



Penerapan Metode *Fuzzy Backpropagation Neural Network* dalam Peramalan Saham PT. Bank Rakyat Indonesia (Persero) Tbk. (IDX: BBRI)

Budi Cahyono¹, Ika Purnamasari^{2*}, Rito Goejantoro³

¹ Statistika, FMIPA, Universitas Mulawarman, Samarinda

² Laboratorium Statistika Ekonomi dan Bisnis, FMIPA, Universitas Mulawarman, Samarinda

³ Laboratorium Statistika Komputasi, FMIPA, Universitas Mulawarman, Samarinda

ika.purnamasari@fmipa.unmul.ac.id

Abstract

The Fuzzy Backpropagation Neural Network (FBPNN) is a forecasting approach based on neural networks that applies the backpropagation learning algorithm, where input and output data are expressed in fuzzy membership values. The construction of the FBPNN model consists of three key phases: fuzzification, neural network training, and defuzzification. In the defuzzification stage, the Smallest of Maximum (SOM) technique is used to determine the lowest value among the members with the highest degree of membership. This research employs FBPNN to forecast the weekly closing prices of PT Bank Rakyat Indonesia (Persero) Tbk. (IDX: BBRI). The dataset is divided into 90% for training and 10% for testing. The results indicate that the best network architecture is 20–4–2, producing a Root Mean Square Error (RMSE) of 728,5308 for training data and 178,2089 for testing data. The Mean Absolute Percentage Error (MAPE) reached 10,3620% (classified as good) in training and 3,9189% (classified as very good) in testing. The developed model was then applied to forecast the next five periods, showing a tendency of increasing stock prices.

Keywords: BBRI; closing stock price; FBPNN; forecasting; SOM

Abstrak

Fuzzy Backpropagation Neural Network (FBPNN) merupakan metode prediksi yang dikembangkan dari jaringan saraf tiruan dengan menggunakan algoritma *backpropagation*, di mana data masukan dan keluaran dinyatakan sebagai derajat keanggotaan *fuzzy*. Proses pembentukan model FBPNN mencakup tiga tahap utama, yaitu fuzzifikasi, pelatihan jaringan saraf tiruan, serta defuzzifikasi. Pada tahap defuzzifikasi, digunakan metode *Smallest of Maximum* (SOM) untuk menentukan nilai terkecil di antara anggota dengan derajat keanggotaan tertinggi. Penelitian ini menerapkan FBPNN dalam memprediksi harga penutupan mingguan saham PT Bank Rakyat Indonesia (Persero) Tbk. (IDX: BBRI). Data penelitian dibagi menjadi dua bagian, yaitu 90% untuk *training* dan 10% untuk *testing*. Hasil penelitian menunjukkan bahwa arsitektur jaringan terbaik adalah 20–4–2 dengan nilai *Root Mean Square Error* (RMSE) sebesar 728,5308 pada data *training* dan 178,2089 pada data *testing*. Nilai *Mean Absolute Percentage Error* (MAPE) tercatat 10,3620% (kategori baik) pada *training* dan 3,9189% (kategori sangat baik) pada *testing*. Model yang dihasilkan kemudian dipakai untuk meramalkan lima periode berikutnya, yang memperlihatkan kecenderungan kenaikan harga saham.

Kata Kunci: BBRI; harga penutupan saham; FBPNN; peramalan; SOM

1. PENDAHULUAN

Pasar saham merupakan salah satu instrumen investasi yang banyak diminati karena berpotensi memberikan keuntungan yang tinggi. Dibandingkan dengan instrumen keuangan lainnya, saham menawarkan peluang pertumbuhan nilai yang besar, meskipun di sisi lain tingkat volatilitas harganya relatif tinggi sehingga mengandung risiko yang cukup signifikan. Perubahan harga saham dipengaruhi oleh berbagai faktor, seperti kondisi ekonomi, kebijakan pemerintah, dan sentimen pasar, yang dapat menimbulkan ketidakpastian (Bodie et al., 2014). Untuk mengantisipasi risiko tersebut, investor kerap menggunakan pendekatan statistika, salah satunya analisis data runtun waktu (*time series*), guna membantu dalam peramalan dan pengambilan keputusan.

Metode *Autoregressive Integrated Moving Average* (ARIMA) merupakan salah satu teknik statistika yang kerap digunakan dalam menganalisis data runtun waktu. Akan tetapi, ARIMA memiliki beberapa keterbatasan, seperti keharusan memenuhi asumsi tertentu, di antaranya kestasioneran data serta distribusi residual yang normal (Box & Jenkins, 1970). Dalam praktiknya, kondisi tersebut tidak selalu terpenuhi, sehingga akurasi prediksi dapat menurun. Untuk mengatasi kendala ini, berbagai metode berbasis kecerdasan buatan, seperti *Neural Network* (NN) dan *Fuzzy Time Series* (FTS), mulai dikembangkan (Aswi & Sukarna, 2006).

