ISSN: 2339-2541
**JURNAL GAUSSIAN, Volume 8, Nomor 2, Tahun 2019, Halaman 194 - 207**
Online di: http://ejournal3.undip.ac.id/index.php/gaussian

# PERBANDINGAN METODE ARIMA BOX-JENKINS DENGAN ARIMA *ENSEMBLE* PADA PERAMALAN NILAI IMPOR PROVINSI JAWA TENGAH

**Riski Arum Pitaloka[1], Sugito[2], Rita Rahmawati[3]**
[1,2,3] Departemen Statistika FSM Universitas Diponegoro
riskiarum88@gmail.com

## ABSTRACT

Import is activities to enter goods into the territory of a country, both commercial and non-commercial include goods that will be processed domestically. Import is an important requirement for industry in Central Java. The increase in high import values can cause deficit in the trade balance. Appropriate information about the projected amount of imports is needed so that the government can anticipate a high increase in imports through several policies that can be done. The forecasting method that can be used is ARIMA Box-Jenkins. The development of modeling in the field of time series forecasting shows that forecasting accuracy increases if it results from the merging of several models called ensemble ARIMA. The ensemble method used is averaging and stacking. The data used are monthly import value data in Central Java from January 2010 to December 2018. Modeling time series with Box-Jenkins ARIMA produces two significant models, namely ARIMA (2,1,0) and ARIMA (0,1,1). Both models are combined using the ARIMA ensemble averaging and stacking method. The best model chosen from the ARIMA method and ensemble ARIMA based on the least RMSE value is the ARIMA model (2,1,0) with RMSE value of 185,8892

Keywords: Import, ARIMA, ARIMA Ensemble, Stacking, Averaging

## 1. PENDAHULUAN

Impor adalah kegiatan memasukkan barang ke dalam wilayah suatu negara, baik bersifat komersial maupun non-komersial serta barang yang akan diolah di dalam negeri yang hasilnya dikeluarkan lagi dari negara tersebut (BPS Jawa Tengah, 2016). Kecenderungan kegiatan impor yang besar tidak sepenuhnya buruk bagi sebuah negara karena impor juga akan merangsang kegiatan investasi, apabila barang yang diimpor merupakan barang modal, barang mentah ataupun barang setengah jadi untuk keperluan perindustrian.

Kepala Bidang Statistik Distribusi Badan Pusat Statistik (BPS) Jawa Tengah, Sri Herawati mengatakan, sepanjang tahun 2017 nilai ekspor Jawa Tengah meningkat sebesar 11,21% dari tahun sebelumnya. Peningkatan ekspor ini juga diiringi oleh peningkatan nilai impor sebesar 20,97%. Hal ini mengakibatkan neraca perdagangan Jawa Tengah mengalami defisit (Anonim, 2018). Oleh karena itu informasi yang tepat mengenai proyeksi jumlah impor diperlukan agar pemerintah dapat mengantisipasi kenaikan impor yang tinggi melalui beberapa kebijakan yang dapat lakukan.

Metode peramalan statistika yang dapat digunakan dalam peramalan di bidang ekonomi salah satunya adalah metode ARIMA Box-Jenkins yang dikembangkan oleh George E.P. Box dan Gwilyn M. Jenkins. Menurut Leutbecher dan Palmer (2008) perkembangan pemodelan di bidang peramalan deret waktu menunjukkan bahwa akurasi peramalan akan meningkat jika dihasilkan dari penggabungan beberapa model dengan kombinasi linier daripada memilih satu model yang terbaik. Metode penggabungan multi-model tersebut sering disebut sebagai pendekatan *ensemble*.

ARIMA *ensemble* merupakan penggabungan hasil ramalan beberapa model ARIMA. Pembentukan ARIMA *ensemble* terdiri dari dua langkah. Pertama, membangkitkan anggota *ensemble* dari dua atau lebih model ARIMA, selanjutnya menggabungkan hasil ramalan anggota *ensemble* dari ARIMA yang terbentuk dengan menggunakan teknik *averaging* dan *stacking* sehingga didapatkan hasil ramalan ARIMA *ensemble* (Silfiani dan Suhartono, 2012). Keakuratan model dalam prediksi diukur berdasarkan kriteria *Root Mean Square Error* (RMSE) yaitu akar dari rata-rata kuadrat *error* dimana model terbaik yang dipilih adalah model dengan RMSE terkecil.

Berdasarkan uraian di atas maka penulis akan melakukan penelitian mengenai perbandingan metode ARIMA Box-Jenkins dengan ARIMA *Ensemble* pada peramalan nilai impor untuk memperoleh hasil ramalan terbaik. Data penelitian yang digunakan adalah data nilai impor (juta $) bulanan di Jawa Tengah yang dipublikasikan oleh Badan Pusat Statistik Provinsi Jawa Tengah.

## 2. TINJAUAN PUSTAKA

### 2.1 Impor

Menurut BPS Jawa Tengah (2016) impor barang adalah kegiatan memasukkan barang ke dalam wilayah suatu negara, baik bersifat komersial maupun bukan komersial serta barang yang akan diolah di dalam negeri yang hasilnya dikeluarkan lagi dari negara tersebut.

### 2.2 Analisis Deret Waktu

Berbagai metode peramalan *time series* telah dikembangkan untuk mendapatkan suatu model yang memberikan hasil ramalan yang lebih akurat. Metode yang sering digunakan antara lain adalah metode ARIMA Box-Jenkins yang digunakan untuk mengolah *time series* yang univariat. Untuk dapat diolah menggunakan metode ARIMA Box-Jenkins, suatu data *time series* harus memenuhi syarat stasioner (Makridakis *et al.*, 1999).

