

LAPORAN AKHIR
PENELITIAN INTERNAL DOSEN
Progam Studi Teknik Industri Fakultas Sains dan Teknik



OPTIMIZING SAFETY STOCK USING ANN-BASED TIME SERIES CLUSTERING

Tim Peneliti:

1. Rizky Stighfarrinata, S.ST., M.T
2. Dr. Eko Wahyu Abryandoko, S.Pd., M.T
3. Shofi Zakiyatul maghfiroh

Dibiayai oleh:

Universitas Bojonegoro

Periode 1 Tahun Anggaran 2025/2026

Nomor Kontrak :

073 / LPPM-LIT / UB / XI / 2025

UNIVERSITAS BOJONEGORO
2026

HALAMAN PENGESAHAN

LAPORAN PENELITIAN PENDANAAN PERGURUAN TINGGI

- 1 **Judul Penelitian** : Optimizing Safety Stock Using Ann-Based Time Series Clustering
- 2 **Ketua Peneliti**
 - a. Nama Peneliti : Rizky Stighfarrinata, S.ST., M.T.
 - b. NIDN : 07 0809 9302
 - c. Program Studi : Teknik Industri
 - d. E-mail : stighfarrinatarizky@gmail.com
 - e. Bidang Keilmuan : Optimasi Sistem Industri
- 3 **Anggota Peneliti 1**
 - a. Nama : Dr. Eko Wahyu Abryandoko, S.Pd., M.T.
(Dosen/Mahasiswa)
 - b. NIDN/NIM : 07 1011 9102
 - c. Program Studi : Teknik Industri
 - d. E-mail : abryandoko@gmail.com
 - e. Bidang Keilmuan : Sistem Industri
- 4 **Anggota Peneliti 2**
 - a. Nama : Shofi Zakiyatul Maghfiroh
(Dosen/Mahasiswa)
 - b. NIDN/NIM : 22262012050
 - c. Program Studi : Teknik Industri
 - d. E-mail : shofizakiyatul@gmail.com
 - e. Bidang Keilmuan : Teknik Industri
- 5 **Jangka Waktu Penelitian** : 6 Bulan
- 6 **Lokasi Penelitian** : PT. XYZ
- 7 **Dana Diusulkan** : Rp 3.500.000,-

Bojonegoro, 23 Februari 2026

Mengetahui,

Ketua LPPM Universitas Bojonegoro



Dr. Laily Agustina Rahmawati, S.Si., M.Sc.

NIDN: 07 2108 8601

Ketua Penelitian

Rizky Stighfarrinata, S.ST., M.T.

NIDN. 07 0809 9302

KATA PENGANTAR

Puji dan syukur senantiasa saya panjatkan kehadiran Allah SWT karena dengan berkat dan rahmat-Nya, saya dapat menyelesaikan proposal penelitian ini sebaik-baiknya. Proposal penelitian ini berjudul “Optimizing Safety Stock Using ANN-Based Time Series Clustering” ini disusun untuk memenuhi salah satu tridarma perguruan tinggi yaitu penelitian. Saya menyadari bahwa, tanpa bantuan dan bimbingan dari berbagai pihak, dari masa penelitian sampai pembuatan proposal ini, sangatlah sulit bagi saya untuk menyelesaikannya. Oleh karena itu saya mengucapkan terimakasih kepada semua pihak yang telah terlibat dalam pembuatan proposal penelitian ini.

Akhir kata, saya berharap Allah SWT berkenan membalas segala kebaikan semua pihak yang telah membantu. Semoga penelitian ini membawa manfaat bagi pengembangan teknologi di bidang pemrograman website ke depannya.

Bojonegoro, 23 Februari 2026

Penulis

ABSTRAK

Penelitian ini bertujuan untuk mengoptimalkan prediksi permintaan dan perhitungan safety stock dengan menerapkan metode *Artificial Neural Network* (ANN) yang dikombinasikan dengan klasterisasi data time series. Data permintaan historis diklasifikasikan ke dalam dua klaster berdasarkan kemiripan pola, yaitu jenis produk Inner Clack dan Inner Goint. Setiap klaster kemudian dilatih menggunakan model ANN secara terpisah untuk meningkatkan spesifisitas dan akurasi prediksi. Evaluasi performa model dilakukan menggunakan metrik *Mean Absolute Percentage Error* (MAPE) terhadap data *out-sample*. Hasilnya menunjukkan bahwa model ANN mampu memberikan akurasi yang baik, dengan MAPE terbaik sebesar 10,55% untuk klaster pertama dan 10,78% untuk klaster kedua. Hasil prediksi dari masing-masing model digunakan dalam perhitungan *safety stock* berdasarkan pendekatan probabilistik, yang memperhitungkan nilai MAPE dan tingkat layanan (*service level*) sebesar 96% atau setara dengan Z-score 1,75. Perhitungan safety stock dilakukan untuk masing-masing bulan dalam satu tahun ke depan, sehingga diperoleh total stok disarankan yang mampu mengantisipasi ketidakpastian permintaan. Hasil penelitian menunjukkan bahwa integrasi ANN dan klasterisasi *time series* dapat meningkatkan ketepatan prediksi serta efisiensi dalam pengelolaan persediaan. Pendekatan ini dapat diterapkan sebagai sistem pendukung keputusan dalam perencanaan persediaan gudang yang lebih adaptif dan responsif terhadap dinamika permintaan.

Kata kunci : *Artificial Neural Network, Klasterisasi Time Series, Safety Stock.*

DAFTAR ISI

Cover	
Halaman Pengesahan.....	i
Kata Pengantar	ii
Abstrak	iii
Daftar Isi.....	iv
Daftar Gambar.....	vi
Daftar Tabel	vii
Daftar Lampiran	viii

BAB I PENDAHULUAN

1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	3
1.4 Manfaat Penelitian.....	4

BAB II TINJAUAN PUSTAKA

2.1 Cluster time series	5
2.2 Safety Stock.....	5
2.3 Manajemen Persediaan Gudang	6
2.4 Preprocessing Data	7
2.5 Normalisasi Data Input ANN	7
2.6 Artificial Neural Network (ANN)	8
2.7 Root Mean Square Error (RMSE)	9
2.8 Mean Absolute Percentage Error (MAPE).....	10
2.9 Demand Forecasting.....	11
2.10 Penelitian Terdahulu	
2.11 Kerangka Konsep Penelitian	14
2.12 Neural Network	15

BAB III METODE PENELITIAN

3.1 Jenis dan Pendekatan Penelitian.....	17
3.2 Lokasi Penelitian	17
3.3 Populasi, Sampel dan Teknik Pengambilan Sampel	17
3.4 Jenis Data dan Teknik Pengumpulan Data.....	18
3.5 Analisis Data	18

BAB IV PENGUMPULAN DAN PENGOLAHAN DATA

4.1 Konseptual Klasterisasi Model.....	19
4.2 Data Permintaan Dan Persediaan Inner Bulanan Pada Tahun 2024.....	20
4.3 Analisis cluster time series	21
4.4 Identifikasi Artificial Neural network	24
a. Identifikasi Cluster Pertama	25
b. Identifikasi Cluster Kedua.....	27
4.5 Validasi Model Artificial Neural Network.....	29
a. Validasi Model Cluster Pertama.....	29
b. Validasi model cluster kedua	30
4.6 Uji Sensitivitas Model Artificial Neural Network (ANN)	31
a. Uji Sensitivitas Model ANN Cluster Pertama	32
b. Uji sensitivitas model ANN Cluster Kedua	33
4.7 Prediksi Permintaan Menggunakan Model Artificial Neural Network	35
a. Prediksi Permintaan Model ANN Cluster Pertama	35
b. Prediksi Permintaan model Cluster Kedua.....	37

4.8 Analisis Safety Stok	39
a. Analisis Safety Stok Cluster Pertama.....	39
b. Analisis Safety Stok Cluster Kedua	40
BAB V PENUTUP	
5.1 Kesimpulan	43
5.2 Saran.....	44
DAFTAR PUSTAKA	
DAFTAR LAMPIRAN	

DAFTAR GAMBAR

Gambar 2. 1 Lead Time dan Safety Stok.....	6
Gambar 2. 2 Ilustrasi Artificial Neural Network	9
Gambar 2. 3 Kerangka Berpikir.....	14
Gambar 2. 4 Neural Network Sederhana	15
Gambar 4. 1 Desain Konseptual klasterisasi model ANN untuk Optimalisasi Safety Stock Dan Prekdisi Persediaan Gudang.....	19
Gambar 4.2 Dendrogram Hasil Clustering	22
Gambar 4.3 Time Series Plot Tiap Anggota Cluster	23
Gambar 4.4 ACF Data Cluster pertama.....	25
Gambar 4.5 PACF Data Cluster Pertama	25
Gambar 4.6 ACF Data Cluster Kedua	27
Gambar 4.7 PACF Data Cluster Kedua	28
Gambar 4.8 Perbandingan Antara Data Aktual Dan Hasil Prediksi Menggunakan Algoritma ANN Cluster Pertama.....	30
Gambar 4.9 Perbandingan Antara Data Aktual dan Hasil Prediksi Menggunakan Algoritma ANN Cluster Kedua	31
Gambar 4.10 Uji Sensitivitas Model ANN Cluster Pertama	33
Gambar 4.11 Uji Sensitivitas Model ANN Cluster Kedua	34
Gambar 4.12 Visualisasi Grafik Prediksi 12 Bulan Pada Cluster Pertama	36
Gambar 4.13 Visualisasi Grafik Prediksi 12 Bulan Pada Cluster Kedua	38