Neural Network (NN) adalah sistem komputasi yang meniru mekanisme kerja otak manusia dalam menyelesaikan masalah melalui proses pembelajaran yang melibatkan penyesuaian bobot sinapsis. NN banyak dimanfaatkan untuk pengenalan pola, pengolahan sinyal, klasifikasi, hingga peramalan (Siang, 2009). Salah satu model NN yang umum digunakan adalah *Backpropagation Neural Network* (BPNN). Model ini memiliki kemampuan untuk memetakan hubungan nonlinear antar data dan terbukti efektif dalam menyelesaikan berbagai persoalan peramalan (Achmalia et al., 2019).

Sejumlah penelitian telah menerapkan BPNN untuk berbagai tujuan peramalan. Novita (2016) menggunakan BPNN untuk memprediksi harga saham BBRI, sedangkan Parab et al., (2021) memanfaatkannya untuk memperkirakan kadar glukosa dan urea pada pasien penyakit ginjal kronis. Penelitian lain oleh Febiyanti et al., (2023) juga memprediksi harga saham BBRI menggunakan pendekatan ini. Meskipun memiliki akurasi tinggi, BPNN memerlukan jumlah iterasi yang besar untuk mencapai tingkat kesalahan minimal, yang berarti waktu pelatihan dan kebutuhan komputasi menjadi lebih tinggi, terutama pada jaringan dengan lapisan dan *neuron* yang banyak.

Salah satu cara untuk mengatasi keterbatasan metode BPNN adalah dengan mengombinasikannya dengan konsep logika fuzzy, yang dikenal sebagai *Fuzzy Backpropagation Neural Network* (FBPNN). Pada metode ini, data input dan output direpresentasikan dalam bentuk derajat keanggotaan *fuzzy*, lalu diproses menggunakan algoritma *backpropagation* (Wiliansa & Kusumawati, 2017). FBPNN telah diterapkan

pada berbagai bidang, seperti peramalan penjualan papan sirkuit cetak (Chang et al., 2005), prediksi nilai tukar rupiah terhadap dolar AS (Wiliansa & Kusumawati, 2017), serta estimasi jumlah wisatawan mancanegara provinsi Kalimantan Timur (Aprilianti et al., 2023).

Di sektor ekonomi, saham menjadi instrumen penting dalam aktivitas pasar modal. Saham PT Bank Rakyat Indonesia (Persero) Tbk. (BBRI) merupakan salah satu emiten perbankan dengan kapitalisasi pasar yang besar dan memiliki volatilitas harga yang cukup tinggi. Tahun 2023, harga saham BBRI mengalami penurunan sekitar 15% akibat ketidakpastian global, namun kembali menguat sebesar 5% pada awal 2024. Secara fundamental, kinerja keuangan perusahaan tetap solid dengan pertumbuhan laba serta penyaluran kredit yang stabil (Prasetyo & Rini, 2024). Berdasarkan latar belakang tersebut, penelitian ini dilakukan untuk menerapkan metode FBPNN dalam memprediksi harga penutupan saham mingguan BBRI.

Meskipun *Neural Network*, termasuk BPNN dan FBPNN, telah banyak digunakan dalam peramalan harga saham, kajian terdahulu umumnya masih berfokus pada aspek penerapan empiris tanpa menelaah secara mendalam peran representasi *fuzzy* dalam meningkatkan kemampuan generalisasi model pada kondisi volatilitas pasar yang tinggi. Selain itu, penelitian dengan data mingguan masih terbatas, sehingga potensi FBPNN dalam mereduksi *noise* jangka pendek sekaligus menangkap pola tren jangka menengah belum dieksplorasi secara optimal.

Perkembangan metode peramalan dalam beberapa tahun terakhir menunjukkan meningkatnya penggunaan model *hybrid* dan *soft computing* untuk meningkatkan akurasi prediksi pasar keuangan. Studi terbaru menunjukkan bahwa pendekatan *hybrid* yang memadukan elemen *fuzzy* dengan arsitektur *neural*, seperti *Long Short-Term Memory Network* (LSTM), mampu menangkap dinamika nonlinier dan ketidakpastian dalam data deret waktu lebih efektif dibandingkan model konvensional (Lin & Hsu, 2024). Selain itu, penerapan sistem evaluasi berbasis *fuzzy* juga terbukti efektif dalam prediksi harga saham melalui pendekatan multi-kriteria, sebagaimana ditunjukkan pada studi kasus saham Tesla (Hašková et al., 2023). Hasil lain menunjukkan bahwa model *hybrid fuzzy-time series* dengan LSTM mampu meningkatkan akurasi prediksi pasar saham/indeks pada kondisi *noise* yang tinggi (Hidayatur et al., 2025). Namun demikian, kajian empiris yang secara khusus mengevaluasi kinerja FBPNN pada saham perbankan di pasar berkembang seperti Indonesia masih terbatas. Oleh karena itu, penelitian ini berkontribusi dengan menerapkan FBPNN pada data harga penutupan saham mingguan BBRI serta mengevaluasi kemampuannya dalam menangkap dinamika nonlinear dan volatilitas pasar saham perbankan Indonesia.

