

---

---

## PERBANDINGAN PERAMALAN UNIVARIAT DAN MULTIVARIAT ARIMA PADA INDEKS HARGA SAHAM GABUNGAN

Dwi Ayu Lusiana<sup>1</sup>, Awalludiyah Ambarwati<sup>2</sup>

<sup>1,2</sup> Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Narotama, Surabaya  
Alamat e-mail : dwi.ayu@narotama.ac.id

### ABSTRAK

Saham merupakan salah satu investasi dengan keuntungan melebihi inflasi di Indonesia. Harga saham tercermin pada Indeks Harga Saham Gabungan (IHSG). Peramalan multivariat IHSG merupakan salah satu cara yang konsisten dibandingkan dengan analisis fundamental dan teknikal. Salah satu metode yang dapat digunakan untuk peramalan multivariat adalah Vector Autoregressive Integrated Moving Average (VARIMA). Metode tersebut merupakan pengembangan dari univariat ARIMA (Autoregressive Integrated Moving Average). Penelitian ini bertujuan membandingkan hasil secara multivariat dan univariat berdasarkan nilai RMSE (Root Mean Square Error) pada data training serta testing. Selain RMSE, penelitian ini juga melihat apakah ramalan high merupakan ramalan maksimum dibandingkan open, low, close. Begitupula untuk low. Terdapat dua model secara univariat yaitu ARI (Autoregressive Integrated) dan IMA (Integrated Moving Average). Sedangkan model multivariat yang terbentuk ialah VARIMA(3,1,0) yang berdasarkan CCF (Cross Correlation Function) dan PCCF (Partial Cross Correlation Function) serta VARIMA([1,3],1,0) berdasarkan lag pada ARIMA. Model VARIMA(3,1,0) merupakan model terbaik berdasarkan RMSE testing dan ketepatan high maupun low.

**Kata kunci :** Univariat, Multivariat, Peramalan, Saham

### PENDAHULUAN

Saham merupakan salah satu jenis investasi, jangka pendek dan jangka panjang, yang cukup menjanjikan. Masyarakat dapat menginvestasikan uangnya dalam bentuk saham dengan rata-rata keuntungan saham maksimal per bulan sebesar 8.558% dan risiko sebesar 4.222% [1]. Tentunya dalam keputusan menjual dan membeli diperlukan sebuah analisa. Analisa yang sering digunakan ialah analisis fundamental dan analisis teknikal. Analisis fundamental memiliki prinsip harga saham berhubungan dengan karakteristik keuangan suatu perusahaan [2]. Perusahaan yang tercatat pada Bursa

Efek Indonesia (BEI) memiliki kewajiban untuk menyerahkan laporan keuangan perusahaan secara triwulan dan tahunan BEI. Sedangkan pergerakan harga saham adalah harian, sehingga laporan keuangan perusahaan tidak dapat mencerminkan data harian harga saham.

Selain itu, analisis teknikal juga kurang sesuai untuk pengambilan keputusan jual maupun beli. Karena analisis teknikal berdasarkan psikologi masyarakat yang tercermin pada harga saham harian [3]. Kemudian harga saham tersebut membentuk suatu pola yang digunakan untuk membuat keputusan. Sedangkan pola tersebut dapat berbeda-

beda tergantung dengan pengalaman investor.

Oleh karena penelitian ini meramalkan data harian saham sehingga tidak akan ada perbedaan pendapat dalam pengambilan kesimpulan. Sebagai perwakilan saham ialah Indeks Harga Saham Gabungan (IHSG). Terdapat beberapa metode peramalan IHSG seperti fungsi transfer [4], ARIMA (*Autoregressive Integrated Moving Average*) [5], WEMA (*Weighted Exponential Moving Average*) [6], Jaringan Syaraf Tiruan *backpropagation* [7] dan *Fuzzy Time Series* [8]. Akan tetapi kedua metode tidak menggunakan data yang membentuk pola harga (data *open, high, low, dan close*).

Metode klasik yang dapat meramalkan data harian saham adalah ARIMA. Akan tetapi penelitian ini menggunakan data yang membentuk pola harga yaitu data *open, high, low, dan close* saham sehingga menggunakan multivariat dari ARIMA yaitu VARIMA (*Vector Autoregressive Integrated Moving Average*). Keempat data tersebut akan diramalkan secara univariat dan multivariat. Kemudian dibandingkan ketepatan pemodelannya menggunakan RMSE (*Root Mean Square Error*) pada data *training* dan *testing*. Serta ketepatan akurasi peramalan *high* dan *low* sebagai maksimal dan minimal dari keempat variabel.

