

RESEARCH ARTICLE • OPEN ACCESS

Penerapan Hybrid Metode ARFIMA-ANN Menggunakan Algoritma Backpropagation pada Peramalan Indeks Harga Saham Gabungan

Rayhanul Jannah Buhungo, Isran K. Hasan dan Nurwan



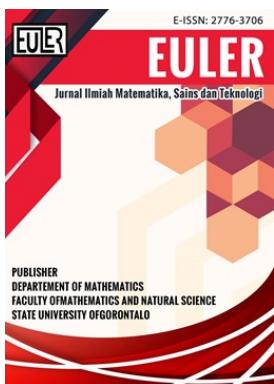
Volume 12, Issue 2, Pages 200–205, Dec 2024

Diterima 22 Oktober 2024, Direvisi 10 Desember 2024, Disetujui 16 Desember 2024, Diterbitkan 17 Desember 2024

To Cite this Article : R. J. Buhungo, I. K. Hasan dan N. Nurwan, "Penerapan Hybrid Metode ARFIMA-ANN Menggunakan Algoritma Backpropagation pada Peramalan Indeks Harga Saham Gabungan", *Euler J. Ilm. Mat. Sains dan Teknol.*, vol. 12, no. 2, pp. 200–205, 2024, <https://doi.org/10.37905/euler.v12i2.28474>

© 2024 by author(s)

JOURNAL INFO • EULER : JURNAL ILMIAH MATEMATIKA, SAINS DAN TEKNOLOGI

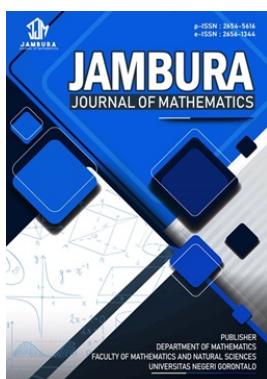


	Homepage	:	http://ejurnal.ung.ac.id/index.php/euler/index
	Journal Abbreviation	:	Euler J. Ilm. Mat. Sains dan Teknol.
	Frequency	:	Biannual (June and December)
	Publication Language	:	English (preferable), Indonesia
	DOI	:	https://doi.org/10.37905/euler
	Online ISSN	:	2776-3706
	License	:	Creative Commons Attribution-NonCommercial 4.0 International License
	Publisher	:	Department of Mathematics, Universitas Negeri Gorontalo
	Country	:	Indonesia
	OAI Address	:	http://ejurnal.ung.ac.id/index.php/euler/oai
	Google Scholar ID	:	QF_r_gAAAAJ
	Email	:	euler@ung.ac.id

JAMBURA JOURNAL • FIND OUR OTHER JOURNALS



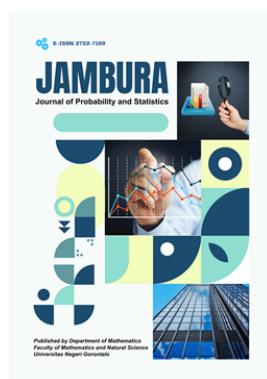
Jambura Journal of Biomathematics



Jambura Journal of Mathematics



Jambura Journal of Mathematics Education



Jambura Journal of Probability and Statistics

Penerapan Hybrid Metode ARFIMA-ANN Menggunakan Algoritma Backpropagation pada Peramalan Indeks Harga Saham Gabungan

Rayhanul Jannah Buhungo¹, Isran K. Hasan^{1,*} dan Nurwan¹

¹Jurusan Matematika, Fakultas MIPA, Universitas Negeri Gorontalo, Gorontalo, Indonesia

ARTICLE HISTORY

Diterima 22 Oktober 2024

Direvisi 10 Desember 2024

Disetujui 16 Desember 2024

Diterbitkan 17 Desember 2024

KATA KUNCI

ARFIMA
ANN
Hybrid

Indeks Harga Saham Gabungan

KEYWORDS

ARFIMA
ANN
Hybrid

Composite Stock Price Index

ABSTRAK. Indeks Harga Saham Gabungan (IHSG) menjadi salah satu hal yang menjadi standar suatu negara dalam melihat keadaan ekonomi. Pergerakan indeks harga saham yang naik turun menciptakan ketidakpastian di pasar saham yang menyulitkan para investor dan pemerintah dalam mengambil sebuah keputusan. Untuk itu, diperlukan suatu metode yang dapat meramalkan indeks harga saham gabungan untuk memantau pergerakan tersebut. Tujuan dari penelitian ini adalah untuk memodelkan indeks harga saham gabungan menggunakan metode hybrid dan mengetahui tingkat akurasi dari metode hybrid. Metode hybrid yang digunakan adalah Autoregressive Fractionally Integrated Moving Average (ARFIMA)-Artificial Neural Network (ANN). Hasil penelitian ini menunjukkan bahwa model terbaik pada model ARFIMA adalah model ARFIMA (1,d,1) dengan menggunakan parameter pembeda dR/S. Untuk pemodelan ANN dengan menggunakan algoritma backpropagation, didapatkan model terbaik ANN (3,2,1). Tingkat akurasi yang diperoleh pada model hybrid ARFIMA-ANN berdasarkan nilai MAPE menghasilkan nilai sebesar 1,0164%, yang lebih kecil dari model ARFIMA tunggal sebesar 1,7326%. Oleh karena itu, dapat disimpulkan bahwa model hybrid dapat meningkatkan akurasi hasil peramalan.

