

PERAMALAN HARGA SAHAM HARIAN PT BANK SYARIAH INDONESIA TBK. MENGUNAKAN HIBRIDA *AUTORESGRESSIVE INTEGRATED MOVING AVERAGE-NEURAL NETWORK*

Iskandar Agung Dzulkarnain, Winita Sulandari*, Respatiwan
Program Studi Statistika, Universitas Sebelas Maret, Surakarta

*Penulis korespondensi: winita@mipa.uns.ac.id

ABSTRAK

Saham Bank Syariah Indonesia menarik minat investor karena posisinya yang strategis dalam industri perbankan syariah di Indonesia. Penelitian ini bertujuan untuk menentukan model peramalan saham harian PT Bank Syariah Indonesia Tbk. menggunakan metode hibrida *autoregressive integrated moving average-neural network* (ARIMA-NN) serta mengevaluasi kinerjanya. Proses penelitian meliputi pemodelan *autoregressive integrated moving average* (ARIMA) untuk mengidentifikasi komponen linear dengan memeriksa stasioneritas, menentukan model terbaik berdasarkan plot ACF dan PACF, serta melakukan uji diagnostik dan evaluasi model. Residu ARIMA kemudian dimodelkan menggunakan *neural network* (NN) dengan tahapan *preprocessing* residu, *hyperparameter optimizer*, dan peramalan residu menggunakan arsitektur NN yang optimal. Model hibrida ARIMA-NN akhirnya diterapkan untuk melakukan peramalan harga saham dan evaluasi kinerja dilakukan menggunakan MAPE. Hasil penelitian menunjukkan bahwa didapatkan tiga model hibrida ARIMA-NN yaitu ARIMA (1, 2, 0) – NN (3, 4, 1), ARIMA (2, 2, 0) – NN (3, 6, 1), dan ARIMA (0, 2, 1) – NN (3, 7, 1). Peramalan menggunakan model ARIMA (0, 2, 1) – NN (3, 7, 1) yang dioptimasi dengan optimasi adam, *batch size* 16, *learning rate* 0,05, dan 100 *epoch*, menghasilkan nilai MAPE terkecil sebesar 1,752%. Penerapan model ini diharapkan dapat membantu investor dalam mengambil keputusan investasi dengan lebih akurat.

Kata kunci: saham, peramalan harga saham, investasi, metode hibrida, arima-nn

1 PENDAHULUAN

Pasar modal memiliki peran vital dalam perekonomian Indonesia, ditunjukkan melalui pertumbuhan signifikan jumlah investor berdasarkan data PT Kustodian Sentral Efek Indonesia (KSEI). Terjadi peningkatan sebesar 92,99% pada 2021, 37,68% pada 2022, dan 3,03% pada 2023, dengan dominasi investor muda berusia 30 tahun mencapai 58,39% dari total aset 52,73 triliun rupiah pada tahun 2023 (KSEI, 2023). Preferensi investor dalam berinvestasi dipengaruhi oleh gaya hidup, faktor demografi seperti usia, jenis kelamin, pendidikan, dan frekuensi investasi, sejalan dengan hasil survei. Seiring perkembangan pasar modal, sektor perbankan syariah juga mengalami pertumbuhan yang pesat, ditandai dengan keberhasilan Bank Syariah Indonesia (BSI) yang terbentuk pada 1 Februari 2021 melalui penggabungan tiga bank syariah BUMN dan berhasil mencapai peringkat ke-7 di tingkat nasional. Total aset bank syariah menunjukkan tren positif, mencapai 593.948 triliun rupiah tahun 2020, 676.735 triliun rupiah tahun 2021, dan 811.960 triliun rupiah tahun 2022.

Investasi saham menjadi metode populer untuk mengelola keuangan di Indonesia, dengan mayoritas investor didominasi oleh anak muda berusia 30 tahun, mencapai 58,39% dari total aset sebesar 52,73 triliun rupiah pada tahun 2023. Data KSEI pada tahun 2023 juga menunjukkan bahwa laki-laki mendominasi jumlah investor dengan 62,85%, sementara sebagian besar dari mereka (59,69%) tidak melanjutkan pendidikan ke perguruan tinggi. Saham merupakan instrumen keuangan yang diterbitkan oleh perusahaan sebagai salah satu metode untuk mengumpulkan modal. Definisi saham adalah sebagai tanda kepemilikan atas suatu perusahaan atau entitas bisnis (Suratna, 2020). Adnyana (2020) menjelaskan bahwa saham secara fisik dapat berupa selembur kertas yang menunjukkan bahwa pemilik kertas tersebut memiliki kepemilikan dalam perusahaan yang mengeluarkan surat berharga tersebut.

