

# Implementasi Jaringan Syaraf Tiruan Backpropagation Untuk Peramalan Penjualan Pada PT. Central Pacific Development

Indra Hertanto<sup>1\*</sup>, Riskiana Wulan<sup>2</sup>, Lutfi Rizaldi Mahida<sup>3</sup>, Dzaky Rakha Meilano<sup>4</sup>,  
Prayoga Ajitya Setiawan<sup>5</sup>, Indra<sup>5</sup>,

<sup>1,2,3,4,5</sup>Fakultas Teknologi Informasi, Teknik Informatika, Universitas Budi Luhur, Jakarta, Indonesia

E-mail: <sup>1\*</sup>indra.hertanto@budiluhur.ac.id, <sup>2</sup>riskiana.wulan@budiluhur.ac.id,

<sup>3</sup>2211501180@student.budiluhur.ac.id, <sup>4</sup>2211501081@student.budiluhur.ac.id,

<sup>5</sup>2211500331@student.budiluhur.ac.id, <sup>6</sup>indra@budiluhur.ac.id

(\* : corresponding author)

## Abstrak

PT. Central Pacific Development memiliki data transaksi penjualan yang melimpah, tetapi belum tersedia sistem untuk memanfaatkan data tersebut secara optimal dalam perencanaan strategis. Penelitian ini bertujuan mengimplementasikan Jaringan Syaraf Tiruan (JST) dengan metode *Backpropagation* untuk memprediksi penjualan produk, menggunakan data historis penjualan dari Januari 2022 hingga November 2024. Sistem ini melalui tahapan normalisasi data, pembagian data menjadi set pelatihan dan pengujian, serta evaluasi kinerja model dengan metrik *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE). Model *Multi-Layer Perceptron* (MLP) dengan konfigurasi 12-15-1 memberikan hasil terbaik, dengan MSE pelatihan 0.000999, MSE pengujian 0.062680, MAPE 22.24%, dan akurasi 77.75%. Sistem yang dikembangkan mampu membantu perusahaan dalam merancang strategi produksi dan pemasaran berbasis data, sekaligus membuka peluang pengembangan lebih lanjut melalui integrasi teknologi *big data* atau metode *hybrid* untuk meningkatkan akurasi prediksi.

**Kata kunci:** *backpropagation*, jaringan syaraf tiruan, MSE, prediksi penjualan

## Abstract

PT. Central Pacific Development possesses an abundance of sales transaction data, yet currently lacks a system to optimally leverage this data for strategic planning. This research aims to implement an Artificial Neural Network (ANN) using the *Backpropagation* method to predict product sales, based on historical sales data from January 2022 to November 2024. The system involves stages such as data normalization, splitting the dataset into training and testing sets, and evaluating model performance using *Mean Squared Error* (MSE) and *Mean Absolute Percentage Error* (MAPE) metrics. A *Multi-Layer Perceptron* (MLP) model with a 12-15-1 configuration yielded the best results, achieving a training MSE of 0.000999, a testing MSE of 0.062680, a MAPE of 22.24%, and an accuracy of 77.75%. The developed system can assist the company in designing data-driven production and marketing strategies, while also opening opportunities for further development through the integration of *big data* technologies or *hybrid* methods to improve prediction accuracy.

**Keywords:** *artificial neural network, backpropagation, MSE, sales prediction*

## 1. PENDAHULUAN

Pada era digital yang semakin berkembang, perusahaan dihadapkan pada tantangan volume transaksi yang semakin besar. Namun, data tersebut seringkali belum dimanfaatkan secara maksimal untuk mendukung pengambilan keputusan strategis. Penjualan, yang didefinisikan sebagai proses transaksi dimana suatu barang atau jasa dialihkan dari satu pihak kepada pihak lainnya, disertai dengan imbalan berupa sejumlah uang sebagai kompensasi atas barang atau jasa tersebut[1], berperan penting dalam mencerminkan kinerja perusahaan dan sumber informasi strategis untuk merumuskan kebijakan bisnis. PT. Central Pacific memiliki volume data penjualan yang besar dari berbagai lini produk, tetapi belum memiliki sistem yang mampu mengolah data tersebut menjadi informasi prediktif untuk mendukung perencanaan produksi, penjualan, dan pemasaran. Ketersediaan data yang melimpah tidak sejalan dengan kemampuan perusahaan dalam memanfaatkannya untuk mendukung strategi bisnis berbasis data. Oleh karena itu, diperlukan pengembangan metode analisis prediktif yang mampu menghasilkan estimasi penjualan secara akurat, sehingga perusahaan dapat merumuskan strategi bisnis yang optimal.

Jaringan Syaraf Tiruan adalah suatu sistem yang meniru jaringan syaraf alami dengan cara menggunakan teknik komputer untuk pengolahan data [2]. Algoritma ini bersifat adaptif, mampu mengenali pola dari data masa lalu, dan memberikan prediksi terhadap data baru secara dinamis dan real-time. Adanya penemuan *backpropagation multilayer* telah mendorong kemajuan signifikan dalam implementasi JST, terbukti melalui penerapannya pada berbagai bidang seperti finansial, pengenalan pola, dan pengolahan citra medis [3].

Penerapan metode *backpropagation* untuk peramalan penjualan menghasilkan tingkat akurasi sebesar 89% dalam meramalkan permintaan pada perusahaan retail, meskipun dengan arsitektur JST sederhana dengan *hidden layer* sebanyak 3 *node* dan *learning rate* terbaik 0,9[4] Penelitian yang lain menggunakan *backpropagation multilayer* dan *particle swarm optimization* untuk mendeteksi serangan intrusi pada *Instruction Detection System (IDS)* di lingkungan *cloud* menghasilkan akurasi terbaik dengan klasifikasi biner adalah 98,97% dan untuk klasifikasi multi-kelas adalah 98,41% [5]. Penelitian tentang prediksi permintaan keripik buah juga dilakukan menggunakan metode JST dengan *learning rate* 0.8 menghasilkan nilai MAPE terbaik sebesar 4.429% [6]. Arsitektur JST 3-3-1 dilakukan oleh Salsabila dalam memprediksi penjualan pakaian dengan algoritma *backpropagation* memperoleh MSE rendah dan nilai regresi (R) mencapai 0.99216 [7]. Meskipun hasilnya cukup baik, penelitian-penelitian ini belum mengeksplorasi variasi arsitektur JST yang lebih kompleks untuk meningkatkan akurasi prediksi.

