

## BAB 2

### TINJAUAN PUSTAKA

Bab ini berisi uraian mengenai metode Peramalan dan inflasi, tahapan dalam setiap model yang meliputi model ARIMA dan metode Penggabungan Ensembel untuk mendapatkan model ARIMA terbaik.

#### 2.1. Metode Peramalan

Peramalan atau *forecasting* merupakan prediksi nilai-nilai sebuah variabel berdasarkan kepada nilai yang diketahui dari variabel tersebut atau variabel yang berhubungan. Meramal juga dapat didasarkan pada keahlian judgment yang didasarkan pada data historis dan pengalaman (Makridakis, 1988).

Situasi peramalan sangat beragam dalam horison waktu peramalan. Faktor yang menentukan hasil sebenarnya terdapat pada tipe pola data dan berbagai aspek lainnya. Untuk menghadapi penggunaan yang luas maka beberapa teknik telah dikembangkan. Peramalan pada umumnya dapat dibedakan dari berbagai segi tergantung dari cara melihatnya. Jangka waktu peramalan dapat dikelompokkan menjadi tiga kategori, yaitu peramalan jangka pendek, peramalan jangka menengah dan peramalan jangka panjang (Heizer dan Render, 1996).

#### 2.2. Inflasi

Inflasi merupakan salah satu fenomena ekonomi makro yang sering terjadi dalam sistem perekonomian. Pengalaman di berbagai negara yang mengalami inflasi menunjukkan bahwa penyebab utama inflasi adalah terlalu banyaknya jumlah uang beredar, upah, paceklik dan defisit anggaran. Dari beberapa faktor penyebab inflasi tersebut ada beberapa pendapat ahli ekonomi tentang inflasi, di antaranya adalah Teori Keynes yang berpendapat bahwa inflasi terjadi karena adanya kenaikan pengeluaran di atas nilai output pada harga tertentu. Sedangkan ada yang berpendapat bahwa inflasi terjadi karena adanya kenaikan harga secara terus menerus dari barang-barang atau jasa secara umum. Inflasi yang sering terjadi di Indonesia disebabkan adanya *cost push inflation* yaitu kenaikan harga yang disertai dengan turunya produksi (Hermanto, 1991).

Masalah inflasi ini menjadi menarik untuk diteliti karena dampak yang ditimbulkannya antara lain:

a. Inflasi memperburuk distribusi pendapatan

Adanya kenaikan harga secara terus-menerus yang tidak diimbangi dengan kenaikan pendapatan masyarakat menyebabkan masyarakat tidak dapat memenuhi kebutuhan hidup ekonominya. Sehingga inflasi dapat memperburuk distribusi pendapatan.

b. Inflasi menyebabkan berkurangnya tabungan domestik

Kenaikan harga secara terus-menerus menyebabkan masyarakat sulit untuk menyimpan uang di bank, sehingga tabungan domestik menjadi berkurang. Padahal tabungan domestik ini merupakan sumber dana investasi.

c. Inflasi menyebabkan defisit anggaran dan meningkatkan hutang luar negeri

Sektor swasta yang belum kuat menyebabkan peran anggaran pemerintah sangat menentukan dalam investasi masyarakat. Selama masa pemerintahan orde lama, defisit anggaran belanja pemerintah ini dibiayai dengan pencetakan uang oleh otoritas moneter sehingga menimbulkan tekanan inflasi yang kuat.

d. Inflasi dapat menimbulkan ketidakstabilan politik

Inflasi yang tinggi pada tahun 1998 yang disertai dengan krisis ekonomi dapat menimbulkan situasi politik menjadi panas atau menimbulkan ketidakstabilan politik (Hermanto, 1991).

Adapun kebalikan dari Inflasi yaitu Deflasi dimana ditandai dengan suatu periode yang mana harga-harga secara umum jatuh dan nilai uang bertambah. Nilai deflasi dapat dituliskan dengan angka negatif, misalnya pada Inflasi Balikpapan bernilai -0,10. Faktor terjadinya deflasi karena menurunnya jumlah uang yang beredar dalam masyarakat. Hal ini terjadi karena banyak orang yang tergiur dengan bunga bank yang tinggi dan masyarakat menabung beramai-ramai uangnya ke bank sehingga jumlah uang yang beredar dalam masyarakat berkurang.