Model ARIMA digunakan menganalisis runtun waktu. Model ARIMA memiliki kekurangan yaitu tidak efektif untuk jangka waktu panjang karena keterbatasan hasil peramalannya. Model ARIMA bersifat *univariate*, cocok digunakan ketika observasi dari runtun waktu karena tidak memiliki keterkaitan statistik satu sama lain. Model ARIMA sangat fleksibel, model ini memiliki beberapa jenis runtun waktu seperti *Autoregressive* (AR), *Moving Average* (MA), dan kombinasi AR dan MA (ARMA), yang diasumsikan berbentuk linear. Salah satu kekurangan ARIMA adalah asumsinya terbatas pada model linear, sehingga tidak mampu menangkap hubungan nonlinear yang umumnya terdapat pada runtun waktu. Keterbatasan ini dapat diatasi dengan menggunakan model *neural network* (NN).

Berdasarkan pemahaman tersebut, penelitian ini memilih menggunakan model hibrida ARIMA-NN untuk meramalkan perubahan harga saham BSI. Penggabungan kedua metode ini diharapkan dapat mengoptimalkan hasil peramalan, baik linear maupun nonlinear, sehingga dapat menjadi alat pendukung keputusan bagi investor dengan nilai *Mean Absolute Percentage Error* (MAPE) yang minimal.

2 METODE

2.1 *Autoregressive Integrated Moving Average* (ARIMA)

Wei (2006) menjelaskan bahwa untuk membuat sebuah runtun waktu yang tidak stasioner menjadi stasioner, dapat dilakukan dengan mengurangi orde d . Model ARMA (p, q) diterapkan pada runtun waktu yang stasioner, sementara model ARIMA (p, d, q) digunakan untuk runtun waktu yang tidak stasioner. Menurut Wei (2006), pemodelan ARIMA dapat dilakukan dalam tiga langkah, yaitu mengidentifikasi model, mengestimasi parameter, dan melakukan diagnostik model.

ARIMA (p, d, q) memiliki model sebagai berikut.

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B)a_t, \quad (1)$$

dengan

$$\text{operator AR : } \phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p, \quad (2)$$

$$\text{operator MA : } \theta_q(B) = 1 - \theta_q B - \dots - \theta_q B^p, \quad (3)$$

- Z_t : nilai runtun waktu periode t ,
 B : operator mundur,
 d : derajat dari diferensi,
 ϕ_p : parameter model AR(p),
 θ_0 : parameter deterministik,
 θ_q : parameter model MA(q),
 a_t : *error* pada waktu ke- t dengan asumsi *white noise* serta berdistribusi normal $(0, \sigma^2)$

2.2 Autocorrelation Function (ACF)

Autocorrelation Function (ACF) adalah fungsi yang menunjukkan korelasi antara Z_t dengan Z_{t+k} dari proses yang sama pada lag waktu yang berbeda. Penghitungan ACF dapat diperoleh dengan persamaan (4) (Wei, 2006)

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\text{Cov}(Z_t, Z_{t+k})}{\sqrt{\text{Var}(Z_t)}\sqrt{\text{Var}(Z_{t+k})}}; k = 0, 1, 2, \dots, \quad (4)$$

dengan

- ρ_k : nilai fungsi autokorelasi ke- i dengan $i = 1, 2, 3, \dots, k$,
 γ_k : fungsi autokovariansi,
 Z_t : nilai data pada waktu periode t ,
 Z_{t+k} : nilai data pada waktu periode $t+k$.

2.3 Partial Autocorrelation Function (PACF)

Fungsi *Partial Autocorrelation Function* (PACF) merupakan himpunan autokorelasi parsial untuk berbagai lag k . PACF digunakan untuk mengukur korelasi antara pengamatan jeda k dan dengan mengontrol korelasi antara dua pengamatan dengan jeda kurang dari k yang dijelaskan pada Persamaan (5).

$$\phi_{kk} = \text{Corr}(Z_t, Z_{t+k} | Z_{t+1}, \dots, Z_{t+k-1}), \quad (5)$$

dengan Z_t adalah nilai data pada waktu periode t .

