

Penerapan *Artificial Neural Network* dengan Algoritma *Backpropagation* untuk Memprediksi Harga Saham

Widhi Aryanti*

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Bandung, Indonesia

ARTICLE INFO

Article history :

Received : 3/11/2023

Revised : 14/12/2023

Published : 24/12/2023



Creative Commons Attribution-
NonCommercial-ShareAlike 4.0
International License.

Volume : 3

No. : 2

Halaman : 107 - 118

Terbitan : Desember 2023

ABSTRAK

Data dapat dimanfaatkan dalam membuat sebuah keputusan di masa yang akan datang. Dalam menentukan sebuah keputusan yang krusial diperlukan sebuah metode yang tepat dalam memprediksi data. Salah satu metode yang paling banyak digunakan dalam memprediksi data adalah regresi linear berganda dengan metode *ordinary least square* (OLS), namun dalam peniterepannya sering kali data tidak memenuhi asumsi sehingga *Artificial neural network* (ANN) dijadikan sebagai alternatif untuk memprediksi data karena kemampuannya dalam melakukan algoritma pembelajaran dari data dimana dalam prosesnya tidak diperlukan asumsi apapun. ANN dapat mempelajari pola-pola yang terdapat pada data melalui serangkaian layer yang saling terhubung, dimana setiap layer terdiri dari sejumlah neuron yang memiliki bobot dan bias tertentu. Fungsi aktivasi sigmoid digunakan untuk mengaktifkan atau menonaktifkan sebuah neuron serta untuk memudahkan perhitungan pada saat melakukan algoritma *Backpropagation Neural Network*. Algoritma *Backpropagation Neural Network* (BNN) dimulai dari inisialisasi bobot dan bias awal, kemudian melakukan prediksi terhadap data testing, menghitung error, dan memperbarui bobot dan bias menggunakan algoritma gradien. Dari hasil pengujian, menggunakan multilayer network diperoleh komponen arsitektur 7-3-1 dan penilaian faktor dengan rincian jumlah iterasi 100, nilai learning rate sebesar 0,9 dan toleransi error sebesar 0,01 sehingga diperoleh nilai hasil rata-rata RMSE *Atrificial neural network* (ANN) sebesar 0,01392 untuk proses training, rata-rata RMSE *Atrificial neural network* (ANN) sebesar 0,01128 untuk proses testing dan akurasi mencapai 96%.

Kata Kunci : Artificial Neural Network (ANN); Backpropagation; Sigmoid

ABSTRACT

Data can be utilized in making a decision in the future. In determining a crucial decision, an appropriate method is needed in predicting data. One of the most widely used methods in predicting data is multiple linear regression with the ordinary least squares (OLS) method, but in its implementation the data often does not meet the assumptions so that Artificial Neural Network (ANN) is used as an alternative for predicting data because of its ability to carry out learning algorithms from data where in the process no assumptions are needed. ANN can study the patterns contained in the data through a series of interconnected layers, where each layer consists of a number of neurons that have certain weights and biases. The sigmoid activation function is used to activate or deactivate a neuron and to facilitate calculations when performing the Backpropagation Neural Network algorithm. The Backpropagation Neural Network (BNN) algorithm starts from initializing the initial weights and biases, then predicts the testing data, calculates errors, and updates the weights and biases using a gradient algorithm. From the test results, using a multilayer network, the architectural components 7-3-1 and the factor assessment are obtained with details of the number of iterations of 100, the learning rate value is 0.9 and the error tolerance is 0.01 so that the average result value of RMSE Artificial Neural Network (ANN) is 0.01392 for the training process, the average RMSE Artificial Neural Network (ANN) is 0.01128 for the testing process and the accuracy reaches 96%.

Keywords : Artificial Neural Network (ANN); Backpropagation; Sigmoid.

A. Pendahuluan

Teknologi informasi yang semakin berkembang membuat data yang dihasilkan mengikuti perkembangannya dan tumbuh menjadi big data. Data dapat dimanfaatkan dengan disimpan, dikumpulkan dan diolah sehingga menghasilkan informasi yang memiliki makna. Data dapat diprediksi untuk membantu kita membuat keputusan yang lebih baik di masa depan. Dalam menentukan sebuah keputusan yang krusial maka dibutuhkan metode yang tepat dalam memprediksi sebuah data. Pemodelan data prediktif dapat menjadi alternatif untuk melakukan prediksi dan membuat sebuah keputusan.

Pendekatan statistik yang paling umum dilakukan dalam pemodelan data prediktif ialah teknik regresi linier berganda menggunakan metode estimasi ordinary least square (OLS). Namun penggunaan teknik regresi linier berganda dengan metode OLS memiliki persyaratan asumsi dasar dan sering ditemukan bahwa data yang akan dimodelkan tidak memenuhi asumsi klasik yang dipersyaratkan. Jika data yang tidak memenuhi asumsi tetap dimodelkan dengan menggunakan pendekatan tersebut maka asumsi tersebut dilanggar sehingga menyebabkan hasil yang diperoleh menjadi jauh dari yang diharapkan, tidak efektif, tidak konsisten atau bahkan menjadi bias [1].

