham kedepannya. Oleh karena itu, dalam penelitian ini akan dibahas teori-teori tentang peramalan.

2.5. Model Peramalan Stasioner

Suatu runtun waktu dikatakan stasioner jika tidak terdapat kecenderungan peningkatan atau penurunan pada data tersebut dalam selang yang cukup panjang atau dengan kata lain fluktuasi data berada di sekitar rata-rata dan varians konstan

serta tidak tergantung pada waktu. Pengujian stasioneritas dari suatu data runtun waktu dapat dilakukan dengan beberapa cara berikut:

1. Pendeteksian ketidakstasioneran data dalam mean (rata-rata) dapat dilihat dengan menggunakan plot dari data asli, plot *fungsi autokorelasi* (ACF) dan plot *fungsi autokorelasi parsial* (PACF). Jika data mengandung komponen trend, data nonstasioner dalam mean dan plot ACF dan PACF akan meluruh secara perlahan.
2. Pendeteksian ketidakstasioneran dalam varians dapat menggunakan plot ACF dan PACF dari residual kuadrat. Dapat juga dilihat dengan melihat nilai variansinya.

Model runtun waktu stasioner diantaranya sebagai berikut

a. Model Autoregresif (AR)

Proses *autoregressive* (AR) menyatakan ketergantungan nilai pengamatan suatu deret waktu dengan deret waktu sebelumnya. Model *autoregressive* berorde p dilambangkan AR (p) atau ARIMA ($p,0,0$).

b. Model Moving Average(MA)

Model *moving average* orde q disingkat MA(q) atau ARIMA ($0,0,q$) menyatakan bahwa data untuk suatu deret waktu Z_t dipengaruhi oleh q buah galat sebelumnya.

c. Model Autoregressive Moving Average(ARMA)

Proses campuran AR dan MA merupakan perluasan dari kedua model tersebut yang dilambangkan ARMA (p,q) atau ARIMA ($p,0,q$) dimana p dan q masing-masing adalah orde untuk proses *autoregressive* dan *moving average*.

d. Model Autoregressive Integrated Moving Average (ARIMA)

Model ARIMA memiliki kelebihan dibandingkan dengan model AR (*Autoregressive*), MA (*Moving Average*), dan campuran (ARMA) yang hanya digunakan untuk data stasioner. Model ARIMA dapat digunakan untuk data non-stasioner dengan memberikan derajat pembedaan (d) pada deret datanya. Model ARIMA dengan orde (p,d,q) dengan p,d,q masing-masing adalah orde untuk proses *autoregressive*, pembedaan (*differencing*), dan *moving average*. Model ARIMA (p,d,q) dengan pembedaan satu kali dapat ditulis dalam bentuk:

$$Z_t = Z_{t-1} + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} - \phi_1 Z_{t-2} - \dots - \phi_p Z_{t-p-1} + \mu' + e_t - \dots - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.1)$$

Menurut Makridakis (1999:394) secara umum untuk tingkatan pembedaan yang lebih tinggi, persamaan ARIMA (p,d,q) dapat ditulis sebagai berikut:

$$(1 - B)^d (1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t \quad (2.2)$$

Dengan $(1 - B)^d$: proses pembedaan ke-d

ϕ_p : parameter model AR

θ_q : parameter model MA

e_t : nilai galat pada saat ke-t

Pada metode ARIMA digunakan operator *shift* mundur (*backshift operator*) yang dinotasikan dengan B yang berpengaruh menggeser data satu periode ke belakang.

2.6. Fungsi Transfer

Fungsi transfer merupakan salah satu metode peramalan yang digunakan pada data deret waktu yang terhubung dengan satu atau lebih deret waktu lainnya. Model fungsi transfer merupakan gabungan beberapa karakteristik dari model-model ARIMA univariat dan beberapa karakteristik analisis linier berganda (Makridakis, 1999:443).

Deret waktu X_t memberikan pengaruhnya kepada deret waktu Y_t melalui fungsi transfer, yang mendistribusikan dampak X_t melalui beberapa periode yang akan datang. Model yang dihasilkan disebut model fungsi transfer, yang menghubungkan deret *output* (Y_t), deret *input* (X_t), dan *noise* (N_t). Fungsi transfer digunakan untuk meramal nilai yang akan datang dari suatu deret *output* (Y_t) berdasarkan nilai yang lalu dari deret *output* tersebut dan deret-deret lain yang berhubungan (secara umum disebut deret *input* (X_t)).