2. METODE PENELITIAN

Data yang digunakan dalam penelitian ini berupa harga penutupan mingguan saham BBRI untuk periode Januari 2024 hingga April 2025. Data diperoleh melalui situs Yahoo Finance. Analisis dilakukan dengan menerapkan metode *Fuzzy Backpropagation Neural Network* (FBPNN), melalui tahapan sebagai berikut:

1. Analisis Deskriptif Awal

Menyusun grafik runtun waktu untuk mengidentifikasi pola pergerakan harga penutupan saham BBRI selama periode pengamatan.

2. Identifikasi *Lag* ACF dan PACF

Membuat plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk menentukan *lag* yang signifikan, yaitu yang berada di luar batas interval kepercayaan.

3. Penentuan Variabel Input dan Pemisahan Data

Menetapkan jumlah variabel *input* berdasarkan jumlah *lag* signifikan pada langkah sebelumnya. Dataset kemudian dibagi menjadi dua bagian, yaitu data *training* untuk membangun model dan data *testing* untuk mengevaluasi performa model.

4. Fuzzifikasi Data

Proses fuzzifikasi dilakukan dengan fungsi keanggotaan linear menurun, yang tahapannya mengacu pada Hidayah & Sugiman, (2021).

a. Menentukan *universe of discourse* U dengan rumus:

$$U = [Z_{\min} - D_1, Z_{\max} + D_2] \quad (1)$$

di mana Z_{\min} adalah nilai terkecil dari data, Z_{\max} adalah nilai terbesar dari data, D_1 dan D_2 merupakan bilangan riil positif yang peneliti tentukan.

b. Menentukan batas kelas dengan persamaan (2).

$$L = \frac{R}{B} = \frac{[U_{\max} - U_{\min}]}{B} \quad (2)$$

di mana U_{\min} adalah nilai minimum, U_{\max} adalah nilai maksimum dari himpunan semesta pembicaraan U dan B adalah banyak kelas interval yang ditentukan berdasarkan fungsi keanggotaan yang digunakan.

c. Membentuk dua himpunan *fuzzy*, yaitu $\mu_1(x)$ dan $\mu_2(x)$, dengan menggunakan rumus fungsi keanggotaan linear menurun pada Persamaan (3).

$$\mu(x) = \begin{cases} \frac{(x-a)}{(b-a)}; & a \leq x \leq b \\ 0; & x \geq b \end{cases} \quad (3)$$

5. Tahap pelatihan BPNN

Pelatihan jaringan dilakukan dengan fungsi aktivasi sigmoid biner. Tahapannya meliputi (Febiyanti et al., 2023):

a. Menentukan jumlah iterasi maksimum, nilai *target error*, serta *learning rate*.

- b. Inisialisasi bobot awal dengan nilai acak kecil.
- c. Proses *feedforward* dilakukan untuk memperoleh sinyal pada *hidden layer* maupun *output layer* melalui tahapan berikut :
 - 1) Menentukan nilai masukan pada *hidden layer* dengan memanfaatkan bobot yang ada sesuai persamaan (4).

$$z_in_j = v_{0j} + \sum_{i=1}^p x_i v_{ij} \quad (4)$$

selanjutnya menghitung nilai *output* berdasarkan persamaan (5).

$$z_j = f(z_in_j) = \frac{1}{1 + e^{-z_in_j}} \quad (5)$$

di mana z_in_j adalah *input* total pada unit ke- j di *hidden layer*, v_{0j} merupakan nilai bobot bias yang terhubung ke *neuron* ke- j pada *hidden layer*, v_{ij} adalah bobot koneksi antara *neuron* ke- i pada *layer input* dan *neuron* ke- j pada *hidden layer* serta z_j adalah *hidden layer* ke- j .

- 2) Menentukan nilai masukan pada *output layer* dengan memanfaatkan bobot yang telah dihitung berdasarkan persamaan (6).

$$y_in_k = w_{0k} + \sum_{j=1}^q z_j w_{jk} \quad (6)$$

selanjutnya menghitung nilai *output* berdasarkan persamaan (7).

$$y_k = f(y_in_k) = \frac{1}{1 + e^{-y_in_k}} \quad (7)$$

di mana y_in_k merupakan *input* total pada unit ke- k di *output layer*, w_{0k} merupakan bobot bias untuk unit ke- k pada *output layer*, w_{jk} merupakan bobot koneksi antara unit ke- j pada *input layer* dan unit ke- k pada *output layer*, dan y_k adalah *output* dari *neuron* ke- k .