2.4 Kestasioneran Data

Dalam analisis runtun waktu menggunakan ARIMA, kestasioneran data menjadi prasyarat penting yang harus dipenuhi. Verifikasi kestasioneran data dapat dilakukan melalui pemeriksaan plot ACF dan PACF, di mana data dianggap stasioner jika nilai koefisien ACF mendekati atau sama dengan nol (Wei, 2006). Sebaliknya, jika plot ACF menunjukkan penurunan yang sangat lambat dan plot PACF terpotong setelah lag pertama, hal ini mengindikasikan bahwa data tersebut tidak stasioner. Dampak musiman juga dapat menghasilkan data varians yang tidak stasioner, sehingga jika pengaruh musiman dihilangkan maka data tersebut dapat menjadi data stasioner (Makridakis *et al*, 1999).

Selain itu, untuk menilai stasioneritas data terhadap variansi, dapat dilakukan transformasi Box Cox. Hasil uji tersebut dapat menunjukkan apakah data yang bersangkutan stasioner dengan nilai parameter $\lambda = 1$. Apabila didapatkan $\lambda \neq 1$, maka data perlu ditransformasikan. Transformasi Tabel 1 merupakan transformasi yang sebelumnya telah dibahas sebagai situasi khusus. Tabel 1

menunjukkan kasus khusus untuk beberapa nilai λ yang umum digunakan dan transformasi yang dilakukan.

Tabel 1. Keterangan λ dan Transformasi yang Sesuai

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

2.5 Estimasi Parameter

Metode maksimum likelihood merupakan pendekatan yang umum digunakan dalam mengestimasi parameter pada model ARIMA. Metode ini bekerja dengan memaksimalkan fungsi log likelihood bersyarat untuk memperoleh estimasi parameter yang optimal (Wei, 2006). Metode ini menghasilkan estimator yang efisien secara statistik dan konsisten untuk sampel berukuran besar.

2.6 Uji Diagnostik Model

Uji diagnostik model dilakukan jika estimasi dan signifikansi semua parameter telah memenuhi asumsi residu. Residu merupakan perbedaan antara nilai aktual dari suatu deret waktu dan nilai yang diprediksi oleh model. Asumsi yang harus dipenuhi yakni residu harus berdistribusi normal dan *white noise*. Uji normalitas digunakan untuk mengetahui apakah residu memiliki distribusi normal atau tidak (Setiawan, 2023). Pengujian ini dapat dilakukan dengan uji Kolmogorov-Smirnov. Uji *white noise* digunakan untuk melihat apakah residu telah mengikuti sifat independen dan identik yang artinya data tersebut harus memenuhi asumsi bahwa tidak terdapat korelasi antarresidu. Uji ini dapat dilakukan dengan uji Ljung Box-Q (Wei, 2006).

2.7 Neural Network (NN)

Neural network merupakan sebuah sistem yang digunakan untuk memproses informasi yang memiliki karakteristik menyerupai jaringan saraf biologi pada manusia. *Neural networks* adalah salah satu metode *machine learning* yang paling banyak digunakan untuk meramalakan data runtun waktu (Ahmad, 2017). *Neural network* memiliki karakteristik dengan beberapa asumsi sebagai berikut:

- Pemrosesan informasi terjadi pada elemen sederhana disebut neuron.
- Sinyal dilewatkan di antara neuron melalui tautan koneksi.
- Setiap tautan koneksi memiliki bobot yang saling terkait, di dalam jaringan saraf yang khas, banyak sinyal yang dikirimkan.
- Setiap neuron menggunakan fungsi aktivasi (biasanya nonlinear) pada *net input* (jumlah sinyal *input* yang memiliki bobot) untuk menentukan sinyal *output*-nya.

Neural network memiliki arsitektur yaitu *single layer perceptron* dan *multilayer perceptron*.

Perubahan hasil pelatihan akan bergantung pada jumlah *hidden layer* yang digunakan (Heaton, 2008). Perbedaannya adalah *single layer perceptron* tidak menggunakan *hidden layer* sedangkan pada *multilayer perceptron* menggunakan *hidden layer*. *Multilayer perceptron* memiliki suatu

layer tambahan yang dapat digunakan untuk menyelesaikan masalah yang lebih rumit daripada *single layer perceptron*. Komponen-komponen yang terdapat pada *neural network* sebagai berikut.