Artificial Neural Network (ANN) merupakan salah satu metode soft computing yang powerful dan sering digunakan dalam melakukan pemodelan data secara prediktif karena tidak bergantung pada bentuk asumsi yang mendasari data [1]. ANN meniru cara kerja jaringan syaraf biologis manusia dalam memproses informasi dengan cara menggunakan struktur berlapis untuk mempelajari pola dan hubungan dalam data [2]. ANN terdiri dari beberapa lapisan atau layer, dimana setiap layer terdiri dari satu atau lebih neuron. Neuron dalam ANN menerima input, melakukan komputasi dan menghasilkan output. Setiap neuron perlu diaktifkan menggunakan fungsi aktivasi, salah satu fungsi aktivasi yang digunakan adalah fungsi aktivasi sigmoid karena dapat mengaktifkan neuron yang terbatas yakni rentang 0 hingga 1. Sigmoid merupakan fungsi monotonic dan kontinu, yang berarti jika input ditingkatkan maka output akan ikut meningkat. Hal ini berguna dalam memudahkan perhitungan gradient pada saat melakukan algoritma backpropagation neural network.

Backpropagation merupakan teknik yang digunakan untuk menghitung gradient atau turunan dari fungsi kesalahan yang diterapkan pada jaringan ANN. Proses pelatihan backpropagation dilakukan dengan menghitung nilai kesalahan antara nilai target dan keluaran yang dihasilkan oleh jaringan, kemudian menghitung gradient dan memperbarui bobot dan bias pada setiap neuron dengan menggunakan algoritma backpropagation neural network. Proses ini berulang-ulang hingga nilai kesalahan batas tertentu atau jaringan telah menghasilkan keluaran yang lebih akurat. Backpropagation neural network dapat memproses data yang lebih kompleks, memperhitungkan faktor-faktor yang beragam dan menghasilkan prediksi yang akurat berdasarkan data historis seperti yang ada pada data saham.

Saham menjadi salah satu instrument pasar modal yang paling popular bagi para investor, karena saham mampu memberikan profit [3]. Tercatat menurut Self Regulatory Organization (SRO) ada satu juta investor saham baru sepanjang tahun 2021. Memprediksi harga saham sangatlah berguna bagi para investor saham karena harga saham dapat mengalami perubahan signifikan dalam waktu yang cepat, maka pemegang saham harus mampu menentukan dengan cepat kapan saham semestinya dijual atau dipertahankan. Laju saham yang relatif tidak linear menyebabkan para investor kesulitan dalam memprediksinya. Oleh sebab itu, investor harus menentukan metode yang paling akurat dalam memprediksi harga saham.

Berdasarkan pemaparan diatas, penelitian ini akan melihat penerapan Artificial Neural Network (ANN) dengan algoritma backpropagation melalui fungsi aktivasi sigmoid dalam memprediksi harga saham PT. ABC dengan menggunakan data historis saham dan data eksternal yang mempengaruhi saham.

B. Metode Penelitian

Artificial Neural Network (ANN)

Artificial Neural Network (ANN) atau jaringan syaraf tiruan ialah salah satu representasi buatan dari otak manusia yang selalu mencoba mensimulasikan proses pembelajaran pada otak manusia [4]. Bangunan dasar dari Artificial Neural Network adalah neuron. Neuron ialah hasil perkalian antara nilai input dengan bobot. Arsitektur neural network terbagi menjadi tiga kategori, yaitu single layer network, multi layer network dan

jaringan lapisan kompetitif. Terdapat beberapa faktor yang berfungsi untuk mengukur ketepatan kinerja jaringan *Artificial Neural Network* (ANN), diantaranya adalah learning rate, iterasi, dan toleransi error [5].

Data dan Sumber Data

Data harga saham PT. ABC yang dipakai dalam penelitian ini adalah data harga saham dari tanggal 1 Maret 2013 – 28 Februari 2023 yang terdiri dari 2487 hari dengan atribut historis harga saham yaitu Date, Open, High, Low, close dan Volume. Sedangkan data eksternal yang mempengaruhi harga saham adalah inflasi, suku bunga, dan kurs rupiah [6]. Di antara posisi harga, harga penutupan (closing) adalah harga terpenting yang merupakan harga saham terakhir kali pada saat transaksi di tutup. Harga close saham di hari itu akan menjadi acuan harga pembukaan di hari esok [7].

Tahapan Pra Analisis *Artificial Neural Network* (ANN)

Tahapan data preparation harga saham PT. ABC dilakukan sebagai berikut: (1) Melakukan data selection dari data historis harga saham maupun faktor eksternal harga saham. (2) Memeriksa kelengkapan data dari setiap atribut data (data cleaning). Data cleaning merupakan langkah untuk menghilangkan atribut yang tidak lengkap. Terdapat 2 cara dalam melakukan data cleaning, yaitu melakukan case deletion dengan cara menghapus record yang hilang pada atribut atau melakukan *imputation techniques* dengan cara mengisi data yang hilang berdasarkan informasi yang didapat pada dataset [8]. (3) Melakukan normalisasi data menggunakan Metode normalisasi MinMax mengubah sebuah kumpulan data menjadi skala mulai dari 0 (min) hingga 1 (max) dengan persamaan berikut [9] :

$$Data_{new} = \frac{Data_{current} - Min}{Max - Min} \quad (1)$$

Keterangan :

$Data_{new}$	=	Data hasil transformasi
$Data_{current}$	=	Data yang akan ditransformasi
Max	=	Nilai terbesar dari data
Min	=	Nilai terkecil dari data

(4) Membagi data menjadi 2 tahap (*split data*), yaitu data *training* dan data *testing* dengan proporsi 80:20.