- d. Melakukan *backpropagation* dengan tahapan berikut:

- 1) Menghitung *error* di *output layer* dengan menggunakan Persamaan (8).

$$\begin{aligned} \delta_k &= (Y_k - y_k) f'(y_in_k) \\ \delta_k &= (Y_k - y_k)(y_in_k)[1 - f(y_in_k)] \end{aligned} \quad (8)$$

di mana δ_k merupakan *error* proses *backpropagation* unit ke- k , Y_k merupakan target *output* untuk *neuron* ke- k , dan y_k merupakan *output* aktual dari *neuron* ke- k .

- 2) Menghitung perubahan bobot dan bias *output layer* dengan menggunakan Persamaan (9) dan Persamaan (10).

$$\Delta w_{jk} = \eta \delta_k z_j \quad (9)$$

$$\Delta w_{0k} = \eta \delta_k \quad (10)$$

di mana Δw_{jk} menggambarkan besarnya perubahan bobot dari *neuron* ke- j pada *hidden layer* menuju *neuron* ke- k di *output layer*, η sebagai *learning rate* dan Δw_{0k} merupakan perubahan bobot bias untuk *neuron* ke- k di *output layer*.

- 3) Menghitung *error* di *hidden layer* dengan menggunakan Persamaan (11) dan Persamaan (12).

$$\delta_{-in_j} = \sum_{k=1}^r \delta_k w_{jk} \quad (11)$$

$$\delta_j = (\delta_{-in_j}) f'(z_{-in_j}) \quad (12)$$

- 4) Menghitung perubahan bobot dan bias *hidden layer* menggunakan Persamaan (13) dan Persamaan (14).

$$\Delta v_{ij} = \eta \delta_j x_i \quad (13)$$

$$\Delta v_{0j} = \eta \delta_j \quad (14)$$

- e. Memperbarui bobot dan bias dengan menggunakan Persamaan (15) dan Persamaan (16).

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (15)$$

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (16)$$

- f. Proses ini diulang hingga *error* memenuhi kriteria target atau jumlah iterasi maksimum tercapai.

6. Pengujian model

Model yang telah dilatih digunakan untuk memprediksi data pengujian melalui proses feedforward menggunakan bobot dan bias terbaik.

7. Defuzzifikasi

Hasil prediksi dalam bentuk derajat keanggotaan dikonversi kembali menjadi nilai tegas (*crisp*) dengan metode yang sejalan dengan proses fuzzifikasi.

8. Evaluasi performa model

Evaluasi performa model dilakukan dengan menghitung *Root Mean Square Error* (RMSE) serta *Mean Absolute Percentage Error* (MAPE) berdasarkan Persamaan (16) dan (17).

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

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100\% \quad (17)$$

di mana n adalah banyaknya data runtun waktu, Z_t adalah data aktual periode ke- t , dan \hat{Z}_t menunjukkan hasil prediksi pada periode ke- t . Kriteria akurasi prediksi dengan MAPE ditampilkan pada Tabel 1 (Makridakis dkk., 1999).

Tabel 1. Tingkat Akurasi MAPE

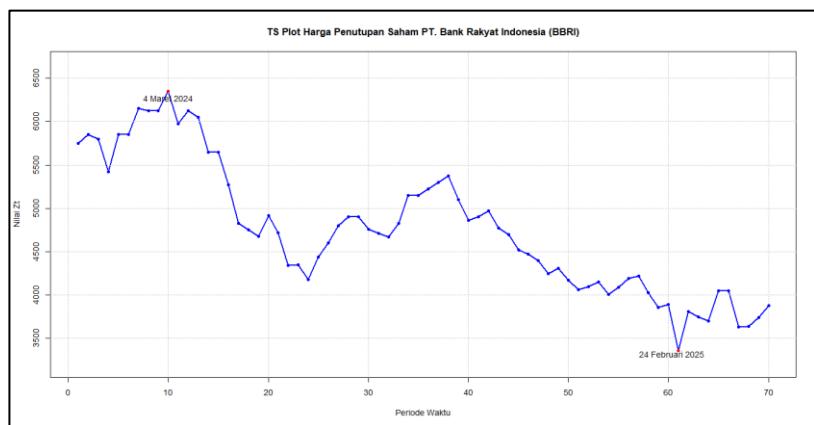
Nilai MAPE	Kriteria Tingkat Akurasi
$MAPE < 10\%$	Sangat Baik
$10\% \leq MAPE < 20\%$	Baik
$20\% \leq MAPE \leq 50\%$	Cukup
$MAPE > 50\%$	Buruk

9. Peramalan periode berikutnya

Menggunakan model terbaik untuk memprediksi harga penutupan saham lima minggu ke depan.