DAFTAR TABEL

Tabel 2.1 Kriteria Nilai MAPE.....	10
Tabel 2.2 Penelitian Terdahulu.....	12
Tabel 4.1 Data Permintaan Inner Bulanan Pada Tahun 2024.....	20
Tabel 4.2 Data Persediaan Inner Bulanan Pada Tahun 2024	21
Tabel 4.3 Deskriptif Cluster Time Series	22
Tabel 4.4 Matrik Evaluasi Model Cluster Pertama	26
Tabel 4.4 Matrik Evaluasi Model Cluster Kedua	29
Tabel 4.5 Modifikasi Data Cluster Pertama	32
Tabel 4.6 Modifikasi Data Cluster Kedua	34
Tabel 4.7 Prediksi Permintaan 1 Tahun Selanjutnya Berdasarkan MAPE Cluster Pertama.....	36
Tabel 4.8 Prediksi Permintaan 1 Tahun Selanjutnya Berdasarkan MAPE Cluster Kedua	37
Tabel 4.9 Safety Stok Dan Total Stok Yang Disarankan Cluster Pertama.....	40
Tabel 4.10 Safety Stok Dan Total Stok Yang Disarankan Cluster Kedua	41

DAFTAR LAMPIRAN

Lampiran 1. Bukti Submit Artikel.....	49
---------------------------------------	----

BAB I

PENDAHULUAN

1.1 Latar Belakang

Persediaan gudang industri manufaktur menuntut perusahaan untuk menggunakan strategi pengelolaan rantai pasok (Wafda,2024). strategi persediaan berdasarkan rantai pasok penting untuk menunjang operasi perusahaan. (Moroff et al., 2021). Tantangan utama dalam pengelolaan persediaan gudang, khususnya dalam konteks industri manufaktur, cukup kompleks karena menyangkut efisiensi operasional, keakuratan data, dan kecepatan respons terhadap permintaan pasar. Ketidakpastian permintaan, fluktuasi produksi, serta risiko keterlambatan pasokan menjadikan penentuan jumlah safety stock dan prediksi persediaan sebagai elemen krusial dalam menjaga keseimbangan antara ketersediaan barang dan efisiensi biaya (Nasution et al., 2022). Persediaan gudang yang tidak dikelola dengan baik menyebabkan efisiensi biaya operasional dan menghambat produktivitas.

Manajemen rantai pasok (SCM) bertujuan meningkatkan produktivitas seluruh aspek perusahaan, mulai dari pemilihan bahan baku hingga pengiriman barang (Namir et al., 2021). Namun, perusahaan sering menghadapi kendala, seperti keterbatasan pengelolaan data multi-produk, yang berisiko menyebabkan ketidakseimbangan stok dan kegagalan produksi (Deng et al., 2021).).kondisi sama terjadi pada PT. XYZ dimana terjadi keterlambatan produksi yang diakibatkan sistem pergudangan kurang tepat. Persediaan gudang yang dilakukan tidak terkelola dengan baik yang menyebabkan efisiensi biaya operasional dan menghambat produktivitas.(Nasution et al,2022). Kejadian ini semakin kompleks karena tidak terstruktur dan sangat bervariasi sering membingungkan pekerja dalam proses pemesanan bahan, yang pada akhirnya dapat menyebabkan ketidaktepatan stok dan berujung pada kegagalan proses produksi (Ramdhani & Setiawan, 2024Oleh karena itu, . Pendekatan machine learning dapat meningkatkan keakuratan dalam analisis data produk dengan variasi yang lebih banyak (Ckristina Nainggolan & Fitri Boy, 2023).

Beberapa tahun terakhir, perkembangan model machine learning semakin populer pada industri manufakturing terutama dalam manajemen rantai pasok (Rizkiawan et al., 2023) Di tengah kompleksitas tersebut, penerapan teknologi berbasis kecerdasan buatan, khususnya *Artificial Neural Network* (ANN), menjadi salah satu pendekatan

yang menjanjikan untuk meningkatkan akurasi prediksi permintaan dan stok. Menurut laporan Statista (2023). Metode peramalan berbasis kecerdasan buatan seperti ANN dikombinasikan dengan teknik klasterisasi data time series dapat memberikan solusi dalam pengelolaan stok yang lebih akurat dan adaptif terhadap perubahan permintaan pasar, sehingga perusahaan dapat menyesuaikan strategi persediaannya secara lebih proaktif.

Klasterisasi data time series telah terbukti menjadi alat yang efektif dalam mengelompokkan pola permintaan berdasarkan karakteristik yang serupa, sehingga memungkinkan perencanaan persediaan yang lebih presisi (Sabharwal et al., 2024). Akan tetapi, sebagian besar penelitian sebelumnya lebih banyak berfokus pada pendekatan statistik konvensional seperti K-Means dan *Hierarchical Clustering*, yang cenderung kurang fleksibel dalam menangani data dengan volatilitas tinggi (Shourie et al., 2024). Selain itu, pendekatan konvensional sering kali tidak mampu menangkap hubungan temporal dalam data permintaan yang sangat dinamis. Dengan menggabungkan ANN dengan klasterisasi data time series, penelitian ini bertujuan untuk memperbaiki keterbatasan tersebut dan meningkatkan keakuratan prediksi permintaan serta optimalisasi safety stock melalui pendekatan yang lebih adaptif dan cerdas.

Penelitian ini akan berkontribusi dengan mengembangkan model prediksi yang lebih cerdas dan adaptif menggunakan ANN dan teknik klasterisasi data time series. Pendekatan ini diharapkan dapat membantu perusahaan dalam mengoptimalkan manajemen stok dengan mengurangi risiko kelebihan dan kekurangan stok. Selain itu, implementasi model ini juga dapat meningkatkan efisiensi rantai pasok dan mengurangi biaya operasional dalam berbagai industri, terutama di sektor manufaktur (Gopal, 2024). Keunggulan utama dari pendekatan ini adalah kemampuannya untuk terus belajar dari data historis dan menyesuaikan model prediksi dengan perubahan pola permintaan, sehingga dapat meningkatkan ketepatan dalam pengambilan keputusan terkait persediaan barang.

Secara teoritis, penelitian ini akan melengkapi literatur yang ada mengenai penggunaan ANN dalam prediksi persediaan dengan menambahkan dimensi klasterisasi data time series. Kombinasi kedua metode ini diharapkan dapat memperbaiki kelemahan dari model prediksi berbasis ANN yang sering kali menghadapi tantangan dalam menangani data dengan pola non-stasioner atau yang mengalami perubahan

mendadak. Sementara itu, dari segi praktis, hasil penelitian ini dapat digunakan oleh perusahaan dalam mengembangkan sistem manajemen persediaan berbasis kecerdasan buatan yang lebih efektif dan akurat (Samal & Dash, 2025). Dengan ini, perusahaan dapat memiliki sistem yang lebih fleksibel dalam menyesuaikan tingkat persediaan dengan tren permintaan pasar yang dinamis.

penelitian ini untuk mengembangkan dan menguji model ANN dengan klasterisasi data time series dalam optimalisasi *safety stock* dan prediksi persediaan gudang. Manfaat yang diharapkan mencakup peningkatan akurasi prediksi permintaan, pengelolaan stok yang lebih efisien, serta pengurangan biaya operasional yang berkaitan dengan penyimpanan dan distribusi barang. Selain itu, penelitian ini diharapkan dapat memberikan wawasan baru dalam bidang perencanaan persediaan dengan menawarkan pendekatan yang lebih holistik dalam menangani tantangan pengelolaan stok dalam lingkungan bisnis yang terus berubah. Dengan pendekatan ini, penelitian ini tidak hanya memberikan kontribusi terhadap pengembangan ilmu pengetahuan, tetapi juga memberikan solusi praktis bagi industri dalam mengelola rantai pasok yang semakin kompleks dan dinamis.