Tahapan Analisis *Artificial Neural Network* (ANN) dengan Algoritma *BackPropagation*

Menurut [10] algoritma backpropagation memiliki langkah-langkah sebagai berikut : (1) Membuat model arsitektur Artificial Neural Network (ANN) dengan cara membuat nomor urut pengamatan (ID), menetapkan banyaknya neuron input dan satu neuron output, menetapkan neuron hidden, learning rate, jumlah iterasi dan toleransi error berdasarkan RMSE terkecil. (2) Inisialisasi bobot dengan bilangan acak kecil.

$$Bobot V = (n_{input} + 1) \times n_{hidden} \quad (2)$$

$$Bobot W = (n_{hidden} + 1) \times n_{output} \quad (3)$$

Keterangan :

$Bobot V$	=	Bobot dan bias diantara <i>input layer</i> dan <i>hidden layer</i>
$Bobot W$	=	Bobot dan bias diantara <i>hidden layer</i> dan <i>output layer</i>

(3) Menetapkan jumlah neuron pada *hidden layer*, toleransi *error*, *learning rate*, dan maksimum iterasi. Kondisi berhenti ketika $RMSE < \text{toleransi error}$ atau $\text{iterasi} > \text{maksimum iterasi}$, jika kondisi berhenti tidak terpenuhi, maka ikuti langkah 3-10. (4) Kerjakanlah langkah 4 s.d 9

Perambatan Maju (*Feed Forward*)

(1) *Input* ($X_i, i = 1, 2, 3, \dots, n$) menerima sinyal *input* X_i dan mentransfer sinyal ini ke semua *hidden unit*. (2) Setiap unit pada *hidden layer* ($z_j, j = 1, 2, 3, \dots, p$) dikalikan dengan bobot dan dijumlahkan dengan biasnya.

$$Z_{net_j} = V_{0j} + \sum_{i=1}^n X_{i1}V_{ij} \quad (4)$$

Keterangan :

- Z_{netj} = Sinyal *neuron input layer* yang masuk menuju *neuron hidden layer* ke-j
- V_{1j} = Bias pada *hidden layer* ke-j
- X_{i1} = *Neuron input* ke-i
- V_{ij} = Bobot yang menghubungkan *input* ke-i dan *hidden* ke-j

Fungsi yang digunakan untuk mengaktifkan *neuron* adalah fungsi aktivasi *sigmoid* (antara 0 sampai 1) yang dihitung dengan persamaan (15). (3) Setiap unit pada output layer ($Y_k, k = 1, 2, 3, \dots, m$) menjumlahkan sinyal-sinyal masukan berbobot sebagai berikut:

$$Y_{netk} = W_{0k} + \sum_{j=1}^p Z_j W_{jk} \quad (5)$$

Keterangan :

- Y_{netk} = Sinyal dari *hidden layer* ke *output layer* ke-k
- W_{0k} = Bias pada *neuron output* ke-k
- Z_j = Nilai dari fungsi aktivasi *sigmoid* pada *neuron hidden* ke-j
- W_{jk} = Bobot yang menghubungkan *hidden layer* ke-j dan *output* ke-k

Fungsi yang digunakan untuk mengaktifkan *neuron* adalah fungsi aktivasi *sigmoid* (antara 0 sampai 1) yang dihitung dengan persamaan (15).

Perambatan Mundur (*Back Propagation*)

(1) Tahapan ini bertujuan untuk memperbarui bobot *output layer* dan *hidden layer* dengan persamaan sebagai berikut:

$$\delta_k = (t_k - Y_k) f'(Y_{netk}) = (t_k - Y_k) Y_k (1 - Y_k) \quad (6)$$

Keterangan :

- δ_k = Faktor koreksi dari *neuron output* ke-k
- t_k = Target keluaran *neuron output* ke-k
- Y_k = Nilai dari fungsi aktivasi *sigmoid* pada *neuron output* ke-k

(2) Menghitung koreksi bias dengan persamaan sebagai berikut:

$$\Delta W_{0k} = \alpha \delta_k \quad (7)$$

Keterangan :

- ΔW_{0k} = Koreksi bias *neuron output* ke-k
- α = *Learning rate*
- δ_k = Faktor koresi dari *neuron output* ke-k

(3) Menghitung koreksi bobot dengan persamaan berikut :

$$\Delta W_{jk} = \alpha \delta_k Z_j \quad (8)$$

Keterangan :

- ΔW_{jk} = Koreksi bobot *neuron output* ke-k dan *neuron hidden* ke-j
- α = *Learning rate*
- Z_j = Nilai dari fungsi aktivasi *sigmoid* pada *neuron hidden* ke-j
- δ_k = Faktor koresi dari *neuron output* ke-k