### 2.3 Uji Stasioneritas Data

Stasioneritas merupakan suatu kondisi data *time series* yang jika rata-rata, varian dan covarian dari peubah-peubah tersebut seluruhnya tidak dipengaruhi oleh waktu. Analisis ARIMA (*Autoregressive Integrated Moving Average*) umumnya mengasumsikan bahwa proses umum dari *time series* adalah stasioner. Tujuan dari proses stasioner adalah rata-rata, varian dan autokorelasi dari *time series* nya konstan terhadap waktu. Untuk mengecek kestasioneran data dapat dilakukan dengan uji ADF (*Augmented Dickey Fuller*). Uji ADF bertujuan untuk mengetahui apakah data masih mengandung unit akar atau tidak. Jika data masih mengandung unit akar maka disimpulkan data tersebut belum stasioner. Sebaliknya apabila data sudah tidak mengandung unit akar maka data sudah stasioner. Bila data sudah stasioner maka data tersebut sudah layak digunakan dalam langkah atau proses perhitungan selanjutnya. Namun apabila data *time series* tidak stasioner maka dapat dilakukan modifikasi data menggunakan *differencing* dan transformasi untuk menghasilkan data yang stasioner. Untuk mengetahui apakah data sudah stasioner dapat dilakukan dengan membandingkan nilai ADF *test* dengan nilai P-value (0.05). Jika nilai ADF *test* lebih kecil dari P-value atau memiliki probabilitas lebih kecil dari 5% maka data tersebut sudah tidak mengandung unit akar dengan kata lain sudah stasioner. Namun sebaliknya, jika nilai ADF *test* lebih besar dari 5% maka data tersebut mengandung unit akar dengan kata lain tidak stasioner dan harus dilakukan proses *differencing* dan transformasi untuk menghasilkan data yang stasioner (Akbar, 2016).

*Time series* dikatakan stasioner rata-rata jika bernilai konstan untuk semua  $t$ . Jika data tidak stasioner terhadap waktu, dapat dilakukan modifikasi data dengan *differencing*.  $Y_t$  merupakan *original data time series* setelah dilakukan *differencing* yang didefinisikan dengan:

$$y_t = Z_t - Z_{t-1} \quad (2.1)$$

Penulisan lain untuk *differencing* disebut operator *backshift* yang didefinisikan dengan  $B^i Z_t = Z_{t-i}$  sehingga menjadi:

$$\begin{aligned} y_t &= (1 - B) Z_t = \nabla Z_t \\ y_t &= Z_t - B Z_t = (1 - B) Z_t \end{aligned} \quad (2.2)$$

dengan  $\nabla = (1 - B)$ . Jika *differencing* pertama tidak menghasilkan time series yang stasioner maka dapat dilakukan *differencing* kedua yaitu:

$$y_t = \nabla^2 Z_t = \nabla (\nabla Z_t) = (1 - B)^2 Z_t = (1 - 2B + B^2) Z_t = Z_t - 2Z_{t-1} + Z_{t-2} \quad (\text{Montgomery, 2008})$$

Data *time series* dikatakan stasioner dalam varian jika mendapatkan varian yang konstan. Apabila suatu data tidak stasioner terhadap varian maka untuk mengatasi ketidakstasioneran dalam varian dapat dilakukan dengan transformasi data. Transformasi data digunakan untuk menstabilkan atau mendapatkan varian yang konstan. Transformasi ini disebut transformasi *Box-Cox* yang didefinisikan oleh:

$$Z_t = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.3)$$

dengan  $\lambda$  adalah parameter transformasi *Box-Cox* dan  $Z_t$  adalah nilai time series pada waktu ke- $t$ . nilai  $\lambda$  biasanya bernilai antara -5 sampe 5. Nilai  $\lambda$  menentukan kekuatan relative dari sebuah transformasi.

#### 2.4 Autokorelasi (ACF)

Autokorelasi digunakan pada data *time series* untuk mengukur bagaimana nilai saling berhubungan dengan nilai masa depan ( $Z_{t+1}, Z_{t+2}, \dots$ ) atau sama untuk nilai masa lalu ( $Z_{t-1}, Z_{t-2}, \dots$ ). Bentuk autokorelasi pada *time series* dapat digunakan untuk mengidentifikasi model ARIMA.