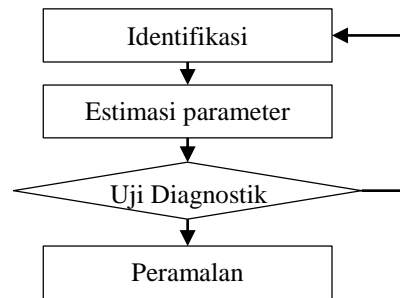
*Autoregressive Integrated Moving Average* (ARIMA) termasuk dalam peramalan univariat dengan bentuk linier. Sedangkan *Vector Autoregressive Integrated Moving Average* (VARIMA) adalah perkembangan ARIMA untuk peramalan multivariat. Secara umum, model  $ARIMA(p, d, q)(P, D, Q)^S$  dapat ditulis seperti berikut.

$$\phi_p(B)\Phi_P(B^S)(1 - B)^d(1 - B^S)^D y_t = \theta_0 + \theta_q(B)\Theta_Q(B^S)y_t \quad (1)$$

$p$  ialah orde dari *autoregressive*,  $d$  ialah orde dari *differencing*, dan  $q$  adalah orde

dari *moving average*. Ketiga orde tersebut ditulis dengan huruf besar menunjukkan bahwa orde dari musiman dengan skala  $S$ . Sedangkan  $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ . Hal tersebut juga berlaku untuk  $\Phi_P(B^S)$ ,  $\theta_q(B)$ , dan  $\Theta_Q(B^S)$ . Operator  $B$  merupakan skala waktu, contoh  $(\phi_1 B)y_t$  akan sama dengan  $\phi_1 y_{t-1}$ . Persamaan 1 juga dapat diaplikasikan pada VARIMA dengan setiap order dan variabel berupa vektor.

Terdapat empat langkah untuk ARIMA dan VARIMA yaitu identifikasi, estimasi parameter, uji diagnostik dan peramalan [9]–[12]. Keempat langkah tersebut dapat digambarkan pada Gb 1.



Gambar 1. Langkah-langkah ARIMA dan VARIMA

Tahap identifikasi meliputi penentuan menggunakan  $\theta_0$ , melihat kestasioneran data, dan menentukan orde pada model. Penentuan orde pada ARIMA berdasarkan ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*). Sedangkan pada VARIMA berdasarkan CCF (*Cross Correlation Function*) dan PCCF (*Partial Cross Correlation Function*). Tahap kedua ialah estimasi parameter. ARIMA dan VARIMA biasanya menggunakan *Ordinary Least Square* atau *Maximum likelihood*. Setelah parameter diestimasi, akan dilakukan pengujian signifikansi parameter. Tahap berikutnya adalah uji diagnostik yang meliputi uji residual *white noise* dan berdistribusi normal. Setelah terpenuhi setiap tahap, akan dilakukan peramalan.

## METODE PENELITIAN

### Sumber Data dan Variabel Penelitian

Penelitian ini menggunakan data IHSG harian dari tahun 2000 sampai 2016 (sebanyak 4106 data *training*) dan tahun 2017 (sebanyak 239 data *testing*). Data penelitian diperoleh melalui *website* <http://finance.yahoo.com/q/hp?s=%5JKSE+Historical+Price>.

### Metode Analisis

Metode yang digunakan adalah ARIMA dan VARIMA. Kedua metode akan dibandingkan nilai RMSE (*Root Mean Square Error*) pada data *training* maupun *testing*. Penelitian ini menggunakan *conditional least square* untuk estimasi parameter ARIMA dan VARIMA

## HASIL PENELITIAN

Sebelum dilakukan peramalan menggunakan ARIMA dan VARIMA, data IHSG dapat disajikan pada Gambar 2.



Gambar 2. Candlestick Plot untuk IHSG


Berdasarkan Gambar 2, dapat diketahui bahwa data *open*, *high*, *low*, dan *close* dari IHSG semakin naik. Dengan kata lain, data IHSG tidak stasioner dalam rata-rata (baik untuk univariat maupun multivariat). Sehingga diperlukan *differencing lag 1* untuk menstasionerkan. Selain itu, data IHSG tidak menunjukkan adanya pola musiman. Berikut ini merupakan analisis univariat ARIMA dan multivariat

ARIMA (disebut dengan VARIMA) untuk peramalan IHSG.