Fungsi transfer memetakan deret *input* X_t ke deret *output* Y_t dimana X_t merupakan *input* yang terkendali. Tetapi pada kenyataannya *input* ini biasanya tidak terkendali. Upaya untuk mengatasi hal ini adalah melakukan pemutihan yaitu menghilangkan seluruh pola yang diketahui sehingga yang berpengaruh hanyalah galat acak. Untuk mempertahankan hubungan fungsional fungsi transfer maka transformasi pemutihan yang dilakukan terhadap deret *input* yang stasioner harus dilakukan juga terhadap deret *output* yang stasioner.

1. Bentuk Dasar Model Fungsi Transfer

Model fungsi transfer bivariat ditulis dalam dua bentuk umum. Bentuk pertama sebagai berikut (Makridakis, 1999:448-449).

$$Y_t = v(B)X_t + N_t \quad (2.3)$$

Dengan:

Y_t : deret *output*

X_t : deret *input*

N_t : pengaruh kombinasi seluruh faktor yang mempengaruhi Y_t (gangguan)

$v(B): (v_0 + v_1B + v_2B^2 + \dots + v_kB^k)$, v adalah respon impuls di mana k adalah orde fungsi transfer

Deret *input* dan *output* harus ditransformasikan dengan tepat (untuk mengatasi varians yang non stasioner), dibedakan (untuk nilai tengah yang non stasioner) dan mungkin perlu dihilangkan unsur musimannya. Jadi X_t dan Y_t (dan juga N_t) pada persamaan diatas harus diingat sebagai nilai yang telah ditransformasikan bukan dalam bentuk data mentah. Orde dari fungsi transfer k (menjadi orde tertinggi untuk proses pembedaan) dan ini kadang-kadang dapat lebih besar (dan oleh karena itu tidak terlalu dibatasi). Karena alasan-alasan ini, model fungsi transfer juga ditulis sebagai berikut:

$$y_t = \frac{\omega(B)}{\delta(B)} x_{t-b} + \frac{\theta(B)}{\phi(B)} a_t \quad (2.4)$$

Dengan:

$$\omega(B) = \omega_0 - \omega_1B - \omega_2B^2 - \dots - \omega_sB^s$$

$$\delta(B) = 1 - \delta_1B - \delta_2B^2 - \dots - \delta_rB^r$$

$$\theta(B) = 1 - \theta_1B - \theta_2B^2 - \dots - \theta_qB^q$$

$$\phi(B) = 1 - \phi_1B - \phi_2B^2 - \dots - \phi_pB^p$$

y_t : nilai Y_t yang telah ditransformasikan dan/atau dibedakan

x_t : nilai X_t yang telah ditransformasikan dan/atau dibedakan

a_t : nilai gangguan *random*

Dimana r, s, p, q dan b merupakan konstanta.

2. Identifikasi Bentuk Model

a. Mempersiapkan *Input* dan *Output* Deret Berkala

Tahap mempersiapkan deret *input* dan deret *output* adalah suatu tahapan untuk memastikan agar deret *input* dan *output* memenuhi asumsi-asumsi kestasioneran data. Konsep kestasioneran data dapat digambarkan sebagai berikut:

1) Stasioner dalam varians

Apabila plot deret berkala tidak memperlihatkan adanya perubahan varian yang jelas dari waktu ke waktu, maka dapat dikatakan deret data tersebut stasioner pada variansnya. Jika data tidak stasioner pada varians, maka harus dilakukan *transformasi*. Box-Cox (1964) memperkenalkan transformasi pangkat (*power transformations*) dalam menangani data yang tidak stasioner dalam varian (Aswi & Sukarna, 2006:91).

$$Z_t^{(\lambda)} = \frac{Z_t^{(\lambda)} - 1}{\lambda} \quad (2.5)$$

Dimana λ disebut sebagai parameter transformasi.

Beberapa penggunaan nilai λ serta kaitannya dengan transformasinya di tampilkan pada Tabel 2.1 berikut :

Tabel 2.1 Nilai-Nilai λ dengan Transformasinya

Nilai λ	-1	-0,5	0	0,5	1
Transformasi	$\frac{1}{Z_t}$	$\frac{1}{\sqrt{Z_t}}$	$\ln Z_t$	$\sqrt{Z_t}$	Z_t

2) Stasioner dalam rata-rata

Apabila suatu deret berkala diplot dan kemudian tidak terbukti adanya perubahan nilai tengah dari waktu ke waktu, maka dikatakan

bahwa deret data tersebut stasioner pada nilai tengahnya (*mean*). Jika deret berkala tidak stasioner terhadap nilai tengahnya, maka harus dilakukan pembedaan (*differencing*).