(4) Tahapan ini bertujuan untuk memperbarui bobot antara *hidden layer* dan *input layer*, dengan persamaan sebagai berikut:

$$\delta_{netj} = \sum_{k=1}^m \delta_k W_{jk} \quad (9)$$

Keterangan :

- δ_{net_j} = Sinyal Faktor koreksi dari *output layer* ke *hidden layer* ke-j
 δ_k = Faktor koresi dari *neuron output* ke-k
 W_{jk} = Bobot yang menghubungkan *hidden* ke-j dan *output* ke-k

(5) Menghitung faktor koreksi *neuron hidden* ke-j dengan mengalikan nilai ini dengan turunan fungsi aktivasinya dengan persamaan sebagai berikut :

$$\delta_j = \delta_{net_j} f'(z_{net_j}) = \delta_{net_j} z_j(1 - z_j) \quad (10)$$

Keterangan :

- δ_{net_j} = Sinyal Faktor koreksi dari *output layer* ke *hidden layer* ke-j
 δ_j = Faktor koresi dari *neuron output* ke-j
 Z_j = Nilai dari fungsi aktivasasi sigmoid pada *neuron hidden* ke-j

(6) Menghitung koreksi bias pada *neuron hidden layer* ke-j dengan menggunakan persamaan sebagai berikut :

$$\Delta V_{0j} = \alpha \delta_j \quad (11)$$

Keterangan :

- ΔV_{0j} = Koreksi bias pada *neuron hidden layer* ke-j
 α = *Learning rate*
 δ_j = Faktor koreksi pada *hidden layer* ke-j

(7) Menghitung koreksi bobot antara *neuron lapisan hidden* ke-j dan *neuron lapisan masukan* ke-i dengan persamaan sebagai berikut:

$$\Delta V_{ij} = \alpha \delta_j X_i \quad (12)$$

Keterangan :

- ΔV_{ij} = Koreksi bobot antara *neuron hidden layer* ke-j dan *neuron input layer* ke-i
 α = *Learning rate*
 δ_j = Faktor koreksi pada *hidden layer* ke-j
 X_i = *Input layer*

Perubahan Bobot dan Bias

(1) *Output hidden* (Y_k , $k = 1, 2, 3, \dots, m$) dengan bias dan bobotnya ($j = 1, 2, 3, \dots, p$) dengan menggunakan persamaan sebagai berikut :

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (13)$$

Keterangan :

- W_{jk} = Bobot terbaru *hidden layer* terhadap *output layer*
 ΔW_{jk} = Suku perubahan bobot

(2) Tahap perhitungan bobot terbaru antara *neuron hidden* ke-j dan *neuron lapisan masukan* ke-i dengan persamaan sebagai berikut :

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (14)$$

Keterangan :

- V_{ij} = Koreksi bobot antara *neuron hidden layer* ke-j dan *neuron input layer* ke-i
 $V_{ij}(\text{baru})$ = Bobot terbaru antara *neuron hidden layer* ke-j dan *neuron input layer* ke-i
 $V_{ij}(\text{lama})$ = Bobot lama antara *neuron hidden layer* ke-j dan *neuron input layer* ke-i

Fungsi Aktivasi Sigmoid

Fungsi aktivasi merupakan fungsi yang digunakan pada jaringan syaraf untuk mengaktifkan atau tidak mengaktifkan neuron [11]. Fungsi sigmoid adalah mengubah nilai prediksi yang sudah di dapatkan menjadi range nilai antara 0-1 dengan persamaan sebagai berikut :

$$f(u) = \frac{1}{1 + e^{(-u_i)}} \quad (15)$$

Keterangan :

- $f(u)$ = Fungsi aktivasi sigmoid
 u_i = Sinyal dari setiap layer (Z_{net_j} dan Y_{net_k})

(1) Melakukan evaluasi model menggunakan *Root Mean Square Error* (RMSE) dengan persamaan berikut [12]:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y)^2}{n}} \quad (16)$$

Keterangan :

- X_i = Nilai hasil observasi
 Y = Nilai hasil prediksi
 n = Jumlah data

(2) Melakukan prediksi. (3) Melakukan interpretasi dari hasil analisis yang telah ditentukan.

C. Hasil dan Pembahasan

Data Preparation

Data preparation merupakan tahapan penting dalam proses analisis data, dimana data mentah yang dihasilkan dari berbagai sumber akan diolah menjadi format yang lebih mudah dipahami dan dapat digunakan untuk analisis lebih lanjut.