3. HASIL DAN PEMBAHASAN

Berdasarkan data harga penutupan mingguan saham BBRI periode 1 Januari 2024 hingga 28 April 2025, dibuat *plot* runtun waktu untuk mengamati pergerakan harga. *Plot* tersebut disajikan pada Gambar 1.

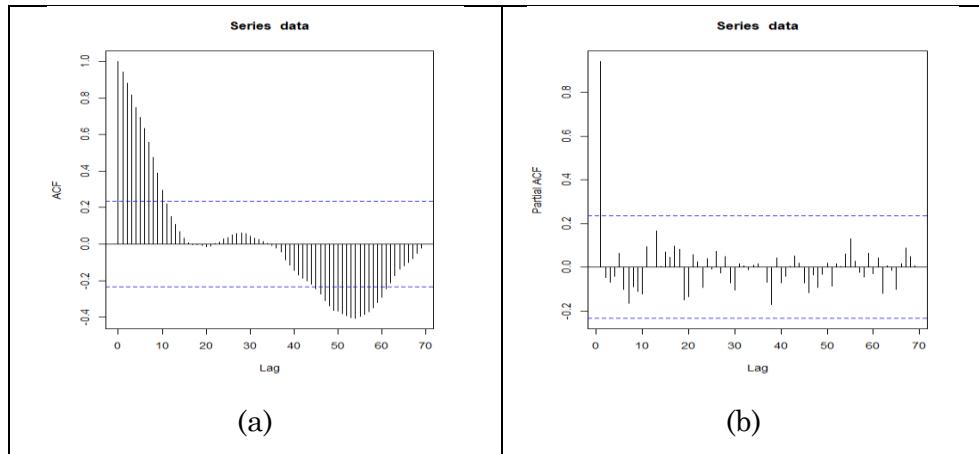


Gambar 1. *Plot* runtun waktu harga penutupan saham BBRI periode Januari 2024 hingga April 2025

Berdasarkan hasil analisis runtun waktu pada Gambar 1, pergerakan harga penutupan saham BBRI selama periode 1 Januari 2024 hingga 28 April 2025 menunjukkan kecenderungan tren menurun dengan fluktuasi yang cukup tinggi. Pola ini mengindikasikan adanya dinamika nonlinier dan volatilitas yang signifikan, yang secara teoritis sulit dimodelkan secara optimal menggunakan pendekatan linier konvensional. Harga terendah tercatat pada tanggal 24 Februari 2025 (minggu keempat bulan Februari) sebesar Rp3.360 per lembar saham, sedangkan harga tertinggi terjadi pada 4 Maret 2024 (minggu pertama bulan Maret) dengan nilai Rp6.350 per lembar.

3.1 Penentuan Variabel Input FBPNN

Penentuan variabel input merupakan tahap penting dalam pemodelan FBPNN karena memengaruhi kemampuan model dalam menangkap ketergantungan temporal data runtun waktu. Pada penelitian ini, pemilihan variabel input dilakukan berdasarkan analisis Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) untuk mengidentifikasi pengaruh harga saham pada beberapa periode sebelumnya.



Gambar 2. Grafik ACF dan PACF harga saham BBRI dari 1 Januari 2024 hingga 28 April 2025

Pada Gambar 2(a) terlihat terdapat 10 *lag*, yaitu *lag* ke-1 hingga *lag* ke-10, yang melewati batas interval kepercayaan, sedangkan pada Gambar 2(b) hanya satu *lag* yang melampaui batas interval, yaitu *lag* ke-1. Karena jumlah *lag* signifikan pada PACF lebih sedikit dibandingkan dengan ACF, maka penentuan banyaknya *input* ditetapkan berdasarkan ACF, yaitu sebanyak 10 *input*. Proses pemodelan dilakukan menggunakan data ke-11 sampai data ke-70, sehingga diperoleh total 60 data, yang dibagi menjadi 54 data *training* (90%) dan 6 data *testing* (10%).

Meskipun PACF hanya menunjukkan satu *lag* dominan, penggunaan ACF sebagai dasar penentuan variabel input dinilai lebih representatif dalam konteks peramalan berbasis *neural network*, karena model ini tidak bergantung pada asumsi struktur linier seperti pada ARIMA.