Pada dasarnya metode *differencing* adalah membentuk suatu data baru yang diperoleh dengan cara mengurangi nilai pengamatan pada waktu ke t dengan nilai pengamatan pada waktu sebelumnya. Secara umum, rumus *differencing* dapat dituliskan sebagai berikut (Aswi & Sukarna, 2006:87).

$$W_t = (1 - B)Z_t \quad (2.6)$$

Jadi, didalam pemodelan fungsi transfer perlu mentransformasikan dan/atau membedakan deret *input* dan deret *output*, terutama apabila terdapat ketidakstasioneran (Makridakis, 1999:451). Sehingga, deret *input* dan *output* yang digunakan selanjutnya adalah deret *input* yang stasioner (x_t) dan *output* yang stasioner (y_t).

b. Pemutihan Deret *Input*

Tahap pemutihan deret *input* merupakan proses transformasi deret yang berkorelasi menuju perilaku *white noise* yang tidak berkorelasi. Proses pemutihan ini menggunakan model ARIMA untuk deret *input*. Oleh karena itu, sebelum proses pemutihan, dibangun terlebih dahulu model ARIMA bagi x_t . Misalkan jika deret *input* x_t dimodelkan sebagai proses ARIMA $(p_x, 0, q_x)$, maka deret ini memiliki model (Makridakis, 1999: 453-454):

$$\phi_{p_x}(B)x_t = \theta_{q_x}(B)\alpha_t \quad (2.7)$$

Dimana $\phi_{p_x}(B)$ adalah operator *autoregresif*, $\theta_{q_x}(B)$ adalah operator *moving average* dan α_t adalah kesalahan *random*, yaitu *white*

noise. Dengan demikian deret *input* yang telah mengalami pemutihan (α_t) adalah:

$$\alpha_t = \frac{\phi_x(B)}{\theta_x(B)} x_t \quad (2.8)$$

Dengan:

α_t : deret *input* yang diputihkan

$\phi_x(B)$: operator *Autoregresif*

$\theta_x(B)$: operator *Moving Average*

x_t : deret *input* yang stasioner

c. Pemutihan Deret *Output*

Fungsi transfer merupakan proses pemetaan x_t terhadap y_t . Sehingga apabila diterapkan suatu proses pemutihan terhadap x_t , maka transformasi yang sama juga harus diterapkan pada y_t agar dapat mempertahankan integritas hubungan fungsional. Sehingga deret *output* yang telah ditransformasi (β_t) sebagai berikut (Makridakis 1999:454).

$$\beta_t = \frac{\phi_x(B)}{\theta_x(B)} y_t \quad (2.9)$$

Dengan:

β_t : deret *output* yang diputihkan

$\phi_x(B)$: operator *Autoregresif*

$\theta_x(B)$: operator *Moving Average*

y_t : deret *output* yang stasioner

d. Penghitungan Korelasi Silang dan Autokorelasi untuk Deret *Input* dan *Output* yang telah diputihkan

Pada pemodelan ARIMA variabel tunggal (*univariate* ARIMA), koefisien *autocorrelation* merupakan statistik kunci dalam membantu menetapkan model. Kenyataannya, terdapat perbedaan yang sangat kecil antara *crosscorrelation* dengan apa yang biasa disebut korelasi, karena fungsi transfer berhubungan dengan dua deret, dan yang terpisah (dalam bentuk yang telah diputihkan α dan β).

Fungsi korelasi antara α_t dan β_t pada lag ke- k adalah (Makridakis, 1999:455-456):

$$r_{\alpha\beta}(k) = \frac{c_{\alpha\beta}(k)}{s_{\alpha}s_{\beta}}, k = 0, \pm 1, \pm 2, \pm 3, \dots \quad (2.10)$$

Dengan:

$r_{\alpha\beta}(k)$: korelasi silang antara α_t dan β_t pada lag ke- k

$c_{\alpha\beta}(k)$: kovarian silang antara α_t dan β_t pada lag ke- k

s_{α} : simpangan baku deret α_t

s_{β} : simpangan baku deret β_t

e. Penaksiran langsung bobot respon impuls

Langkah selanjutnya setelah perhitungan korelasi silang adalah penaksiran nilai bobot respon impuls. Bobot respon impuls ini berguna untuk menghitung deret *noise*. Untuk penaksiran bobot respon impuls secara langsung rumusnya adalah sebagai berikut (Makridakis, 1999:459):

$$v_k = r_{\alpha\beta}(k) \frac{s_{\beta}}{s_{\alpha}} \quad (2.11)$$

Dengan:

$r_{\alpha\beta}(k)$: korelasi silang antara α_t dan β_t pada lag ke- k

s_{α} : simpangan baku deret α_t

S_β : simpangan baku deret β_t

f. Menentukan nilai (b, r, s)

Konstanta b , r , dan s ditentukan berdasarkan pola fungsi korelasi silang antara α_t dan β_t . Tiga prinsip petunjuk yang ditujukan untuk membantu dalam menentukan nilai yang tepat untuk (b, r, s) (Makridakis, 1999:460):

- 1) Sampai *lag* waktu ke b , korelasi silang tidak akan berbeda dari nol secara signifikan.
- 2) Untuk *stime lag* selanjutnya, korelasi silang tidak akan memperlihatkan adanya pola yang jelas.
- 3) Untuk *rtime lag* selanjutnya, korelasi silang akan memperlihatkan suatu pola yang jelas.

g. Identifikasi model deret gangguan

Taksiran bobot impuls yang diperlihatkan memungkinkan untuk menghitung taksiran awal komponen *noise* dari model fungsi transfer. Deret gangguan ini diperoleh dari model ARIMA *input* awal. Dapat dikatakan bahwa untuk mendapatkan deret *noise* stasioner diperoleh dari deret *input* yang stasioner.

$$\eta_t = y_t - v_0 x_t - v_1 x_{t-1} - v_2 x_{t-2} - \dots - v_g x_{t-g} \quad (2.12)$$

Sesudah menggunakan persamaan (2.12) untuk mengukur deret gangguan, kemudian nilai-nilai η_t dianalisis dengan cara ARIMA biasa untuk menentukan apakah terdapat model ARIMA $(p,0,q)$, untuk mendapatkan $\phi_\eta(B)\eta_t = \theta_\eta(B)a_t$

3. Penaksiran Parameter-Parameter Model

Penduga parameter fungsi transfer yaitu $\hat{\delta} = (\delta_1, \delta_2, \dots, \delta_r)$ dan $\hat{\omega} = (\omega_0, \omega_1, \dots, \omega_s)$ dicari dengan memanfaatkan persamaan berikut:

$$v_j = 0 \text{ untuk } j < b,$$

$$v_j = \delta_1 v_{j-1} + \dots + \delta_r v_{j-r} + \omega_0 \text{ untuk } j = b,$$

$$v_j = \delta_1 v_{j-1} + \dots + \delta_r v_{j-r} - \omega_{j-b} \text{ untuk } j = b+1, \dots, b+s,$$

$$v_j = \delta_1 v_{j-1} + \dots + \delta_r v_{j-r} \text{ untuk } j > b+s.$$

Taksiran model dilakukan untuk melihat pola korelasi silang antara α_t dan β_t .

4. Uji Diagnosa Model

Dalam diagnostik fungsi transfer, perlu dilakukan pengujian terhadap α_t dan a_t untuk menunjukkan bahwa asumsi terpenuhi. Analisis residual yang dilakukan untuk mendiagnosa model meliputi uji keberadaan korelasi silang dan autokorelasi.

a. Analisis nilai sisa: autokorelasi.

Analisis ini dilakukan untuk memeriksa apakah deret a_t adalah *white noise*. Untuk menentukan apakah gugus autokorelasi secara signifikan berbeda dengan nol digunakan uji Q Box-Pierce dengan hipotesis :

$$H_0 : \rho_a = 0 \text{ (tidak terdapat autokorelasi pada deret } a_t)$$

$$H_1 : \rho_a \neq 0 \text{ (terdapat autokorelasi pada deret } a_t)$$

Statistik uji :

$$\chi^2_{(af)} = (n - b - r - s) \sum_{k=1}^m r_{aa}^2(k) \quad (2.13)$$

Dengan:

n : jumlah pengamatan

m : lag terbesar yang diperhatikan

$r(k)$: autokorelasi untuk waktu tunda k

df : derajat bebas $= m - p - q$

Kriteria uji, terima H_0 jika $Q_{hit} < \chi^2_{\alpha, (m-p-q)}$ atau $P\text{-value} < \alpha$, artinya model fungsi transfer dapat dikatakan sudah memiliki deret sisa yang bersifat acak.