Koefisien autokorelasi di lag  $k$  adalah:

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, \quad k = 0, 1, 2, \dots$$

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (2.4)$$

Dengan  $\rho_0 = 1$  dan kumpulan dari nilai  $\rho_k, k = 1, 2, \dots$  disebut fungsi autokorelasi (ACF).

Cara membaca plot ACF yaitu pada orde yang dilihat dari lag yang memotong garis batas interval. Berikut ini adalah contoh membaca plot ACF untuk orde MA ( $q$ ).



Gambar 2.1 Grafik ACF Data Inflasi Nasional

Berdasarkan Gambar 2.1 dapat dilihat bahwa nilai ACF signifikan pada lag 1 dan 3 maka orde untuk *moving average* ( $q$ ) adalah 0, 1 dan 3.

## 2.5 Autokorelasi Parsial (PACF)

Autokorelasi Parsial merupakan hubungan antara  $Z_t$  dan  $Z_{t+k}$  dengan mengabaikan ketidakbebasan  $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ . Autokorelasi parsial diperoleh dari persamaan regresi yaitu:

$$\phi_{k+1,k+1} = \frac{\rho_{k+1} \sum_{j=1}^k \phi_{kj} \rho_{k+1-j}}{1 - \sum_{j=1}^k \phi_{kj} \rho_j} \quad (2.5)$$

dan


$$\phi_{k+1,j} = \phi_{kj} - \phi_{k+1,k+1} \phi_{k,k+1-j}, \quad j = 1, \dots, k \quad (2.6)$$

dengan,

$\phi_{kj}$  : koefisien regresi,  $j: 1, 2, 3, \dots, k$

$a_{t+k}$  : nilai *error* dengan rata-rata nol

Cara membaca plot PACF yaitu pada orde yang dilihat dari lag yang memotong garis batas interval. Berikut ini adalah contoh membaca plot PACF untuk orde AR ( $p$ ).



Gambar 2.2 Grafik PACF Data Inflasi Nasional

Berdasarkan Gambar 2.2 dapat dilihat bahwa nilai PACF signifikan pada lag 1 dan 2 atau *cut off lag* 1 dan 2 maka orde untuk *autoregressive* ( $p$ ) adalah 0, 1 dan 2.

## 2.6 Model ARIMA

Model ARIMA merupakan gabungan antara model AR (*Autoregressive*) dan model MA (*Moving Average*). Model ARIMA dilakukan untuk mengetahui peramalan sejumlah variabel dengan sederhana dan akurat karena hanya membutuhkan data variabel yang akan diramal. Pada penelitian ini akan dijelaskan mengenai model AR, model MA dan model ARMA (Dhartikasari, 2011).

### 2.6.1 Model AR (*Autoregressive*)

*Autoregressive* adalah suatu bentuk regresi tetapi bukan untuk menghubungkan variabel tak bebas, melainkan menghubungkan nilai-nilai sebelumnya pada selang waktu yang bermacam-macam. Jadi suatu model *Autoregressive* akan menyatakan suatu ramalan sebagai fungsi nilai-nilai sebelumnya dari *time series* tertentu (Makridakis, 1995).

Model *Autoregressive* (AR) dengan orde  $p$  dinotasikan dengan AR( $p$ ). bentuk umum model AR( $p$ ) adalah sebagai berikut:

$$Z_t = C + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t \quad (2.7)$$

dengan,

$Z_t$  : nilai variabel pada waktu ke- $t$

$Z_{t-1}, \dots, \phi_p Z_{t-p}$  : nilai dari *time series* pada periode waktu sebelumnya

$\phi_i$  : koefisien regresi,  $i: 1, 2, 3, \dots, p$

$a_t$  : nilai *error* pada waktu ke- $t$

$C$  : konstanta

$p$  : orde AR

Persamaan (2.1) dapat ditulis menggunakan operator  $B$  (*backshift*) menjadi:

$$(1 - \phi_1 B + \dots + \phi_p B^p) Z_t = a_t \quad (2.8)$$

$$= (B)$$

$$\phi_p(B) Z_t = a_t \quad (2.9)$$

Terdapat dua kasus yang paling sering dihadapi adalah apabila  $p = 1$  dan  $p = 2$ , yaitu AR(1) dan AR(2) atau ARIMA(1,0,0) atau ARIMA(2,0,0).