### 2.3 Stasioneritas Data Deret Waktu

Data time series dikatakan stasioner jika rata-rata dan variansinya konstan, tidak ada unsur trend dalam data, dan tidak ada unsur musiman. Menurut Wei (2006) untuk proses stasioner Zt memiliki 3 sifat berikut:

1. $E(Z_t) = \mu$, konstan untuk semua t
2. $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$, konstan untuk semua t
3. Cov $(Z_t, Z_{t+k}) = E[(Z_t - \mu)(Z_{t+k} - \mu)] = \gamma_k$, konstan untuk semua t dan

k ≠ 0 dan $\gamma_k$ adalah autokovariansi pada lag k

### 2.4 Pemeriksaan Stasioneritas Deret Waktu

#### 2.4.1 Uji *Augmented Dickey-Fuller* (ADF)

Uji ADF digunakan untuk menguji stasioneritas data dalam *mean*. Menurut Juanda dan Junaidi (2012) model pada ADF *test* untuk pengujian korelasi serial antara residual dengan $\Delta Z_t$ dapat dinyatakan dalam bentuk umum proses autoregresif sebagai berikut:

$$\Delta Z_t = \beta_1 + \beta_2 t + \delta Z_{t-1} + \alpha_1 \Delta Z_{t-1} + \alpha_2 \Delta Z_{t-2} + \cdots \alpha_1 \Delta Z_{t-2} + a_t \quad (1)$$

dimana $\varepsilon_t$ adalah proses yang *white noise* berdistribusi normal N(0,$\sigma^2$) dan

$\Delta Z_{t-1} = (Z_{t-1} - Z_{t-2})$.
Hipotesis:
$H_0$ : $\delta = 0$ (terdapat akar unit atau data runtun waktu tidak stasioner)
$H_1$ : $\delta < 0$ (tidak terdapat akar unit atau data runtun waktu stasioner)
Taraf Signifikansi: α
Statistik Uji:

$$t = \frac{\hat{\delta}}{SE(\hat{\delta})} \tag{2}$$

Kriteria Uji:
$H_0$ ditolak jika ADF < nilai kritis Dickey Fuller atau *p-value* < α

### 2.4.2 Transformasi Box-Cox

Wei (2006) menjelaskan bahwa transformasi Box-Cox adalah transformasi pangkat pada respon. Box-Cox dengan mempertimbangkan kelas transformasi berpangkat tunggal, yaitu $\lambda$ yang dapat dipangkatkan pada variabel respon $Z_t$, sehingga transformasinya menjadi $Z_t^{\lambda}$ , dimana $\lambda$ adalah parameter yang perlu diduga

## 2.5 Autocorrelation Function (ACF)

Menurut Makridakis *et al.* (1999) istilah autokorelasi digunakan untuk menjelaskan asosiasi atau ketergantungan bersama (*mutual dependence)* antara nilai-nilai suatu deret berkala yang sama pada periode berlainan. Autokorelasi pada lag k, didefinisikan sebagai berikut:

$$\rho_k = \frac{kov(Z_t, Z_{t-k})}{[Var(Z_t).Var(Z_{t-k})]^{1/2}} = \frac{\gamma_k}{\gamma_0} \tag{3}$$

## 2.6 Partial Autocorrelation Function

Menurut Makridakis *et al.* (1999) ukuran *partial autocorrelation* digunakan untuk menunjukkan besarnya hubungan antara nilai suatu variabel saat ini dengan nilai variabel sebelumnya dari variabel yang sama (nilai-nilai untuk berbagai kelambatan waktu) dengan menganggap pengaruh dari semua kelambatan waktu lainnya adalah konstan. *Partial autocorrelation* didefinisikan sebagai berikut:

$$\emptyset_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}} \tag{4}$$

## 2.7 Model Umum Runtun Waktu

Secara umum, terdapat 3 model runtun waktu, yaitu model *Autoregressive* (AR), model *Moving Average* (MA), dan model non stasioner homogen *Autoregressive Integrated Moving Average* (ARIMA).
Wei (2006) menjelaskan bentuk umum suatu proses *autoregressive* orde ke-p (AR(p)) adalah:

$$Z_t = \emptyset_1 Z_{t-1} + \emptyset_2 Z_{t-2} + \cdots + \emptyset_p Z_{t-p} + a_t \tag{5}$$

Model *Moving Average* (MA) orde ke-q dapat dituliskan sebagai berikut:

$$Z_t = a_t + \theta_1 a_{t-1} + \cdots + \theta_q a_{t-q} \tag{6}$$

Untuk menangani data runtun waktu yang tidak stasioner, maka digunakan proses *differencing* ke-d yang tepat, agar data menjadi stasioner dengan menggunakan model ARIMA. Model ARIMA(p,d,q) dapat dituliskan sebagai berikut:

$$\emptyset_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B) a_t \tag{1}$$

dimana $\emptyset_p(B) = (1 - \emptyset_1 B - \cdots - \emptyset_1 B^p)$ dan $\theta_q(B) = (1 - \theta_1 B - \cdots - \theta_q B^q)$.

## 2.8 Identifikasi Model

Untuk menentukan orde p dan q dalam model ARIMA(p,d,q) digunakan grafik ACF dan PACF. Ada beberapa pedoman dalam pendugaan model ARIMA dari suatu data *time series* yang dijelaskan oleh Wei (2006) berkaitan dengan plot ACF dan PACF yang telah dirangkum pada Tabel 2.