1.2 Rumusan Masalah

Sesuai dengan latar belakang pembahasan di atas, maka dapat merumuskan masalah yang menjadi pokok bahasan penelitian ini ialah :

1. Bagaimana penerapan *Artificial Neural Network* dalam memprediksi kebutuhan persediaan gudang berdasarkan data time series?
2. Bagaimana penggunaan metode klasterisasi data *time series* untuk mengelompokkan pola permintaan?
3. Bagaimana optimalisasi *safety stock* dengan pendekatan *Artificial Neural Network*?

1.3 Tujuan Penelitian

Berikut ini merupakan tujuan dari kegiatan penelitian ini adalah :

1. Menganalisis efektivitas *Artificial Neural Network* dalam memprediksi persediaan gudang.

2. Mengimplementasikan klasterisasi data *time series* guna mengelompokkan pola permintaan.
3. Mengoptimalkan *safety stock* menggunakan pendekatan ANN dan klasterisasi untuk meningkatkan efisiensi persediaan.

1.4 Manfaat Penelitian

Adapun manfaat yang akan didapatkan dalam penelitian ini, diantaranya adalah sebagai berikut :

1. Bagi Peneliti: Menambah wawasan dalam penerapan kecerdasan buatan dalam manajemen rantai pasokan.
2. Bagi Perusahaan: Membantu perusahaan dalam mengoptimalkan persediaan gudang dan mengurangi risiko stockout maupun overstocking.
3. Bagi universitas: Sebagai referensi di perpustakaan khususnya bagi mahasiswa teknik industri untuk digunakan sebagai penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA


2.1 *Cluster time series*

Clustering merupakan teknik pengelompokan objek berdasarkan karakteristik data tertentu dengan tujuan untuk memaksimalkan kesamaan dalam satu kelompok (*intra-cluster kesamaan*) dan meminimalkan kesamaan antar kelompok (*inter cluster kesamaan*). Konteks data deret waktu (*Time Series*), proses ini dikenal sebagai *Cluster Time Series* , yang bertujuan untuk membagi data deret waktu ke dalam beberapa kelompok berdasarkan kesamaan pola atau jarak antar data. Teknik ini memungkinkan identifikasi pola distribusi yang dapat digunakan dalam analisis lebih lanjut.

Cluster Time Series memerlukan algoritma atau metode pengelompokan yang tepat. Objek-objek dalam satu cluster memiliki kesamaan berdasarkan atribut kedekatan (Kilborn et al., 2017). Proses pengelompokan data deret waktu ini biasanya dilakukan dalam dua tahap utama. Tahap pertama adalah menentukan metrik kesamaan atau jarak antar data deret waktu, sedangkan tahap kedua adalah menerapkan teknik *clustering* seperti, *Hierarchical Clustering*, *Density Based Clustering*, atau *Subspace Clustering* untuk membentuk struktur *cluster* yang optimal.

2.2 *Safety Stok*

Persediaan pengaman (*Safety stock*) adalah stok cadangan yang disediakan untuk mengantisipasi ketidakpastian permintaan dan variabilitas waktu tunggu (*lead time*). Persediaan ini bertujuan untuk mencegah kekurangan stok yang dapat terjadi akibat fluktuasi permintaan yang tidak terduga atau keterlambatan dalam proses pengadaan barang. Menurut Anubhav Sanket (Sanket et al., 2024) *safety stock* ditentukan oleh beberapa faktor utama, seperti rata-rata penggunaan bahan baku dalam periode tertentu sebelum pesanan tiba dan variabilitas waktu tunggu dalam rantai pasok. Keberadaan *safety stock* sangat penting untuk menjaga kelancaran operasional, terutama dalam menghadapi situasi di mana konsumsi barang lebih tinggi dari perkiraan awal atau terjadi hambatan dalam proses distribusi.



Gambar 2. 1 Lead Time dan Safety Stok

Gambar 2.1 menjelaskan *Lead time* adalah waktu yang diperlukan sejak pemesanan hingga barang tiba di gudang, dipengaruhi oleh waktu pemrosesan, produksi, dan pengiriman. *Safety stock* atau persediaan pengaman adalah stok cadangan yang disimpan untuk mengantisipasi ketidakpastian permintaan dan variabilitas *lead time*, sehingga mencegah kehabisan stok saat terjadi lonjakan permintaan atau keterlambatan pengadaan. Pengelolaan lead time dan *safety stock* yang optimal memastikan ketersediaan barang tanpa menimbulkan kelebihan stok yang berlebihan, sehingga meningkatkan efisiensi rantai pasok. Safety stok mempunyai rumus sebagai berikut:

$$SS = P \times MAPE \times Z$$

Keterangan :

P = prediksi permintaan (unit)

Z = nilai *Z-score* berdasarkan tingkat service level

MAPE = error model prediksi

2.3 Manajemen Persediaan Gudang

Manajemen persediaan Gudang adalah bagian dari pengendalian dan perencanaan proses produksi yang bertujuan untuk meminimalkan total biaya penyimpanan material , sekaligus mengoptimalkan tingkat persediaan selama lead time dan mendan menekan biaya akuisisi . Manajemen persediaan memainkan peran penting dalam keberlangsungan produksi, di mana salah satu faktor utama yang mempengaruhinya adalah prediksi permintaan . Fluktuasi permintaan yang tinggi dapat berdampak

langsung terhadap ketersediaan produk dan kelancaran aktivitas produksi (Anggraeni, 2024).

Proses pengadaan barang memerlukan waktu pemesanan sebelum barang dapat tersedia. Oleh karena itu, perusahaan harus memastikan bahwa persediaan selalu siap untuk memenuhi permintaan pelanggan pada waktu yang tepat. Pengendalian persediaan berperan dalam menjaga kelancaran proses produksi, distribusi, dan penjualan, serta membantu perusahaan dalam mengelola kebutuhan bahan baku dan lokasi penyimpanan secara efisien. Dengan strategi pengendalian yang baik, perusahaan dapat meningkatkan efektivitas operasional dan meminimalkan risiko kekurangan stok yang dapat menghambat kegiatan bisnis (Sumekar et al., 2022).

2.4 Preprocessing Data

Preprocessing data dalam penelitian ini dilakukan menggunakan Google Colab dengan bahasa pemrograman Python untuk memastikan kualitas dan konsistensi data sebelum masuk ke tahap klusterisasi dan pemodelan *Artificial Neural Network* (ANN). Data disusun dalam format time series bulanan agar dapat dianalisis secara deret waktu. Proses pembersihan dilakukan untuk menghilangkan nilai kosong, duplikasi, serta memastikan struktur data sesuai. Data kemudian dinormalisasi menggunakan metode Min-Max Scaling agar skala antar inner seragam dan tidak menyebabkan bias saat penghitungan jarak. Tahapan terakhir adalah membentuk matriks jarak menggunakan *autocorrelation-based distance*, yang digunakan sebagai dasar dalam metode *hierarchical clustering* dengan teknik *complete linkage*. Seluruh proses ini dijalankan di Google Colab untuk efisiensi komputasi dan kemudahan integrasi pustaka analisis data.

2.5 Normalisasi Data Input ANN

Normalisasi data merupakan langkah penting dalam mengoptimalkan proses pelatihan pada *neural network*. Proses ini bertujuan untuk menyelaraskan skala seluruh fitur input agar berada dalam rentang yang sebanding (*comparable*), sehingga dapat meningkatkan stabilitas dan efisiensi algoritma pembelajaran. Menurut Prathyusha (Prathyusha & Reddy, 2021) normalisasi harus diterapkan sebelum pemodelan guna memastikan distribusi data yang lebih seragam dan menghindari dominasi fitur dengan skala yang lebih besar terhadap fitur lainnya. Penelitian ini menggunakan metode normalisasi yang

digunakan adalah transformasi data ke dalam rentang 0 hingga 1. Berdasarkan analisis mendalam terhadap fungsi-fungsi pendukung dalam paket “nnfor” pada RStudio®, seperti yang dikemukakan oleh Nikolaos Passalis (Passalis et al., 2020), metode normalisasi yang terbukti memberikan akurasi terbaik serta mempercepat konvergensi model adalah modifikasi dari metode normalisasi Min-Max.

$$X^1 = L + \frac{(X - X_{min})}{(X_{max} - X_{min})} (H - L)$$


Keterangan :

H : nilai maksimum dari atribut X
 L : nilai minimum dari atribut X
 x' : hasil normalisasi
 x : data asli
 x_{max} : nilai maksimum dari seluruh data asli
 x_{min} : nilai minimum dari seluruh data asli

2.6 Artificial Neural Network (ANN)

Jaringan syaraf tiruan (*Artificial Neural Network*) adalah sistem komputasi yang dirancang untuk meniru cara kerja otak manusia dalam memproses informasi. Arsitektur dan operasionalnya sangat mirip dengan jaringan syaraf biologis, di mana sistem ini belajar melalui contoh. Setiap neuron dalam jaringan memiliki beberapa masukan dan satu keluaran. Jalur masukan pada suatu neuron bisa berupa data mentah atau hasil olahan dari neuron sebelumnya, sementara keluaran dari neuron tersebut dapat berupa hasil akhir atau digunakan sebagai masukan bagi neuron berikutnya. jaringan yang saling terhubung melalui lapisan input, lapisan tersembunyi (*hidden layer*), dan lapisan output, yang memungkinkan pemrosesan informasi secara kompleks dan non-linear (Yusof, 2024). Jaringan syaraf tiruan terdiri dari kumpulan neuron yang tersusun dalam beberapa lapisan, yaitu: pertama lapisan Masukan (*Input Layer*) yang menerima data awal yang akan diproses, kedua lapisan Tersembunyi (*Hidden Layer*) yang melakukan pemrosesan lebih lanjut terhadap data yang diterima dari lapisan masukan, dan ketiga Lapisan Keluaran (*Output Layer*) yang menghasilkan output yang merupakan hasil akhir dari proses perhitungan. Struktur ini memungkinkan jaringan syaraf tiruan untuk belajar dan menyelesaikan masalah yang kompleks melalui pembelajaran berbasis data.