Untuk mengisi kesenjangan tersebut, penelitian ini akan menguji tiga konfigurasi model *ulti-Layer Perceptron (MLP)*, yaitu 12-10-1, 12-15-1, dan 12-20-1, untuk menganalisis pengaruh variasi jumlah neuron terhadap akurasi prediksi penjualan. Penelitian ini bertujuan mengimplementasikan JST dengan metode *backpropagation* untuk memprediksi penjualan produk di PT. Central Pacific menggunakan data penjualan dari Januari 2022 hingga November 2024. Sistem berbasis *web* yang dirancang ini diharapkan mampu membantu perusahaan dalam menganalisis data historis secara efisien, menghasilkan prediksi akurat, serta mendukung perencanaan produksi dan strategi pemasaran yang optimal. Selain itu, penelitian ini diharapkan mampu memberi dampak positif terhadap pengembangan teori di bidang akademik serta mendukung penerapan praktis dalam konteks dunia industri, khususnya dalam pengembangan model JST dengan konfigurasi yang lebih efisien, guna menjawab tantangan analisis data yang kian menunjukkan kompleksitas seiring dengan perkembangan era digital.

## 2. METODE PENELITIAN

### 2.1 Pengumpulan Data

Data yang dimanfaatkan dalam penelitian ini bersumber dari total penjualan bulanan dari seluruh produk PT Central Pacific Development dalam periode Januari 2022 hingga November 2024. Data bersifat deret waktu (*time-series univariant*) dan dikumpulkan dari laporan keuangan perusahaan. Untuk keperluan pemrosesan, data dikonversi dari format Excel (.xlsx) ke format CSV (.csv). Variabel *input* yang digunakan merupakan tiga nilai data penjualan bulan sebelumnya sebelumnya misalnya (t-3, t-2, t-1), sedangkan variabel target adalah penjualan bulan ke-t. Tabel 1 menyajikan ringkasan karakteristik dataset yang digunakan dalam penelitian.

Tabel 1. Karakteristik Dataset

Attribut	Deskripsi
Rentang Waktu	Januari 2022 – November 2024
Interval	Bulanan
Variabel Masukan	Penjualan ke-(t-3), (t-2) dan (t-1)
Variabel Target	Total nilai penjualan produk bulan ke-t
Jumlah Data	46 record (1 record per bulan)
Jenis Data	Time-series univariant

Dataset didistribusikan ke dalam dua subset, yaitu 24 data untuk data latih dan 22 data untuk pengujian performa model. Rincian distribusi pembagian data ditampilkan pada Tabel 2.

Tabel 2. Distribusi Data Latih dan Data Uji

Jenis Data	Jumlah Data	Periode
Data latih	24	Jan 2022-Des 2023
Data Uji	22	Jan 2023-Nov 2024

Teknik *sliding window* digunakan pada penelitian ini karena data penjualan yang tersedia relatif terbatas. Pada kasus ini, ukuran *sliding window* ditetapkan sebesar 12, artinya setiap 12 bulan data penjualan berturut-turut digunakan sebagai *input* untuk memprediksi data ke-13 sebagai target. Sebagai informasi yang ada di Tabel 2, data penjualan dari Januari 2022 sampai dengan Desember 2022 digunakan sebagai data input, sedangkan nilai targetnya adalah data penjualan bulan Januari 2023. Selain data kuantitatif, pendekatan metode eksploratif digunakan dengan memulai analisis dari kondisi masa lampau dan masa sekarang sebagai acuan, lalu diarahkan ke masa depan dengan mempertimbangkan semua kemungkinan yang ada [8]. Untuk mendukung pendekatan ini dilakukan wawancara semi-terstruktur dengan pihak manajemen untuk memahami alur bisnis, pola permintaan produk, serta ekspektasi pengguna terhadap sistem prediksi yang akan dikembangkan.

### 2.1. *Preprocessing* dan Normalisasi

*Preprocessing* dilakukan dengan mengelompokkan data penjualan tiap produk dan diagregasi menjadi total penjualan bulanan. Normalisasi dilakukan untuk menyesuaikan rentang nilai input atau *output* agar sesuai dengan fungsi aktivasi yang diterapkan dalam model [9]. Data hasil agregasi kemudian dinormalisasi menggunakan metode *min-max scaling* dengan rentang nilai [0.1, 0.9]. Rentang ini juga digunakan dalam penelitian Akilli dan Atıl[10] sebagai salah satu variasi normalisasi untuk JST. Proses normalisasi ini penting untuk meningkatkan stabilitas pelatihan, mempercepat konvergensi bobot, dan mengoptimalkan kinerja JST. Proses normalisasi dilakukan menggunakan persamaan:

$$x' = \frac{0.8(x-a)}{b-a} + 0.1 \quad (1)$$

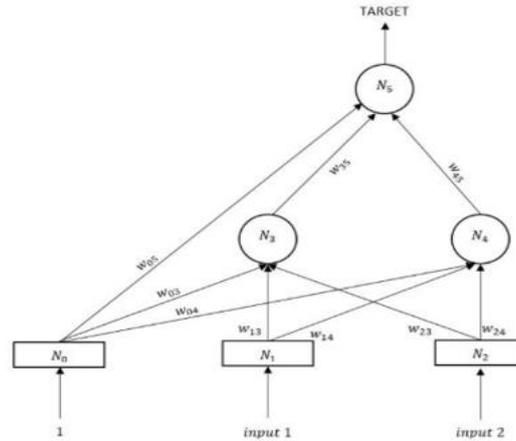
Dimana:

- x = Nilai asli penjualan
- a = Nilai minimum yang terkandung dalam dataset
- b = Nilai maksimum yang terkandung dalam dataset
- x' = Nilai penjualan setelah dinormalisasi.

Nilai minimum dan maksimum diperoleh dari keseluruhan data penjualan berdasarkan rentang waktu yang sudah ditentukan, termasuk data latih dan data uji. Setelah model selesai dilatih, hasil prediksi yang diperoleh dalam bentuk nilai normalisasi dikembalikan ke skala aslinya melalui proses normalisasi agar dapat dibandingkan dengan nilai aktual.

#### a. Penentuan Arsitektur Jaringan Syaraf Tiruan

Penelitian ini memanfaatkan arsitektur JST sebagai pendekatan utama dengan banyak lapisan (*multilayer network*) dengan algoritma *backpropagation* karena memiliki kemampuan yang lebih baik dalam menyelesaikan permasalahan kompleks dibandingkan dengan jaringan yang hanya terdiri dari satu lapisan. Gambar 2 menunjukkan struktur koneksi antar node dalam arsitektur jaringan, di mana node pada lapisan input terhubung secara langsung ke node pada lapisan tersembunyi, koneksi dilanjutkan dari node pada lapisan tersembunyi menuju node pada lapisan *output*. Setiap koneksi antar node memiliki bobot tersendiri yang nilainya bervariasi, karena ditetapkan secara acak pada tahap inisialisasi [11].