Tabel 1. Pendugaan model berdasarkan plot ACF dan PACF

| Model | ACF | PACF |
|---|---|---|
| AR(p) | Turun secara eksponensial atau membentuk gelombang sinus. | *Cut off* setelah lag p. |
| MA(q) | *Cut off* setelah lag q. | Turun secara eksponensial atau membentuk gelombang sinus. |
| ARMA (p,q) | Turun cepat setelah lag (q-p) | Turun cepat setelah lag (p-q) |

## 2.9 Estimasi Parameter Model

Estimasi parameter yang digunakan adalah *Ordinary Least Square* (OLS). Menurut Wei (2006) estimasi OLS merupakan estimasi yang meminumkan kuadrat selisih antara nilai parameter yang sebenarnya dengan nilai estimasinya. Setelah dilakukan proses estimasi parameter, maka parameter tersebut perlu diuji apakah parameter tersebut layak digunakan pada model atau tidak.Berikut adalah prosedur uji signifikansi parameter yang dilakukan secara individu untuk model ARIMA

Hipotesis:

Untuk Model AR(p)

$H_0$ : $\phi_i = 0$ (parameter tidak signifikan terhadap model)

$H_1$ : $\phi_i \neq 0$ (parameter signifikan terhadap model) dengan i=1,2,..., p

Untuk Model MA(q)

$H_0$ : $\theta_i = 0$ (parameter MA tidak signifikan terhadap model)

$H_1$ : $\theta_i \neq 0$ (parameter MA signifikan terhadap model) dengan i=1,2,...,q

Taraf Signifikansi: α

Statistik Uji:

Untuk Model AR(p)

$$t = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \tag{8}$$

Untuk Model MA(q)

$$t = \frac{\hat{\theta}_i}{SE(\hat{\theta}_i)} \tag{9}$$

Kriteria uji:

$H_0$ ditolak jika $|t| > t_{(\alpha/2, n-1)}$ atau *p-value* < α

## 2.10 Pemeriksaan Diagnostik

Soejoeti (1987) menjelaskan bahwa diagnosa atau verifikasi dimaksudkan untuk memeriksa apakah model yang diestimasi sudah cocok dengan data yang ada. Residual yang diperoleh harus memenuhi asumsi *white noise* dan mengikuti distribusi normal

### 2.11.1 Uji White Noise Residual

Asumsi dasar adalah bahwa residual bersifat *white noise* yang artinya tidak terdapat korelasi antar residual (independen) dengan *mean* sama dengan 0 dan *variance* konstan (homogen) (Wulansari *et al.*, 2014).

2.10.1.1 Uji Independensi Residual

Uji independensi *error* digunakan untuk mengetahui apakah *error* antar lag bersifat independen, artinya tidak terdapat korelasi *error* antar lag. Uji yang digunakan adalah uji Q-Ljung-Box.

Hipotesis:

$H_0$ : $\rho_1 = \rho_2 = \cdots = \rho_k = 0$ (*error* bersifat independen)

$H_1$ : minimal ada satu $\rho_k \neq 0$ (*error* tidak bersifat independen)

Taraf Signifikansi: α

Statistik Uji:

$$Q = n(n+2)\sum_{k=1}^{K}(n-k)^{-1}\hat{\rho}_k^2 \qquad (10)$$

Q berdistribusi $\chi^2_{(\alpha,\ K-m)}$

dengan n: banyak data, $\hat{\rho}_k$: autokorelasi *error* lag ke-k, m = p + q

Kriteria uji:

$H_0$ ditolak jika Q >$\chi^2_{(\alpha,\ K-m)}$ atau *p-value* < α

2.10.1.2 Uji Homogenitas Residual

Menurut Engle (1982), uji ini diperlukan untuk mengetahui bahwa tidak terjadi kasus heteroskedastisitas dalam residual model.

Hipotesis

$H_0$ : $\theta_1 = \theta_2 = \cdots = \theta_m = 0$ (tidak ada efek ARCH/GARCH)

$H_1$ : minimal ada satu nilai $\theta_i \neq 0$ untuk $i$ = 1,2,…,m (terdapat efek ARCH/GARCH)

Taraf Signifikansi: α

Statistik Uji

$$LM = TR^2 \qquad (11)$$

dengan:

T = banyaknya observasi

$R^2$ = koefisien determinasi

Kriteria Uji

Ho ditolak jika nilai LM > $\chi^2_{(\alpha;m)}$ atau $p - value < \alpha$.

2.10.1.3 Uji Normalitas

Uji normalitas bertujuan untuk menguji apakah *error* dari model mengikuti distribusi normal. Menurut Kabasarang *et al.* (2012) salah satu cara untuk menguji asumsi normalitas dari suatu data yaitu dengan menggunakan uji Jarque-Bera (JB).

Hipotesis:

$H_0$ : *error* berdistribusi normal

$H_1$ : *error* tidak berdistribusi normal

Taraf Signifikansi: α

Statistik Uji:

$$JB = \frac{n}{6}\left[S^2 + \frac{(K-3)^2}{4}\right] \qquad (12)$$

Kriteria Uji:
$H_0$ ditolak jika JB > $\chi^2_{(\alpha,2)}$ atau *p-value* < α

## 2.11 *Autoregressive Integrated Moving Averge Ensemble* (ARIMA *Ensemble*)

ARIMA *ensemble* merupakan penggabungan hasil ramalan beberapa model ARIMA. Ada dua metode yang dapat digunakan untuk mengkombinasikan *output* hasil ramalan yang berbeda dari anggota *ensemble* yaitu *ensemble averaging* dan *ensemble stacking*. Skema proses peramalan ARIMA *ensemble* dapat dilihat pada Gambar 1 (Silfiani dan Suhartono, 2012).