b. Analisis nilai sisa : korelasi silang

Pemeriksaan korelasi silang dilakukan untuk mengetahui apakah deret α_t independent terhadap deret α_t . Untuk mengujinya dapat digunakan uji Q Box-Pierce dengan hipotesis :

$H_0 : \rho_{\alpha\alpha} = 0$ (tidak terdapat korelasi silang antara α_t dan α_t)

$H_1 : \rho_{\alpha\alpha} \neq 0$ (terdapat korelasi silang antara α_t dan α_t)

Statistik uji :

$$\chi^2_{(df)} = (n - n^*) \sum_{k=1}^m r_{\alpha\alpha}^2(k) \quad (2.14)$$

Dengan:

n : jumlah pengamatan

m : lag terbesar yang diperhatikan

$r_{\alpha\alpha}(k)$: autokorelasi untuk lag k

n^* : $\max(s + b + p_\eta, p_x)$

p_x : jumlah parameter AR deret input (X_t)

Kriteria keputusan untuk menolak H_0 jika $Q_{hit} < \chi^2_{\alpha, (m-r-s)}$ atau $P\text{-value} < \alpha$, artinya barisan sisa a_t dan deret x_t yang sudah diputihkan (α_t) dinyatakan bebas. Jika pada saat pemeriksaan diagnostik model fungsi transfer hasilnya tidak mencukupi, maka harus dilakukan identifikasi ulang dari model fungsi transfer, serta mengulang tahapan-tahapan dalam membangun model sampai diperoleh model yang terbaik.

5. Peramalan Menggunakan Model Fungsi Transfer

Peramalan dihitung dengan menggunakan persamaan:

$$y_t = \frac{\omega_s(B)}{\delta_r(B)} x_{t-b} + \frac{\theta_q(B)}{\phi_p(B)} a_t \quad (2.15)$$

Dengan memasukkan nilai-nilai parameter fungsi transfer dan nilai deret *input* dan *output* yang didapat dari langkah-langkah sebelumnya.

2.7. Autoregressive Distributed Lag(ARDL)

Autoregressive Distributed Lag adalah Model regresi yang memasukkan nilai lag dari variabel bebas sebagai tambahan model dan memasukkan nilai lag dari variabel tak bebas sebagai salah satu variabel penjelas (Apriyanto,2014: 386). Model ini dapat membedakan respon jangka pendek dan jangka panjang dari variabel tak bebas terhadap satu unit perubahan dalam nilai variabel penjelas. Menurut Apriyanto (2014: 386) model ARDL dapat dituliskan sebagai berikut:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \beta_1 X_t + \dots + \beta_q X_{t-q} + \varepsilon_t \quad (2.16)$$

Dengan :

Y_t : Variabel Dependen

β_0 : Konstanta

ϕ_1 : koefisien variabel dependen

t-1: waktusebelumnya

β_1 : koefisien variabel independen

ε_t : variabel pengganggu(galat)

Dalam keadaan dimana Y_t dan X_t tidak stasioner namun berkointegrasi, maka dapat digunakan model *Error Correction Model* (ECM). Tetapi jika keadaan Y_t dan X_t tidak stasioner namun tidak berkointegrasi, dapat digunakan

model ARDL (Rosadi, 2011:192).

1) Uji Kestasioneran

Tahap pertama dalam melakukan penelitian menggunakan metode ARDL adalah memastikan apakah data stasioner di tingkat level, differensing 1 ataupun differensing 2, karena metode ARDL tidak cocok digunakan untuk data yang stasioner di differensing 2 (Serdawati, 2018; 26). Uji stasioner dapat menggunakan uji unit *root test* Dickey – Fuller. Pengujian stasioner menggunakan *Augmented Dickey Fuller Test* jika suatu data *time series* tidak stasioner pada orde nol, $I(0)$, maka stasioneritas data tersebut bisa dicari melalui orde berikutnya sehingga diperoleh tingkat stasioneritas pada orde ke-n. Uji ini memiliki persamaan:

$$Y_t = Y_{t-1} + \varepsilon_t \quad (2.17)$$

$$\Delta Y_t = \beta_1 + \delta Y_{t-1} + \varepsilon_t \quad (2.18)$$

$$\Delta Y_{t-1} = \beta_1 + \beta_2 t + \delta Y_{t-1} + \varepsilon_t \quad (2.19)$$