ABSTRACT. The Composite Stock Price Index (IHSG) is a of the key indicator a country uses to assess its economic condition. The fluctuating movements of stock prices create uncertainly in the stock market, complicating decision-making for investors and government entities. Therefore, there is a need for a method that can forecast the Composite Stock Price Index to monitor such fluctuations. The objective of this study is to model the Composite Stock Price Index Utilizing a hybrid method and to assess the accuracy of this hybrid approach. The hybrid method employed is the Autoregressive Fractionally Integrated Moving Average (ARFIMA)-Artificial Neural Network (ANN). The results of this study show that the best ARFIMA model is ARFIMA (1,d,1) with a differencing parameter of dR/S = 0.362. The ANN model's optimal architecture obtained through the backpropagation algorithm is ANN (3,2,1). The accuracy of the hybrid ARFIMA-ANN model, measured by the Mean Absolute Percentange Error (MAPE), yielded of 1.0164%, lower than the MAPE value of 1.7326% for the standalone ARFIMA model. This suggests that the hybrid model improves forecasting accuracy and is the most efferctive model for predicting the IHSG.



This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonComercial 4.0 International License. **Editorial of EULER:** Department of Mathematics, Universitas Negeri Gorontalo, Jln. Prof. Dr. Ing. B. J. Habibie, Bone Bolango 96554, Indonesia.

1. Pendahuluan

Investasi saham kini menjadi pilihan yang menarik bagi investor, karena melalui investasi saham, para investor memiliki peluang untuk mendapatkan profit berupa dividen dan *capital gain* [1]. Suatu acuan yang menjadi salah satu pertimbangan investor dalam berinvestasi adalah Indeks Harga Saham Gabungan (IHSG) [2]. IHSG merupakan indeks harga saham yang memperlihatkan gambaran perubahan harga-harga sekelompok saham perusahaan yang diperdagangkan di Bursa Efek Indoensia, mencerminkan kinerja pasar saham secara keseluruhan [3]. IHSG termasuk dalam salah satu standar suatu negara untuk melihat kondisi perekonomiannya. Ketika indeks harga saham pada suatu negara mengalami penurunan, seringkali diartikan sebagai tanda adanya permasalahan atau ketidakstabilan ekonomi dalam negara tersebut. Sebaliknya, apabila terjadi peningkatan pada indeks harga

saham gabungan, hal tersebut dianggap sebagai indikasi perbaikan kinerja ekonomi yang positif di dalam negara tersebut [4].

Pergerakan indeks harga saham yang naik turun menciptakan ketidakpastian di pasar saham sehingga menyulitkan para investor dan pemerintah untuk mengambil sebuah keputusan. Peramalan IHSG menjadi solusi penting untuk dilakukan. Dengan meramalkan pergerakan IHSG membantu pihak-pihak terkait untuk memahami dan mengantisipasi ketidakpastian dan memberikan gambaran yang lebih akurat tentang pergerakan IHSG di masa depan. Sehingga dapat merencanakan strategi dalam proses pengambilan keputusan [5].

Autoregressive Fractionally Integrated Moving Average (ARFIMA) dan *Artificial Neural Network (ANN)* adalah dua metode yang dapat digunakan dalam peramalan. Metode ARFIMA merupakan metode yang digunakan khusus untuk mengatasi masalah dimana terdapat ketergantungan jangka panjang (*long memory*) dalam data [6]. Kelebihan metode ARFIMA adalah mampu memodelk-

*Penulis Korespondensi.

an persistensi jangka panjang, memiliki derajat integrasi fraksional yang memungkinkan *differencing* atau pembedaan pada nilai estimasi parameter pembeda d berupa bilangan desimal [7]. Sementara itu, metode ANN merupakan metode kecerdasan buatan yang memiliki kelebihan, yaitu: menangkap pola-pola nonlinear dalam data [8], Singh [9], dan Cheng, dkk. [7]. Model-model ini memiliki cara defuzzifikasi yang berbeda untuk mendapatkan nilai ramalan. Chen mengusulkan penggunaan rata-rata dalam mendapatkan nilai ramalan [8]. Dalam ANN, terdapat sebuah algoritma yang melatih jaringan untuk mengimbangi kemampuan mengenali pola dan memberikan tanggapan tepat terhadap input yang sebanding dengan pola pelatihan, yaitu: algoritma *backpropagation* [9].