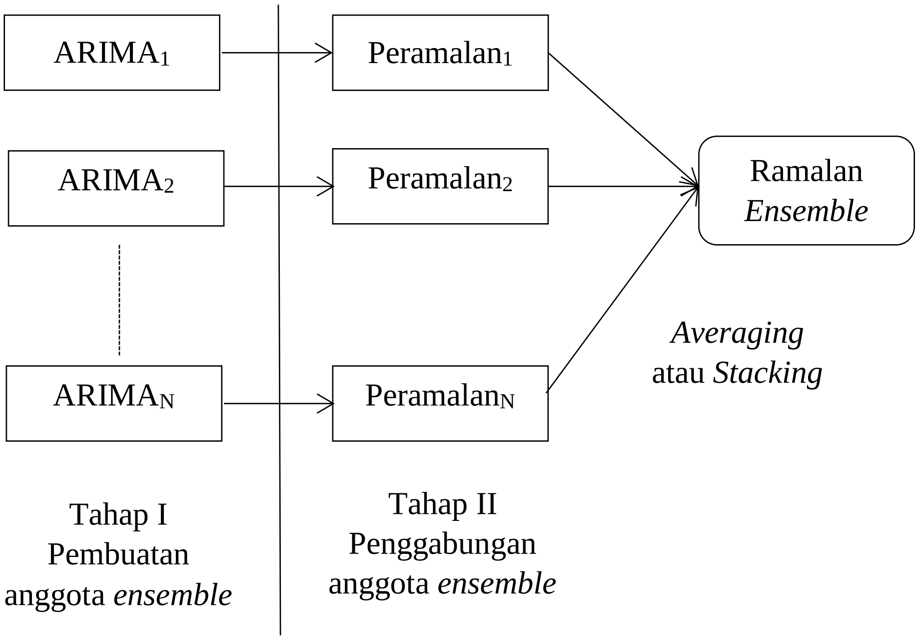


Gambar 1. Skema ARIMA *Ensemble*

### 2.11.1 Ensemble Averaging

Silfiani dan Suhartono (2012) menjelaskan bahwa peramalan *ensemble averaging* dilakukan dengan menggunakan metode rata-rata yaitu *output* hasil ramalan dari *ensemble* diperoleh dengan menghitung rata-rata dari *output* anggota *ensemble*. Jika k adalah banyaknya anggota ensembel solusi dari pendekatan ensembel dengan averaging adalah:

$$f\left(\hat{Z}_t^{(N)}\right) = \frac{1}{N}\sum_{k=1}^{N}\hat{Z}_t^{(k)} \ dengan\ k = 1,2,\dots,N \tag{13}$$

### 2.11.2 Ensemble Stacking

Menurut Silfiani dan Suhartono (2012) stacking merupakan metode untuk membentuk kombinasi linear dari prediktor untuk meningkatkan akurasi dari suatu peramalan. Metode stacking dilakukan dengan memberi nilai koefisien dari masing-masing prediktor sehingga terbentuk kombinasi linear.

Breiman (1996) menyarankan untuk mendapatkan nilai koefisien stacking dilakukan dengan meminimalisasi suatu fungsi $G^2$ untuk memperbaiki kemampuan generalisasi dari suatu model, yaitu:

$$G^2 = \sum_{t=1}^{m}[Z_t - \sum_{k=1}^{N}\hat{c}_k\hat{Z}_t^{(k)}]^2 \quad \text{dimana } \hat{c}_k > 0 \tag{14}$$

Nilai minimum diperoleh dengan mencari turunan G terhadap $\hat{c}_k$ dan kemudian menyamakan setiap turunan itu sama dengan nol. Koefisien-koefisien $\hat{c}_1, \hat{c}_2, \dots,$

$\hat{c}_N$ diestimasi untuk membentuk atau mengkonstruksi suatu nilai prediksi akhir dari suatu *ensemble*, yaitu:

$$\hat{Z}_t = \sum_{k=1}^{N} \hat{c}_k \, \hat{Z}_t^{(k)} \qquad , t = 1,2, \dots , m \tag{15}$$

Metode-metode tersebut merupakan suatu bentuk perkembangan metode peramalan yang digunakan oleh ilmuwan di dunia untuk mendapatkan alternatif peramalan yang menghasilkan akurasi terbaik.  Namun, semakin kompleks metode yang digunakan belum tentu metode tersebut menghasilkan akurasi yang lebih baik dibandingkan metode yang lebih sederhana. Hal itu sesuai dengan yang disebutkan dalam hasil *M-3 Competition* oleh Makridakis dan Hibbon (2000), yaitu:

1. Metode statistika yang canggih atau kompleks belum tentu memberikan akurasi yang lebih baik dibandingkan dengan metode yang sederhana.
2. Ranking relatif dari performansi metode-metode peramalan bervariasi dan bergantung pada ukuran akurasi yang digunakan.
3. Akurasi ketika beberapa metode peramalan dikombinasikan, misalnya metode individu yang dikombinasikan, akan menghasilkan akurasi lebih baik jika dibandingkan dengan metode lain.

Akurasi dari metode bergantung pada panjang horizon ramalan

## 2.12 Pemilihan Model Terbaik

Menurut Zaier *et al.* (2010), salah satu ukuran yang digunakan untuk mengukur ketepatan adalah *root mean square error* (RMSE) dimana model terbaik adalah model yang memiliki nilai RMSE terkecil. Nilai RMSE dapat dihitung sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{t=1}^{m}(Z_t - \hat{Z}_t)^2}{m}} \tag{16}$$

dengan:

$Z_t$ = nilai aktual atau data sebenarnya pada periode ke-t

$\hat{Z}_t$ = nilai prediksi atau besarnya ramalan pada periode ke-t

m = ukuran sampel

# 3. METODE PENELITIAN

Data yang digunakan pada penelitian ini adalah data runtun waktu sekunder yaitu data Nilai Impor (juta \$) bulanan di Provinsi Jawa Tengah periode Januari 2010 sampai dengan Desember 2018 yang diperoleh dari Badan Pusat Statistik Provinsi Jawa Tengah melalui *website* resminya di https://jateng.bps.go.id/.