- *Autoregressive* orde 1, AR(1) atau ARIMA(1,0,0).

Suatu proses  $\{Z_t\}$  dikatakan mengikuti model *autoregressive* orde 1 jika memenuhi:

$$(1 - \phi_1 B) Z_t = C + a_t \quad (2.10)$$

atau

$$Z_t = C + \phi_1 Z_{t-1} + a_t \quad (2.11)$$

- *Autoregressive* orde 2, AR(2) atau ARIMA(2,0,0).

Suatu proses  $\{Z_t\}$  dikatakan mengikuti model *autoregressive* orde 2 jika memenuhi:

$$(1 - \phi_1 B - \phi_2 B^2) Z_t = C + a_t \quad (2.12)$$

atau

$$Z_t = C + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + a_t \quad (2.13)$$

(Montgomery, 2008)

## 2.6.2 Model MA (*Moving Average*)

MA atau *Moving Average* adalah salah satu metode peramalan yang menghitung rata-rata suatu nilai runtun waktu dan kemudian digunakan untuk memperkirakan kondisi atau nilai pada masa yang akan datang dengan menggunakan kumpulan data-data masa lalu (data-data historis).

Model *Moving Average* (MA) dengan orde  $q$  dinotasikan dengan  $MA(q)$ . Bentuk umum model  $MA(q)$  adalah sebagai berikut:

$$Z_t = a_t - \phi_1 a_{t-1} - \dots - \phi_q a_{t-q} \quad (2.14)$$

dengan,

$Z_t$  : nilai variabel pada waktu ke- $t$

$a_t, a_{t-1}, \dots, a_{t-q}$  : nilai-nilai dari *error* pada periode waktu sebelumnya

$\phi_q$  : parameter moving average orde  $q$  ( $MA(q)$ )

$a_t$  : nilai *error* pada waktu ke- $t$

Persamaan (2.7) dapat ditulis menggunakan operator  $B$  (*backshift*) menjadi:

$$Z_t = \mu + \underbrace{(1 - \theta_1 B - \dots - \theta_q B)}_{= (B)} a_t \quad (2.15)$$

sehingga,

$$Z_t = \theta_q (B) a_t \quad (2.16)$$

Dalam praktik, dua kasus yang paling sering dihadapi adalah apabila  $q = 1$  dan  $q = 2$ , yaitu  $MA(1)$  dan  $MA(2)$  atau  $ARIMA(0,0,1)$  atau  $ARIMA(0,0,2)$ .

- *Moving Average* orde 1,  $MA(1)$  atau  $ARIMA(0,0,1)$ .

Suatu proses  $\{Z_t\}$  dikatakan mengikuti model *moving average* orde 1 jika memenuhi:

$$\begin{aligned} (1 - \theta_1 B) Z_t &= a_t \\ Z_t &= (1 - \theta_1 B) a_t \end{aligned} \quad (2.17)$$

- *Moving Average* orde 2,  $MA(2)$  atau  $ARIMA(0,0,2)$ .

Suatu proses  $\{Z_t\}$  dikatakan mengikuti model *moving average* orde 2 jika memenuhi:

$$\begin{aligned} (1 - \phi_1 B - \theta_2 B^2) Z_t &= a_t \\ Z_t &= (1 - \theta_1 B - \theta_2 B^2) a_t \end{aligned} \quad (2.18)$$

(Montgomery, 2008)

### 2.6.3. Model ARMA (*Autoregressive Moving Average*)

Model ARMA (*Autoregressive Moving Average*) atau sering disebut model campuran. Model ARMA merupakan model ARIMA tanpa proses pembedaan atau ARIMA( $p,0,q$ ).