### Univariat ARIMA

Analisis pertama pada penelitian adalah univariat ARIMA, dimana dilakukan peramalan harga *open*, *high*, *low*, dan *close* IHSG secara individu. Terdapat 4 langkah dalam analisis ARIMA berdasarkan Box-Jenkins yaitu identifikasi, estimasi parameter, cek diagnostik, dan peramalan.

*Opening* IHSG merupakan data pertama yang akan dianalisis ARIMA. Tahap pertama ialah melakukan identifikasi. Berdasarkan Gambar 2, data *opening* IHSG tidak stasioner sehingga diperlukan *differencing lag 1*. Selain itu, penelitian ini juga menggunakan  $\theta_0$ . Kemudian data yang telah di-*differencing lag 1* digunakan untuk membuat ACF dan PACF seperti berikut.



Gambar 3. ACF dari *Opening* IHSG *Differencing Lag 1*



Gambar 4. PACF dari *Opening* IHSG *Differencing Lag 1*

Berdasarkan Gambar 3, dapat diketahui bahwa lag yang keluar batas meliputi 1, 3, 4, 6, 26, 33, 35, 36, dan 54.

Akan tetapi penelitian ini menggunakan lima lag ACF yang paling tinggi keluar batas yaitu 1, 3, 26, 33, dan 35. Sedangkan Gambar 4 menunjukkan bahwa 5 lag PACF yang paling tinggi keluar batas ialah 1, 3, 26, 33, dan 65. Sehingga model yang memungkinkan adalah ARIMA([1,3,26,33,65], 1,0) dan ARIMA(0, 1, [1,3,26,33,35]). Model pertama ARIMA([1,3,26,33,65], 1,0) diestimasi menggunakan *conditional least square* seperti yang ditampilkan pada Tabel 1

**Tabel 1.** Estimasi Parameter ARIMA([1,3,26,33,65], 1,0)

Parameter	Estimasi	P-value	Kesimpulan
$\theta_0$	1.13	0.0278	Signifikan
$\phi_1$	0.05	0.0022	Signifikan
$\phi_3$	-0.07	<0.001	Signifikan
$\phi_{26}$	0.07	<0.001	Signifikan
$\phi_{33}$	-0.06	0.0002	Signifikan
$\phi_{65}$	-0.04	0.0201	Signifikan

Berdasarkan Tabel 1, dapat diketahui bahwa semua parameter ARIMA([1,3,26,33,65], 1,0) telah signifikan. Sehingga model ARIMA tersebut dapat ditulis seperti berikut (2):

$$(1 + 0.05B^1 - 0.07B^3 + 0.07B^{26} - 0.06B^{33} - 0.04B^{65})(1 - B)y_t = 1.13 + a_t \quad (2)$$

Tahap berikutnya adalah uji diagnostik. Berdasarkan nilai p-value pada *autocorrelation check of residuals* bernilai kurang dari 0.05 sehingga residual tidak *white noise*. Sedangkan uji diagnostik kedua adalah residual berdistribusi normal. Uji tersebut menggunakan Kolmogorov-smirnov sebesar 0.13449 dan p-value < 0.01 sehingga dapat disimpulkan bahwa residual tidak berdistribusi normal.

Model ARIMA(0, 1, [1,3,26,33,35]) untuk data *open* dilakukan pengujian yang menyerupai dengan ARIMA([1,3,26,33,65], 1,0). Model ARIMA(0, 1, [1,3,26,33,35])

menghasilkan parameter yang signifikan, residual tidak *white noise*, akan tetapi residual tidak berdistribusi normal.

Data *High* tidak stasioner (berdasarkan Gambar 2) sehingga perlu di-*differencing* lag 1. Data yang telah stasioner dibuat ACF (5 lag yang keluar batas meliputi 1, 11, 26, 33, dan 59) dan PACF (5 lag yang keluar batas meliputi 1, 2, 11, 33, dan 59). Sehingga terdapat 2 kemungkinan model untuk data *high* yaitu ARIMA([1,2,11,33,59], 1, 0) dan ARIMA(0, 1, [1,11,26,33,59]). Kedua model ARIMA untuk data *high* memiliki parameter yang signifikan (termasuk konstanta), residual tidak *white noise* dan residual tidak berdistribusi normal.