Dengan :

Y : Stasioner tingkat level

ΔY_t : *first difference* dari y

ΔY_{t-1} : *second difference* dari y

dengan hipotesis :

$H_0 : \delta = 0$ (terdapat *root test*, variabel Y tidak stasioner)

$H_0 : \delta \neq 0$ (tidak terdapat *root test*, variabel Y stasioner)

Statistik Uji : $t_\delta = \frac{\hat{\delta} - \delta_0}{se(\hat{\delta})}$

Jika t_δ lebih besar dari nilai kritis ADF maka terima hipotesis nol, yang

berarti terdapat *root test* (data tidak stasioner). Dan jika t_δ lebih kecil dari nilai kritis ADF maka tolak hipotesis nol, artinya tidak terdapat *root test* (data stasioner)

2) Penentuan Selang Optimum

Pemilihan selang optimal akan memanfaatkan kriteria informasi yang diperoleh dari *akaike Information Criteria* (AIC) (Serdawati, 2018: 28). AIC memberikan penalti atas tambahan variabel (termasuk variabel selang) yang mengurangi derajat kebebasan. Oleh karena itu, selang optimal akan ditemukan pada spesifikasi model yang memberikan nilai AIC paling minimum. Adapun rumus AIC adalah:

$$AIC = \log \left[\sum \frac{\varepsilon_t^2}{n} \right] + \frac{2k}{n} \quad (2.20)$$

Dengan :

$\sum \frac{\varepsilon_t^2}{n}$: Jumlah Residual Kuadrat

n : Ukuran Sampel

k : banyaknya variabel

3) Uji Kointegrasi

Uji kointegrasi merupakan salah satu metode untuk mengindikasikan kemungkinan adanya hubungan kesetimbangan (*equilibrium*) jangka panjang antara variabel dependen dan variabel independen (Malim, 2014: 41). Kointegrasi terjadi apabila variabel independen dan variabel dependen sama – sama merupakan *trend*, sehingga masing-masing tidak stasioner. Menurut Rosadi (2012: 201) untuk menguji adanya kointegrasi dapat dilakukan dengan menggunakan metode uji Engle Granger, yang langkah- langkahnya sebagai

berikut:

- a. Ujilah stasioneritas dalam variabel Y_t dan X_t (misalnya dengan menggunakan uji ADF). Orde unit roots ini harus sama dan bernilai d. jika hipotesis adanya unit root ditolak, maka hipotesis adanya kointegrasi antar variabel akan ditolak.
- b. Selanjutnya estimasi persamaan regresi antara Y_t dan X_t dan hitung nilai residual.
- c. Lakukan uji stasioneritas terhadap residual yang diperoleh pada regresi. Apabila hasil stasioneritas ditolak maka Y_t dan X_t berkointegrasi.

4) Menentukan Model Dinamis *Autoregressive*

Pada pembahasan model dinamis terdapat suatu model yang mempunyai persamaan yang sama dengan model dinamis autoregresif yaitu model Kyock. Adapun persamaan model dinamis autoregresif adalah sebagai berikut :

$$Y_t = \alpha_0 + \alpha_1 X_t + \alpha_2 Y_{t-1} + \varepsilon_t \quad (2.21)$$

Suatu model dikatakan bersifat autoregresif apabila variabel dependen dipengaruhi oleh variabel independen pada waktu sekarang, serta dipengaruhi juga oleh variabel dependen itu sendiri pada satu waktu yang lalu. Untuk melakukan estimasi parameter dari persamaan autoregresif ini, sering digunakan estimasi parameter menggunakan metode OLS (Ordinary Least Square). Namun, metode OLS (Ordinary Least Square) dinilai kurang tepat dalam melakukan estimasi parameter menggunakan persamaan dinamis autoregresif karena :

1. Adanya variabel-variabel bebas yang stokastik.
2. Adanya autokorelasi

Implikasi yang terjadi dalam model dinamis autoregresif adalah variabel

bebas Y_{t-1} jelas berkorelasi dengan variabel gangguan ε_t . Jika model regresi berkorelasi dengan kesalahan pengganggu maka pemerkira (estimator) dengan metode OLS (Ordinary Least Square) selain bias juga tak konsisten, walaupun sampel diperbesar sampai tak terhingga. Oleh karena itu apabila akan melakukan estimasi parameter menggunakan metode OLS (Ordinary Least Square) perlu dilakukan pengecekan autokorelasi lanjut pada model dinamis autoregressif menggunakan statistik h Durbin-Watson (Gujarati, 2003).