Pengolahan data pada penelitian ini menggunakan bantuan program Microsoft Excel 2013, Minitab 14 dan EViews 8. Berikut adalah langkah-langkah pengolahan data dalam penelitian ini:

1. Membagi data kedalam dua bagian yaitu data *in-sample* sebanyak 96 data (Januari 2010 sampai dengan Desember 2017) dan data *out-sample* sebanyak 12 data (Januari 2018 sampai dengan Desember 2018).
2. Data *in-sample* digunakan untuk membentuk model ARIMA.
3. Data *out-sample* digunakan untuk menentukan tingkat ketepatan model.
4. Mengetahui hasil peramalan *ensemble* dari berbagai model ARIMA *time series* yang dihasilkan dengan langkah-langkah sebagai berikut:
5. Membuat *plot trend analysis* data Nilai Impor (juta \$) bulanan Provinsi Jawa Tengah.
6. Memeriksa kestasioneritasan data dalam varian dan *mean* dengan melakukan transformasi Box-Cox dan uji hipotesis *Augmented* Dickey Fuller (ADF). Jika data

tidak stasioner dalam varian maka dilakukan proses transformasi dan jika data tidak stasioner dalam *mean* maka dilakukan diferensiasi sehingga data menjadi stasioner.

7. Mengidentifikasi model ARIMA Box-Jenkins dengan menggunakan metode pemilihan model melalui plot ACF dan PACF.
8. Mengevaluasi parameter model ARIMA Box-Jenkins terbaik melalui uji signifikansi parameter.
9. Melakukan uji independensi, uji homoskedastisitas dan uji normalitas pada tahap pemeriksaan diagnostik residual.
10. Mengitung nilai RMSE untuk masing-masing model ARIMA.
11. Membangkitkan data anggota *ensemble* dari beberapa model ARIMA yang lolos uji diagnostik.
12. Menggabungkan ramalan anggota *ensemble* menggunakan metode *averaging* yaitu dengan menghitung rata-rata hasil ramalan anggota *ensemble* sehingga didapatkan hasil ramalan ARIMA *ensemble averaging*.
13. Menggabungkan ramalan anggota *ensemble* menggunakan metode *stacking* yaitu dengan mencari nilai koefisien yang diperoleh dari hasil regresi nilai taksiran *in-sample*, kemudian nilai koefisien *stacking* digunakan untuk menggabungkan ramalan anggota dari *ensemble* sehingga didapatkan hasil ramalan ARIMA *ensemble stacking*.
14. Menghitung nilai RMSE untuk metode *ensemble averaging* dan *stacking*.
15. Menentukan model terbaik berdasarkan nilai RMSE pada model ARIMA, ARIMA *ensemble averaging* dan ARIMA *ensemble stacking.*
16. Melakukan peramalan untuk 6 periode ke depan berdasarkan model terbaik.

## 4. HASIL DAN PEMBAHASAN

### 4.1 Karakteristik Nilai Impor

Diketahui nilai-nilai statistik deskriptif dari nilai impor dari periode Janauari 2010 sampai dengan Desember 2017. Terlihat bahwa rata-rata nilai impor sebesar US$1022,4 juta/bulan. Nilai varian sebesar 73827,3 menunjukkan bahwa ukuran variabilitas cukup besar yang artinya fluktuasi data antar satu data dengan data yang lain cukup tinggi. Untuk mengetahui pergerakan nilai impor bulanan pada tahun 2010 sampai dengan 2017 maka digunakan time series plot sebagai berikut:

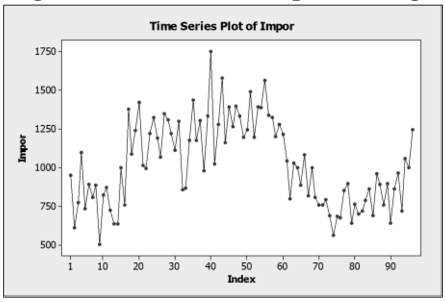


Gambar 2 Plot Data *Return* Saham BSDE

Gambar 2 menunjukan bahwa terjadi perubahan dari pola plot data, dimana pola plot tersebut berubah-ubah sesuai dengan nilai impor tiap bulannya. Perkembangan nilai impor Jawa Tengah selama delapan tahun terakhir (Januari 2010- Desember 2017) menunjukkan kecenderungan yang terus meningkat hingga mencapai nilai tertinggi pada bulan April 2013 sebesar US$1748,3 juta sedangkan nilai impor terendah dicapai pada bulan September 2010 sebesar US$501,8 juta.

### 4.2 Peramalan Nilai Impor menggunakan Metode ARIMA Box-Jenkins

### 4.2.1 Stasioneritas Data Deret Waktu

4.2.1.1 Stasioneritas Varian

Pada data awal diperoleh nilai *rounded value* atau lambda sebesar 0,50. Nilai lambda sebesar 0,50 menunjukkan bahwa data belum stasioner dalam varian, sehingga diperlukan adanya transformasi. Nilai lambda 0,50 menunjukkan bahwa data perlu ditransformasi ke dalam bentuk $Z_t^{0,50}$. Setelah dilakukan transformasi diperoleh nilai *rounded value* atau lambda sebesar 1,00. Nilai lambda sebesar 1,00 menunjukkan bahwa data telah stasioner dalam varian sehingga tidak diperlukan transformasi lagi.