3.2 Proses Fuzzifikasi

3.2.1 Penentuan Himpunan Semesta Pembicaraan *U*

Berdasarkan hasil *trial and error*, diperoleh kombinasi nilai $D_1 = 1$ dan $D_2 = 9$. Dengan demikian, diperoleh domain semesta *U* diperoleh melalui Persamaan (1).

$$\begin{aligned} U &= [Z_{\min} - D_1, Z_{\max} + D_2] \\ &= [3.360 - 1, 6.350 + 9] \\ &= [3.359, 6.359] \end{aligned}$$

Rentang ini dibagi menjadi dua sub himpunan *fuzzy* $\mu_1(x)$ dan $\mu_2(x)$ melalui fungsi keanggotaan linier menurun yang dapat dituliskan sebagai berikut:

$$\mu_1(x) = \begin{cases} \frac{(4.859-x)}{(4.859-3.359)}; & 3.359 \leq x \leq 4.859 \\ 0; & x \geq 4.859 \end{cases}$$

$$\mu_2(x) = \begin{cases} \frac{(6.359-x)}{(6.359-4.859)}; & 4.859 \leq x \leq 6.359 \\ 0; & x \geq 6.359 \end{cases}$$

3.2.2. Derajat Keanggotaan Fuzzy

Derajat nilai keanggotaan *fuzzy* ditentukan dengan memasukkan tiap nilai masukan ke dalam rumus fungsi keanggotaan linear menurun yang sudah ditentukan. Proses ini diterapkan pada seluruh data baik variabel *input* ($x_1, x_2, x_3, \dots, x_{10}$) dan variabel *output* (y) untuk data *training* dan *testing*. Hasil perhitungan ditampilkan pada Tabel 3 dan Tabel 4.

Tabel 2. Derajat Keanggotaan *Fuzzy* Data *Training*

x_1	x_2	...	x_{10}	y
$\mu_1(x)$	$\mu_2(x)$	$\mu_1(x)$	$\mu_2(x)$	$\mu_1(x)$
0	0,0060	0	0,1560	...
0	0,2560	0	0,0060	...
0	0,1560	0	0,2560	...
0	0,2060	0	0,1560	...
⋮	⋮	⋮	⋮	⋮
0,7393	0	0,6993	0	...
			0,5660	0
				0,7727
				0

Tabel 3. Derajat Keanggotaan *Fuzzy* Data *Training*

x_1^*	x_2^*	...	x_{10}^*	y^*
$\mu_1(x)$	$\mu_2(x)$	$\mu_1(x)$	$\mu_2(x)$	$\mu_1(x)$
0,7727	0	0,7393	0	...
0,5393	0	0,7727	0	...
0,5393	0	0,5393	0	...
0,8193	0	0,5393	0	...
0,8127	0	0,8193	0	...
0,7460	0	0,8127	0	...
			0,5922	0
				0,5987
				0

Pada tahap fuzzifikasi, transformasi data numerik ke dalam derajat keanggotaan *fuzzy* berperan penting dalam mereduksi ketidakpastian dan *noise* yang melekat pada data harga saham. Representasi *fuzzy* memungkinkan informasi harga tidak diperlakukan secara tegas (*crisp*), melainkan sebagai nilai dengan tingkat keanggotaan tertentu, sehingga variasi kecil pada data tidak langsung menghasilkan perubahan ekstrem pada proses pembelajaran jaringan. Dengan demikian, proses fuzzifikasi membantu meningkatkan stabilitas pembelajaran dan kemampuan model dalam menangkap pola data yang bersifat tidak pasti dan fluktuatif.

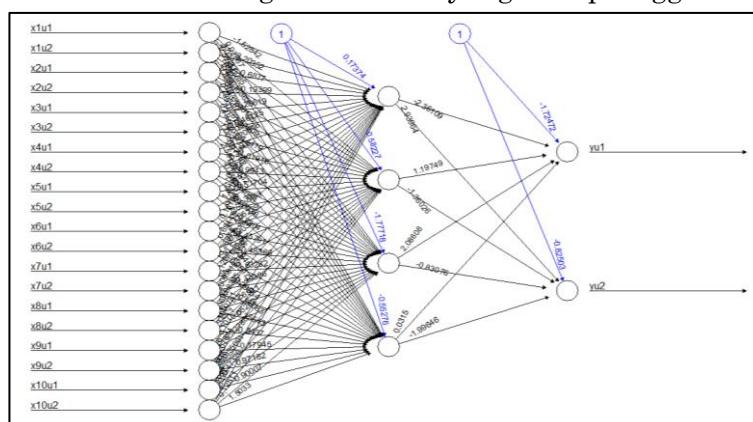
3.3 Neural Network (NN)

Pada tahap ini, model FBPNN dikonstruksi dengan parameter *learning rate* sebesar 0,01, target *error* 0,05, serta jumlah iterasi maksimum 10.000. Bobot awal ditentukan secara acak, sedangkan banyaknya *neuron* pada lapisan tersembunyi ditentukan melalui proses *trial and error* guna memperoleh hasil kinerja yang optimal. Proses evaluasi dilakukan dengan cara membandingkan nilai RMSE dan MAPE pada data *training* maupun *testing*, sebagaimana ditunjukkan pada Tabel 4.