- a. *Layer: neural network* terdiri atas kumpulan neuron yang saling berhubungan dan dikelompokkan pada *layer-layer*. *Neural network* terdiri dari tiga layer, yaitu *input layer*, *hidden layer*, dan *output layer*.
- b. *Input*: Data yang dijadikan *input* adalah data numerik. Sehingga apabila ada data selain numerik maka data tersebut harus diubah menjadi data numerik.
- c. *Output*: Merupakan suatu hasil dari pemecahan masalah yang berupa data numerik.
- d. Bobot (*weight*) : sebuah angka yang membantu sistem menerjemahkan *input* data menjadi *output* data.
- e. Bias: Setiap *hidden layer* memiliki bias yang terdapat pada *hidden layer* (Haykin, 1994).

2.8 Backpropagation

Algoritma *backpropagation* adalah metode pelatihan NN yang terdiri dari tiga fase utama: *feedforward* untuk menghitung output berdasarkan bobot awal, *backward propagation* untuk menghitung kesalahan dan memperbarui bobot berdasarkan gradien, serta pembaruan bobot dan bias hingga mencapai konvergensi (Fausett, 1994). Penelitian ini menggunakan fungsi aktivasi *Rectified Linear Neurons* (ReLU). ReLU merupakan fungsi aktivasi sederhana dengan membuat batas bawah menjadi 0. Jika $x < 0$ maka $x = 0$ dan jika $x > 0$ maka $x = x$ dinyatakan dalam Persamaan (6).

$$f(x) = \max(0, x). \quad (6)$$

Proses pelatihan dimulai dengan inisialisasi bobot acak, propagasi maju untuk menghitung *output*, propagasi mundur untuk mengoreksi kesalahan, dan diulang hingga mencapai jumlah iterasi (*epoch*) tertentu (Vijayalakshmi, 2019).

2.9 Preprocessing Data

Preprocessing data pada residu dilakukan dengan melakukan normalisasi data dengan tujuan memastikan konsistensi dalam rentang nilai residu dengan fungsi aktivasi yang akan digunakan sehingga hasil analisis menjadi lebih akurat. Normalisasi yang digunakan adalah normalisasi data dengan *min – max* dengan rentang nilai 0 sampai dengan 1. Normalisasi data dengan *min – max* dinyatakan dengan Persamaan (7).

$$a'_t = \left[\frac{a_t - a_{min}}{a_{maks} - a_{min}} \right], \quad (7)$$

dengan

- a_t : residu ke- t ,
 a_{min} : nilai residu terkecil,
 a_{max} : nilai residu terbesar.

2.10 Fungsi Optimasi

Fungsi optimasi berperan dalam meningkatkan efisiensi pembelajaran sistem, dan nilai dari *learning rate* menjadi parameter dalam menentukan seberapa cepat atau lambat sistem dapat mempelajari informasi. Salah satu metode optimasi yang banyak digunakan adalah Optimasi

Adaptive Moment Estimation (ADAM). Optimasi adam menggabungkan pendekatan RMSprop dan *Stochastic Gradient Descent* (SGD) dengan momentum. Optimasi adam menggunakan estimasi momen adaptif pertama dan kedua. Optimasi adam, gradien rata-rata dari iterasi sebelumnya disimpan secara eksponensial, serupa dengan pendekatan RMSprop. Umumnya, nilai standar untuk learning rate dalam optimasi adam adalah sekitar 0,001. Kingma dan Lei Ba, (2015) merumuskan optimasi adam dan dijelaskan dengan Persamaan (8).

$$w_i = w_{i-1} - \frac{\alpha}{\sqrt{\hat{A}_i + \varepsilon}} \cdot \hat{F}_i, \quad (8)$$

dengan

- w_i : parameter hasil pembaruan (bobot baru),
- w_{i-1} : parameter hasil pembaruan sebelumnya,
- α : *learning rate*,
- \hat{F}_i : gradien kuadrat momen orde pertama,
- \hat{A}_i : gradien kuadrat momen orde kedua,
- ε : Skalar kecil untuk mencegah pembagian dengan nol.