4.2.1.2 Stasioneritas Mean

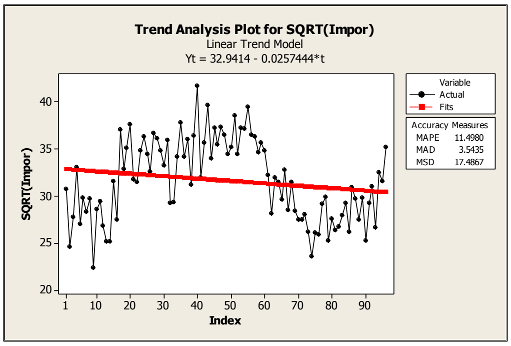


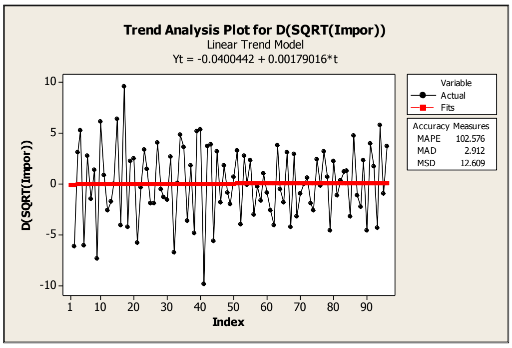


Gambar 3. *Trend Analysis Plot* Impor  Gambar 4.*Trend Analysis Plot* D(Impor)

Pada Gambar 3 terlihat bahwa plot data dari waktu ke waktu mempunyai fluktuasi yang tidak tetap dan cenderung memiliki trend turun. Sehingga perlu dilakukan proses *differencing.* Setelah dilakukan proses *differencing* orde pertama pada Gambar 4 terlihat data nilai impor cenderung stabil dan tidak memiliki *trend* naik maupun turun. Sehingga secara visual dapat dikatakan bahwa pada diferensi pertama data sudah stasioner dalam *mean.*

Untuk memperkuat hasil uji secara visual maka dilakukan pengujian secara formal dengan menggunakan ADF *test* dengan hasil sebagai berikut:

Tabel 2. Hasil Uji *Augmented* Dickey Fuller

| | t-satistic | Prob | Keputusan |
|---|---|---|---|
| Nilai Impor | -1,989675 | 0,2909 | Ho diterima |
| D(Nilai Impor) | -12,00644 | 0,0001 | Ho ditolak |

Berdasarkan tabel diatas dapat disimpulkan bahwa pada diferensi pertama data nilai impor sudah stasioner dalam *mean*.

### 4.2.1 Identifikasi Model ARIMA Box Jenkins

Berdasarkan plot ACF terlihat bahwa plot cut-off pada lag 1. Sedangkan pada plot PACF terlihat cut-off pada lag 1 dan 2. Model tentatif yang bisa diidentifikasi berdasarkan plot ACF dan PACF menggunakan metode underfitting dan overfitting sampai dengan dua orde adalah ARIMA (4,1,3), ARIMA (4,1,2), ARIMA (4,1,1), ARIMA (3,1,3), ARIMA (3,1,2), ARIMA (3,1,1), ARIMA (2,1,3), ARIMA (2,1,2), ARIMA (2,1,1) ,ARIMA(1,1,1), ARIMA (0,1,2), ARIMA (0,1,1), ARIMA (2,1,0) dan ARIMA (1,1,0).

### 4.2.2 Estimasi Parameter Model

Berdasarkan hasil uji signifikansi parameter model diperoleh kesimpulan bahwa pada taraf signifikansi 5% dari 14 model awal teridentifikasi hanya 3 model yang signifikan yaitu model ARIMA(1,1,0), ARIMA(2,1,0) dan ARIMA(0,1,1) karena memiliki parameter yang signifikan terhadap model sehingga dapat dijadikan sebagai model sementara. Hasil uji signifikansi parameter pada ketiga model tersebut adalah:

Tabel 3. Hasil Uji SIgnifikasi Parameter

| Model | Parameter | Koefisien | Prob |
|---|---|---|---|
| ARIMA (1,1,0) | $\hat{\phi}_1$ | -5,305566 | 0,0000 |
| ARIMA (2,1,0) | $\hat{\phi}_1$ | -5,674593 | 0,0000 |
| | $\hat{\phi}_2$ | -3,774352 | 0,0003 |
| ARIMA (0,1,1) | $\hat{\theta}_1$ | -8,036683 | 0,0000 |

### 4.2.3 Pemeriksaan Diagnostik

Pemeriksaan diagnostik asumsi *white noise* dilakukan dengan uji Ljung-Box untuk menguji apakah terdapat korelasi pada residual antar lag dari setiap model dan untuk menguji asumsi homoskedastisitas residual dilakukan menggunakan uji Lagrange Multiplier (LM *test*). Sedangkan untuk asumsi normalitas residual menggunakan uji Jarque Bera.

Tabel 4. Hasil signifikansi pada uji Ljung-Box

| Model | Lag | *p-value* | Keputusan |
|---|---|---|---|
| ARIMA(1,1,0) | 12 | 0,066 | $H_o$ diterima |
| | 24 | 0,001 | $H_o$ ditolak |
| | 36 | 0,001 | $H_o$ ditolak |
| ARIMA(2,1,0) | 12 | 0,728 | $H_o$ diterima |
| | 24 | 0,305 | $H_o$ diterima |
| | 36 | 0,343 | $H_o$ diterima |
| ARIMA(0,1,1) | 12 | 0,844 | $H_o$ diterima |
| | 24 | 0,273 | $H_o$ diterima |
| | 36 | 0,371 | $H_o$ diterima |

Berdasarkan uji independensi residual didapat kesimpulan bahwa hanya model ARIMA(2,1,0) dan ARIMA(0,1,1) yang menerima Ho artinya tidak terdapat korelasi pada residual antar lag (residual independen). Sedangkan model ARIMA(1,1,0) mempunyai residual yang saling berkorelasi karena terdapat beberapa lag yang menolak Ho.