Secara matematis, model ARMA ( $p,q$ ) ditulis sebagai berikut:

$$\begin{aligned} Z_t &= C + \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \\ Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} &= a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \\ Z_t - \phi_1 B Z_{t-1} - \dots - \phi_p B^p Z_{t-p} &= a_t - \theta_1 B a_{t-1} - \dots - \theta_q B^q a_{t-q} \\ (1 - \phi_1 B - \dots - \phi_p B^p) Z_t &= (1 - \theta_1 B - \dots - \theta_q B^q) a_t \\ \phi_p B Z_t &= \theta_q(B) a_t \end{aligned} \tag{2.19}$$

(Montgomery, 2008)

### 2.6.4. Model ARIMA (*Autoregressive Integrated Moving Average*)

Model ARIMA (*Autoregressive Integrated Moving Average*) merupakan model ARMA ( $p,q$ ) nonstasioner. Pada model ARMA ( $p,q$ ) nonstasioner, proses pembedaan dilakukan agar stasioner. Setelah model ARMA mengalami proses pembedaan atau *differencing* sebanyak  $d$  kali hingga stasioner, maka model ARMA ( $p,q$ ) menjadi model ARIMA ( $p,d,q$ ).

Secara matematis, model ARIMA ( $p,d,q$ ) ditulis sebagai berikut:

$$\phi_p(B)(1-B)^d Z_t = \phi_0 + \theta_q(B) a_t \tag{2.20}$$

Persamaan (2.20) dapat ditulis menggunakan operator  $B$  (*backshift*) menjadi:

$$\begin{aligned} 1 - B^d \quad 1 - \phi_1 B - \dots - \phi_p B^p \quad Z_t \\ = (1 + \phi_1 B + \dots + \phi_p B^p) Z_t \end{aligned}$$

sehingga diperoleh:

$$\begin{aligned} 1 - B^d \quad Z_t - \theta_1 Z_{t-1} + \dots + \theta_q Z_{t-q} \\ = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \end{aligned}$$

dengan,

$Z_t$  : data observasi ke- $t$

$B$  : operator *backshift*

$1 - B^d Z_t$  : *time series* yang stasioner pada pembedaan ke- $d$

$a_t$  : nilai *error* pada waktu ke- $t$

- $p$  : orde AR  
 $d$  : orde pembedaan (*integrated*)  
 $q$  : orde MA

Apabila pembedaan pertama dilakukan terhadap model agar menjadi stasioner, maka model menjadi ARIMA (1,1,1) didefinisikan sebagai berikut:

$$(1 - B)(1 - \phi_1 B)Z_t = (1 - \theta_1 B)a_t$$

## 2.7 Tahapan Dalam Model ARIMA

*Autoregressive Integrated Moving Average* atau ARIMA sering juga disebut metode runtun waktu Box-Jenkins. Model *Autoregressive Integrated Moving Average* (ARIMA) adalah model yang secara penuh mengabaikan variabel independen dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat. ARIMA cocok jika observasi dari deret waktu (*time series*) secara statistic berhubungan satu sama lain (*dependent*).

Berikut ini adalah tahapan dari ARIMA yaitu:


1. Model umum dan uji stasioneritas data.
2. Identifikasi model dengan plot ACF dan PACF.
3. Pendugaan parameter model.
4. Pemeriksaan diagnostik.
5. Pemilihan model terbaik.
6. Penggunaan model untuk peramalan.

(Wenthy, 2011)

## 2.8 *Autoregressive Integrated Moving Average Ensembl* (ARIMA Ensembl)

ARIMA Ensembl merupakan penggabungan hasil ramalan beberapa model ARIMA. Pembentukan ARIMA Ensembl terdiri dari dua langkah. Langkah pertama menciptakan anggota ensembl dari beberapa model ARIMA selanjutnya menggabungkan hasil ramalan anggota ensembl dari ARIMA yang terbentuk dengan menggunakan *averaging* dan *stacking* sehingga didapatkan hasil ramalan ARIMA Ensembl. *Averaging* adalah nilai rata-rata bergerak dan *stacking* adalah

untuk meningkatkan akurasi prediksi. Arsitektur model ARIMA Ensemble dapat dilihat melalui gambar berikut:



Gambar 2.3 Arsitektur ARIMA Ensemble

## 2.9 Metode Penggabungan Ensemble

Ketika anggota ensemble telah dibentuk maka langkah kedua yang harus dilakukan adalah menggabungkan output (hasil ramalan) yang berbeda dari masing-masing member dalam ensemble. Dua pendekatan yang paling sering digunakan adalah *averaging* dan *stacking*.