2.11 Hibrida ARIMA-NN

Metode hibrida ARIMA-NN merupakan kombinasi antara metode ARIMA dengan menyelesaikan kasus data linear dan NN dengan menyelesaikan kasus data nonlinear. Data runtun waktu sering ditemui dengan masalah data yang linear dan nonlinear, sehingga model hibrida ARIMA-NN cocok untuk mengatasi masalah tersebut. Kombinasi dari kedua model tersebut yang memiliki struktur linear dan non linear dalam persamaan (9).

$$z_t = L_t + N_t, \quad (9)$$

Di mana L_t merupakan komponen linear (ARIMA) dan N_t merupakan komponen non linear (NN).

2.12 Mengevaluasi Model Hibrida ARIMA-NN

Hanke & Wichern (2014) menjelaskan bahwa metode peramalan yang menggabungkan data kuantitatif dengan data deret waktu tertentu menciptakan ketidakakuratan. Oleh karena itu, diperlukan suatu metode untuk mengukur jumlah *error* yang dapat dihasilkan oleh metode peramalan sebelum suatu keputusan dibuat. Pemilihan model terbaik dilakukan dengan melihat nilai *Mean Absolute Percentage Error* (MAPE). *Mean Absolute Percentage Error* (MAPE) dihitung untuk mengetahui perbandingan kesalahan dalam peramalan dengan nilai aktual. Nilai MAPE dapat dirumuskan dalam Persamaan (10).

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \frac{|z_t - \hat{z}_t|}{|z_t|} \right) \times 100\%, \quad (10)$$

dengan

- \hat{z}_t : nilai peramalan pada periode t ,
- z_t : nilai aktual pada periode t .

Model peramalan yang lebih baik dapat ditemukan dengan nilai MAPE yang lebih kecil. Rentang nilai MAPE dapat dilihat pada Tabel 2.

Tabel 2. Kriteria Nilai MAPE

MAPE	Kriteria
<10%	Kemampuan peramalan sangat baik

10-20%	Kemampuan peramalan baik
20-50%	Kemampuan peramalan layak
>50%	Kemampuan peramalan buruk

2.13 Prosedur Penelitian

Adapun prosedur penelitian yang dilakukan adalah sebagai berikut:


- 1) Melakukan pemodelan ARIMA
- 2) Melakukan pemodelan NN
- 3) Menetapkan model hibrida ARIMA–NN
- 4) Mengevaluasi model hibrida ARIMA–NN

3 HASIL DAN PEMBAHASAN

Pada bagian ini, pemodelan dengan metode hibrida ARIMA-NN dijelaskan secara rinci. Proses dimulai dengan pemodelan ARIMA untuk mengidentifikasi komponen linear melalui pemeriksaan stasioneritas, analisis plot ACF dan PACF, estimasi parameter, serta uji diagnostik. Residu ARIMA yang dihasilkan kemudian dimodelkan menggunakan NN dengan tahapan normalisasi residu, pencarian parameter terbaik, dan pelatihan model untuk memprediksi residu. Hasil prediksi ARIMA dan residu oleh NN digabungkan untuk membentuk model hibrida ARIMA-NN, yang mampu menangkap pola linear dan nonlinear secara efektif untuk menghasilkan prediksi yang lebih akurat.


3.1 Pemodelan dengan ARIMA

Data yang digunakan untuk penelitian ini merupakan data saham harian dari PT Bank Syariah Indonesia Tbk. Data yang digunakan adalah data harga penutupan saham dari tanggal 13 November 2023 – 16 Februari 2024, sebanyak 64 data dari laman Yahoo Finance. Alasan data yang diambil pada jangka waktu tersebut adalah pola data dalam jangka waktu tersebut memiliki pola tren. Gambar 1 menunjukkan plot data harga penutupan saham harian PT BSI.



Gambar 1. Plot Harga Saham Penutupan PT BSI


Tahap awal pemodelan dengan metode ARIMA melibatkan pengujian stasioneritas data training. Data yang memiliki pola tren dianggap tidak stasioner. Transformasi Box Cox dilakukan pada data *training* dengan jumlah 51 data dan menghasilkan nilai lambda -1, yang menunjukkan data belum stasioner dalam variansi.




Gambar 2. Plot Harga Saham Data Training

Gambar 2 menunjukkan bahwa data training masih belum stasioner dalam rata-rata. Hal ini terlihat dari pola data yang cenderung naik. Ketidakstasioneran dalam rata-rata dapat menyebabkan pemodelan menjadi tidak akurat dan peramalan kurang baik.