Keunggulan ANN dalam pemrosesan data berskala besar serta kemampuannya untuk menyesuaikan bobot koneksi antar neuron menjadikannya alat yang sangat efektif dalam menangkap tren musiman dan pola permintaan yang dinamis. ANN mampu melakukan prediksi yang lebih akurat dibandingkan model statistik tradisional karena dapat mengatasi permasalahan non-linearitas dalam data (Wang, 2024). Selain itu, ANN juga memiliki fleksibilitas dalam integrasi dengan metode lain seperti algoritma optimasi dan teknik klasterisasi, yang meningkatkan efisiensi sistem prediksi.



Gambar 2. 2 Ilustrasi *Artificial Neural Network*

2.7 *Root Mean Square Error (RMSE)*

Root Mean Square Error (RMSE) sebagai salah satu indikator evaluasi kinerja model prediksi dalam penelitian. RMSE digunakan untuk mengukur besarnya deviasi rata-rata antara nilai prediksi dan nilai aktual dalam satuan yang sama dengan data aslinya, sehingga memberikan gambaran kuantitatif mengenai tingkat kesalahan absolut model. Dalam konteks penelitian ini, RMSE berperan dalam menilai keakuratan model *Artificial Neural Network (ANN)* dalam memprediksi jumlah kebutuhan persediaan gudang. Berikut rumus dari RMSE :

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t^{\wedge} - Y_t)^2}{n}}$$

Dimana :

Y_t = nilai sebenarnya pada waktu ke – t

$Y_t^{\wedge}$ = nilai dugaan pada waktu ke-t

n = jumlah observasi dari data time series

2.8 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah metrik yang digunakan untuk mengukur tingkat kesalahan dalam proses peramalan. MAPE menggambarkan persentase rata-rata kesalahan prediksi dibandingkan dengan nilai aktual, sehingga memberikan gambaran seberapa akurat model peramalan yang digunakan. Perhitungan MAPE dilakukan dengan mengambil rata-rata nilai absolut dari selisih antara data aktual dan hasil peramalan, yang kemudian dinormalisasi terhadap nilai aktual dalam bentuk persentase. Secara matematis, MAPE dapat dirumuskan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \times 100$$

Dimana:

n = jumlah data

A_i = Nilai actual pada data ke- i

F_i = Nilai hasil peramalan pada data ke- i

Mean Absolute Percentage Error (MAPE) merupakan metrik yang digunakan untuk mengukur tingkat deviasi hasil peramalan terhadap nilai aktual dalam bentuk persentase. Semakin kecil nilai MAPE, semakin tinggi akurasi model peramalan yang digunakan. MAPE sering digunakan sebagai indikator utama dalam menilai kualitas suatu model prediksi, terutama dalam bidang peramalan deret waktu (*time series forecasting*). Tingkat akurasi model berdasarkan nilai MAPE dapat dikategorikan sebagai berikut:

Tabel 2.1 Kriteria Nilai MAPE

Nilai MAPE	Keterangan
< 10%	Kemampuan peramalan sangat baik
10% - 20%	Kemampuan peramalan baik
20% - 50%	Kemampuan peramalan cukup
> 50%	Kemampuan peramalan buruk

Tabel 2.1 menjelaskan tingkat akurasi model prediksi berdasarkan nilai MAPE. Nilai MAPE <10% menunjukkan prediksi sangat akurat, 10–20% cukup akurat, 20–50%

kurang akurat, dan >50% menunjukkan prediksi tidak akurat. Klasifikasi ini membantu menilai keandalan model dalam meramalkan data

2.9 Demand Forecasting

Prediksi permintaan (*demand forecasting*) adalah proses proyeksi jumlah kebutuhan produk yang diperkirakan akan diminta konsumen dalam periode waktu tertentu. Dalam konteks manajemen rantai pasok dan pengelolaan persediaan, prediksi ini memiliki peran strategis dalam memastikan ketersediaan barang secara optimal. Dengan melakukan prediksi yang akurat, perusahaan dapat menghindari risiko kekurangan stok (*stockout*) yang dapat mengganggu pelayanan, maupun kelebihan stok (*overstock*) yang menyebabkan pemborosan sumber daya dan biaya penyimpanan. Berikut rumus demand forecasting pada penelitian ini.

$$P_{t+n} = (P_t + n \cdot \bar{\Delta}) \pm (P_t + n \cdot \bar{\Delta}) \cdot MAPE$$

Diketahui :

P_t = Prediksi bulan terakhir

$\bar{\Delta}$ = rata-rata

n = prediksi permintaan bulan ke- n setelah bulan terakhir

MAPE = Hasil model ANN terbaik

2.10 Penelitian Terdahulu

Tabel 2.2 Penelitian Terdahulu


NO	Nama Penulis dan Tahun	Judul	Metode	Variable penelitian	Tujuan Penelitian	Hasil
1	Mahya seyedan et.al (2023)	<i>Order Up To Level Inventory Optimization Model Using Time Series Demand Forecasting With Ensemble Deep Learning</i>	<i>Ensemble Deep Learning</i>	Stok keselamatan, model peramalan, kuantitas pesanan, biaya, dan tingkat layanan	Meningkatkan manajemen inventaris di industri ritel online dengan secara akurat memperkirakan permintaan masa depan menggunakan metode pembelajaran mendalam ansambel.	Menunjukkan peningkatan yang signifikan dalam akurasi, stabilitas, dan optimalisasi biaya.
2	Dwi Puspita Anggraeni (2024)	<i>Optimisation Of Inventory Management Through Time Series Analysis Of Inventory Data With Double Exponential Smoothing Method</i>	<i>Double Exponential Smoothing (DES)</i>	Data penjualan, konstanta peralusan, output peramalan, metrik kesalahan, dan tingkat persediaan aktual	Meminimalkan kesalahan dalam menentukan jumlah item stok, yang sangat penting untuk mencegah situasi kelebihan stok atau kekurangan stok	Model peramalan menggunakan metode DES, menunjukkan efektivitasnya dalam meningkatkan manajemen inventaris melalui prediksi yang akurat dan rekomendasi praktis.
3	Hanny setyaningrum et.al (2025)	<i>Inventory Optimization Model Using Artificial Neural Network Method and Continuous Review (s,Q)</i>	<i>Artificial Neural Network Method and Continuous Review (s,Q)</i>	Data Inventaris, Biaya Perbaikan, Biaya Penahan, Biaya Pemesanan, Biaya Kekurangan	Merencanakan perkiraan permintaan untuk perangkat medis, khususnya kotak pengaman, yang menyebabkan cacat dan kerusakan	Hasil permintaan menunjukkan perkiraan total 17.936 unit untuk item dalam dan 3.370 unit untuk item luar selama 20 bulan ke depan (Mei 2023 hingga Desember 2024)

Tabel 2.2 Penelitian Terdahulu (lanjutan)

NO	Nama Penulis dan Tahun	Judul	Metode	Variable penelitian	Tujuan Penelitian	Hasil
4	Anubhav sanket et. al. (2024)	<i>Sales Forecasting And Inventory Optimization At Big Mart Using Time Series Techniques: A Survey</i>	<i>Time series techniques :</i> eksplorasi data, pemrosesan, dan teknik pemodelan canggih	Data penjualan, pendapatan, dan tingkat stok	Meningkatkan keakuratan prediksi penjualan menggunakan berbagai algoritma.	Metode regresi ridge dan XGBoost secara signifikan mengungguli regresi linier dan polinomial dalam hal akurasi prediksi. Algoritme ini memberikan hasil yang unggul dalam metrik seperti Akurasi, Kesalahan Mutlak Rata-rata (MAE), dan Root Mean Squared Error (RMSE)
5	Muhammad miftah arzaq rahmansyah dan tedjo sukmono (2024)	<i>Implementation Of Fuzzy Inventory Method And Artificial Neural Network In Determining Safety Inventory Of Bag Products.</i>	<i>Fuzzy Inventory Method And Artificial Neural Network</i>	Data permintaan, data produksi, dan kalkulasi stok keamanan	Memprediksi permintaan penjualan untuk produk tas menggunakan metodologi canggih, khususnya Artificial Neural Networks (ANN) dan metode Fuzzy Inventory.	Root Mean Square Error (RMSE) sebesar 45.031 dari analisis ANN dan metode Fuzzy Inventory menghitung stok pengaman sebesar 43.647 buah untuk tahun 2023

2.11 Kerangka Berfikir

Kerangka berpikir penelitian disusun dengan mempertimbangkan permasalahan yang ada, potensi yang dapat dimanfaatkan, tujuan yang ingin dicapai, serta hasil yang diharapkan dari penelitian. kerangka konsep berpikir yang dijelaskan pada Gambar 3.1.