Data Selection

Proses pemilihan subset data dari data yang tersedia untuk pengolahan analisis lebih lanjut adalah dengan cara melakukan *correlation based*, yaitu melihat korelasi dari setiap atribut data. Sehingga atribut data yang terpilih adalah *open*, *high*, *low*, *close*, *volume*, inflasi, suku bunga dan kurs rupiah yang disajikan dalam tabel 2 berikut ini :

Tabel 1. Atribut Harga Saham PT. ABC

No	Date	Open	High	Low	Close	Volume	Inflasi	Suku Bunga	Kurs Rupiah
1	3/1/2013	91,6411	92,6372	90,645	91,6411	8880640	5,9%	6%	9630
2	3/4/2013	90,6450	91,6411	90,645	90,6450	9974909	5,9%	6%	9655
3	3/5/2013	90,6450	91,6411	89,645	90,6450	9045785	5,9%	6%	9656
:	:	:	:	:	:	:	:	:	:
2485	2/24/2023	67	68	66	67	10852460	5,5%	5,8%	15216
2486	2/27/2023	67	68	66	67	84307200	5,5%	5,8%	15274
2487	2/28/2023	67	68	66	67	14228720	5,5%	5,8%	15240

Data Cleaning

Pada tahap data *cleaning* dilakukan proses perbaikan data dengan cara menghapus data yang memiliki missing value. Pada penelitian ini terjadi missing value pada tanggal 19 Juni 2019 sehingga jumlah data dari tanggal 1 Maret 2013 – 28 Februari 2023 terdiri dari 2486 hari.

Tabel 2. Atribut Harga Saham PT. ABC Setelah dilakukan Data Cleaning

No	Date	Open	High	Low	Close	Volume	Inflasi	Suku Bunga	Kurs Rupiah
1	3/1/2013	91,6411	92,6372	90,645	91,6411	8880640	5,9%	6%	9630
2	3/4/2013	90,6450	91,6411	90,645	90,6450	9974909	5,9%	6%	9655
3	3/5/2013	90,6450	91,6411	89,645	90,6450	9045785	5,9%	6%	9656
:	:	:	:	:	:	:	:	:	:
2484	2/24/2023	67	68	66	67	10852460	5,5%	5,8%	15216
2485	2/27/2023	67	68	66	67	84307200	5,5%	5,8%	15274
2486	2/28/2023	67	68	66	67	14228720	5,5%	5,8%	15240

Data Hasil Normalisasi

Atribut data saham PT. ABC yang telah terpilih harus di normalisasikan untuk mengubah nilai dalam skala yang sama atau standar. Berikut hasil normalisasi harga saham PT. ABC yang disajikan pada Tabel 4.

Tabel 3. Hasil Normalisasi Data Harga Saham PT. ABC

No	Date	Open	High	Low	Volume	Inflasi	Suku Bunga	Kurs Rupiah
1	3/1/2013	0,364	0,381	0,363	0,04	0,240	0,4	0,639
2	3/4/2013	0,136	0,138	0,140	0,001	0,613	0,556	0,003
3	3/5/2013	0,136	0,138	0,136	0,001	0,613	0,556	0,004
:	:	:	:	:	:	:	:	:
2484	2/24/2023	0,057	0,060	0,055	0,013	0,560	0,511	0,785
2485	2/27/2023	0,057	0,060	0,055	0,010	0,560	0,511	0,794
2486	2/28/2023	0,057	0,060	0,055	0,017	0,560	0,511	0,789

Split Data

Data *training* bertujuan untuk mengenali pola data dan data *testing* bertujuan untuk melihat efektivitas dari algoritma *backpropagation* dalam melakukan prediksi harga saham PT. ABC. Data dibagi menjadi data *training* dan data *testing* dengan proporsi 80:20. Diperoleh data *training* sebanyak 1988 baris dan data *testing* sebanyak 498 baris yang disajikan dalam Tabel 5. dan Tabel 6.

Tabel 4. Data *Training*

No	Open	High	Low	Close	Volume	Inflasi	Suku Bunga	Kurs Rupiah
1	0,1294	0,1318	0,1330	0,1294	0,0009	0,5600	0,7778	0,0255
2	0,8334	0,8544	0,8289	0,8135	0,0124	0,1600	0,5556	0,6832
3	0,2338	0,2323	0,2334	0,2272	0,0516	0,0400	0,1778	0,6505
:	:	:	:	:	:	:	:	:
1986	0,0431	0,0429	0,0341	0,0332	0,0003	0,8000	1	0,5257
1987	0,0531	0,0560	0,0511	0,0531	0,0003	0,4667	1	0,3391
1988	0	0	0	0	0	0,3333	0,2889	0,5033

Tabel 5. Data Testing

No	Open	High	Low	Close	Volume	Inflasi	Suku Bunga	Kurs Rupiah
1	0,1372	0,1429	0,1376	0,1406	0,1121	0,4133	0,5111	0,7273
2	0,0995	0,1022	0,0989	0,0962	0,0002	0,6667	1	0,4687
3	0	0	0	0	7E-05	3,73E-01	7,78E-01	5,93E-01
:	:	:	:	:	:	:	:	:
496	0,0597	0,0626	0,0545	0,0597	0,0016	0,6533	1	0,3559
497	0,0133	0,0198	0,0136	0,0133	0,0001	0,9200	1	0,3703
498	0	0	0	0	3.6E-06	4,1E-01	2,9E-01	5,3E-01