Data ketiga adalah *low* IHSG. Berdasarkan Gambar 2, *low* IHSG tidak stasioner sehingga memerlukan *differencing* lag 1. Data yang stasioner memiliki lag ACF keluar batas meliputi 1, 3, 4, 35, dan 36. Sedangkan lag PACF keluar batas meliputi 1, 2, 3, 35, dan 65. Sehingga kemungkinan model *low* IHSG adalah ARIMA([1,2,3,35,65], 1, 0) dan ARIMA(0, 1, [1,3,4,35,36]). Kedua model ARIMA untuk data *high* memiliki parameter yang signifikan (kecuali konstanta), residual tidak *white noise* dan residual tidak berdistribusi normal.

Sedangkan kemungkinan model ARIMA untuk data *close* IHSG adalah ARIMA([1,3,6,26,67], 1, 0) dan ARIMA(0, 1, [1,3,6,26,35]). Kedua model tersebut berdasarkan Gambar 2 (menggunakan *differencing* lag 1), lag ACF (meliputi 1, 3, 6, 26, dan 35), serta lag PACF (meliputi 1, 3, 6, 26, dan 67). Kedua model ARIMA untuk *close* IHSG memiliki parameter yang signifikan (termasuk konstanta), residual tidak *white noise* dan residual tidak berdistribusi normal.

## VARIMA

VARIMA merupakan pengembangan ARIMA untuk data multivariat. Langkah-langkah pada VARIMA hampir sama

dengan ARIMA yaitu identifikasi, estimasi parameter, uji diagnostik dan peramalan. Berdasarkan Gambar 2, dapat diketahui bahwa data *open*, *high*, *low*, dan *close* IHSG tidak stasioner sehingga


dapat diestimasi dengan *conditional least square*. Model VARIMA(3,1,0) terdapat beberapa parameter yang tidak signifikan. Sehingga parameter tersebut dikeluarkan dari model dan diestimasi

$$\begin{bmatrix} -0.70 JCI_{t-1}^{open} - 0.37 JCI_{t-2}^{open} - 0.07 JCI_{t-3}^{open} + 0.97 JCI_{t-1}^{close} + 0.62 JCI_{t-2}^{close} + 0.30 JCI_{t-3}^{close} \\ 0.07 JCI_{t-3}^{open} - 0.72 JCI_{t-1}^{high} - 0.46 JCI_{t-2}^{high} - 0.22 JCI_{t-3}^{high} + 0.84 JCI_{t-1}^{close} + 0.54 JCI_{t-2}^{close} + 0.25 JCI_{t-3}^{close} \\ -0.07 JCI_{t-1}^{high} - 0.68 JCI_{t-1}^{low} - 0.42 JCI_{t-2}^{low} - 0.22 JCI_{t-3}^{low} + 0.94 JCI_{t-1}^{close} + 0.55 JCI_{t-2}^{close} + 0.22 JCI_{t-3}^{close} \\ -0.03 JCI_{t-3}^{open} + 0.07 JCI_{t-1}^{close} - 0.08 JCI_{t-3}^{close} \end{bmatrix} (1-B)^1 \begin{bmatrix} JCI_t^{open} \\ JCI_t^{high} \\ JCI_t^{low} \\ JCI_t^{close} \end{bmatrix} = \alpha_t \quad (3)$$


$$\begin{bmatrix} -0.15 JCI_{t-1}^{open} - 0.07 JCI_{t-1}^{high} + 0.91 JCI_{t-1}^{close} \\ 0.17 JCI_{t-1}^{open} - 0.52 JCI_{t-1}^{high} + 0.71 JCI_{t-1}^{close} - 0.04 JCI_{t-3}^{close} \\ 0.15 JCI_{t-1}^{open} - 0.02 JCI_{t-3}^{open} - 0.10 JCI_{t-1}^{high} - 0.47 JCI_{t-1}^{low} + 0.78 JCI_{t-1}^{close} - 0.08 JCI_{t-3}^{close} \\ 0.07 JCI_{t-1}^{close} - 0.10 JCI_{t-3}^{close} \end{bmatrix} (1-B)^1 \begin{bmatrix} JCI_t^{open} \\ JCI_t^{high} \\ JCI_t^{low} \\ JCI_t^{close} \end{bmatrix} = \alpha_t \quad (4)$$

perlu di-differencing lag 1. Data yang telah stasioner digunakan untuk membuat CCF dan PCCF seperti Gb. 5 dan Gb. 6 berikut.

ulang sampai dengan semua parameter signifikan. Berdasarkan parameter yang signifikan tersebut, dapat ditulis model VARIMA(3,1,0) seperti pada persamaan 3.