Sejumlah penelitian menunjukkan bahwa jika dua metode dikombinasikan dapat meningkatkan akurasi peramalan. Metode ini disebut dengan metode *hybrid*. *Hybrid* metode pada prinsipnya bertujuan untuk memanfaatkan kelebihan masing-masing metode sehingga meminimumkan error yang dapat meningkatkan keakuratan hasil ramalan [10]. Susila, et. al [11] meramalkan peredaran uang elektronik di Indonesia menggunakan *hybrid* model dan non *hybrid*. Hasil penelitian menunjukkan bahwa model *hybrid* dengan metode ARIMA-*Artificial neural network* dapat meningkatkan akurasi ramalan karena memiliki nilai error paling kecil dibandingkan dengan model ARIMA. Penelitian lain juga dikembangkan oleh Talyudin, et. al [12], yang membahas tentang pemodelan mortality pasien COVID-19 dengan menggunakan metode kombinasi SARIMA-LSTM. Kajian tersebut menghasilkan kesimpulan bahwa model *hybrid* memiliki akurasi paling tinggi dibandingkan dengan model SARIMA dan LSTM. Penelitian lainnya dilakukan juga Hasan dan Djakaria [13] yang membandingkan akurasi peramalan dari model ARIMA, *hybrid* ARIMA-NN dan *hybrid* ARIMA-GARCH pada peramalan nilai tukar petani di Provinsi Gorontalo. Kajian ini menghasilkan model *hybrid* ARIMA-NN menjadi model paling baik diantara dua model lainnya dengan melihat MAPE dan RMSE terkecil. Kemudian model *hybrid* ARIMA (*Autoregressive integrated moving average*)-ANN (*artificial neural network*) juga telah digunakan oleh Kamadewi dan Achmad [14] untuk memodelkan inflasi di Indoensia tahun 2009-2020. Penelitian ini menunjukkan bahwa model *hybrid* lebih akurat dibandingkan dengan model tunggal. Pada penelitian yang dilakukan oleh Zalan dan Yaseen [15] dengan menggunakan metode Fuzzy-ARFIMA dalam memprediksi kelahiran di Kegubernuran Basra, didapatkan kesimpulan bahwa Fuzzy-Arfima merupakan model yang lebih baik dalam memprediksi karena memiliki nilai kriteria akurasi prediksi yang lebih rendah.

Hasil penelusuran pada kajian sebelumnya menunjukkan bahwa belum ada penelitian yang mengkombinasikan ARFIMA dan ANN. Oleh karena itu, penelitian ini bertujuan untuk memodelkan indeks harga saham gabungan menggunakan metode *hybrid* ARFIMA-ANN dan mengetahui hasil peramalan IHSG dengan melihat tingkat akurasi dari metode *hybrid*. Metode ARFIMA-ANN dipilih karena kombinasi kelebihan masing-masing metode saling melengkapi dalam analisis deret waktu. ARFIMA (*AutoRegressive Fractional Integrated Moving Average*) memiliki keunggulan dalam menangkap sifat non-stasioner dan memori jangka panjang dari data, sehingga lebih efektif dalam menganalisis pola yang menunjukkan perilaku musiman atau tren yang kompleks dibandingkan dengan metode lainnya, seperti ARIMA atau

SARIMA. Di sisi lain, ANN (*Artificial Neural Networks*) menawarkan kemampuan dalam menangkap pola non-linier dalam residual data, yang seringkali tidak dapat dimodelkan dengan metode lainnya seperti ARFIMA. Dalam implementasi ini, algoritma *backpropagation* digunakan untuk melatih jaringan saraf, memungkinkan pembaruan bobot secara efisien berdasarkan kesalahan output, sehingga meningkatkan akurasi prediksi model. Dengan menggabungkan kedua metode ini, dapat diperoleh hasil yang lebih akurat dalam memprediksi nilai deret waktu yang dalam hal ini adalah indeks harga saham gabungan.

2. Metode

Data pada penelitian berupa data sekunder tentang data harian harga *close* Indeks Harga Saham Gabungan (IHSG) dan didapatkan dari website finance.yahoo.com. Periode data yang digunakan mulai dari bulan Januari 2021 sampai Februari 2024, yakni: sebanyak 771 data. Jumlah data harian yang hanya mencapai 771 data dari periode Januari 2021 hingga Februari 2024 ini disebabkan oleh tidak adanya perdagangan pada hari libur dan akhir pekan sehingga mempengaruhi jumlah hari perdagangan bursa. Data terdiri dari data latih (*training*) untuk menghasilkan model dan data uji (*testing*) untuk menguji validitas hasil ramalan. Pada data *training*, digunakan data dari bulan Januari 2021 sampai Januari 2024 dan data *testing* menggunakan data bulan Februari 2024. Penelitian ini diolah menggunakan *software R Studio*.

Tahapan penelitian yang dilakukan oleh peneliti secara detail diuraikan sebagai berikut:

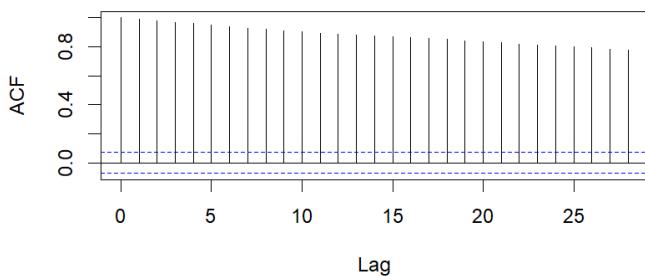
1. Menyiapkan data penelitian.
2. Memplot data *time series*.
3. Mengidentifikasi jangka panjang (*long memory*).
4. Menguji kestasioneran data menggunakan uji ADF untuk mean dan uji Box-cox untuk varian dan jika tidak stasioner dilakukan *differencing* untuk mean dan transformasi untuk varian.
5. Menentukan nilai estimasi parameter pembeda (d) menggunakan *Rescaled Range Statistics* (R/S).
6. Melakukan *differencing* fraksional dengan memanfaatkan nilai yang diestimasi dari parameter pembeda (d).
7. Memplot fungsi autokorelasi (ACF), fungsi autokorelasi parzial (PACF) untuk mengestimasi parameter (d).
8. Menentukan model ARFIMA (p,d,q) dan mengukur parameter ϕ dan θ melalui estimasi untuk masing-masing model.
9. Melakukan penentuan model yang signifikan dengan melihat nilai AIC (*Akaike Information Criterion*) terkecil.
10. Melakukan uji diagnostik model untuk melihat apakah residual model bersifat *white noise*.
11. Menginput data residual ARFIMA sebagai input ANN.
12. Melakukan perancangan model ANN menggunakan algoritma *backpropagation*.
13. Melakukan peramalan ANN *backpropagation*.
14. Pemodelan *hybrid* ARFIMA-ANN.
15. Melakukan peramalan *hybrid* ARFIMA-ANN serta evaluasi kriteria model menggunakan MAPE.