Data yang stasioner dalam variansi dan rata-rata dilanjutkan dengan melakukan identifikasi model yang tepat. Proses identifikasi ini dilakukan dengan menganalisis plot ACF dan PACF. Plot tersebut membantu menentukan nilai p dan q yang optimal untuk model ARIMA. Hasil ACF dan PACF disajikan pada Gambar 3 dan Gambar 4.




Gambar 3. Plot ACF Data Training Setelah Differencing Orde Ke 1




Gambar 4. Plot PACF Data Training Setelah Differencing Orde Ke 1

Orde p dan q pada model ARIMA dapat diduga dari plot ACF dan PACF dari data *training* yang telah stasioner. Gambar 3 dan 4 menunjukkan bahwa tidak ada lag yang signifikan sebagai

kombinasi dari orde p dan q yang akan digunakan. *Differencing* ke dua dilakukan untuk mengatasi masalah ini dengan hasil ACF dan PACF sebagai berikut



Gambar 5. Plot ACF Data Training Setelah Differencing Orde Ke 2



Gambar 6. Plot PACF Data Training Setelah Differencing Orde Ke 2

Hasil ACF dan PACF *differencing* kedua disajikan pada Gambar 5 dan Gambar 5. Gambar 5 menunjukkan bahwa lag 1 signifikan sebagai kombinasi dari orde p yang akan digunakan. Gambar 6 menunjukkan bahwa lag 1 dan 2 signifikan sebagai kombinasi untuk orde q yang akan digunakan

Berdasarkan model ARIMA data *training* yang telah ditentukan nilai ordenya pada tahap identifikasi model, selanjutnya dilakukan estimasi dari nilai setiap parameternya menggunakan metode *maksimum likelihood* dengan memaksimalkan fungsi bersyarat dari *log likelihood*. Uji signifikansi dilakukan untuk estimasi masing-masing parameter. Uji signifikansi dilakukan untuk melihat model mana yang layak digunakan. Model dikatakan layak jika seluruh parameter model memiliki $p_{value} \leq \alpha = 0,05$. Hasil estimasi parameter dan uji signifikansi pada setiap model ditunjukkan oleh Tabel 3.

Tabel 3. Estimasi Parameter Model ARIMA Data Training

Model	Parameter	p_{value}	Kesimpulan
ARIMA (1,2,1)	$\phi_1 = 0,061$	0,704	Tidak signifikan
	$\theta_1 = 0,952$	0,000	Signifikan
ARIMA (1,2,0)	$\phi_1 = -0,464$	0,001	Signifikan
ARIMA (2,2,0)	$\phi_1 = -0,632$	0,000	Signifikan
	$\phi_2 = -0,402$	0,007	Signifikan

	$\phi_1 = 0,079$	0,607	Tidak signifikan
ARIMA (2,2,1)	$\phi_2 = -0,064$	0,690	Tidak signifikan
	$\theta_1 = 0,9706$	0,000	Signifikan
ARIMA (0,2,1)	$\theta_1 = 0,948$	0,000	Signifikan

Tabel 3 menunjukkan hasil uji signifikansi parameter dari seluruh model ARIMA yang diujikan pada data *training*, diperoleh tiga model yang seluruh parameternya signifikan terhadap model. Model tersebut yakni ARIMA (1, 2, 0), ARIMA (2, 2, 0), dan ARIMA (0, 2, 1).

Model ARIMA data *training* yang seluruh parameternya signifikan, selanjutnya dilakukan pengujian terhadap residu. Model yang layak harus memenuhi asumsi residu berdistribusi normal dan *white noise*. Residu berdistribusi normal jika memiliki nilai $p_{value} > \alpha = 0,05$ dan residu merupakan *white noise* jika memiliki nilai $p_{value} > \alpha = 0,05$. Hasil uji diagnostik model dapat dilihat pada Tabel 4.

Tabel 4. Uji Diagnostik Model

Model	Uji Normalitas	White Noise
ARIMA (1, 2, 0)	Memenuhi	Memenuhi
ARIMA (2, 2, 0)	Memenuhi	Memenuhi
ARIMA (0, 2, 1)	Memenuhi	Memenuhi

3.2 Pemodelan dengan NN

Residu data *training* dari model ARIMA digunakan sebagai input pada pemodelan NN. *Preprocessing* dilakukan pada residu agar bentuk datanya lebih sesuai untuk analisis. Residu memiliki nilai jangkauan yang besar jika digunakan langsung, sehingga dilakukan normalisasi *min-max* pada residu *training* dan *testing* untuk menyesuaikan rentang fungsi aktivasi. Tujuan *preprocessing* ini adalah untuk meningkatkan akurasi analisis.