Gambar 1. Salah Satu Arsitektur *Multilayer Perceptron*

b. Menentukan Model Jaringan

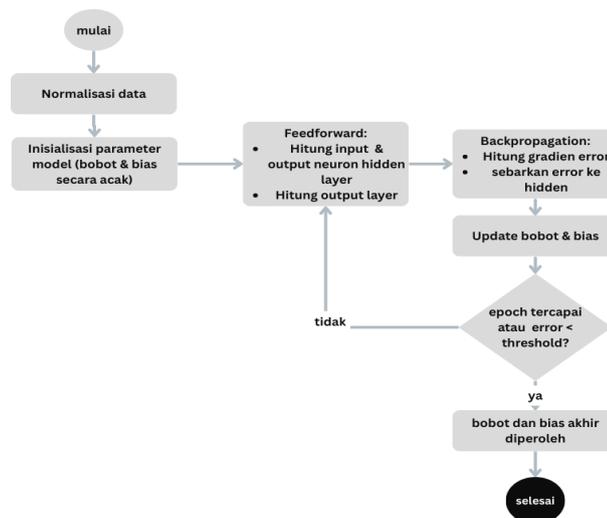
Penentuan model jaringan didasarkan pada keseimbangan antara kemampuan mempelajari pola data dan risiko *overfitting* maupun *underfitting*, dimana jumlah *layer* atau neuron yang terlalu sedikit cenderung menyebabkan *underfitting*, sedangkan jumlah yang berlebihan berpotensi menimbulkan *overfitting* [12]. Penelitian ini menguji tiga variasi model, yaitu 12-10-1, 12-15-1, dan 12-20-1, yaitu 12 *input* yang merupakan total penjualan pada tiap bulan. Model 12-10-1 menggunakan 10 neuron di *hidden layer*, sedangkan model 12-15-1 dan 12-20-1 masing-masing menggunakan 15 dan 20 neuron di *hidden layer*. Perbandingan hasil prediksi dari ketiga model ini akan dianalisis untuk menentukan model dengan performa terbaik berdasarkan akurasi, MSE, dan MAPE.

Tabel 3. Model Jaringan

Model	Jumlah Neuron		
	Input	Hidden	Output
12-10-1	12	10	1
12-15-1	12	15	1
12-20-1	12	20	1

2.2. Implementasi Algoritma *Backpropagation*

Alur proses algoritma *backpropagation* pada penelitian ini ditunjukkan pada Gambar 3, yang menunjukkan tahapan mulai dari normalisasi data hingga diperoleh bobot dan bias akhir untuk model prediksi.



Gambar 3. Alur Proses Algoritma *Backpropagation*

Tahap implementasi terdiri dari fase *training* dan *testing*. Pada fase pelatihan (*training*), proses dimulai dengan fase *feed forward*. Dalam fase ini, setiap data *input* yang telah dinormalisasi akan diteruskan melalui jaringan syaraf mulai dari lapisan *input*, kemudian menuju lapisan tersembunyi (*hidden layer*), dan berakhir di lapisan *output*. Setiap neuron akan menghitung nilai total *inputnya* dengan mengalikan nilai *input* terhadap bobot awal, menjumlahkannya menggunakan persamaan:

$$z_j = \sum_{i=1}^n (x_i \cdot w_{ij}) + b_j \quad (2)$$

Dimana :

- $x_i$  = Nilai *input* unit ke-i
- $w_{ij}$  = Bobot dari *input layer* i dan *layer* tersembunyi j,
- $b_j$  = Bias pada *layer* tersembunyi ke- j.
- $z_j$  = *Input* total ke *layer* tersembunyi

Selanjutnya, nilai *input* yang telah diolah akan diaktivasi menggunakan fungsi aktivasi sigmoid biner guna menghasilkan *output* sementara, yang dihitung berdasarkan persamaan berikut:

$$f(z) = \frac{1}{1 + e^{-z_j}} \quad (3)$$

Dimana:

- $z_j$  = *Input* total ke *hidden layer*
- $f(z)$  = *Output* dari *hidden layer*

*Output* dari *hidden layer* kemudian diteruskan ke *layer output* melalui persamaan:

$$y_{ink} = b_y + \sum_{j=1}^p z_j w_{kj} \quad (4)$$

$$y_{out} = \frac{1}{1 + e^{-y_{ink}}} \quad (5)$$

Dimana:

- $b_y$  = Bias *output layer*
- $w_{kj}$  = Bobot dari *hidden layer* j ke *layer* k
- $y_{ink}$  = *Input* total ke *output layer*
- $y_{out}$  = Hasil prediksi JST

Tujuan utama dari proses *feedforward* adalah untuk menghasilkan *output* prediksi awal dari JST berdasarkan bobot dan bias yang telah diinisialisasi.

Setelah *output* awal diperoleh, sistem menghitung selisih antara *output* JST dengan target yang sebenarnya. Selisih ini disebut sebagai *error* dan menjadi dasar dalam proses selanjutnya, yaitu fase *backpropagation*.

$$\text{Error} = t_k - y_{out} \quad (6)$$

Dimana:

- $t_k$  = nilai target
- $y_{out}$  = nilai prediksi
- Error = selisih prediksi dan target

Dalam fase ini, error dikembalikan dari lapisan *output* menuju lapisan sebelumnya untuk mengidentifikasi kontribusi masing-masing neuron terhadap kesalahan. Perhitungan ini dilakukan dengan menghitung turunan dari fungsi *error* terhadap bobot menggunakan algoritma penurunan gradien (*gradient descent*) dengan persamaan:

$$\delta_k = (t_k \cdot y_{out})y_{out}(1 - y_{out}) \quad (7)$$

Dimana:

- $\delta_k$  = Faktor koreksi *error* pada *output* unit
- $t_k$  = Nilai aktual target
- $y_{out}$  = Keluaran pada *output* unit

Proses selanjutnya melibatkan penyesuaian bobot dan bias, yang dilakukan berdasarkan hasil perhitungan gradien dari proses *backpropagation*. Setelah setiap iterasi, bobot dan bias diperbarui untuk mengurangi *error*. Proses pelatihan dilanjutkan secara berulang hingga *error* mencapai nilai minimum yang diharapkan [13].