Gambar 5. CCF data *Open*, *High*, *Low*, *Close* IHSG



Gambar 6. PCCF data *Open*, *High*, *Low*, *Close* IHSG

Nilai lag yang digunakan sebagai model VARIMA berdasarkan CCF dan PCCF adalah jumlah (+) atau (-) minimal 3 pada setiap variabel. Berdasarkan Gambar 5 dapat diketahui bahwa lag 1 memiliki jumlah (-) sebanyak 4 untuk setiap *open*, *high*, *low*, dan *close*. Sehingga lag 1 dimasukkan dalam model VARIMA. Selain lag 1, lag yang digunakan ialah 3, 35, 176, dan 221. Dengan menggunakan prinsip yang sama seperti CCF, lag PCCF yang masuk dalam model VARIMA meliputi lag 1, 2, dan 3. Sehingga terdapat dua kemungkinan model VARIMA yaitu VARIMA(3, 1, 0) dan VARIMA(0,1, [1,3,35,176,221]). Akan tetapi model VARIMA(0,1, [1,3,35,176,221]) tidak

Sama seperti model ARIMA, tahap berikutnya adalah tahap uji diagnostik. Model VARIMA(3,1,0) tidak multivariat white noise dan tidak berdistribusi multivariat normal. Karena p-value yang dihasilkan sebesar  $< 0.001$  dimana kurang dari 0.05..

Selain menggunakan CCF dan PCCF, penelitian ini juga menggunakan hasil univariat ARIMA sebagai dasar pemodelan VARIMA. Berdasarkan model ARIMA data *open*, *high*, *low*, dan *close* IHSG dengan minimal lag yang signifikan berada pada 3 data. Sehingga kemungkinan model VARIMA adalah VARIMA([1,3],1,0) dan VARIMA(0,1,[1,3,26,35]).

Model VARIMA([1,3],1,0) terdapat beberapa parameter yang tidak signifikan. Sehingga parameter tersebut dikeluarkan dari model dan diestimasi ulang sampai dengan semua parameter signifikan. Berdasarkan parameter yang signifikan tersebut, dapat ditulis model VARIMA([1,3],1,0) seperti pada persamaan 4. Selain itu, model tersebut juga tidak memenuhi uji diagnostik (tidak multivariat *white noise* dan tidak berdistribusi multivariat normal).

**Perbandingan ARIMA dan VARIMA**

Model ARIMA dan VARIMA yang telah signifikan, dibandingkan nilai RMSE dan ketepatan peramalan *high* serta *low*. Kedua perbandingan tersebut dilakukan secara multivariate. Model univariat setiap data *open*, *high*, *low*, dan *close* dikelompokkan menjadi dua yaitu model univariat ARI dan univariat IMA. Univariat ARI diperoleh dengan hasil peramalan *open* dengan model ARIMA([1,3,26,33,65], 1,0), peramalan *high* ARIMA([1,2,11,33,59], 1, 0), peramalan *low* ARIMA([1,2,3,35,65], 1, 0), dan peramalan *close* ARIMA([1,3,6,26,67], 1, 0). Begitu pula dengan model univariat IMA. Sedangkan model multivariat yang diperoleh penelitian ini meliputi VARIMA(3, 1, 0) dan VARIMA([1,3],1,0).

Nilai RMSE data *training* dan *testing* untuk keempat model dapat ditabelkan pada Tb. 2 berikut.

**Tb. 2.** RMSE Data *Training* dan *Testing*

Model	<i>Training</i>	<i>Testing</i>
Univariat ARI	2484.34	4749.64
Univariat IMA	2484.36	4742.74
Multivariat VARIMA(3,1,0)	2484.80	4581.06
Multivariat VARIMA([1,3],1,0)	2484.78	4589.40

Berdasarkan Tb. 2, dapat diketahui bahwa model univariat ARI merupakan model terbaik pada data *training*. Sedangkan model VARIMA(3, 1, 0) adalah model terbaik pada data *testing*. Model tersebut diperoleh berdasarkan CCF dan PCCF. Kedua model multivariat lebih akurasi dibandingkan model univariat pada data *testing*. Akan tetapi melihat besarnya keempat model tidak baik digunakan untuk peramalan jangka panjang (harian selama setahun). Selain RMSE, penelitian ini juga melihat akurasi peramalan *high* dan *low* yang dapat ditabelkan seperti berikut.