### 2.9.1 Averaging

*Averaging* biasa disebut dengan rata-rata bergerak. Jika  $k$  adalah banyaknya anggota ensemble maka solusi dari pendekatan ensemble dengan *averaging* adalah sebagai berikut:

$$Z_t = \frac{1}{k} \sum_{i=1}^k Z_t^{(i)}, i = 1, \dots, k \quad (2.15)$$

Contoh: misal  $k = 2$  maka,

$$Z_t = \frac{1}{2} \sum_{i=1}^2 Z_t^{(i)}$$

Dimana  $Z_t^{(i)}$  adalah nilai yang diprediksi ke- $t$  dari anggota ensemble ke- $i$ .

(Silfiani, 2012)

### 2.9.2 Stacking

*Stacking* merupakan metode untuk membentuk kombinasi linier dari prediktor untuk meningkatkan akurasi peramalan. *Stacking* didapatkan dari meminimumkan kuadrat terkecil dari fungsi  $G$  dengan syarat non-negatif untuk memperoleh koefisien dari kombinasi.

$$G = \sum_{t=1}^n [ Z_t - \sum_{i=1}^k c_i Z_t^i ], c_i > 0, \sum_{i=1}^k c_i = 1 \quad (2.16)$$

Koefisien  $\hat{c}_1, \hat{c}_2, \hat{c}_3, \dots, \hat{c}_k$  diestimasi untuk mendapatkan final output dari ensemble, yaitu

$$\hat{Z}_t = \sum_{i=1}^k \hat{c}_i \hat{Z}_t(i) \quad (2.17)$$

Nilai minimum diperoleh dengan mencari turunan  $\sum_{t=1}^n G^2$  terhadap  $\hat{c}_i$  dan kemudian menyamakan tiap turunan itu dengan nol.

(Silfiani, 2012)

### 2.10 Akaike Information Criterion (AIC)

Metode AIC adalah metode yang dapat digunakan untuk memilih model terbaik yang ditemukan oleh Akaike (Grasa, 1989). Metode ini didasarkan pada *maximum likelihood estimation*.

Untuk menghitung nilai AIC digunakan rumus sebagai berikut:

$$\ln AIC = \frac{2k}{n} + \ln \left( \sum_{i=1}^n u_i^2 \div n \right) \quad (2.18)$$

dengan:

$k$  = jumlah parameter yang diestimasi

$n$  = jumlah observasi

$u$  = sisa

Menurut metode AIC, model regresi terbaik adalah model regresi yang mempunyai nilai AIC terkecil (Widarjono, 2007).

### 2.11 Root Mean Square Error (RMSE)

RMSE merupakan akar dari nilai MSE yang sudah dicari sebelumnya. RMSE digunakan untuk mencari keakuratan hasil peramalan dengan data history dengan menggunakan rumus RMSE adalah sebagai berikut:

$$RMSE = \sqrt{\sum_{t=1}^N (Z_t - \hat{Z}_t)^2} \quad (2.19)$$

Semakin kecil nilai RMSE yang dihasilkan semakin bagus pula hasil peramalan yang dilakukan (Aswi dan Sukarna, 2006).

www.itk.ac.id

## 2.12 Penelitian Terdahulu

Berikut adalah rangkuman hasil penelitian terdahulu yang memiliki keterkaitan dengan penelitian yang telah dilakukan.

Tabel 2.1 Penelitian terdahulu

No	Nama dan Tahun Publikasi	Hasil
1	Mega Silfiani dan Suhartono, 2012	Metode : <i>Ensemble</i> Hasil : Metode yang lebih rumit tidak selalu meningkatkan akurasi peramalan pada data out of sample dibandingkan dengan metode yang sederhana meskipun metode yang lebih rumit cocok dengan model statistik untuk data historis yang tersedia.
2	Ari dkk, 2015	Metode : <i>Box Jenkins</i> Hasil : Hasil peramalan IHK membentuk pola yang tidak sama dengan pola data aktual dikarenakan terdapat data <i>outliers</i> pada data aktual.
3	Hasniah dkk, 2016	Metode : <i>ARIMA Ensemble</i> Hasil : Model ARIMA Ensemble yang sesuai untuk peramalan inflasi di Indonesia adalah model ARIMA Ensemble <i>averaging</i> .

www.itk.ac.id