Setelah proses pelatihan selesai, Pengujian dilakukan dengan menjalankan kembali proses *feedforward*, di mana data uji yang telah dinormalisasi dimasukkan ke dalam jaringan untuk menghasilkan prediksi. Karena *output* masih berupa nilai normalisasi, maka dilakukan proses denormalisasi menggunakan rumus *invers* dari metode *min-max scaling*, agar hasil prediksi dapat dikembalikan ke skala aslinya dan dibandingkan langsung dengan nilai aktual penjualan.

### 2.3. Pengujian Model

Langkah berikutnya adalah pengujian *model* arsitektur jaringan. Hasil prediksi yang telah dinormalisasi dibandingkan dengan data sebenarnya untuk mengukur kinerja model. Pengujian dilakukan dan dievaluasi menggunakan metrik *Mean Squared Error* (MSE), *Mean Absolute Percentage Error* (MAPE), dan persentase akurasi. MSE memberikan indikasi tentang seberapa besar *error* kuadrat rata-rata, Adapun MAPE mengukur rata-rata kesalahan absolut antara nilai prediksi dan aktual, yang dinyatakan sebagai persentase dari nilai aktual [14]. Nilai MAPE yang rendah mengindikasikan bahwa model berpotensi untuk menghasilkan prediksi dengan tingkat akurasi yang tinggi. Formula yang digunakan masing-masing adalah sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \tag{8}$$

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{N} \tag{9}$$

Selain itu, akurasi juga dihitung untuk mengetahui seberapa dekat hasil prediksi terhadap nilai sebenarnya secara persentase. dengan nilai Akurasi = 100% - Selisih, dimana Selisih = Data Prediksi - Data Aktual.

Tahap terakhir adalah pemilihan model paling baik. Model yang menghasilkan nilai MSE juga MAPE terendah serta akurasi tertinggi akan dipilih sebagai model prediksi final. Model inilah yang nantinya direkomendasikan untuk digunakan dalam sistem prediksi penjualan karena telah terbukti menghasilkan hasil prediksi yang paling mendekati kenyataan.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Pengumpulan Data

Pada tahap ini, data penjualan yang telah dikumpulkan dan diproses sesuai prosedur pada metode penelitian sub bab 2.1 yang disajikan untuk mendukung analisis. Informasi dalam tabel 4 memuat rekapitulasi penjualan bulanan selama periode pengamatan yang disusun secara berurutan untuk mempermudah identifikasi pola dan tren.

Tabel 4. Dataset

No	Bulan	2022	2023	2024
1	Januari	2.246.853.400	3.586.897.600	4.500.623.600
2	Februari	2.200.531.300	2.937.746.350	3.930.198.250
3	Maret	2.788.007.750	3.405.712.750	4.650.748.300
...	...	...	...	...
11	November	4.027.318.900	3.844.718.900	4.637.337.100
12	Desember	3.956.328.750	4.198.324.900	-

Tabel 4 adalah data historis penjualan dari PT Central Pacific Development dari Januari 2022 sampai November 2024 dikelompokkan per bulan dan tahun, lalu diagregasikan ke dalam mata uang Rupiah.

Tabel 5. Data Latih

No	Bulan	2022	2023
1	Januari	2.246.853.400	3.586.897.600
2	Februari	2.200.531.300	2.937.746.350
3	Maret	2.788.007.750	3.405.712.750
...	...	...	...
11	November	4.027.318.900	3.844.718.900
12	Desember	3.956.328.750	4.198.324.900

Tabel 5 adalah data penjualan dari bulan Januari 2022 - Desember 2023 dengan nilai *input* di tahun 2022 dan nilai target di tahun 2023.

Tabel 6. Data Testing

No	Bulan	2023	2024
1	Januari	3.586.897.600	4.500.623.600
2	Februari	2.937.746.350	3.930.198.250
3	Maret	3.405.712.750	4.650.748.300
...	...	...	...
10	Oktober	4.969.297.300	5.007.660.350
11	November	3.844.718.900	4.637.337.100

Tabel 6 adalah data penjualan dari bulan Januari 2023 - November 2023 dan Januari 2024- November 2024 dengan nilai *input* di tahun 2023 dan nilai target di tahun 2024.

### 3.2 Preprocessing dan Normalisasi

Penelitian ini dilakukan dengan menggunakan lingkungan teknis yang spesifik untuk membangun dan menguji sistem. Tabel 7 dan Tabel 8 menyajikan rincian konfigurasi perangkat keras (*hardware*) dan perangkat lunak (*software*) yang digunakan.

Tabel 7. Komponen Perangkat Lunak

Komponen	Deskripsi
Windows 10	Sistem operasi yang digunakan
XAMPP	Paket server web lokal yang berisi Apache ( <i>Server web</i> ), MariaDB(Database), dan bahasa pemrograman PHP untuk membangun web dinamis
Python	Bahasa pemrograman utama untuk pengolahan data dengan beberapa pustaka yang digunakan antara lain: - Pandas : untuk memproses dan mengelola dataset penjualan - NumPy : untuk melakukan perhitungan matematis dan operasi matrik pada JST Matplotlib: untuk visualisasi hasil pelatihan dan pengujian
Django	Kerangka kerja ( <i>framework</i> ) web berbasis python
Visual Studio Code	<i>Editor</i> kode sumber untuk menulis, mengedit dan melakukan <i>debugging</i> kode program

Tabel 8. Komponen Perangkat Keras

Komponen	Deskripsi
CPU atau Processor	Intel Core i5 4460 3.20 GHz
Memory	8GB
Storage	1TB

Setelah data dikumpulkan dan dikelompokkan, kemudian dilakukan proses normalisasi. Normalisasi data dilakukan untuk penyesuaian rentang antara 0,1 hingga 0,9 dengan menghitung persamaan 1.