Tabel 4. Nilai RMSE dan MAPE

Neuron	RMSE		MAPE	
	Training	Testing	Training	Testing
1	764,3134	192,7713	10,9859	4,3263
2	756,2838	179,9818	10,5644	4,0550
3	736,1889	180,7167	10,2966	4,1503
4	728,5308	178,2089	10,3620	3,9189
5	753,0556	232,6120	10,7301	5,5181
6	777,6751	235,9897	10,4824	5,4342
7	766,5016	217,6169	10,6032	5,1790
8	764,3611	223,7541	10,4654	4,8852
9	779,7797	211,4959	10,5643	5,1518
10	785,5701	223,0908	10,5044	5,1327

Berdasarkan nilai MAPE pada Tabel 5, diketahui bahwa model FBPNN dengan konfigurasi *hidden layer* sebanyak 4 *neuron* memberikan akurasi tertinggi, dengan RMSE dan MAPE terendah pada data *testing*, sehingga model terbaik adalah arsitektur 20–4–2. Hasil ini menunjukkan bahwa penambahan neuron tidak selalu meningkatkan kinerja model dan justru berpotensi menyebabkan *overfitting*. Oleh karena itu, arsitektur yang lebih sederhana memberikan kemampuan generalisasi yang lebih baik dalam memodelkan data deret waktu dengan fluktuasi yang cukup tinggi.



Gambar 3. Grafik ACF dan PACF harga saham BBRI
periode Januari 2024 hingga April 2025

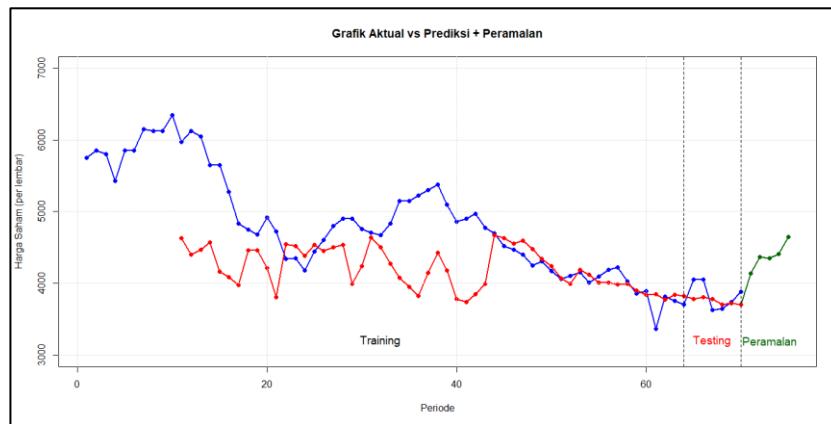
3.4 Peramalan FBPNN

Peramalan model FBPNN 5 periode (minggu) ke depan dengan 4 *neuron hidden layer* disajikan pada Tabel 5.

Tabel 5. Hasil Peramalan

Periode ke-	Hasil Peramalan
71	4.139,962
72	4.365,851
73	4.346,164
74	4.404,961
75	4.643,365

Selanjutnya dibuat grafik pada Gambar 4 yang memperlihatkan perbandingan antara data aktual dengan hasil prediksi FBPNN menggunakan 4 *neuron* pada lapisan *hidden*.



Gambar 4. Grafik perbandingan model

Pada Gambar 4 menunjukkan perbandingan harga penutupan saham aktual, hasil prediksi FBPNN pada tahap *training* dan *testing*, serta peramalan lima minggu ke depan. Prediksi mengikuti pola harga aktual dengan deviasi kecil, dan proyeksi menunjukkan tren kenaikan bertahap. Secara keseluruhan, hasil penelitian menunjukkan bahwa FBPNN efektif digunakan untuk peramalan harga saham pada kondisi pasar yang fluktuatif sekaligus mampu meningkatkan akurasi peramalan.

4. SIMPULAN

Berdasarkan hasil penelitian, model FBPNN terbaik untuk memprediksi harga saham BBRI memiliki arsitektur 20–4–2, yaitu terdiri atas 20 *neuron* pada lapisan *input*, 4 *neuron* pada lapisan *hidden*, dan 2 *neuron* pada lapisan *output*. Model ini menghasilkan tingkat akurasi nilai RMSE sebesar 732,5308 pada data *training* dan 178,2089 pada data *testing*. Nilai MAPE yang diperoleh pada data *training* adalah 10,3620% (kategori baik), sedangkan pada data *testing* sebesar 3,9189% (kategori sangat baik). Dengan demikian, konfigurasi tersebut dapat dianggap sebagai model paling optimal untuk meramalkan harga saham BBRI pada periode Mei hingga pertengahan Juni 2025, dengan estimasi harga berada di kisaran Rp4.380,061 per lembar saham.