Tabel 5. Hasil signifikansi uji Lagrange Multiplier (LM test)

| Model | *p-value* | Keputusan |
|---|---|---|
| ARIMA(2,1,0) | 0,2888 | $H_o$ diterima |
| ARIMA(0,1,1) | 0,5884 | $H_o$ diterima |

Berdasarkan hasil uji homoskedastisitas residual yang terdapat pada Tabel 5 didapat bahwa model ARIMA(2,1,0) dan ARIMA(0,1,1) menerima Ho yang artinya tidak terdapat efek ARCH/GARCH atau residual model homogen.

Tabel 6. Hasil signifikansi uji Jarque Bera

| Model | *p-value* | Keputusan |
|---|---|---|
| ARIMA(2,1,0) | 0,2695 | $H_o$ diterima |
| ARIMA(0,1,1) | 0,4979 | $H_o$ diterima |

Berdasarkan hasil uji normalitas residual dengan uji Jarque Bera yang terdapat pada Tabel 6 didapat bahwa model ARIMA(2,1,0) dan ARIMA(0,1,1) menerima Ho yang artinya residual berdistribusi normal.

**4.3 Peramalan Nilai Impor Menggunakan Metode ARIMA *Ensemble***

Selanjutnya dilakukan peramalan untuk setiap model sebanyak 12 periode ke depan dengan menggunakan model yang signifikan yaitu ARIMA(2,1,0) dan ARIMA(0,1,1). Nilai ramalan yang diperoleh dari setiap model kemudian digabungkan dengan menggunakan teknik *ensemble averaging* dan *ensemble stacking*. Adapun hasil ramalan untuk setiap model adalah sebagai berikut:

Tabel 7. Hasil Ramalan Model ARIMA

| Periode | ARIMA(2,1,0) | ARIMA (0,1,1) |
|---|---|---|
| Januari 2018 | 1102,7580 | 1032,4231 |
| Februari 2018 | 1079,6359 | 1032,8799 |
| Maret 2018 | 1151,7176 | 1075,3580 |
| April 2018 | 1077,6113 | 1069,7062 |
| Mei 2018 | 1172,6198 | 1144,3534 |
| Juni 2018 | 1232,8730 | 1224,1222 |
| Juli 2018 | 1194,2687 | 1127,4637 |
| Agustus 2018 | 1224,6106 | 1187,9315 |
| September 2018 | 1250,0992 | 1308,7370 |
| Oktober 2018 | 1330,0945 | 1264,5659 |
| November 2018 | 1421,6079 | 1344,3867 |
| Desember 2018 | 1316,4083 | 1332,5372 |

**4.3.1 Peramalan *Ensemble Averaging***

Penggabungan peramalan dengan tenik ensemble averaging dilakukan dengan merata-ratakan hasil ramalan setiap periode dari model ARIMA(2,1,0) dan ARIMA(0,1,1). Hasil dari peramalan menggunakan teknik ARIMA e*nsemble averaging* untuk periode Januari 2018 sampai dengan Desember 2018 adalah sebagai berikut:

Tabel 8.. Nilai Ramalan *Out-sample* ARIMA *ensemble averaging*

| Periode | ARIMA *Ensemble averaging* |
|---|---|
| Januari 2018 | 1067,5892 |
| Februari 2018 | 1056,2591 |
| Maret 2018 | 1113,5406 |
| April 2018 | 1073,6603 |
| Mei 2018 | 1158,4856 |
| Juni 2018 | 1228,4994 |

| | |
|---|---|
| Juli 2018 | 1160,8656 |
| Agustus 2018 | 1206,2739 |
| September 2018 | 1279,4177 |
| Oktober 2018 | 1297,3267 |
| November 2018 | 1382,9975 |
| Desember 2018 | 1324,4700 |

### 4.3.2 Peramalan *Ensemble Stacking*

Penggabungan dengan *ensemble stacking* didapatkan dari meregresikan nilai taksiran dengan nilai observasi data *in-sample* sehingga diperoleh nilai parameter koefisien *stacking* (bobot) $\hat{c}_1$ sebesar 0,647 dan $\hat{c}_2$ sebesar 0,358. Hasil dari peramalan menggunakan teknik ARIMA e*nsemble stacking* untuk periode Januari 2018-Desember 2018 sebagai berikut:

Tabel 9. Nilai Ramalan *Out-sample* ARIMA *ensemble stacking*

| Periode | ARIMA *Ensemble averaging* |
|---|---|
| Januari 2018 | 1067,5892 |
| Februari 2018 | 1056,2591 |
| Maret 2018 | 1113,5406 |
| April 2018 | 1073,6603 |
| Mei 2018 | 1158,4856 |
| Juni 2018 | 1228,4994 |
| Juli 2018 | 1160,8656 |
| Agustus 2018 | 1206,2739 |
| September 2018 | 1279,4177 |
| Oktober 2018 | 1297,3267 |
| November 2018 | 1382,9975 |
| Desember 2018 | 1324,4700 |

### 4.4 Pemilihan Model Terbaik

Berdasarkan nilai aktual data *out-sample* dan hasil perhitungan nilai prediksi, diperoleh nilai RMSE untuk masing-masing model sebagai berikut:

Tabel 10. Nilai RMSE Model ARIMA dan ARIMA *Ensemble*

| Model | RMSE |
|---|---|
| ARIMA(2,1,0) | 185,8892 |
| ARIMA(0,1,1) | 204,4792 |
| ARIMA *Averaging* | 193,6024 |
| ARIMA *Stacking* | 190,3400 |

Berdasarkan Tabel 10 diperoleh model dengan nilai RMSE *out-sample* terkecil yaitu model ARIMA (2,1,0) dengan rumus persamaan:

$$\Delta Z_t = \phi_1 \Delta Z_{t-1} + \phi_{2\Delta} Z_{t-2} + a_t$$

$$\Delta Z_t = \phi_1(Z_{t-1} - Z_{t-2}) + \phi_2(Z_{t-2} - Z_{t-3}) + a_t$$
$$\Delta Z_t = -0{,}654506\,(Z_{t-1} - Z_{t-2}) - 0{,}364361\,(Z_{t-2} - Z_{t-3}) + a_t$$

Berdasarkan hasil dari penelitian ini menunjukkan bahwa semakin kompleks suatu metode yang digunakan belum tentu metode tersebut menghasilkan akurasi yang lebih baik dibandingkan metode sederhana (klasik). Namun dalam penelitian ini nilai RMSE ARIMA *ensemble stacking* tidak berbeda jauh dengan nilai RMSE model terbaik ARIMA(2,1,0) yaitu berbeda sebesar 4,4504, hal ini mengindikasikan bahwa metode ARIMA *ensemble stacking* dapat dipertimbangkan untuk digunakan sebagai metode alternatif lain pada penelitian selanjutnya.

## 5. KESIMPULAN

Berdasarkan hasil analisis diperoleh model terbaik yang digunakan untuk memprediksi nilai impor provinsi Jawa Tengah periode Januari 2019 sampai dengan Juni 2019 adalah model ARIMA(2,1,0) karena memiliki nilai RMSE terkecil yaitu sebesar 185,8892 dengan hasil nilai ramalan untuk 6 periode ke depan adalah sebagai berikut:

| Periode | ARIMA(2,1,0) |
|---|---|
| Januari 2019 | 1283,465 |
| Februari 2019 | 1223,927 |
| Maret 2019 | 1176,938 |
| April 2019 | 1228,975 |
| Mei 2019 | 1211,932 |
| Juni 2019 | 1204,029 |

Hasil dari penelitian ini menunjukkan bahwa semakin kompleks suatu metode yang digunakan belum tentu metode tersebut menghasilkan akurasi yang lebih baik dibandingkan metode sederhana (klasik).

## DAFTAR PUSTAKA


Anonim. 16 Januari 2018. *Perdagangan Jateng Defisit*. http://radarsemarang.com/2018/01/16/perdagangan-jateng-defisit/. Diakses: 30 Januari 2018.

Badan Pusat Statistik (BPS) Indonesia. 2018. *Statistik Indonesia 2018*. Katalog BPS 1101001. BPS Statistik Indonesia.

Badan Pusat Statistik (BPS) Provinsi Jawa Tengah. 2016. *Statistik Impor Jawa Tengah 2016*. Katalog BPS 8202017.33. Jawa Tengah : Badan Pusat Statistik Provinsi Jawa Tengah.

Breiman, L. 1996. *Stacked regression*. *Machine Learning*, Vol. 24, Page: 49-64.

Engle, R.F. 1982. *Autoregressive Conditional Heteroscedasticity with Estimation of the Variance of United Kingdom Inflation. Journal Econometrica,* Vol. 50, No. 4.

Juanda, Bambang dan Junaidi. 2012. *Ekonometrika Deret Waktu Teori dan Aplikasi*. Bogor:IPB Press.

Kabasarang, D.C., Satiawan, A., dan Susanto, B. 2013. *Uji Normalitas Menggunakan Statistik Jarque-Bera Berdasarkan Metode Bootstrap*. ISBN : 978-979-17763-6-3. Prosiding: Seminar Nasional Matematika LSM Matematika FMIPA UNY.

Leutbecher, M., and Palmer, T. N. 2008. *Ensemble Forecasting*. Journal of Computational Physics 227 (2008) 3515-3539.

Makridakis, S., & Hibon, M. (2000). The M-3 Competition: results, conclusions and implications. International Journal of Forecasting. Vol. 16. Page. 451–476.

Makridakis, S., WheelWright, S., dan McGree, V. E. 1999. *Metode dan Aplikasi Peramalan*. Edisi *kedua*. Untung Sus Andriyanto dan Abdul Basith, penerjemah. Jakarta: Erlangga. Terjemahan dari Forecasting, 2nd Edition.

Silfiani, M., dan Suhartono. 2012. *Aplikasi Metode Ensemble untuk Peramalan Inflasi di Indonesia.* Jurnal Sains dan Seni ITS. Vol.1, No.1.

Soejoeti, Z. 1987. *Analisis Runtun Waktu*. Jakarta: Karunika Jakarta.

Wei, W.W.S. 2006. *Time Series Analysis:Univariate and Multivariate Methods.* New York: Pearson.

Wulansari, R. E., Suryanto, E., Ferawati, K., Andalita, I., dan Suhartono. 2014. *Penerapan Time Series Regression with Calender Variation Effect pada Data Netflow Uang kartal Bank Indonesia Sebagai Solusi Kontrol Likuiditas Perbankan di Indonesia*. Jurnal Statistika, Vol. 14, No. 2, Hal: 59-64.

Zaier, I., Shu, C., Ouarda, T., and Chebana, F. 2010. *Estimation of Ice Thickness on Lakes using Artificial Neural Network Ensembles. Journal of Hydrology*, *Volume* 383, *Issue* 3, *Page*: 330-340.