5) Pengujian Parameter Model Regresi

Setelah menduga hubungan antara variabel bebas dan terikat maka dilakukan uji parameter regresi untuk meyakinkan bahwa asumsi kelinearan terpenuhi. Dalam pengujian parameter regresi, ada dua pengujian yang harus dilakukan untuk mengetahui signifikansi dari variabel bebas yaitu:

1. Pengujian Serentak (Uji F)

Uji F dikenal dengan uji serentak digunakan untuk melihat pengaruh variabel bebas secara bersama-sama terhadap variabel terikat. Adapun statistik uji yang digunakan adalah F dengan rumus sebagai berikut:

$$F = \frac{R^2/(p-1)}{(1-R^2)(N-p)} \quad (2.22)$$

Dengan :

R^2 : Koefisien Determinasi

P : Banyaknya parameter total

N : banyaknya unit observasi

Kriteria pengujiannya yaitu:

Terima H_0 jika $F_{hit} \leq F_{\alpha,k,n-k-1}$ atau Tolak H_0 jika $F_{hit} > F_{\alpha,k,n-k-1}$

2. Pengujian Individu (Uji T)

Pengujian individu atau uji T digunakan untuk menguji pengaruh masing-masing variabel secara sendiri-sendiri terhadap variabel terikat. Statistik uji yang akan digunakan adalah uji t dengan rumus berikut:

$$t_{obs} = \frac{b_j}{s(b_j)} \quad (2.23)$$

Kriteria pengujiannya yaitu:

Terima H_0 jika $|t_{obs}| \leq t_{\frac{\alpha}{2}, n-k-1}$ atau Tolak H_0 jika $|t_{obs}| > t_{\frac{\alpha}{2}, n-k-1}$

6) Melakukan uji asumsi klasik

Model regresi yang diperoleh dari metode kuadrat terkecil merupakan model regresi yang menghasilkan Best, Linear, Unbiased estimator (BLUE). Kondisi ini akan terpenuhi jika dipenuhi beberapa asumsi, yang disebut asumsi klasik. Menurut Gujarati (1999: 153), beberapa asumsi klasik yang harus dipenuhi sebagai berikut:

1. Uji Normalitas

Uji normalitas bertujuan untuk menguji apakah dalam model regresi, variabel pengganggu atau residual memiliki distribusi normal dengan rata-rata nol dan varians σ^2 . Uji normalitas dapat dilakukan melalui uji ChiSquare, Kolmogorof Smirnov, Shapiro Wilk dan Jarque-Bera (JB). Dalam penelitian, uji normalitas menggunakan uji Jarque Bera.

Hipotesis pengujiannya adalah sebagai berikut:

H_0 : Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal

Statistik Uji:

$$JB = \frac{n}{6} (S^2 + \frac{(C-3)^2}{4})$$

Kriteria Uji : Tolak H_0 jika $JB > \chi^2_{(1-\alpha)n}$ atau $P\text{-value} < \alpha$

2. Uji Autokorelasi

Autokorelasi dalam model regresi kuadrat terkecil berarti komponen error berkorelasi berdasarkan urutan waktu (pada daret berkala), urutan ruang, atau korelasi pada dirinya sendiri. Autokorelasi secara umum dapat diuji dengan uji *Breusch – Godfrey* (BG) karena salah satu kelemahan uji Durbin–Watson adalah penguraian adanya autokorelasi hanya pada lag-1, tidak melihat autokorelasi pada lag-2, pada lag-3 dan seterusnya (Setiawan & Kusriani 2010; 146). Uji BG dilakukan dengan meregresikan variabel pengganggu menggunakan autoregressive model orde p :

$$\varepsilon_t = \rho_1 \varepsilon_{t-1} + \rho_2 \varepsilon_{t-2} + \dots + \rho_p \varepsilon_{t-p} + v_t \quad (2.24)$$

Dengan :

ε_t : residual atau error dari model regresi

ε_{t-1} : residual atau error sebelumnya

ρ : koefisien autokorelasi

v_t : error dari residual (ε_t)

Pengujian menggunakan statistik BG memiliki hipotesis sebagai berikut:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_p = 0$ (tidak terdapat autokorelasi)

$H_1 : \rho_p \neq 0$ (terdapat autokorelasi)

Stratistik Uji :

$$LM = TR^2$$

Kriteria Uji : Tolak H_0 jika nilai $LM > \chi^2_{(\alpha, df=k)}$ atau $P\text{-value} \leq \alpha$