Tabel 9. Perhitungan Normalisasi Data Bulan Januari

Nilai Maksimum (Juli 2024)	5.370.869.350
Nilai Minimum (Mei 2022)	1.056.512.600
Januari 2022	2.246.853.400
Januari 2023	3.586.897.600
Januari 2024	4.500.623.600
x' Januari 2022	$\frac{0,8(2246853400 - 1056512600)}{(5370869350 - 1056512600)} = 0.3207$
x' Januari 2023	$\frac{0,8(3586897600 - 1056512600)}{(5370869350 - 1056512600)} = 0.5692$
x' Januari 2024	$\frac{0,8(4500623600 - 1056512600)}{(5370869350 - 1056512600)} = 0.7386$

Tabel 10. Hasil Normalisasi Data

No	Bulan	2022	2023	2024
1	Januari	0.3207218121218186	0.5692027380443214	0.7386325841042236
2	Februari	0.31213242507124617	0.4488323027528959	0.6328600885867864
3	Maret	0.4210666619073631	0.5356061004922692	0.7664698184729392
...	...	...	...	...
11	November	0.6508689192195337	0.6170098740675536	0.7639830143856323
12	Desember	0.6377053995360	0.6825781189745146	-

Setelah proses normalisasi dilakukan, proses penentuan nilai *input* dan target dengan menggunakan teknik *sliding window* dengan mekanisme yang disebutkan pada subbab 2.1.. Pada Tabel 11, baris pertama x1, ... x12 menggambarkan nilai *input* dari Januari 2022 sampai dengan Desember 2022 sebagai data latih dengan nilai 0,3207 hingga 0,6377 dan targetnya adalah bulan Januari 2023 dengan nilai 0,5692.

Tabel 11. *Input* dan Target Data Latih 2022-2023

X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	Target
0.3207	0.3121	0.4211	0.3402	0.1000	0.3799	0.5759	0.5299	0.5818	0.7009	0.6509	0.6377	0.5692
0.3121	0.4211	0.3402	0.1000	0.3799	0.5759	0.5299	0.5818	0.7009	0.6509	0.6377	0.5692	0.4488
0.4211	0.3402	0.1000	0.3799	0.5759	0.5299	0.5818	0.7009	0.6509	0.6377	0.5692	0.4488	0.5356
...	...	...	...	...	...	...	...	...	...	...	...	...
0.6509	0.6377	0.5692	0.4488	0.5356	0.3881	0.4858	0.8663	0.6591	0.7708	0.7784	0.8255	0.6170
0.6377	0.5692	0.4488	0.5356	0.3881	0.4858	0.8663	0.6591	0.7708	0.7784	0.8255	0.6170	0.6826

Pada data uji juga diterapkan teknik *sliding*, dengan data *input* Januari 2023-Desember 2023 dengan nilai 0,5692 hingga 0,6826 dan targetnya adalah bulan Januari 2024 dengan nilai 0,7386 ditampilkan pada tabel 12.

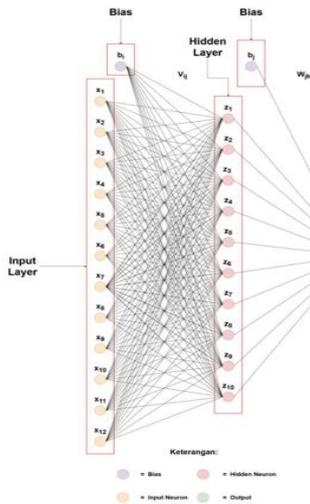
Tabel 12. *Input* dan Target Data Uji 2023-2024

X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	Target
0.5692	0.4488	0.5356	0.3881	0.4858	0.8663	0.6591	0.7708	0.7784	0.8255	0.6170	0.6826	0.7386
0.4488	0.5356	0.3881	0.4858	0.8663	0.6591	0.7708	0.7784	0.8255	0.6170	0.6826	0.7386	0.6329
...	...	...	...	...	...	...	...	...	...	...	...	...
0.6170	0.6826	0.7386	0.6329	0.7666	0.2866	0.8255	0.8466	0.9000	0.7016	0.8451	0.8327	0.7640

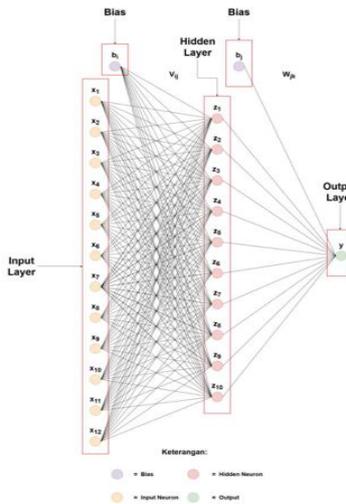
### 3.3 Penentuan Arsitektur Jaringan Syaraf Tiruan

*Backpropagation* memiliki keunggulan dalam menghasilkan *error* yang relatif kecil karena melibatkan tiga lapisan dalam proses pelatihan: *input*, *hidden*, dan *output layer* [15]. Berikut ini

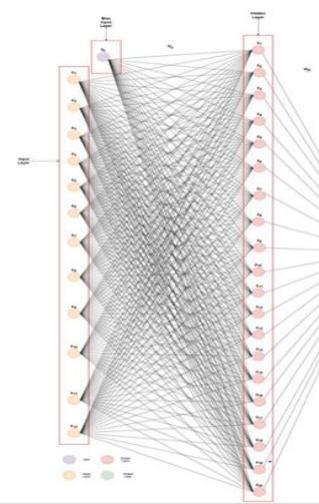
adalah struktur JST untuk model 12-10-1, 12-15-1, 12-20-1. Ketiga arsitektur tersebut dapat dilihat pada Gambar 3, Gambar 4 dan Gambar 5.



Gambar 3. Model Arsitektur Jaringan 12-10-1



Gambar 4. Model Arsitektur Jaringan 12-15-1



Gambar 5. Model Arsitektur Jaringan 12-20-1

Gambar 3, Gambar 4, dan Gambar 5 menunjukkan arsitektur *Multi-Layer Perceptron* (MLP) yang digunakan dalam penelitian ini dengan konfigurasi *sliding window* berukuran 12, sehingga terdapat 12 neuron pada lapisan *input* yang merepresentasikan data penjualan bulanan selama satu tahun. Perbedaan ketiga model terletak pada jumlah neuron pada *hidden layer*, yaitu masing-masing 10 neuron untuk model 12-10-1, 15 neuron untuk model 12-15-1, dan 20 neuron untuk model 12-20-1. Setiap neuron pada *input layer* terhubung ke neuron pada *hidden layer* melalui bobot  $w_{ij}$ , sementara neuron pada *hidden layer* terhubung ke neuron pada *output layer* melalui bobot  $w_{jk}$ . Bias  $b_i$  dan  $b_j$  ditambahkan pada lapisan *input* dan *output* untuk meningkatkan kemampuan model dalam mempelajari pola data. Lapisan *output* pada ketiga model terdiri dari satu neuron yang menghasilkan prediksi penjualan bulan berikutnya. Parameter pelatihan jaringan disajikan pada Tabel 13.