3. Hasil dan Pembahasan

3.1. Mengidentifikasi *long memory* (jangka Panjang)

Proses memori jangka panjang dilakukan untuk menentukan apakah data memiliki keterkaitan jangka panjang. Pola *long*

memory dapat diidentifikasi dengan mengamati plot *Autocorrelation Function* yang menunjukkan penurunan perlahan atau pola hiperbolik.

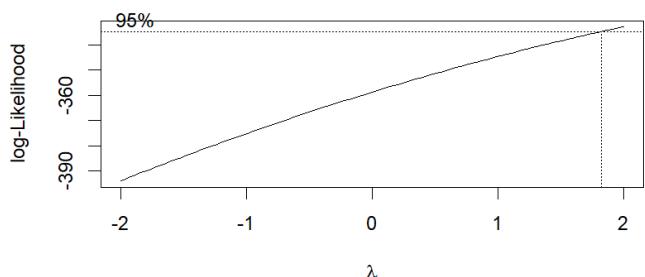


Gambar 1. Plot ACF data *training* harga *close* indeks harga saham gabungan

Berdasarkan Gambar 1, data *training* harga *close* indeks harga saham gabungan menunjukkan plot ACF yang *lag*-nya turun secara perlahan membentuk pola hiperbolik. Sehingga menunjukkan bahwa data memiliki keterkaitan jangka panjang yang dapat dikonfirmasi dengan melihat nilai statistik *hurst*. Hasil perhitungan nilai statistik *hurst* menggunakan *software R Studio* didapatkan nilai sebesar 0,862. Berdasarkan uji *hurst* ketika $0,5 < H < 1$, artinya bahwa data harga *close* IHSG terindikasi *long memory*.

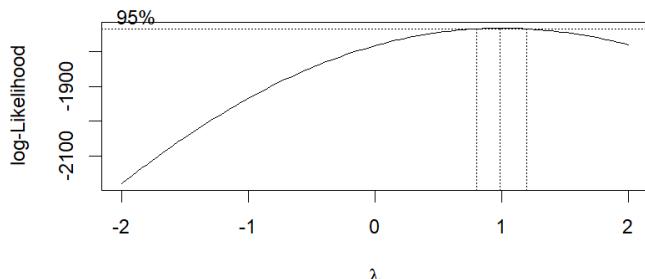
3.2. Uji Stasioner Data

Untuk melakukan pemodelan ARFIMA, sebelumnya dilakukan uji kestasioneran data berupa uji stasioner dalam varian dan *mean*. Uji stasioner dalam varian menggunakan uji *box-cox* dengan syarat nilai lamda (λ) = 1.



Gambar 2. Plot data *training* uji stasioner dalam varian

Gambar 2 menunjukkan bahwa data tidak memiliki kestasioneran dalam varian karena nilai lamda ($\lambda \neq 1$), sehingga diperlukan transformasi.



Gambar 3. Plot data *training* uji stasioner dalam varian setelah transformasi

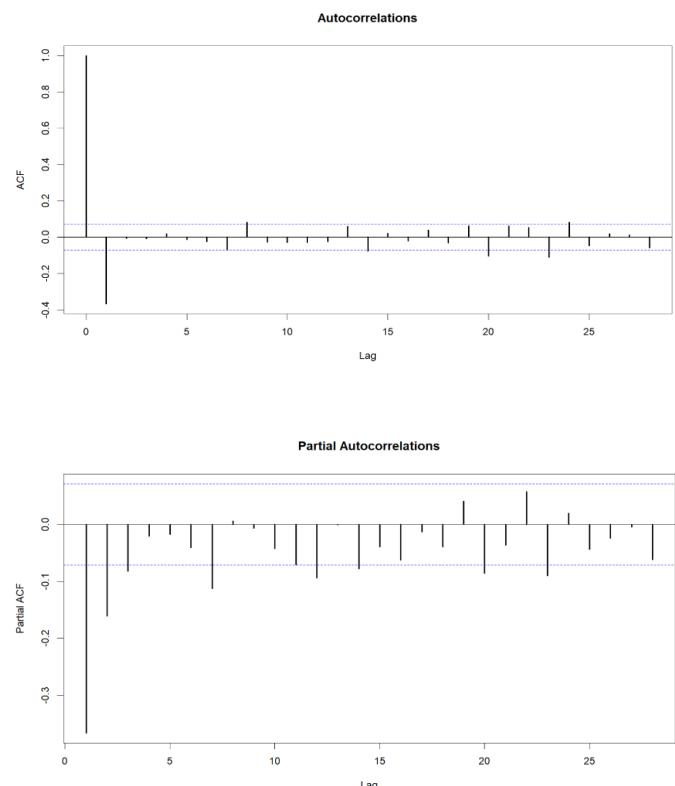
Gambar 3 menunjukkan bahwa setelah melakukan transformasi, diperoleh nilai lamda (λ) sebesar 1. Hal ini bermakna bahwa data telah stasioner dalam varians. Selanjutnya, untuk menguji stasioneritas dalam *mean*, dilakukan uji ADF yang menghasilkan nilai *p-value* sebesar 0,226. Karena nilai ini melebihi nilai taraf signifikan (α), yaitu: 0,05 maka kestasioneratan dalam *mean* pada data masih belum terpenuhi. Oleh karena itu, *differencing* diperlukan untuk menstasionerkan data dalam *mean*. Setelah dilakukan *differencing*, hasil uji ADF menunjukkan bahwa *p-value* = 0,01. Nilai ini kurang dari taraf signifikan (α). Artinya, kestasioneran dalam *mean* telah terpenuhi