3. Uji Homoskedastisitas

Pendugaan parameter regresi dengan metode kuadrat terkecil mengasumsikan ragam sisaan selalu konstan atau homogen. Kondisi ini disebut dengan homoskedastisitas. Homoskedastisitas berarti variansi dari error bersifat konstan atau memiliki varian yang sama.

$$Var(\varepsilon_i) = \sigma^2, i = 1, 2, \dots, n$$

Salah satu metode formal yang digunakan untuk mendeteksi homoskedastisitas pada penelitian ini menggunakan Breusch Pagan Godfrey (BPG). Adapun hipotesis yang akan diuji yaitu:

$H_0 : var \varepsilon_i = 0$ (terdapat homoskedastisitas)

$H_1 : var \varepsilon_i \neq 0$ (tidak terdapat homoskedastisitas)

Statistik Uji : $\phi = \frac{1}{2} JKR$

Kriteria pengujianya yaitu:

H_0 ditolak jika $\phi_{hitung} > \chi^2_{df \text{ tabel}}$

4. Multikolinearitas

Uji Multikolinieritas bertujuan untuk mengetahui ada tidaknya hubungan antara variabel independen atau variabel bebas. Pengujian ini dilakukan sebagai syarat digunakannya analisis berganda dimana regresi yang baik adalah regresi yang terbebas dari masalah multikolinearitas (Ghozali, 2009). Menurut Montgomery (2006; 118), salah satu cara mendeteksi gejala multikolinearitas adalah dengan menghitung nilai VIF (Variance Inflation Error) dengan persamaan sebagai berikut: $VIF = \frac{1}{1-R_j^2}$

Jika nilai VIF melebihi 10 maka hal tersebut menunjukkan bahwa gejala multikolinearitas terjadi antar variabel bebas.

7) Model Regresi Dinamis

Model regresi dinamis adalah model yang menggambarkan pergerakan variabel dependen yang dipengaruhi masa lalu. Waktu yang diperlukan oleh variabel bebas dalam mempengaruhi variabel terikat disebut beda kala atau lag (Supranto, 1995: 188). Ada 2 macam model regresi linear dinamis yaitu:

1. Model Distributed Lag

Menurut Gujarati (2012; 269) Distributed Lag Model adalah model regresi yang memasukkan tidak hanya variabel yang menjelaskan (X) saat ini, tapi juga masa lalu (lagged).

2. Model Dinamis *Autoregressive*

Autoregressive Model adalah model regresi yang memasukkan variabel bebas pada waktu t , serta dipengaruhi juga oleh variabel tak bebas itu sendiri pada waktu $t-1$. Bentuk modelnya adalah:

$$\hat{Y}_t = \delta + \phi_1 \hat{Y}_{t-1} + \phi_2 \hat{Y}_{t-2} + \dots + \phi_p \hat{Y}_{t-p} + \varepsilon_t \quad (2.25)$$

2.8. Ukuran Ketepatan Model

Untuk mengukur kesesuaian suatu metode peramalan tertentu untuk sekumpulan data digunakan suatu ukuran ketepatan model. Langkah ini dilakukan untuk memeriksa apakah model fungsi transfer dan model ARDL yang dipilih cukup cocok untuk data. Setelah melakukan peramalan, ketepatan peramalan dapat dicari dengan menghitung MAPE (*Mean Absolute Percentage Error*), dengan rumus sebagai berikut:

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{Y_t - Y_{t(h)}}{Y_t} \right|}{n} \times 100\% \quad (2.26)$$

Dengan Y_t adalah data aktual pada waktu ke- t dan $Y_{t(h)}$ adalah ramalan pada waktu ke- t . Semakin kecil nilai MAPE menunjukkan data hasil peramalan semakin

mendekati nilai aktual. Menurut Zhang (2015) kriteria nilai MAPE yang menyatakan model layak digunakan dapat dilihat pada tabel 2.2 sebagai berikut.

Tabel 2.2. Kriteria Nilai MAPE

MAPE	Kekuatan Peramalan
<10%	Peramalan yang sangat akurat
10%-20%	Peramalan yang baik
20%-50%	Peramalan yang cukup baik
>50%	Peramalan yang tidak akurat

Berdasarkan tabel 2.2 di atas dapat dilihat bahwa semakin kecil persentase nilai MAPE, maka akan semakin akurat peramalan suatu data.