**Tb. 3.** Ketepatan Peramalan *High* dan *Low*

	<i>Training</i>		<i>Testing</i>	
	<i>High</i>	<i>Low</i>	<i>High</i>	<i>Low</i>
Univariat ARI	67.9%	74.8%	100.0%	6.7%
Univariat IMA	68.3%	75.2%	100.0%	92.1%
Multivariat VARIMA(3,1,0)	99.7%	99.8%	100.0%	100.0%
Multivariat VARIMA([1,3],1,0)	98.1%	98.8%	100.0%	100.0%

Berdasarkan Tb. 3, dapat diketahui bahwa model multivariat lebih baik dalam meramalkan *high* dan *low* daripada model univariat. Terutama pada data *testing* dimana semua ramalannya 100% tepat untuk *high* dan *low*. Sedangkan pada *training* hampir mendekati 100%. Selain itu, penetapan orde berdasarkan CCF dan PCCF lebih baik daripada berdasarkan model ARIMA.

**KESIMPULAN**

Terdapat empat model untuk IHSG yaitu univariat ARI, univariat IMA, multivariat VARIMA(3,1,0) yang berdasarkan CCF dan PCCF serta multivariat VARIMA([1,3],1,0) berdasarkan lag pada ARIMA. Berdasarkan ketepatan peramalan *high* dan *low*, model multivariat lebih akurat dibandingkan dengan univariat. Hal tersebut dikarenakan model multivariat menyimpan sifat yang berlaku antar variabel. Sedangkan model univariat meramalkan data *open*, *high*, *low*, *close* secara independen.

Model multivariat juga model yang paling baik daripada model univariat berdasarkan RMSE *testing*. Terutama model multivariate yang menggunakan CCF dan PCCF sebagai dasar penentuan orde model. Sedangkan RMSE *training* menunjukkan bahwa model univariat dan multivariat tidak memiliki perbedaan yang signifikan.

---



---

**DAFTAR PUSTAKA**

- [1] D. A. Lusia and Muntari, Perbandingan Risk dan Return Investasi Saham Indonesia, Gold, dan EURUSD dengan Inflasi, *Jurnal Spirit Pro Patria*, vol. 2, no. 2, pp. 8–16, 2016.
- [2] A. Damodaran, *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset*, 3rd ed. New Jersey: John Wiley & Sons, 2012.
- [3] J. J. Murphy, *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. United States: New York Institute of Finance, 1999.
- [4] D. L. Nurini and B. Sutijo, Metode Peramalan Indeks Harga Saham Gabungan (IHSG), Nikkei 255 dengan Pendekatan Fungsi Transfer, vol. 2, no. 2, pp. D271–D274, Sep. 2013.
- [5] D. L. Nurini and B. Sutijo, Metode Peramalan Indeks Harga Saham Gabungan (IHSG) Nikkei 255 dengan Pendekatan Fungsi Transfer, *Journal Sains Dan Seni ITS*, vol. 2, no. 2, pp. D271–D274, Sep. 2013.
- [6] S. Hansun, Penerapan WEMA dalam Peramalan Data IHSG, *Journal Ultimatics*, vol. 5, no. 2, pp. 63–66, Dec. 2013.
- [7] S. Hansun, Peramalan Data IHSG Menggunakan Metode Backpropagation, *Journal Ultimatics*, vol. 5, no. 1, pp. 26–30, Jun. 2013.
- [8] S. Hansun, Peramalan Data IHSG Menggunakan Fuzzy Time Series, *IJCCS Indones. J. Comput. Cybern. Syst.*, vol. 6, no. 2, pp. 79–88, Jul. 2012.
- [9] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*. John Wiley & Sons, 2015.
- [10] S. Makridakis, S. C. Wheelwright, and M. McGee, *Forecasting: Methods and Applications*, 2nd ed. New York: Wiley, 1983.
- [11] W. W. S. Wei, *Time Series Analysis: Univariate and Multivariate Methods (2nd Edition)*, 2nd ed. Pennsylvania: Addison Wesley, 2005.
- [12] D. Cryer and K.-S. Chan, *Time Series Analysis: With Applications in R*. Springer Science & Business Media, 2008.