5. REKOMENDASI

Berdasarkan hasil penelitian, direkomendasikan agar penelitian selanjutnya mengeksplorasi penggunaan fungsi keanggotaan *fuzzy* lainnya, seperti fungsi segitiga, kurva-S, atau Gaussian, untuk mengetahui pengaruhnya terhadap tingkat akurasi prediksi. Selain itu, Skema pembagian data juga perlu divariasi, misalnya dengan perbandingan 80:20 atau 70:30, serta mempertimbangkan penerapan validasi silang (*cross-validation*) untuk memastikan konsistensi dan generalisasi model yang lebih baik.

6. REFERENSI

- Achmalia, A. F., Walid, & Sugiman. (2019). Peramalan Penjualan Semen Menggunakan Backpropagation Neural Network dan Recurrent Neural Network. *UNNES Journal of Mathematics*, 8(1), 92–106.
- Aprilianti, R., Purnamasari, I., & Prangga, S. (2023). *Peramalan Jumlah Wisatawan Mancanegara di Provinsi Kalimantan Timur Menggunakan Fuzzy Backpropagation Neural Network*. 2(1), 1–11.
- Aswi, A., & Sukarna. (2006). *Analisis Runtun Waktu: Teori dan Aplikasi*. Andira Publisher.
- Bodie, Z., Kane, A., & Marcus, A. J. (2014). *Investments* (10th ed). McGraw-Hill Education.
- Box, G. E. P., & Jenkins, G. M. (1970). *Time Series Analysis: Forecasting and Control*. Holden-Day.
- Chang, P. C., Wang, Y. W., & Liu, C. H. (2005). Fuzzy back-propagation network for PCB sales forecasting. *Lecture Notes in Computer Science*, 3610(PART I), 364–373. https://doi.org/10.1007/11539087_45
- Febiyanti, D., Amalita, N., Permana, D., & Mukhti, T. O. (2023). Backpropagation Neural Network Application in Predicting The Stock Price of PT. Bank Rakyat Indonesia Tbk. *UNP Journal of Statistics and Data Science*, 1(5), 441–448. <https://doi.org/10.24036/ujsds/vol1-iss5/113>
- Hašková, S., Šuleř, P., & Kuchár, R. (2023). A Fuzzy Multi-Criteria Evaluation System for Share Price Prediction: A Tesla Case Study. *Mathematics*, 11(3033). <https://doi.org/10.3390/math11133033>
- Hidayah, D. Y., & Sugiman. (2021). Peramalan Nilai Tukar Rupiah terhadap Dollar Amerika dengan Metode Fuzzy Time Series (FTS) Markov Chain. *UNNES Journal of Mathematics*, 10(2), 85–95.
- Hidayatur, A., Idhom, M., & Syaifulah, W. (2025). Hybrid Prediction Model Fuzzy Time Series-LSTM on Stock Price Data with Volatility Variation. *Bit-Tech (Binary Digital Technology)*, 8(2), 1625–1636. <https://doi.org/10.32877/bt.v8i2.3014>
- Lin, H. Y., & Hsu, B. W. (2024). Application of hybrid fuzzy interval-based machine learning models on financial time series — A case study of Taiwan biotech index during the epidemic period. *Frontiers in Artificial Intelligence*, 6:1283741. <https://doi.org/10.3389/frai.2023.1283741>
- Makridakis, S., Wheelwright, S. C., McGee, V. E. (1999). *Metode dan Aplikasi Peramalan Jilid 1*. Erlangga.
- Novita, A. (2016). Prediksi Pergerakan Harga Saham Pada Bank Terbesar Di Indonesia Dengan Metode Backpropagation Neural Network. *Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, 5(1), 965–972. <https://doi.org/10.35889/jutisi.v5i1.155>
- Parab, J., Sequeira, M., Lanjewar, M., Pinto, C., & Naik, G. (2021). Backpropagation Neural Network-Based Machine Learning Model for Prediction of Blood Urea and Glucose in CKD

Patients. *IEEE Journal of Translational Engineering in Health and Medicine*, 9(April), 1–8.
<https://doi.org/10.1109/JTEHM.2021.3079714>

Prasetyo, A., & Rini, H. (2024). Ancaman Resesi Global 2025 dan Dampaknya pada Sektor Perbankan di Indonesia. *Jurnal Ekonomi Dan Keuangan*, 34(2), 152–169.

Siang, J. J. (2009). *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Andi.

Wiliansa, G., & Kusumawati, R. (2017). Optimasi Fuzzy Backpropagation Neural Network dengan Algoritma Genetika untuk Memprediksi Nilai Tukar Rupiah Terhadap Dolar Amerika. *Jurnal Matematika*, 6(3), 10–20.

Yahoo Finance. (2025). BBRI.JK (Bank Rakyat Indonesia) stock price. Yahoo! Finance. Diakses pada 30 April 2025, dari <https://finance.yahoo.com/quote/BBRI.JK>