Arsitektur Artificial Neural Network (ANN) dengan Algoritma Backpropagation

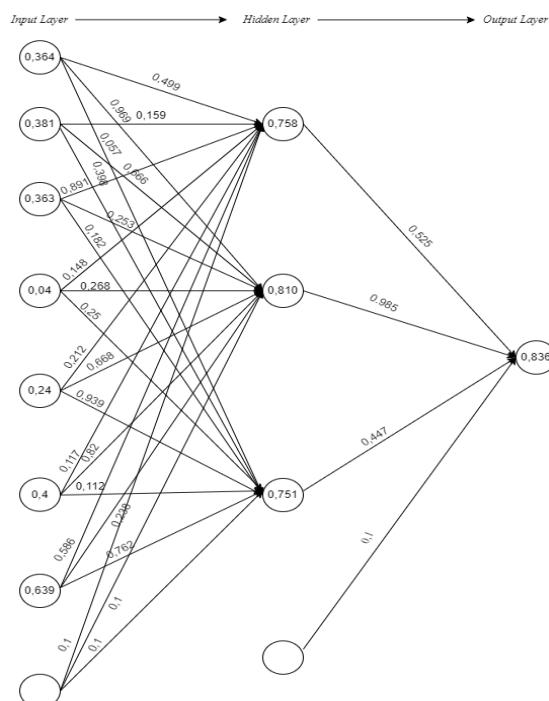
Pembentukan arsitektur *Artificial Neural Network* (ANN) dengan cara menetapkan *neuron hidden*, *learning rate*, jumlah iterasi dan toleransi *error* berdasarkan RMSE terkecil. komponen arsitektur (*neuron input*, *neuron hidden* dan *neuron output*) dan penilaian faktor (*learning rate*, jumlah iterasi minimum dan toleransi *error*) *Artificial Neural Network* (ANN) yang telah ditentukan dengan rincian sebagai berikut :

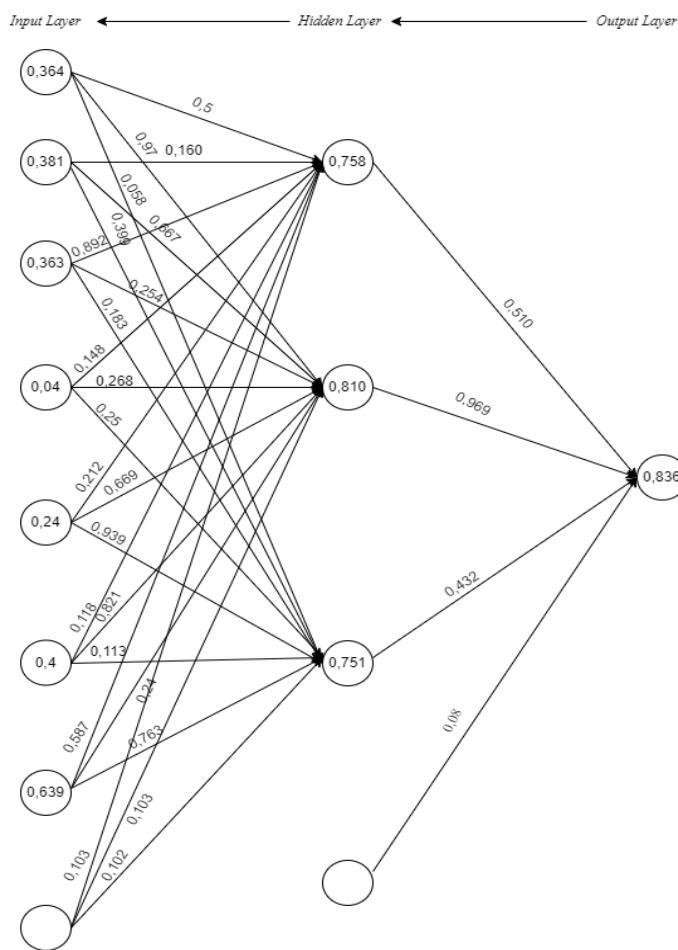
Tabel 7. Komponen Arsitektur dan Penilaian Faktor *Artificial Neural Network* (ANN)

No	Neuron Input	Neuron Hidden	Neuron Output	Learning rate	Jumlah Iterasi Minimum	Toleransi Error
1	7	3	1	0,9	100	0,01

Hasil Proses Training Artificial Neural Network (ANN)

Proses training pada *Artificial Neural Network* (ANN) dengan algoritma *backpropagation* terdiri dari tahapan *feed forward neural network*, *backpropagation neural network* dan mengupdate bobot serta bias. Untuk memudahkan dalam melihat proses *feed forward neural network* maka dapat dilihat pada Gambar 1 dan Gambar 2 berikut ini :

**Gambar 1.** Proses Feed Forwad Neural Network

**Gambar 2.** Proses Backpropagation Neural Network

Berdasarkan nilai Y yang telah didapatkan pada proses feed forward neural network dapat diketahui bahwa nilai Y sebesar 0,836 masih kurang dari nilai optimal sebesar 1 dan masih kurang untuk mencapai nilai optimal berdasarkan toleransi error sebesar 0,01 atau mencapai optimal ketika nilai 0,99. Agar mendapatkan nilai Y yang optimal maka proses harus dilanjutkan dengan proses back propagation dan mengganti nilai bobot dan bias guna mendapatkan nilai bobot dan bias yang optimal. Untuk memudahkan dalam melihat proses back propagation neural network maka dapat dilihat pada Gambar 2. diatas.