Gambar 2.3 Kerangka Berpikir

Kerangka berpikir gambar 2.4 menjelaskan Penelitian ini berfokus pada optimalisasi *safety stock* dan prediksi persediaan gudang menggunakan metode *Artificial Neural Network* (ANN) dengan pendekatan klusterisasi data *time series*. Dimulai dari permasalahan ketidakakuratan prediksi stok, variasi *lead time* pemasok, serta permintaan musiman yang sulit diprediksi, penelitian ini mengolah data barang masuk dan keluar untuk membentuk pola stok yang lebih akurat. Proses yang dilakukan mencakup klusterisasi pola stok, pengembangan model ANN, serta pelatihan dan evaluasi akurasi prediksi. Hasil penelitian ini menghasilkan model prediksi yang mampu mengoptimalkan *safety stock*, menghindari risiko kelebihan atau kekurangan stok, serta meningkatkan efisiensi manajemen gudang dan pengambilan keputusan perusahaan.

2.12 Neural Network

Neural network adalah model komputasi yang terdiri dari sejumlah besar elemen pemrosesan sederhana yang disebut neuron, unit, sel, atau node. Setiap neuron saling terhubung melalui jalur komunikasi yang memiliki bobot tertentu, yang berfungsi sebagai parameter utama dalam proses pembelajaran. Bobot ini merepresentasikan kekuatan hubungan antar neuron dan berperan dalam menentukan bagaimana informasi diproses dan ditransformasikan dalam jaringan. *Neural network* dapat diterapkan dalam berbagai bidang, seperti penyimpanan dan pemanggilan data atau pola, klasifikasi pola, pemetaan hubungan antara input dan output, pengelompokan data berdasarkan kesamaan, serta penyelesaian masalah optimasi. Setiap neuron memiliki keadaan internal, yang disebut aktivasi (*activation*) atau tingkat aktivitas (*activity level*), yang bergantung pada sinyal yang diterimanya dari neuron lain. Aktivasi ini kemudian dikirim sebagai sinyal keluaran ke neuron lain dalam jaringan. Hal ini menjadikan neural network sebagai pendekatan yang kuat dalam pemrosesan data dan pembelajaran mesin.



Gambar 2.4 Neural Network Sederhana

Pertimbangkan sebuah *neuron* Z, seperti yang diilustrasikan pada Gambar 2.1, yang menerima masukan dari tiga *neuron* sebelumnya, yaitu X₁, X₂, dan X₃. Setiap neuron input ini memiliki aktivasi (sinyal output) masing-masing. Hubungan antara neuron-neuron ini dikendalikan oleh bobot koneksi yang diberikan, yaitu w₁, w₂, dan w₃, yang menunjukkan seberapa besar pengaruh masing-masing input terhadap neuron Z. Masukan total ke *neuron* Z, yang disebut sebagai z_{in}, dihitung sebagai jumlah dari sinyal input yang telah dikalikan

dengan bobotnya masing-masing. Secara matematis, hal ini dapat dinyatakan sebagai:

$$Z = x_1w_1 + x_2w_2 + x_3w_3$$

Nilai z_{in} ini kemudian diproses menggunakan fungsi aktivasi, seperti sigmoid, ReLU, atau tanh, untuk menghasilkan output akhir dari *neuron* Z , yang akan diteruskan ke lapisan berikutnya dalam jaringan saraf tiruan.

BAB III

METODE PENELITIAN

3.1 Jenis dan Pendekatan Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan eksperimental yang berfokus pada pengujian kinerja model Artificial Neural Network (ANN) untuk optimalisasi safety stock dan prediksi persediaan gudang inner sepatu. Desain yang digunakan adalah within-subject factorial atau treatment by subject, di mana model dibandingkan dalam dua kondisi, yaitu prediksi langsung tanpa klasterisasi dan prediksi setelah data diklasterisasi berdasarkan pola time series. Perlakuan penelitian meliputi preprocessing data, normalisasi, klasterisasi deret waktu, penentuan lag signifikan melalui ACF dan PACF, lalu pelatihan beberapa arsitektur ANN dengan variasi jumlah neuron tersembunyi. Kinerja tiap model dievaluasi menggunakan indikator RMSE dan MAPE, baik untuk data in-sample maupun out-sample, sehingga dapat dipilih konfigurasi ANN terbaik yang paling akurat untuk masing-masing klaster permintaan dan selanjutnya digunakan dalam perhitungan safety stock persediaan gudang.

3.2 Lokasi Penelitian

Lokasi penelitian adalah PT. XYZ yang berlokasi di Bojonegoro, khususnya pada bagian pergudangan yang mengelola persediaan inner sepatu. Perusahaan manufaktur ini bergerak pada produksi komponen sepatu, sehingga membutuhkan sistem pengelolaan stok yang andal untuk menjamin kelancaran proses produksi. Fokus utama penelitian diarahkan pada gudang inner sepatu karena di bagian inilah terjadi permasalahan keterlambatan produksi akibat ketidaktepatan pengelolaan persediaan. Data yang dianalisis berupa catatan stok masuk, stok keluar, dan stok akhir yang tercatat secara periodik, serta informasi terkait lead time pemasok. Lingkup lokasi dibatasi hanya pada gudang inner sehingga analisis dapat lebih mendalam terhadap pola permintaan dan persediaan lima jenis inner yang kemudian direduksi menjadi dua kelompok utama sesuai hasil klasterisasi, yakni klaster produk Inner Clack dan Inner Goint.

3.3 Populasi, Sampel dan Teknik Pengambilan Sampel

Populasi dalam penelitian ini adalah seluruh data persediaan gudang inner sepatu di PT. XYZ selama periode pengamatan satu tahun, meliputi lima jenis inner (Teva, Clack, Hey Dude, Goint, dan Artisan) dengan data stok masuk dan keluar yang tercatat tiap bulan. Dari populasi tersebut dilakukan reduksi sehingga hanya dua kelompok data yang dianalisis lebih lanjut, yaitu klaster inner dengan karakteristik permintaan tinggi dan fluktuatif serta klaster inner dengan permintaan lebih rendah dan stabil. Pada tahap analisis pola, pemilihan deret waktu perwakilan klaster dilakukan secara purposive dan acak terbatas, misalnya memilih Clack dan Teva sebagai representasi klaster pertama serta Hey Dude, Goint, dan Artisan sebagai representasi klaster kedua. Strategi ini bertujuan memperoleh sampel yang mencerminkan karakteristik pola permintaan masing-masing klaster tanpa melepaskan keterwakilan populasi data persediaan gudang secara keseluruhan.

3.4 Jenis Data dan Teknik Pengumpulan Data

Jenis data yang digunakan adalah data sekunder dan data lapangan pendukung. Data utama berupa data historis persediaan gudang: jumlah stok masuk, stok keluar, dan stok akhir lima jenis inner sepatu yang dicatat secara periodik selama satu tahun, serta informasi lead time pemasok. Data ini diperoleh dari dokumen administrasi perusahaan, rekap gudang, dan arsip sistem pencatatan persediaan. Untuk memperkaya pemahaman konteks, peneliti juga melakukan observasi langsung terhadap aktivitas pergudangan, wawancara dengan kepala gudang dan staf terkait alur pemesanan serta kendala stok, serta dokumentasi tambahan yang menjelaskan prosedur operasional. Dalam batasan masalah disebutkan pula penggunaan kuesioner kepada pekerja gudang sebagai bahan identifikasi persoalan awal. Seluruh data kemudian disusun dalam format time series bulanan, dirapikan di Microsoft Excel, dan diimpor ke Google Colab sebagai dasar proses preprocessing, klasterisasi, dan pemodelan ANN.