3.3. Estimasi parameter diferensial *d*

Parameter diferensial *d* dalam ARFIMA diestimasi melalui penerapan metode *R/S*. Dari perhitungan estimasi parameter *d* untuk data *training close price* indeks harga saham gabungan dengan menggunakan *software R studio* didapatkan nilai *dR/S* = 0,362. Nilai ini terletak dalam rentang $0 < d < 0,5$. Artinya data menunjukkan hubungan positif jangka panjang diantara observasi.

3.4. Identifikasi model ARFIMA (*p,d,q*)

Model ARFIMA diidentifikasi dengan merujuk pada plot ACF dan plot PACF dari data yang telah di-*differencing* berdasarkan nilai parameter *d* yang digunakan. Pemilihan model dilakukan dengan mengamati *lag* di luar garis batas kepercayaan (garis biru) pada plot ACF dan PACF.



Gambar 4. Plot ACF dan PACF differensial $d_{R/S} = 0,362$

Gambar 4 menunjukkan bahwa terdapat *lag-lag* yang melewati garis berwarna biru. Menenerapkan prinsip *parcimony*, model ARFIMA yang diperoleh yaitu 14 model.

Tabel 1. Perancangan Model ARFIMA

Model	MA0	MA1	MA8
AR0	-	ARFIMA(0,d,1)	ARFIMA(0,d,8)
AR1	ARFIMA(1,d,0)	ARFIMA(1,d,1)	ARFIMA(1,d,8)
AR2	ARFIMA(2,d,0)	ARFIMA(2,d,1)	ARFIMA(2,d,8)
AR3	ARFIMA(3,d,0)	ARFIMA(3,d,1)	ARFIMA(3,d,8)
AR7	ARFIMA(7,d,0)	ARFIMA(7,d,1)	ARFIMA(7,d,8)

3.5. Model terbaik ARFIMA (p,d,q)

Tabel 2 merupakan hasil estimasi parameter serta nilai AIC untuk model ARFIMA (p,d,q) dengan $d_{R/S} = 0,362$ dari total 14 model yang telah terbentuk.

Tabel 2. Penentuan model terbaik ARFIMA

No	Model	Signifikansi Parameter	AIC
1	ARFIMA(1,d,0)	Parameter Signifikan	83576,59
2	ARFIMA(2,d,0)	Parameter Signifikan	83738,05
3	ARFIMA(3,d,0)	Parameter Signifikan	83858,95
4	ARFIMA(7,d,0)	Parameter Signifikan	84152,87
5	ARFIMA(1,d,1)	Parameter Signifikan	83495,90
6	ARFIMA(2,d,1)	Parameter Signifikan	83555,88
7	ARFIMA(3,d,1)	Parameter Signifikan	83753,96
8	ARFIMA(7,d,1)	Parameter Signifikan	83901,73
9	ARFIMA(1,d,8)	Parameter Signifikan	83579,26
10	ARFIMA(2,d,8)	Parameter Signifikan	83743,15
11	ARFIMA(3,d,8)	Parameter Signifikan	83867,99
12	ARFIMA(7,d,8)	Parameter Tidak Signifikan	84166,40
13	ARFIMA(0,d,1)	Parameter Signifikan	83992,47
14	ARFIMA(0,d,8)	Parameter Signifikan	84152,87

Tabel 2 menunjukkan bahwa parameter dari semua model memiliki 13 parameter yang signifikan dan 1 tidak signifikan dengan model ARFIMA terbaik yang didapatkan, yaitu: ARFIMA model (1,d,1). Hal ini disebabkan oleh ARFIMA(1,d,1) memiliki nilai AIC terkecil, yaitu: 83495,90. Selanjutnya, hasil uji diagnostik model menggunakan uji *L-Jung Box* menunjukkan bahwa $p\text{-value} = 0,7793$. Hal ini bermakna bahwa $p\text{-value}$ lebih besar dari α . Artinya, residual model memenuhi kriteria *white noise*. Oleh karena itu, model ini dapat digunakan untuk peramalan. Selanjutnya, model ini akan diterapkan dalam pemodelan *hybrid*.

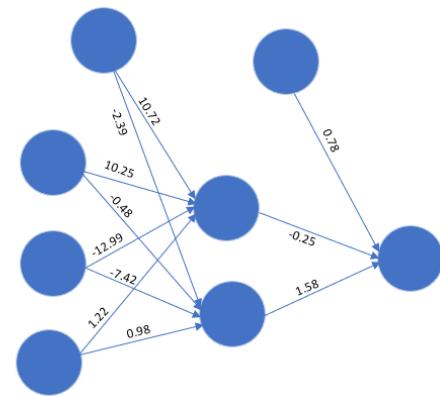
3.6. Hybrid ARFIMA-ANN

Setelah didapatkan model ARFIMA (p,d,q) terbaik, residual dari model digunakan sebagai input ANN. Dalam membangun model ANN menggunakan algoritma *backpropagation*, dilakukan pembentukan struktur jaringan yang mencakup lapisan input, tersembunyi, dan output, yang masing-masing memiliki sejumlah neuron. Pembentukan model ANN menggunakan 1 *input layer* dengan melihat *lag* yang signifikan dari Plot PACF [19], yaitu: *lag1*, *lag2*, *lag3* dan *lag7*. Pada *hidden layer*, digunakan 1 *hidden layer* dengan jumlah neuron *hidden* mulai dari 1 neuron sampai 10 neuron. Untuk *output layer*, digunakan 1 neuron *output*. Hasil pelatihan jaringan ANN sebanyak 4 model dan nilai RMSE masing-masing model disajikan pada Tabel 3.