Tabel 13. Parameter Pelatihan JST *Backpropagation*

Parameter	Nilai
Fungsi aktivasi	Sigmoid biner
<i>Learning rate</i>	0.1
<i>Epoch</i> Maksimum	10000
Batas maksimum <i>error</i>	0.001
Bobot dan bias diinisialisasi menggunakan nilai acak.	Berada pada rentang nilai -0.5 hingga 0.5.

Berdasarkan tabel parameter di atas, proses pelatihan menggunakan fungsi aktivasi sigmoid biner untuk memetakan *output* dalam rentang 0 hingga 1. Nilai *learning rate* yang digunakan adalah 0,1, yang berfungsi untuk menentukan tingkat penyesuaian bobot selama proses pelatihan. Jumlah *epoch* maksimum ditetapkan sebesar 10.000 iterasi, dengan batas maksimum *error* sebesar 0,001 sebagai ambang konvergensi. Bobot dan bias diinisialisasi secara acak dengan nilai pada rentang -0,5 hingga 0,5 yang dihasilkan menggunakan *library NumPy* untuk menghasilkan nilai acak.

### 3.4 Implementasi Algoritma *Backpropagation*

Setelah data dinormalisasi menggunakan metode *min-max scaling*, tahapan selanjutnya adalah pelatihan model (*training*) yang dimulai dengan proses *feedforward*. Sebagai contoh, pada arsitektur jaringan 12-10-1 dengan *input* data penjualan bulan Januari hingga Desember 2022 yang telah dinormalisasi (dinyatakan sebagai  $x_1$  hingga  $x_{12}$ ), nilai total *input* ke salah satu neuron pada lapisan tersembunyi (*hidden layer*) dihitung menggunakan Persamaan 2. Dari perhitungan

tersebut diperoleh nilai  $z_j = -0.4624$ . Nilai ini kemudian diaktifkan menggunakan fungsi aktivasi sigmoid biner sesuai Persamaan 3 sehingga menghasilkan *output* neuron sebesar

$$f(-0.4624) = \frac{1}{1 + e^{-( -0.4624)}} = 0.3864 \tag{10}$$

Proses ini dilakukan untuk setiap neuron pada *hidden layer*. Selanjutnya, *output* dari *hidden layer* digunakan sebagai *input* baru untuk neuron pada lapisan *output*. Berdasarkan Persamaan (4), total *input* ke neuron *output* dihitung dan menghasilkan nilai  $y_{ink} = 0.3656$ , Nilai ini kemudian diproses kembali menggunakan fungsi aktivasi sigmoid seperti pada Persamaan 5 sehingga diperoleh *output* prediksi jaringan sebesar  $y_{out} = 0.5903$ .

Pada tahap pengujian (*testing*), nilai target yang diharapkan untuk bulan Januari 2023 berdasarkan hasil normalisasi adalah 0.5692, Dengan demikian, berdasarkan Persamaan 6, nilai *error* yang dihasilkan adalah  $0.5692 - 0.5903 = -0.0211$ . *Error* ini selanjutnya digunakan dalam proses *backpropagation* untuk melakukan koreksi terhadap bobot jaringan. Koreksi *error* pada lapisan *output* dilakukan dengan menghitung turunan fungsi sigmoid sebagaimana dijelaskan dalam Persamaan 7, dan menghasilkan nilai gradien sebesar  $\delta_k = -0.0051$ .

Langkah berikutnya adalah pembaruan bobot pada koneksi dari lapisan tersembunyi ke lapisan *output*, dan kemudian dilanjutkan dengan pembaruan bobot pada lapisan *input* ke *hidden*. Seluruh proses ini diulang selama beberapa *epoch* hingga mencapai kriteria *minimum error* atau jumlah iterasi maksimum yang telah ditentukan.

### 3.5 Pengujian model

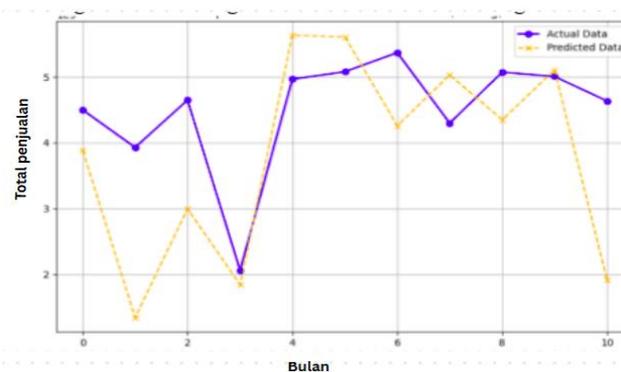
Setelah seluruh proses pelatihan selesai, JST diuji menggunakan tiga arsitektur jaringan yang berbeda, yaitu 12-10-1, 12-15-1, dan 12-20-1. Pengujian model menggunakan dua metode pengukuran, yaitu *Mean Squared Error* (MSE) dan *Mean Absolute Percentage Error* (MAPE), sebagai indikator untuk mengevaluasi seberapa tinggi hasil prediksi mendekati nilai aktual.

#### a. Hasil Pengujian Model 12-10-1

Tabel 14. Perbandingan Data Latih dan Data Uji Model 12-10-1

No	MSE Latih	MSE Uji	Epochs	MAPE
1	0.000100	0.06349	48970	23.84%

Tabel 14 menunjukkan uji coba untuk model 12-10-1 didapatkan nilai *MSE* untuk data latih yaitu 0.000100 dan *MSE* untuk data uji 0.06349 dengan *epochs* 48970 dari 100000. Lalu nilai *MAPE* yang didapatkan adalah 23.84%. Nilai *MAPE* ini termasuk dalam kategori yang cukup atau layak.



Gambar 6. Grafik Hasil Perbandingan Aktual Data vs *Predicted Data* model 12-10-1

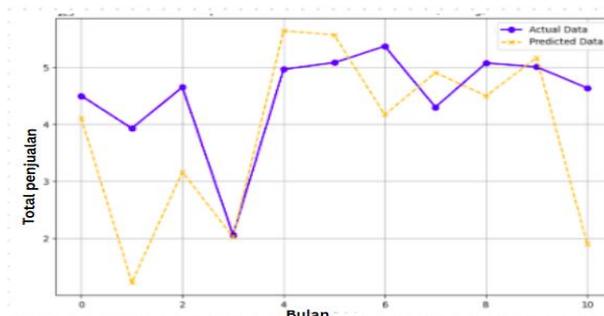
Gambar 6 menunjukkan performa yang baik karena mampu mengikuti tren penjualan riil di sebagian besar bulan. Akan tetapi, terdapat deviasi yang signifikan pada bulan Februari, Maret, dan November, di mana akurasi prediksi menurun dan menunjukkan selisih yang cukup jauh dari data aktual, menandakan adanya anomali yang perlu dianalisis lebih lanjut pada periode tersebut.

b. Hasil Pengujian Model 12-15-1

Tabel 15. Perbandingan Data Latih dan Data Uji Model 12-15-1

No	MSE Latih	MSE Uji	Epochs	MAPE
1	0.000999	0.062680	42707	22.24%

Tabel 15 menunjukkan uji coba untuk model 12-15-1 didapatkan nilai MSE untuk data latih yaitu 0.000999 dan MSE untuk data uji 0.0626 dengan epochs 42707 dari 100000. Lalu nilai MAPE yang didapatkan adalah 22.24%. Nilai MAPE ini termasuk dalam kategori yang cukup atau layak.