3.5 Analisis Data


Analisis data diawali dengan preprocessing di Google Colab menggunakan Python, mencakup pembersihan data, pengecekan duplikasi, penanganan data kosong, dan penyusunan deret waktu bulanan. Data kemudian dinormalisasi menggunakan modifikasi metode Min-Max agar berada pada rentang 0–1 sehingga memudahkan proses pelatihan ANN. Tahap berikutnya adalah klasterisasi time series dengan autocorrelation-based distance dan hierarchical clustering teknik complete linkage untuk mengelompokkan inner berdasarkan kemiripan pola permintaan. Setelah terbentuk dua klaster, dilakukan analisis ACF dan PACF guna menentukan lag signifikan sebagai input ANN. Berbagai konfigurasi ANN dengan variasi neuron tersembunyi dilatih dan dievaluasi menggunakan RMSE serta MAPE, lalu dipilih model terbaik untuk tiap klaster. Model ini digunakan memprediksi permintaan 12 bulan ke depan, hasilnya dijadikan dasar perhitungan safety stock dengan mempertimbangkan MAPE dan tingkat layanan 96% ($Z = 1,75$), sehingga diperoleh total stok optimal yang disarankan.

BAB IV PENGUMPULAN DAN PENGOLAHAN DATA

Bab ini menjelaskan tahapan pengumpulan dan pengolahan data dalam penelitian yang bertujuan mengoptimalkan *safety stock* dan prediksi persediaan gudang menggunakan metode *Artificial Neural Network* (ANN) berbasis klasterisasi data time series. Proses dimulai dari pengumpulan data permintaan, klasterisasi pola data, pelatihan dan evaluasi model ANN menggunakan metrik *Root Mean Square Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE), hingga perhitungan *safety stock* berbasis hasil prediksi untuk menentukan jumlah stok optimal secara akurat dan efisien.

4.1 Konseptual Klasterisasi Model

Konseptual klasterisasi model diilustrasikan melalui diagram protocol eksperimen, ditunjukkan pada gambar 4.1



Gambar 4.1 Desain Konseptual klasterisasi model ANN untuk Optimalisasi Safety Stock Dan Prekdisi Persediaan Gudang

Gambar 4.1 menjelaskan penelitian ini bertujuan untuk mengoptimalkan *safety stock* gudang dengan menerapkan metode *Artificial Neural Network* (ANN) yang didukung oleh klasterisasi data *time series*. Proses diawali dengan pengumpulan data historis persediaan gudang, kemudian dilakukan klasterisasi untuk mengelompokkan pola permintaan yang serupa. Masing-masing klaster dilatih menggunakan model ANN, dan hasil prediksinya dievaluasi menggunakan metrik RMSE dan MAPE untuk mengukur tingkat akurasi model. Berdasarkan hasil prediksi yang telah tervalidasi, dilakukan perhitungan *safety stock* dengan mempertimbangkan nilai MAPE dan tingkat service level ($Z = 1,75$ untuk 96%).

Output dari proses ini adalah total stok optimal yang disarankan dalam periode prediksi, sehingga mampu meminimalkan risiko kekurangan stok dan meningkatkan efisiensi pengelolaan persediaan.

4.2 Data Permintaan Dan Persediaan Inner Bulanan Pada Tahun 2024

Penelitian membutuhkan sejumlah data yang relevan dengan permasalahan pengelolaan persediaan di Gudang pada perusahaan PT. XYZ. Data yang digunakan meliputi jenis-jenis inner sepatu yang dijual, jumlah permintaan dan persediaan bulanan selama satu tahun, serta informasi biaya seperti biaya pemesanan ulang, biaya penyimpanan, dan harga masing-masing jenis sepatu. Data tersebut diperoleh melalui kombinasi metode wawancara dengan staf gudang, observasi langsung terhadap sistem operasional Gudang. Fokus utama penelitian ini adalah pada produk inner sepatu yang memiliki frekuensi penjualan tinggi dan berkontribusi signifikan terhadap omzet perusahaan. Data dalam format *time series* ini akan digunakan untuk proses klusterisasi guna mengelompokkan pola permintaan yang serupa, sebelum dilanjutkan ke tahap pelatihan model *Artificial Neural Network* (ANN) untuk melakukan prediksi dan optimalisasi *safety stock* secara lebih akurat dan efisien.

Berikut data bulanan permintaan dan persediaan jenis inner di persediaan Gudang PT. XYZ selama satu tahun.

Tabel 4.1 Data Permintaan Inner Bulanan Pada Tahun 2024

Bulan	Jenis Inner				
	Teva	Clack	Hey dude	Goint	Artisan
Januari	7275	9076	2696	1446	2700
Februari	5758	8147	2406	1268	2465
Maret	6750	8781	2596	1450	2346
April	6876	9603	2154	1388	2801
Mei	6896	8701	2000	2122	2602
Juni	5996	7609	1897	1883	2341
Juli	9706	9099	2706	1685	2000
Agustus	8707	6908	2500	1408	1980
September	6676	7146	2346	1768	2942
Oktober	6247	7546	1776	2248	3000
November	5076	8377	2338	2198	1976

Tabel 4.1 Data Permintaan Inner Bulanan Pada Tahun 2024 (lanjutan)


Bulan	Jenis Inner				
	Teva	Clack	Hey dude	Goint	Artisan
Desember	7065	9076	2409	1989	2240
Total	83028	100069	27824	20853	29393
Mean	6919	8339,1	2318,7	1737,8	2449,4
Koef. variasi	18,10	10,39	13,13	19,99	14,92

Tabel 4.2 Data Persediaan Inner Bulanan Pada Tahun 2024

Bulan	Jenis Inner				
	Teva	Clack	Hey dude	Goint	Artisan
Januari	5752	8177	2416	1273	2475
Februari	6790	8803	2606	1460	2356
Maret	6897	9645	2164	1398	2811
April	6701	8715	2010	2133	2612
Mei	6002	7619	1907	1893	2351
Juni	9710	10025	2716	1695	2010
Juli	8717	6923	2510	1418	1990
Agustus	6700	7163	2356	1778	2952
September	6269	7579	1786	2258	3010
Oktober	5100	8402	2348	2203	1986
November	7110	9100	2419	1999	2250
Desember	4981	6015	2107	1788	2100
Total	80729	98166	27345	21296	28903
Mean	6727,4	8180,5	2278,8	1774,7	2408,6
Koef. variasi	19,90	14,32	12,53	18,89	15,35

4.3 Analisis *cluster time series*

Analisis klaster time series dalam penelitian ini diterapkan pada tahap pra-pemrosesan data sebagai upaya untuk mengelompokkan jenis barang berdasarkan pola pergerakan stok bulanan yang serupa. Klasterisasi ini bertujuan mempermudah proses pelatihan model prediksi dengan *Artificial Neural Network* (ANN), karena masing-masing klaster merepresentasikan karakteristik stok yang homogen. Pengukuran kemiripan antar *time series* dilakukan menggunakan pendekatan *Autocorrelation-Based Distance* dengan matriks bobot berupa matriks identitas. Proses pembentukan klaster dilakukan menggunakan metode *hierarchical clustering* dengan teknik *complete linkage*.



Gambar 4.2 Dendrogram Hasil *Clustering*

Gambar 4.2 menampilkan dendrogram hasil klasterisasi deret waktu yang divalidasi dengan nilai *Concordance Correlation Coefficient* (CCC) sebesar 0,97. Nilai ini mengindikasikan kesesuaian yang sangat tinggi antara hasil klasterisasi dengan data observasi asli, sehingga validitas metode clustering dapat dipercaya. Dari visualisasi dendrogram, terlihat bahwa jenis inner Teva dan Clack tergabung pertama kali dalam satu klaster, menandakan tingkat kemiripan atribut yang paling kuat di antara seluruh sampel. Selanjutnya, jenis Hey Dude dan Artisan membentuk klaster terpisah yang mencerminkan kesamaan karakteristik yang signifikan. Jenis Goint kemudian bergabung ke dalam klaster Hey Dude-Artisan, menunjukkan bahwa Goint memiliki karakteristik yang lebih dekat dengan kelompok tersebut dibandingkan dengan klaster lainnya. Berdasarkan struktur dendrogram dan jarak antar *cluster*, data dapat dikelompokkan menjadi dua klaster utama.


Tabel 4.3 Deskriptif *Cluster Time Series*

Cluster	Anggota	Total
1	3	78070
2	2	183097

Berdasarkan Tabel 4.4 dapat disimpulkan bahwa *Cluster 1* merupakan klaster dengan jumlah anggota terbanyak, yaitu terdiri dari 3 jenis inner.

Sementara itu, *Cluster 2* terdiri dari 2 jenis inner, menjadikannya klaster dengan jumlah anggota paling sedikit. Jika ditinjau dari sisi performa penjualan, *Cluster 2* menunjukkan total penjualan tertinggi dengan total penjualan mencapai 183.097 unit. Sebaliknya, *Cluster 1* memiliki total penjualan terendah dengan total penjualan sebanyak 78.070 unit. Hasil ini menunjukkan bahwa jenis inner yang tergolong dalam *Cluster 2* cenderung lebih diminati pasar dibandingkan dengan jenis-jenis inner dalam *Cluster 1*.