Tabel 3 menunjukkan bahwa model terbaik dari keempat model, yaitu: model ANN (3,2,1). Hal ini karena model ANN (3,2,1) menghasilkan nilai RMSE terkecil. Gambar 5 merupakan arsitektur dari model ANN (3,2,1).

Tabel 3. Model ANN hasil pelatihan dengan algoritma *backpropagation*

Model	RMSE
ANN (1,10,1)	311,0725
ANN (2,1,1)	423,3588
ANN (3,2,1)	52,8324
ANN (7,9,1)	261,4560

**Gambar 5.** Arsitektur ANN (3,2,1)

Untuk bobot-bobot yang menghubungkan setiap neuron terhadap neuron lain bisa diperhatikan pada Tabel 4 dan Tabel 5.

Tabel 4. Bobot-bobot neuron *input* terhadap neuron *hidden*

Neuron <i>hidden</i> ke- j'	Neuron <i>input</i> ke- i'		
	Bias	1	2
1	10,72	10,25	-12.99
2	-2,39	-0,48	-7,42

Tabel 5. Bobot-bobot neuron *hidden* terhadap neuron *output*

Neuron <i>output</i>	Neuron <i>hidden</i> ke- j'		
	Bias	1	2
1	0.78	-0.25	1.58

Setelah melakukan analisis ARFIMA dan ANN, diperoleh model dari setiap analisis yang kemudian digabungkan untuk menghasilkan persamaan model *hybrid* ARFIMA-ANN, yang dapat dilihat pada persamaan (1) sampai dengan persamaan (4) berikut ini.

Model ARFIMA (1,d,1) menggunakan $d_{R/S} = 0,362$, dengan persamaan:

$$\phi_p(B)(1-B)^d C_t = \theta_q(B)a_t \quad (1)$$

$$(1 - 0.935610B)(1 - B)^{0.362} C_t = (1 - 0.402561)a_t \quad (2)$$

Model ANN (3,2,1) menggunakan algoritma *backpropagation*, dengan persamaan:

$$\hat{y}_t = \sum_{j'=1}^p w_{j'1} \cdot \frac{1}{1 + e^{-(v_{0j'} + \sum_{i'=1}^q x_{i'} v_{i'j'})}} + w_{01} \quad (3)$$

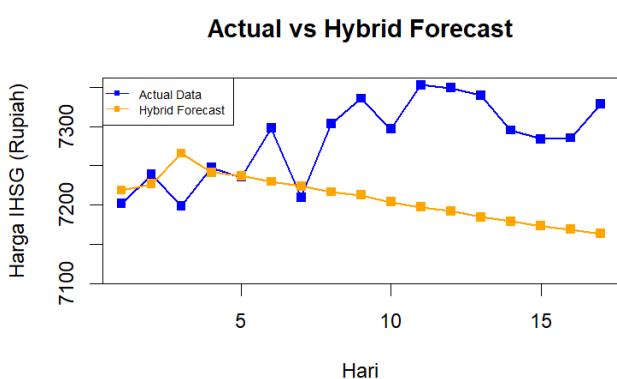
$$\hat{y}_t = \sum_{j'=1}^2 w_{j'1} \cdot \frac{1}{1 + e^{-(v_{0j'} + \sum_{i'=1}^3 x_{i'} v_{i'j'})}} + w_{01} \quad (4)$$

Selanjutnya, nilai MAPE dari model ARFIMA (1,d,1) dan model *hybrid* ARFIMA-ANN dihitung untuk dibandingkan. **Tabel 6** merupakan nilai MAPE dari model ARFIMA (1,d,1) dan model *hybrid* ARFIMA-ANN.

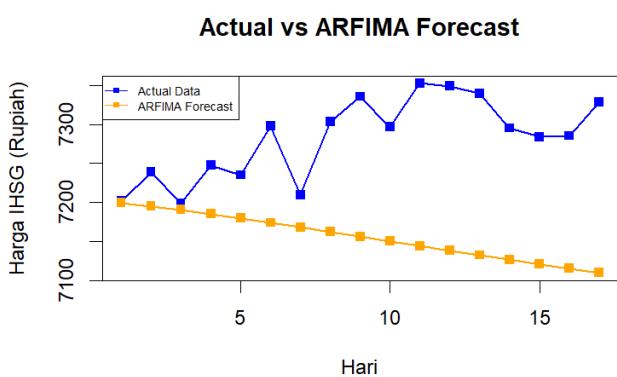
Tabel 6. Hasil akurasi model ARFIMA dan *hybrid* ARFIMA-ANN

Model	MAPE (%)
ARFIMA-ANN (1,d,1)-(3,2,1)	1,0164
ARFIMA (1,d,1)	1,7326

Tabel 6 menginformasikan bahwa model *hybrid* ARFIMA-ANN memiliki nilai MAPE lebih kecil dibandingkan dengan model ARFIMA, yaitu: sebesar 1,0164%. Dengan demikian, dapat disimpulkan bahwa penggabungan model dapat meningkatkan akurasi peramalan.