Gambar 7. Grafik Hasil Perbandingan Aktual Data vs Predicted Data model 12-15-1

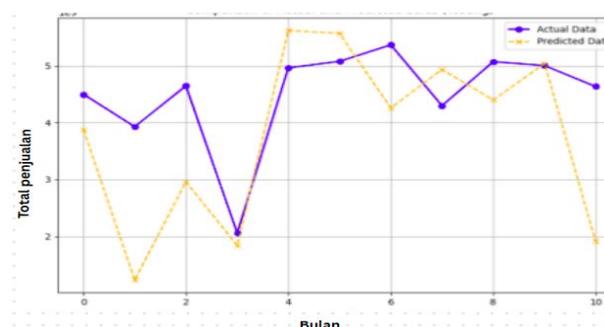
Gambar 7 menunjukkan akurasi prediksi tergolong baik, bahkan mencapai puncak presisinya di bulan April, di mana hasil prediksi hampir identik dengan data aktual. Namun, tantangan signifikan muncul pada bulan Februari, Maret, dan Desember, yang menunjukkan adanya selisih besar antara nilai prediksi dan penjualan riil.

3.5.3. Hasil Pengujian model 12-20-1

Tabel 16. Perbandingan Data Latih dan Data Uji Model 12-20-1

No	MSE Latih	MSE Uji	Epochs	MAPE
1	0.000999	0.06537	44201	23.80%

Tabel 16 menggambarkan uji coba untuk model 12-20-1 didapatkan nilai MSE untuk data latih yaitu 0.000999 dan MSE untuk data uji 0.06537 dengan epochs 44201 dari 100000. Lalu nilai MAPE yang didapatkan adalah 23.80%. Nilai MAPE ini termasuk dalam kategori yang cukup atau layak.

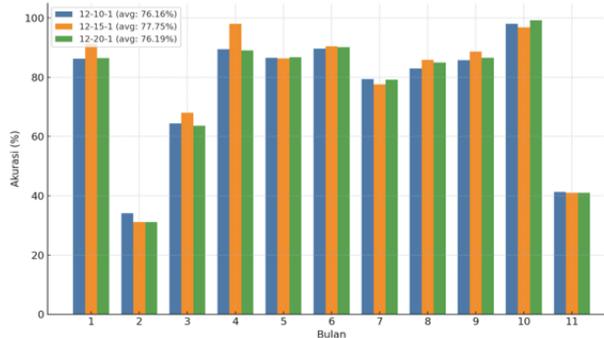


Gambar 8. Grafik Hasil Perbandingan Aktual Data vs Predicted Data model 12-20-1

Meskipun secara umum performanya cukup baik di sebagian besar bulan, terdapat beberapa catatan penting. Deviasi yang signifikan terlihat pada bulan Februari, Maret, dan November, di mana prediksi jauh dari nilai aktual. Selain itu, akurasi pada bulan April juga tercatat belum seoptimal model 12-15-1, menandakan adanya ruang untuk perbaikan spesifik pada periode-periode tersebut.

Berdasarkan uji coba ketiga model arsitektur jaringan, model 12-15-1 menunjukkan performa pelatihan terbaik, dengan penurunan MSE yang lebih cepat dan nilai error yang lebih

rendah. Model ini memiliki nilai MAPE terendah sebesar 22,24% dan akurasi tertinggi mencapai 77,75%, serta memerlukan jumlah *epoch* yang lebih rendah (42,707), menandakan proses konvergensi yang lebih cepat. Sementara itu, model 12-10-1 dan 12-20-1 masing-masing menunjukkan performa yang tergolong baik, meskipun sedikit lebih rendah, dengan nilai MAPE sekitar 23,8% dan tingkat akurasi berada di kisaran 76%. Hasil ini mengindikasikan bahwa penambahan jumlah neuron tersembunyi tidak selalu meningkatkan akurasi model, bahkan berpotensi menimbulkan *overfitting* yaitu saat model terlalu cocok pada data pelatihan namun gagal menggeneralisasi ke data baru jika tidak sesuai dengan kompleksitas data yang digunakan [16]. Rangkuman hasil evaluasi tersebut ditampilkan pada Gambar 10 dan Tabel 17.



Gambar 9. Grafik Hasil Perbandingan Aktual Data vs *Predicted Data* model 12-10-1,12-15-1 dan 12-20-1

Tabel 17. Ringkasan Hasil Evaluasi Model JST

Arsitektur Model	MSE Latih	MSE Uji	MAPE(%)	<i>Epoch</i>	Akurasi (%)
12-10-1	0.001000	0.06349	23.84	48.969	76.16
12-15-1	0.000999	0.06268	22.24	42.707	77.75
12-20-1	0.000999	0.06537	23.80	44.201	76.19

Dari hasil uji coba ketiga model diatas ditemukan bahwa model tersebut memiliki ketergantungan tinggi pada kualitas data historis yang digunakan, sehingga memerlukan data yang lengkap, akurat, dan relevan agar dapat menghasilkan prediksi yang optimal. Kehadiran data *outlier* pada dataset dapat menurunkan performa model secara signifikan. Selain itu, proses pelatihan JST memiliki kompleksitas komputasi yang relatif tinggi, terutama jika jumlah neuron dan iterasi diperbesar, sehingga memerlukan waktu dan sumber daya yang memadai. Selain itu, fitur yang digunakan masih terbatas pada total penjualan bulanan tanpa mempertimbangkan faktor pendukung lain seperti tren pasar, promosi , atau kondisi ekonomi, sehingga kemampuan prediksi untuk tahun target menjadi terbatas.