Selanjutnya mengidentifikasi karakteristik pola data dari masing-masing klaster secara lebih mendalam, dilakukan analisis lanjutan menggunakan pendekatan *time series plot*. Analisis ini bertujuan untuk mengevaluasi pola tren, fluktuasi musiman, serta dinamika penjualan dari jenis inner yang merepresentasikan masing-masing klaster. Proses analisis dilakukan dalam dua tahap dengan menggunakan sampel data yang dipilih secara purposif sebagai representasi dari setiap klaster. Pada tahap pertama, jenis inner yang dianalisis adalah Clack sebagai perwakilan dari *Cluster 1* dan Hey Dude sebagai perwakilan dari *Cluster 2*. Hasil visualisasi melalui *time series plot* dilihat gambar 4.3.



Gambar 4.3 Time Series Plot Tiap Anggota Cluster

Gambar 4.3 menunjukkan pola permintaan bulanan dua jenis inner, Clack dan Hey Dude, yang mewakili dua klaster berbeda. Clack memiliki permintaan tinggi dengan fluktuasi besar, terutama pada April dan Juli, mencerminkan klaster dengan permintaan tidak stabil. Sebaliknya, Hey Dude menunjukkan permintaan rendah yang stabil, dengan sedikit kenaikan pada Juli dan November, menandakan klaster dengan permintaan konsisten.


Untuk memperkuat hasil analisis dan memastikan konsistensi pola yang terbentuk dalam masing-masing klaster, dilakukan percobaan kedua dengan menggunakan data perwakilan lainnya yang dipilih secara acak dari tiap klaster. Pada percobaan ini, jenis inner Teva dipilih sebagai representasi dari *Cluster 1*, sementara jenis Artisan mewakili *Cluster 2*. Pemilihan kedua sampel ini bertujuan untuk memperoleh gambaran yang lebih menyeluruh mengenai variasi dan kecenderungan pola penjualan dalam masing-masing klaster. Hasil analisis *time series* plot dari kedua jenis inner tersebut dapat dilihat pada gambar 4.3.

4.4 Identifikasi *Artificial Neural network*

Setelah klasterisasi menghasilkan dua kelompok utama, tahap berikutnya adalah analisis prediktif dengan *Artificial Neural Network* (ANN). Jumlah input optimal pada model ditentukan berdasarkan hasil analisis *Autocorrelation Function* (ACF) masing-masing klaster. ACF digunakan untuk mengidentifikasi lag signifikan yang mencerminkan pola ketergantungan temporal data penjualan. Lag-lag signifikan ini menjadi dasar penentuan jumlah input pada arsitektur ANN. Hasil analisis ACF tiap klaster digunakan sebagai acuan penyusunan model prediksi.


a. Identifikasi *Cluster Pertama*

Data yang digunakan pada tahap analisis ini adalah data penjualan dari jenis inner clack. Pengambilan data dilakukan secara acak dari himpunan data yang tersedia, dengan tujuan untuk mengevaluasi pola ketergantungan temporal dalam rangkaian waktu penjualan. Analisis selanjutnya dilakukan menggunakan metode *Autocorrelation Function* (ACF), yang berfungsi untuk mengidentifikasi hubungan atau korelasi antara nilai-nilai data penjualan pada periode waktu yang berbeda. Hasil visualisasi ACF disajikan pada Gambar 4.4.



Gambar 4.4 ACF Data *Cluster* pertama

Gambar 4.4 Grafik hasil analisis *Autocorrelation Function* (ACF) terhadap data time series menunjukkan bahwa pada lag ke-0 terdapat korelasi sempurna (nilai 1.0), yang secara alami terjadi karena data dikorelasikan dengan dirinya sendiri. Pada lag ke-1, nilai korelasi sekitar 0.25 menunjukkan adanya pengaruh moderat dari permintaan bulan sebelumnya terhadap permintaan bulan berjalan. Sementara itu, korelasi pada lag ke-2 hingga lag ke-5 menunjukkan penurunan signifikan yang menandakan pengaruh historis semakin lemah seiring bertambahnya lag. Selain itu, secara praktis, lag ke-1 dinilai lebih relevan karena merepresentasikan pola hubungan permintaan dari satu bulan ke bulan berikutnya dalam konteks manajemen persediaan. Hasil analisis PACF pada Gambar 4.4 juga memperkuat pemilihan lag ke-1 sebagai variabel input yang paling potensial untuk model prediksi.



Gambar 4.5 PACF Data *Cluster* Pertama

Berdasarkan Gambar 4.5, hasil analisis *Partial Autocorrelation Function* (PACF) menunjukkan bahwa terlihat bahwa hanya lag ke-1 yang mendekati

ambang batas signifikansi meskipun tidak sepenuhnya keluar dari interval kepercayaan 96%. Hal ini mengindikasikan bahwa lag ke-1 memiliki pengaruh parsial yang relatif lebih kuat dibandingkan lag lainnya dalam memprediksi nilai di masa depan. Sementara lag lainnya (lag 2, 3, 4 dan 5) menunjukkan nilai korelasi parsial yang kecil dan berada dalam batas kepercayaan, sehingga dianggap tidak signifikan. Proses evaluasi model menggunakan matrik RMSE, MAPE (*in-sample dan out-sample*) dengan Setiap konfigurasi dilatih sebanyak 10 kali untuk memperoleh hasil yang stabil, dengan jumlah neuron pada hidden layer divariasikan dari 1 hingga 5. Hasil pelatihan disajikan dalam bentuk tabel 4.4 guna menunjukkan efektivitas masing-masing arsitektur dalam memprediksi data time series.


Tabel 4.4 Matrik Evaluasi Model *Cluster* Pertama

Neuorn	RMSE	MAPE	
		In sample (%)	Out sample (%)
1	323,339	13,01	11,12
2	381,910	12,57	15,41
3	294,386	15,69	10,55
4	349,645	12,55	13,27
5	379,138	12,65	15,26

Tabel 4.3 menunjukkan bahwa model ANN dengan 3 neuron pada hidden layer memberikan akurasi terbaik dibanding konfigurasi lainnya. Nilai RMSE terkecil sebesar 294,386 yang berarti rata-rata deviasi prediksi terhadap data aktual lebih kecil dibanding model dengan jumlah neuron lainnya. Selain itu, nilai MAPE in-sample 15,69% dan MAPE out-sample 10,55% menandakan bahwa tingkat kesalahan relatif model, baik pada data latih maupun data uji, berada pada kategori cukup baik untuk model *time series* (MAPE > 10% dianggap baik). Hasil tersebut mengindikasikan bahwa model dengan 5 neuron memiliki kemampuan terbaik dalam mengenali pola data historis dan menghasilkan prediksi yang paling mendekati nilai aktual, baik pada data latih maupun data uji.

b. Identifikasi Cluster Kedua


Data yang digunakan pada tahap analisis ini adalah data permintaan dari jenis inner Goint, yang dipilih secara acak sebagai objek kajian. Selanjutnya, untuk mengevaluasi keterkaitan nilai penjualan dari waktu ke waktu serta mendeteksi adanya pola berulang atau korelasi jangka pendek, dilakukan analisis menggunakan plot *Autocorrelation Function* (ACF). Analisis ACF ini berperan penting dalam mengidentifikasi struktur ketergantungan temporal dalam data deret waktu. Hasil visualisasi ACF dari data Goint disajikan pada Gambar 4.6.



Gambar 4.6 ACF Data Cluster Kedua

Gambar 4.6 menampilkan hasil analisis *Autocorrelation Function* (ACF) terhadap data time series. Pada lag 0, nilai korelasi sebesar 1.0 mencerminkan

korelasi sempurna karena data dikorelasikan dengan dirinya sendiri. Pada lag 1, korelasi masih cukup tinggi (sekitar 0.50), menunjukkan adanya pengaruh kuat permintaan bulan sebelumnya terhadap bulan ini. Nilai korelasi kemudian menurun tajam pada lag 2 hingga lag 5, mendekati nol atau negatif, yang menandakan pengaruh historis semakin lemah seiring bertambahnya lag. Dalam grafik ACF dan *Partial Autocorrelation Function* (PACF), batas kepercayaan 96% ditunjukkan oleh garis biru horizontal batang yang melampaui batas ini dianggap signifikan secara statistik dalam menjelaskan hubungan temporal. Selain ACF, analisis PACF yang ditampilkan pada Gambar 4.7.