Gambar 6. Plot aktual data dan ramalan data *hybrid* ARFIMA-ANN



Gambar 7. Plot aktual data dan ramalan data ARFIMA

Gambar 6 dan **Gambar 7** menginformasikan bahwa ramalan menggunakan model *hybrid* ARFIMA-ANN lebih mendekati data aktual dibandingkan dengan ramalan model ARFIMA. Artinya model *hybrid* merupakan model terbaik untuk peramalan data indeks harga saham gabungan. Beberapa penelitian sebelumnya menggunakan data indeks harga saham gabungan seperti penelitian Syalsabilla, et. al [16], Jange [17], serta Meliana, et. al [18] menghasilkan MAPE masing-masing 1,45%, 8,27%, serta 2,4284%. Jika MAPE dari ketiga peneliti sebelumnya dibandingkan dengan MAPE pada penelitian ini, MAPE model ARFIMA-ANN lebih baik. Ini menunjukkan bahwa akurasi ramalan model *hybrid* ini unggul

dalam memprediksi dibandingkan dengan model-model pada penelitian sebelumnya. Hasil MAPE yang lebih rendah menandakan bahwa model *hybrid* ARFIMA-ANN memiliki kemampuan yang lebih tinggi dalam menangkap pola dan fluktuasi harga IHSG, sehingga lebih efektif dalam memberikan ramalan yang akurat.

4. Kesimpulan

Berdasarkan hasil analisis dan pembahasan dapat disimpulkan bahwa model *hybrid* ARFIMA(1,d,1)-ANN(3,2,1) dengan menggunakan algoritma *backpropagation* merupakan model terbaik untuk meramalkan indeks harga saham gabungan. Model ARFIMA dibangun dari data latih menggunakan parameter $d_{R/S}$, Residual model ARFIMA digunakan untuk membangun model ANN. Dari kedua model yang digunakan dapat ditunjukkan bahwa model *hybrid* ARFIMA-ANN menghasilkan nilai akurasi MAPE sebesar 1,0164%, yang lebih kecil dari akurasi MAPE model ARFIMA yakni sebesar 1,7326%. Hal ini menunjukkan bahwa dengan melakukan *hybrid* pada kedua model dapat meningkatkan akurasi dari model tersebut.

Kontribusi Penulis. Rayhanul Jannah Buhungo: Identifikasi Masalah, Metodologi, Analisis Formal, Penulisan – Persiapan Draf Asli. Isran K. Hasan: Investigasi, Software, Penulisan-review dan pengeditan. Nurwan: penulisan — tinjauan, pengawasan. Semua penulis telah membaca dan menyetujui versi manuskrip yang diterbitkan.

Ucapan Terima Kasih. Para penulis menyampaikan terima kasih kepada editor dan reviewer yang telah mendukung kami dalam meningkatkan kualitas naskah ini.

Pembiayaan. Seluruh proses penelitian mendapatkan dukungan anggaran melalui PNBP-Universitas Negeri Gorontalo berdasarkan SK Nomor 1243/UN47.B4/HK.04/2024 dan kontrak nomor 485/UN47.B4/PT.01.03/2024

Konflik Kepentingan. Para penulis menyatakan tidak ada konflik kepentingan yang terkait dengan artikel ini.

Referensi

- [1] U. Tarumanagara, "Faktor-Faktor Yang Mempengaruhi Pengambilan Keputusan Investasi Saham," *J. Ekon*, vol. XXV, no. 2, pp. 251–269, 2020, doi: [10.24912/je.v25i2.669](https://doi.org/10.24912/je.v25i2.669).
- [2] Y. A. Putri, M. Muchtar, and P. R. Sihombing, "Analisis Makroekonomi Terhadap Pergerakan Indeks Harga Saham Gabungan (IHSG) Di Indonesia," *J. Bayesian*, vol. 3, no. 2, pp. 210–223, 2023, doi: [10.46306/bay.v3i2.62](https://doi.org/10.46306/bay.v3i2.62).
- [3] H. Handika and A. Damajanti, "Faktor Penentu Fluktuasi Indeks Harga Saham Gabungan (IHSG) Di Bursa Efek Indonesia (BEI)," *J. SOLUSI*, vol. 19, no. 3, pp. 153–165, 2021, doi: [10.26623/slsi.v19i3.3503](https://doi.org/10.26623/slsi.v19i3.3503).
- [4] A. Oktavia and M. Y. Fajar, "Peramalan Laju Inflasi , BI Rate dan Indeks Harga Saham Gabungan," *J. Ris. Mat*, vol. 2, no. 1, pp. 17–24, 2022, doi: [10.29313/jrm.v2i1.789](https://doi.org/10.29313/jrm.v2i1.789).
- [5] N. N. Layla and E. Kurniati, "Peramalan Indeks Harga Saham dengan Auto-regressive Moving Average Generalized Autoregressive Conditional Heteroscedasticity (ARMA-GARCH)," *J. Ris. Mat.*, vol. 1, no. 1, pp. 7–12, 2021, doi: [10.29313/jrm.v1i1.103](https://doi.org/10.29313/jrm.v1i1.103).
- [6] P. Kartikasari, H. Yasin, and D. A. I. Maruddani, "Autoregressive fractional integrated moving average (arfima) model to predict covid-19 pandemic cases in indonesia," *Media Stat*, vol. 14, no. 1, pp. 44–55, 2021, doi: [10.14710/medstat.14.1.44-55](https://doi.org/10.14710/medstat.14.1.44-55).
- [7] A. Lembang, Ferry Kondo and Sinay, Lexy Janzen and Irfanullah, "ARFIMA Modelling for Tectonic Earthquakes in The Maluku Region," *J. Stat. its Appl*, vol. 5, no. 1, pp. 39–49, 2021, doi: [10.29244/ijsa.v5i1p39-49](https://doi.org/10.29244/ijsa.v5i1p39-49).
- [8] W. Aryanti, "Penerapan artificial neural network dengan algoritma backpropagation dalam memprediksi indeks harga saham gabungan (IHSG) di bursa efek indonesia," *J. Teknologi dan Inovasi*, vol. 1, no. 1, pp. 1–10, 2021, doi: [10.5220/0010700100010010](https://doi.org/10.5220/0010700100010010).