#### 4. KESIMPULAN DAN SARAN

Hasil penelitian mengindikasikan bahwa model Jaringan Syaraf Tiruan (JST) *Backpropagation* dengan arsitektur 12–15–1 memberikan performa terbaik dalam memprediksi penjualan produk di PT Central Pacific. Model ini menghasilkan nilai *Mean Squared Error* (MSE) sebesar 0.000999 dan *Mean Absolute Percentage Error* (MAPE) sebesar 22.24%, dengan tingkat akurasi sebesar 77.75%. Berdasarkan nilai MAPE yang berada pada rentang 20%–50%, model ini dapat dikategorikan sebagai cukup layak untuk digunakan sebagai alat bantu dalam melakukan peramalan.

Penelitian ini menyarankan evaluasi berkelanjutan terhadap kinerja model *Backpropagation*, guna memastikan efektivitas dan relevansinya seiring dengan dinamika data. Sebagai pengembangan ke depan, disarankan untuk menggunakan dataset historis yang lebih lengkap, akurat, dan relevan agar model dapat meningkatkan kemampuan generalisasinya serta mampu mengenali pola data yang lebih kompleks dengan lebih tepat. Mengingat keterbatasan

data, penerapan teknik *cross-validation* direkomendasikan guna memperoleh evaluasi performa yang lebih andal dan meminimalkan risiko *overfitting*.

#### DAFTAR PUSTAKA

- [1] Sumiyati and Yatimatun Nafi'ah, *Akuntansi Keuangan SMK/MAK Kelas XI*. Gramedia Widisarana Indonesia, 2021.
- [2] E. Ofori-Ntow Jnr and Y. Y. Ziggah, "Electricity demand forecasting based on feature extraction and optimized backpropagation neural network," *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, vol. 6, pp. 1-13, 2023, doi: <https://doi.org/10.1016/j.prime.2023.100293>.
- [3] R. T. Untari and M. Devegi, "Penerapan Algoritma Backpropagation untuk Memprediksi Jumlah Permintaan Buku dan Alat Tulis," *JURTEII: Jurnal Teknologi Informasi*, vol. 2, no. 1, pp. 1-7, 2022, doi: <https://doi.org/10.22202/jurteii.2022.6670>.
- [4] M. Marjiyono, B. Soedijono, and E. T. Luthfi, "Penggunaan Jaringan Syaraf Tiruan Untuk Meramalkan Permintaan pada Perusahaan Retail," *Seminar Nasional Teknologi Informasi dan Multimedia*, vol. 6, no. 1, pp. 8-12, 2020, [Online] Available: <https://ojs.amikom.ac.id/index.php/semnasteknomedia/article/view/1999/1808>.
- [5] S. Alzughabi and S. El Khediri, "A Cloud Intrusion Detection Systems Based on DNN Using Backpropagation and PSO on the CSE-CIC-IDS2018 Dataset," *Applied Sciences (Switzerland)*, vol. 13, no. 4, 2023, pp.1-21, doi: <http://dx.doi.org/10.3390/app13042276>.
- [6] B. Salsabila and I. Cholissodin, "Prediksi Permintaan Keripik Buah dengan Metode Jaringan Syaraf Tiruan Backpropagation (Studi Kasus: CV. Arjuna 999)," *J-PTIHK*, vol. 4, no. 6, pp. 1667-1674, 2020, [Online] Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/7335>.
- [7] M. F. Mubarak, M. Nasir, and D. Komalasari, "Jaringan Syaraf Tiruan Untuk Memprediksi Penjualan Pakaian Menggunakan Algoritma Backpropagation," *Journal of Computer and Information Systems Ampera*, vol. 1, no. 1, pp. 29-43, 2020, doi: <http://dx.doi.org/10.51519/journalcisa.v1i1.3>.
- [8] K. Jaya Atmaja *et al.*, "Implementation of Artificial Neural Network on Sales Forecasting Application," *Journal of Intelligent Decision Support System (IDSS)*, vol. 5, no. 4, pp. 124-131, 2022, doi: <https://doi.org/10.35335/idss.v5i4>.
- [9] E. P. Madani, M. T. Furqon, and N. Hidayat, "Peramalan Indeks Harga Konsumen Indonesia menggunakan Metode Jaringan Saraf Tiruan Backpropagation," *J-PTIHK*, vol. 4, no. 9, pp. 2801-2809, 2020, [Online] Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/7743>.
- [10] Asli Akilli and Hulya Atil, "Evaluation of Normalization Techniques on Neural Networks for the Prediction of 305-Day Milk Yield," *Turkish Journal of Agricultural Engineering Research*, vol. 1, no. 2, pp. 354-367, 2020, doi: 10.46592/turkager.2020.v01i02.011.
- [11] A. P. Wibawa, *et al.*, "Multilayer Perceptron untuk Prediksi Sessions pada Sebuah Website Journal Elektronik," *Indonesian Journal of Data and Science*, vol. 1, no. 3, pp. 57-67, 2020, doi: <https://doi.org/10.33096/ijodas.v1i3.15>.
- [12] S. J. Russell and P. Norvig, *Artificial Intelligence - A Modern Approach*, 3rd ed. Prentice Hall, 2010.
- [13] P. D. Sari and F. Ahyaningsih, "Jaringan Saraf Tiruan Backpropagation untuk Prediksi Harga Bahan Pangan di Wilayah Kabupaten Deli Serdang," *Algoritma: Jurnal Matematika, Ilmu pengetahuan Alam, Kebumihan dan Angkasa*, vol. 2, no. 6, pp. 105-117, 2024, doi: <https://doi.org/10.62383/algoritma.v2i6.287>.
- [14] I. Nabillah and I. Ranggadara, "Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut," *JOINS (Journal of Information System)*, vol. 5, no. 2, 2020, doi: <https://doi.org/10.33633/joins.v5i2.3900>.
- [15] H. F. Mahfuzh, D. Widiyanto, N. Chamidah, and I. Komputer, "Pengaruh Algoritma Inisialisasi Nguyen-Widrow Terhadap Algoritma Backpropagation Dalam Prediksi Indeks Harga Konsumen (IHK)," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya*, vol. 1, pp. 707-720, 2020, [Online] Available: <https://conference.upnvj.ac.id/index.php/senamika/article/view/632>.
- [16] G. I. Marthasari, S. A. Astiti, and Y. Azhar, "Prediksi Data Time-series menggunakan Jaringan Syaraf Tiruan Algoritma Backpropagation Pada Kasus Prediksi Permintaan Beras," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 6, no. 3, pp. 187-193, 2021, doi: 10.30591/jpit.v6i3.2627.