Hyperparameter Optimizer adalah parameter dalam model NN yang ditentukan di awal dan tetap konstan selama proses pelatihan (Michelucci, 2018). *Hyperparameter* yang umum digunakan dalam NN, yaitu jumlah *input layer*, jumlah *hidden layer*, *epoch*, *batch size*, fungsi aktivasi, dan lain sebagainya. Pemilihan *hyperparameter* disesuaikan untuk mengatasi potensi *overfitting* yang mungkin terjadi pada dataset yang jumlahnya terbatas. *Learning rate* yang digunakan yakni 0,001; 0,005; 0,01; dan 0,05. *Batch size* yang digunakan yakni 16. *Lookback* yang digunakan yakni 1 sampai dengan 5. Fungsi aktivasi yang digunakan pada neuron *hidden* adalah fungsi aktivasi Relu. Fungsi aktivasi yang digunakan pada neuron *output* adalah fungsi aktivasi linear. Fungsi *optimizer* menggunakan optimasi ADAM. *Neuron hidden layer* yang digunakan adalah 1 sampai dengan 10. Semua parameter yang diujikan menggunakan 100 *epoch* mendapatkan model terbaik untuk residu data *training* dengan melihat MAPE dari data *training* semua model ARIMA. Parameter model terbaik disajikan pada Tabel 5.

Tabel 5. Parameter Model Terbaik

Parameter	Input Residu ARIMA (1,2,0)	Input Residu ARIMA (2,2,0)	Input Residu ARIMA (0,2,1)
<i>Learning rate</i>	0,001	0,001	0,05
<i>Lookback</i>	3	3	3
<i>Batch size</i>	16	16	16

<i>Neuron hidden layer</i>	4	6	7
<i>Optimizer</i>	ADAM	ADAM	ADAM
<i>Fungsi aktivasi hidden layer</i>	Relu	Relu	Relu
<i>Fungsi aktivasi output layer</i>	Linear	Linear	Linear
<i>Epoch</i>	100	100	100

3.3 Penetapan Model Hibrida ARIMA – NN

Persamaan (9) merupakan model Hibrida ARIMA–NN yang digunakan untuk menghitung nilai MAPE data *testing*. Hasil peramalan yang diperoleh dari pemodelan dengan model NN, ditambahkan dengan hasil peramalan model ARIMA. Peramalan hibrida ARIMA–NN menggunakan data *testing* diperoleh dari Persamaan (9). Model ARIMA–NN yang akan dievaluasi disajikan pada Tabel 6.

Tabel 6. Model Hibrida ARIMA-NN

Model	Model Hibrida ARIMA-NN
ARIMA (1, 2, 0) – NN (3, 4, 1)	$Z_t = 1,536Z_{t-1} - 0,072Z_{t-2} - 0,464Z_{t-3} + (w_{0k} + \sum_{j=1}^4 f(v_{0j} + \sum_{i=1}^4 x_i v_{ij})w_{jk}) + a_t.$
ARIMA (2, 2, 0) – NN (3, 6, 1)	$Z_t = 1,368Z_{t-1} - 0,138Z_{t-2} + 0,172Z_{t-3} - 0,402Z_{t-4} + (w_{0k} + \sum_{j=1}^6 f(v_{0j} + \sum_{i=1}^6 x_i v_{ij})w_{jk}) + a_t.$
ARIMA (0, 2, 1) – NN (3, 7, 1)	$Z_t = 2Z_{t-2} - Z_{t-1} - 0,9487a_{t-1} + (w_{0k} + \sum_{j=1}^7 f(v_{0j} + \sum_{i=1}^7 x_i v_{ij})w_{jk}) + a_t.$

3.4 Pengevaluasian Model Hibrida ARIMA – NN

Model Hibrida ARIMA – NN yang telah diperoleh digunakan untuk melakukan peramalan ke depan. Hasil dari peramalan data dengan menggunakan model hibrida ARIMA – NN dihitung MAPE-nya. Hasil peramalan model ARIMA – NN akan dievaluasi menggunakan metode MAPE dengan data *testing* saham PT BSI. Hasil MAPE disajikan pada Tabel 7.