- ropagation untuk memprediksi harga saham," *J. Ris. Stat.*, vol. 3, no. 2, pp. 107–118, 2023, doi: [10.29313/jrs.v3i2.2953](https://doi.org/10.29313/jrs.v3i2.2953).
- [9] M. S. Hamid, Muhammad Rifaldi and Henny, Henny and Said, "Algoritma backpropagation dalam memprediksi jumlah penduduk yang belum melakukan perekaman ktp elektronik di kota kendari , " *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 8, no. 2, pp. 392–397, 2023, doi: [10.51876/simtek.v8i2.326](https://doi.org/10.51876/simtek.v8i2.326).
- [10] S. Fadhlia, E. P. Hendri, and D. D. C. A, "Model peramalan nilai tukar rupiah terhadap dollar singapura menggunakan metode hybrid arima-ann," *J. Lebesgue J. Ilm. Pendidik. Mat. Mat. dan Stat.*, vol. 5, no. 3, pp. 1513–1523 2024, doi: [10.46306/lb.v5i3.720](https://doi.org/10.46306/lb.v5i3.720).
- [11] M. R. Susila, M. Jamil, and B. H. Santoso, "Akurasi Model Hybrid ARIMA-Artificial Neural Network dengan Model Non Hybrid pada Peramalan Peredaran Uang Elektronik di Indonesia," *Jambura J. Math.*, vol. 5, no. 1, pp. 46–58, 2023, doi: [10.34312/jjom.v5i1.14889](https://doi.org/10.34312/jjom.v5i1.14889).
- [12] I. Tahyudin, R. Wahyudi, U. A. Purwokerto, and H. Nambo, "The mortality modeling of covid-19 patients using a combined time series model and evolutionary algorithm," *Int. J. Adv. Intell. Informatics*, vol. 8, no. 1, pp. 69–83, 2022, doi: [10.26555/ijain.v8i1.669](https://doi.org/10.26555/ijain.v8i1.669).
- [13] I. K. Hasan and I. Djakaria, "Perbandingan Model Hybrid ARIMA-NN dan Hybrid ARIMA-GARCH untuk Peramalan Data Nilai Tukar Petani di Provinsi Gorontalo," *J. Stat. dan Apl.*, vol. 5, no. 2, pp. 155–165, 2021, doi: [10.21009/JSA.05204](https://doi.org/10.21009/JSA.05204).
- [14] R. Kamadewi and A. I. Achmad, "Pemodelan Hybrid ARIMA (Autoregressive Integrated Moving Average) – ANN (Artificial Neural Network) pada Data Inflasi Indonesia Tahun 2009 - 2020," pp. 33–41, 2020.
- [15] Dr. R. A. Zalan and Z. S. Yaseen, "Using Fuzzy-ARFIMA Models to Predict Births in Basra Governorate," *Jj. Phys. Conf. Ser.*, vol. 1963, no. 1, pp. 1–13, 2021, doi: [10.1088/1742-6596/1963/1/012139](https://doi.org/10.1088/1742-6596/1963/1/012139).
- [16] A. F. Syalsabilla, S. Astutik, A. F. Rozy, U. Brawijaya, and P. Korespondensi, "Optimalisasi Prediksi Harga Ihsg Menggunakan Hybrid Weighted Fuzzy Time Series Hidden Markov Model Dengan Algoritma Evolusi Diferensial," *J. Teknol. dan Inf. ilmu Komput.*, vol. 11, no. 4, pp. 837–844, 2024, doi: [10.25126/jtiik.1148867](https://doi.org/10.25126/jtiik.1148867).
- [17] B. Jange, "Prediksi Indeks Harga Saham Gabungan (IHSG) Menggunakan Prophet," *J. Manag. Enterpreneursh.*, vol. 1, no. 2, pp. 53–59, 2022, doi: [10.56445/jme.v1i2.18](https://doi.org/10.56445/jme.v1i2.18).
- [18] M. Arimax and D. Variabel, "Peramalan indeks harga saham gabungan (ihsg) menggunakan arimax dengan variabel eksogen covid-19," *Pros. Semin. Edusainstech*, pp. 258–267, 2020.
- [19] M. Viskha and D. U. Wutsqa, "Peramalan Harga Beras Menggunakan Metode Hybrid Autoregressive Integrated Moving Average dan Neural Network (ARIMA-ANN)," *J. Kajian dan Terapan Matematika*, vol. 9, no. 3, pp. 148–162, 2023.