Tabel 8. Hasil Prediksi Proses *Training*

Date	Close Hasil Prediksi	Close/Output Sebenarnya	Error	Akurasi %
1	158,776	161	2,224	98,62
2	62,413	64	1,337	97,9
3	54,908	50	5,103	90,71
:	:	:	:	:
1986	64,515	67.000	2,485	96,29
1987	59,711	5976597.000	0,055	99,91
1988	91,532	92.000	0,468	99,49

Berdasarkan hasil prediksi data training menggunakan model jaringan yang didapatkan pada tabel 4.16 dalam memprediksi harga saham di PT. ABC diperoleh rata-rata nilai RMSE sebesar 0,01392 dan akurasi model yang dihasilkan sebesar 96%.

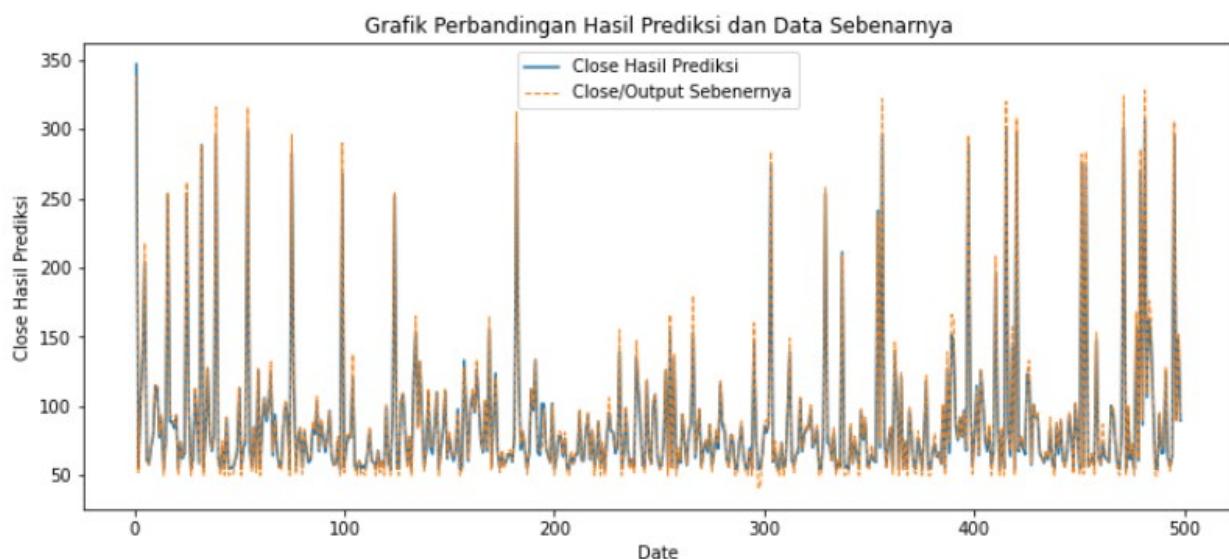
Hasil Proses Testing Artificial Neural Network (ANN)

Proses testing pada *Artificial Neural Network* (ANN) dengan algoritma *backpropagation* terdiri dari tahapan *feed forward neural network* dengan menggunakan bobot dan bias dari hasil proses *training*.

Tabel 9. Hasil Prediksi Proses Testing

Date	Close Hasil Prediksi	Close/Output Sebenarnya	Error	Akurasi %
1	346,998	338,337	8,661	92,66
2	55,091	51,797,161	3,294	94,02
3	99,045	100,606,026	1,561	98,45
:	:	:	:	:
496	90,978	88	2,978	96,73
497	148,564	153	4,436	97,1
498	89,309	91	1,691	98,14

Nilai hasil prediksi dan data sebenarnya dapat menjadi acuan keakuratan model untuk *Artificial Neural Network* (ANN) dengan Algoritma *Backpropagation* dalam memprediksi harga saham PT. ABC. Untuk mempermudah melihat perbedaan data aktual dan data prediksi dari atribut close pada data saham maka dibuat grafik sebagai berikut :



Gambar 3. Hasil Prediksi Proses Testing

Berdasarkan hasil proses testing pada gambar 4.6 dapat diketahui bahwa data sebenarnya dilambangkan dengan garis berwarna merah dan hasil prediksi dilambangkan dengan garis berwarna biru. Sumbu Y merupakan harga saham dan Sumbu X merupakan hari terjadinya close dari data testing. Terlihat bahwa garis hasil prediksi dan data sebenarnya saling berhimpitan dan tidak memiliki jarak yang jauh, ini menandakan bahwa hasil prediksi sangat akurat karena tidak berbeda jauh dengan data sebenarnya. Hasil prediksi dikatakan sangat baik jika nilai RMSE kurang dari 10%. Diperoleh nilai rata-rata RMSE sebesar 0,01128 dan akurasi model prediksi yang dihasilkan sebesar 96% Sehingga performa model dapat dikatakan sangat baik.