Tabel 7. Perbandingan MAPE

Model	MAPE (%)	
	<i>Training</i>	<i>Testing</i>
ARIMA (1, 2, 0) – NN (3, 4, 1)	1,473	1,887
ARIMA (2, 2, 0) – NN (3, 6, 1)	2,262	2,341
ARIMA (0, 2, 1) – NN (3, 7, 1)	1,304	1,752

Nilai MAPE *training* dan *testing* dari peramalan hibrida ARIMA (0, 2, 1) – NN (3, 7, 1) adalah 1,304% dan 1,752%. Model hibrida ARIMA (0, 2, 1) – NN (3, 7, 1) menghasilkan MAPE yang lebih baik.

4 KESIMPULAN

Peramalan menggunakan model hibrida ARIMA-NN yang dapat digunakan pada data harga saham penutupan PT BSI Tbk. periode 26 Januari – 16 Februari 2024 adalah model hibrida ARIMA (1, 2, 0) – NN (3, 4, 1), ARIMA (2, 2, 0) – NN (3, 6, 1), dan ARIMA (0, 2, 1) – NN (3, 7, 1). Model

hibrida ARIMA-NN yang didapatkan merupakan model yang semua parameternya signifikan dan telah memenuhi asumsi residu. Nilai MAPE *training* dan *testing* dari peramalan hibrida ARIMA (0, 2, 1) – NN (3, 6, 1) adalah 1,304% dan 1,752% yang berarti hasil dari pemodelan ARIMA (0, 2, 1) – NN (3, 7, 1) menghasilkan MAPE yang lebih baik.

UCAPAN TERIMAKASIH

Penulis menyampaikan apresiasi yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan, baik secara langsung maupun tidak langsung, dalam proses penelitian dan penulisan artikel ini. Dukungan tersebut mencakup berbagai bentuk bantuan, seperti penyediaan fasilitas, masukan yang konstruktif, hingga dorongan semangat selama proses ini berlangsung. Kontribusi dari berbagai pihak telah memberikan dampak positif yang signifikan terhadap penyelesaian penelitian ini.

DAFTAR PUSTAKA

- Adnyana, I Made. (2020). *Manajemen Investasi Dan Portofolio*. Jakarta: Lembaga Penerbitan Universitas Nasional
- Ahmad, A. (2017). *Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning*. *Jurnal Teknologi Indonesia*. Yayasan Cahaya Islam.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. Prentice Hall, New Jersey.
- Hanke, J.E., & Wichern, D. (2014). *Business Forecasting (9th Ed.)*. Pearson Education, New York.
- Haykin, S. (1994). *Neural Network: A Comprehensive Foundation*. 2nd Edition. Pearson Education, New York.
- Heaton, J. (2008). *Introduction to Neural Network for Java*. 2nd Ed. Heaton Research Inc, Florida.
- Kingma, D. P & Lei Ba, J. (2017). ADAM: A Method for Stochastic Optimization. *International Conference for Learning Representations*. San Diego.
- KSEI. (2023). Statistik Pasar Modal Indonesia Februari 2023. *Kustodian Sentral Efek Indonesia*, 1–6.
- Makridakis, S., Wheelwright, S.C., & McGee, V.E. (1999). *Metode dan Aplikasi Peramalan*. Ed. ke-2. Terjemah Untung Sus Andriyanto. Erlangga, Jakarta.
- Michelucci, U. (2018). *Applied Deep Learning: A Case-Based Approach to Understanding Deep Neural Network*. Apress Berkeley, California.
- Setiawan, C. D., Sulandari, W., dan Susanti, Y. (2023). Peramalan Harga Saham PT Unilever Indonesia Menggunakan Metode Hibrida ARIMA-Neural Network. *Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK)*. 186 – 192.
- Suratna. (2020). *Investasi Saham*. Yogyakarta: lppm upn "Veteran".
- Vijayalakshmi, V. & Venkatachalapathy, K. (2019). Deep Neural Network for Multi-Class Prediction of Student Performance in Educational Data. *International Journal of Recent Technology and Engineering (IJRTE)*. 8(2): 5073-5081.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Method* (2nd (ed.)). New York: Pearson Eddison Wesley.
- Yahoo Finance. *Stock Price PT Bank Syariah Indonesia Tbk*. <https://finance.yahoo.com/quote/BRIS.JK/>. Diakses 10 Januari 2024.