Hasil Prediksi

Berdasarkan arsitektur *Artificial Neural Network* (ANN) yang terpilih yaitu dengan menggunakan 7 *neuron input*, 3 *neuron hidden* dan 1 *neuron output* maka hasil prediksi atribut harga saham dapat dilihat pada tabel sebagai berikut :

Tabel 10. Hasil Prediksi

Date	Close Hasil Prediksi	Close/Output Sebenarnya	Error	Akurasi %
9/10/2021	119,873	115	4,873	95,93
9/13/2021	120,944	116	4,944	95,91
9/14/2021	120,629	117	3,629	96,99
:	:	:	:	:
2/24/2023	67,142	67	0,142	99,79
2/27/2023	67,142	67	0,142	99,79
2/28/2023	67,205	67	0,205	99,69

D. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, untuk memprediksi harga saham di PT. ABC menggunakan *Artificial Neural Network* (ANN) dengan algoritma backpropagation melalui fungsi aktivasi sigmoid diperoleh kesimpulan bahwa hasil komponen arsitektur dan penilaian faktor *Artificial Neural Network* (ANN) dengan menggunakan multilayer network diperoleh komponen arsitektur terbaik yang terdiri atas 7 *neuron* pada *input layer*, 3 *neuron* pada *hidden layer*, 1 *neuron* pada *output layer* dan penilaian faktor dengan rincian jumlah iterasi 100, nilai *learning rate* sebesar 0,9 dan toleransi *error* sebesar 0,01. Diperoleh nilai hasil rata-rata RMSE sebesar 0,01392 untuk proses *training*, rata-rata RMSE sebesar 0,01128 untuk proses *testing* dan akurasi mencapai 96% dengan menggunakan data historis dan data eksternal yang mempengaruhi harga saham.

Daftar Pustaka

- [1] J. S. Sebayang and B. Yuniarso, “Perbandingan Model Estimasi Artificial Neural Network Optimasi Genetic Algorithm dan Regresi Linier Berganda,” *Media Statistika*, vol. 10, no. 1, p. 13, 2017, doi: 10.14710/medstat.10.1.13-23.
- [2] M. N. Zain, “Algoritma Artificial Neural Network dalam Klasifikasi Chest X-Rays Pasien COVID-19,” *Jurnal Riset Statistika*, pp. 137–144, Dec. 2022, doi: 10.29313/jrs.v2i2.1426.
- [3] Azizah, “Bunga Deposito Dan Volume Perdagangan Saham. In Jurnal keuangan dan Perbankan,” vol. 9, 2019.
- [4] X. Wang, “Application of artificial neural network to predict short-term capital flow,” *ICRCCS 2009 - 2009 International Conference on Research Challenges in Computer Science*, no. Lm, pp. 124–127, 2009, doi: 10.1109/ICRCCS.2009.39.
- [5] F. A. Y. Putri, “Studi Komparasi Peramalan Harga Minyak Mentah Menggunakan Metode Generalized Regression Neural Network dan Feed Forward Neural Network (Studi Kasus: Harga Minyak Mentah West Texas Intermediate),” *Tugas Akhir*, 2018.
- [6] Z. S. C. Viqri and E. Kurniati, “Perbandingan Penerapan Metode Fuzzy Time Series Model Chen-Hsu dan Model Lee dalam Memprediksi Kurs Rupiah terhadap Dolar Amerika,” *DataMath: Journal of Statistics and Mathematics*, vol. 1, no. 1, pp. 19–26, 2023, doi: 10.29313/datamatht.v1i1.12.
- [7] N. A. K. Rifai, “Pendekatan Regresi Nonparametrik dengan Fungsi Kernel untuk Indeks Harga Saham Gabungan,” *Statistika*, vol. 19, no. 1, pp. 53–61, 2019.
- [8] T. Hendrawati, “Kajian Metode Imputasi dalam Menangani Missing Data,” *Prosiding Seminar Nasional Matematika dan Pendidikan Matematika UMS*, pp. 637–642, 2015.
- [9] C. Saranya and G. Manikandan, “A study on normalization techniques for privacy preserving data mining,” *International Journal of Engineering and Technology*, vol. 5, no. 3, pp. 2701–2704, 2013.

- [10] D. N. Agus Perdana Windarto, M. S. H. Anjar Wanto, Frinto Tambunan, M. R. L. Muhammad Noor Hasan Siregar, and D. N. Solikhun, Yusra Fadhillah, *Jaringan Saraf Tiruan: Algoritma Prediksi dan Implementasi*, vol. 53, no. 9. 2019.
- [11] Julpan, E. B. Nababan, and M. Zarlis, “Analisis Fungsi Aktivasi Sigmoid Biner dan Sigmoid Bipolar dalam Algoritma Backpropagation pada Prediksi Kemampuan Siswa,” *Jurnal Teknovasi*, vol. 02, pp. 103–116, 2015.
- [12] T. Chai and R. R. Draxler, “Root mean square error (RMSE) or mean absolute error (MAE)? - Arguments against avoiding RMSE in the literature,” *Geosci Model Dev*, vol. 7, no. 3, pp. 1247–1250, 2014, doi: 10.5194/gmd-7-1247-2014.