Gambar 4.7 PACF Data *Cluster Kedua*

Gambar 4.7 menunjukkan bahwa lag ke-1 memiliki korelasi parsial yang signifikan dengan nilai sekitar 0,50, yang mengindikasikan adanya pengaruh langsung yang kuat dari nilai pada periode sebelumnya terhadap nilai saat ini. Sebaliknya, lag ke-2 hingga lag ke-5 tidak menunjukkan signifikansi statistik karena berada dalam batas kepercayaan, yang berarti kontribusinya terhadap proses prediksi relatif rendah. Peneliti ini menegaskan bahwa lag ke-1 merupakan variabel yang paling relevan untuk dimasukkan dalam pembangunan model prediktif. Proses evaluasi model menggunakan matrik RMSE, MAPE (*in-sample dan out-sample*) dengan Setiap konfigurasi dilatih sebanyak 10 kali untuk memperoleh hasil yang stabil, dengan jumlah neuron pada hidden layer divariasikan dari 1 hingga 5. Hasil pelatihan disajikan dalam bentuk tabel 4.5 guna menunjukkan efektivitas masing-masing arsitektur dalam memprediksi data time series.

Tabel 4.4 Matrik Evaluasi Model *Cluster* Kedua

Neuorn	RMSE	MAPE	
		In sample (%)	Out sample (%)
1	293,647	15,74	10,78
2	300,651	13,71	10,20
3	381,899	12,67	15,45
4	396,540	12,96	16,45
5	355,470	12,71	13,74

Tabel 4.6 menunjukkan bahwa model ANN dengan hidden layer 1 neuron memberikan akurasi terbaik dibanding konfigurasi lainnya. Hal ini dibuktikan dengan nilai RMSE terkecil sebesar 293,647 yang berarti rata-rata deviasi prediksi terhadap data aktual lebih kecil dibanding model dengan jumlah neuron lainnya. Selain itu, model ini juga menghasilkan MAPE in-sample sebesar 15,74% dan MAPE out-sample sebesar 10,78%, yang menandakan kemampuan model dalam menangkap pola data latih cukup baik dan akurasi prediksi pada data uji sangat baik. Nilai MAPE out-sample yang jauh lebih kecil dibanding MAPE in-sample mengindikasikan model mampu melakukan generalisasi dengan baik pada data baru.


4.5 Validasi Model Artificial Neural Network

Pemodelan algoritma *Artificial Neural Network* (ANN) dalam penelitian ini dilakukan untuk memprediksi jumlah penjualan jenis inner Hey Dude di masa mendatang dengan menggunakan data historis selama lima bulan terakhir sebagai input. Model ANN yang dibangun menggunakan arsitektur sederhana dengan satu hidden layer yang terdiri atas 100 unit neuron. Proses validasi model menggunakan algoritma optimasi Adam dengan learning rate sebesar 0,001, batch size sebanyak 8, jumlah epoch sebanyak 200, dan menggunakan MAPE Out sample terbaik tiap cluster.

1. Validasi Model Cluster Pertama

Validasi model cluster pertama dilakukan pada data pengujian dan diperoleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 10,55%. yang menunjukkan bahwa tingkat kesalahan prediksi relatif rendah dan model memiliki performa

yang cukup baik. Visualisasi hasil pemodelan dan prediksi ditampilkan pada gambar berikut.




Gambar 4.8 Perbandingan Antara Data Aktual Dan Hasil Prediksi Menggunakan Algoritma ANN Cluster Pertama

Gambar 4.8 di atas memperlihatkan perbandingan antara data aktual dan hasil prediksi menggunakan algoritma *Artificial Neural Network* (ANN) pada cluster pertama. Secara umum, model ANN mampu mengikuti pola tren permintaan dengan cukup baik, meskipun terdapat deviasi pada beberapa bulan, terutama pada Agustus dan Oktober. Prediksi cenderung mendekati nilai aktual pada bulan-bulan seperti Januari, April, Juli, dan Desember. Secara keseluruhan, model ANN ini layak digunakan untuk prediksi permintaan dengan akurasi yang cukup memadai.

2. Validasi model cluster kedua

Validasi model algoritma *Artificial Neural Network* (ANN) cluster kedua ini diterapkan untuk memprediksi jumlah permintaan jenis inner Goint di masa mendatang. Evaluasi kinerja model dilakukan terhadap data pengujian, dan diperoleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 10,78%. Nilai ini menunjukkan bahwa tingkat akurasi model berada pada kategori cukup baik dalam memproyeksikan pola permintaan. Visualisasi hasil prediksi dan perbandingannya dengan data aktual ditampilkan pada gambar berikut.



Gambar 4.9 Perbandingan Antara Data Aktual dan Hasil Prediksi Menggunakan Algoritma ANN Cluster Kedua

Gambar 4.9 Hasil validasi model ANN untuk permintaan produk Inner Goint menunjukkan bahwa model mampu mengikuti pola umum dari data aktual, terutama pada periode kenaikan tajam seperti bulan Mei dan Oktober. Beberapa titik prediksi, seperti pada Januari, Mei, dan September, memiliki nilai yang cukup dekat dengan data aktual, mencerminkan kinerja model yang baik dalam menangkap tren utama. Namun, deviasi masih terlihat pada bulan April, Agustus, dan Desember, di mana model kurang akurat dalam merespons fluktuasi mendadak. Secara keseluruhan, model ANN memberikan hasil yang cukup representatif dan dapat digunakan sebagai alat bantu prediksi permintaan

4.6 Uji Sensitivitas Model *Artificial Neural Network* (ANN)

Uji sensitivitas model prediksi dalam penelitian ini bertujuan untuk mengevaluasi stabilitas dan ketahanan model *Artificial Neural Network* (ANN) terhadap variasi kecil pada data input. Proses ini dilakukan dengan memodifikasi data permintaan aktual inner sebesar 5%, sebagai bentuk simulasi kenaikan permintaan yang mungkin terjadi di kondisi nyata. Model ANN yang digunakan merupakan konfigurasi terbaik yang sebelumnya menunjukkan performa paling optimal berdasarkan evaluasi metrik RMSE dan MAPE. Data yang telah dimodifikasi kemudian digunakan sebagai input ke dalam model tanpa dilakukan pelatihan

ulang, guna mengamati konsistensi model dalam mempertahankan tren dan akurasi prediksi terhadap perubahan data yang bersifat minor.


1. Uji Sensitivitas Model ANN *Cluster* Pertama

Uji sensitivitas model ANN *cluster* pertama dilakukan dengan cara memodifikasi data aktual permintaan inner Clack, yaitu dengan menambahkan 5% dari nilai aslinya untuk mensimulasikan potensi peningkatan permintaan di masa mendatang. Langkah ini bertujuan untuk menguji seberapa stabil dan adaptif model prediksi *Artificial Neural Network* (ANN) terhadap perubahan nilai input. Model ANN yang digunakan dalam tahap ini adalah model terbaik yang diperoleh pada konfigurasi neuron ke-3, berdasarkan evaluasi performa sebelumnya menggunakan metrik RMSE dan MAPE. Berikut tabel 4.6 yang sudah di modifikasi pada data permintaan.

Tabel 4.5 Modifikasi Data *Cluster* Pertama

Bulan	Aktual	Aktual +5%
Januari	9076	9530
Februari	8147	8554
Maret	8781	9219
April	9603	10083
Mei	8701	9136
Juni	7609	7989
Juli	9099	9554
Agustus	6908	7253
September	7146	7503
Oktober	7546	7923
November	8377	8796
Desember	9076	9530

Tabel 4.5 menyajikan data permintaan aktual bulanan dan penambahan sebesar 5% dari nilai aktual sebagai bentuk antisipasi fluktuasi permintaan. Setelah dilakukan penambahan sebesar 5% terhadap data aktual, proses uji sensitivitas dilanjutkan dengan menerapkan model *Artificial Neural Network* (ANN) terbaik yang sebelumnya diperoleh pada konfigurasi neuron ke-3.



Gambar 4.10 Uji Sensitivitas Model ANN Cluster Pertama

Gambar 4.10 menjelaskan grafik uji sensitivitas memperlihatkan perbandingan antara data aktual yang telah ditambahkan 5% dan hasil prediksi model ANN untuk inner Clack. Model ANN mampu mengikuti arah perubahan data dengan baik, menunjukkan bahwa prediksi yang dihasilkan tetap selaras dengan pola permintaan yang dimodifikasi. Nilai MAPE sebesar 10,55% memperkuat bahwa performa model tetap stabil meskipun terjadi perubahan input, sehingga ANN dinilai cukup andal dalam memproyeksikan permintaan yang berfluktuasi.


2. Uji sensitivitas model ANN Cluster Kedua

Uji sensitivitas pada model ANN cluster kedua dilakukan dengan memodifikasi data permintaan inner Goint sebesar 5% sebagai simulasi peningkatan permintaan. Tujuan dari tahap ini adalah untuk mengevaluasi stabilitas dan adaptivitas model terhadap perubahan kecil pada input data. Model yang digunakan merupakan konfigurasi terbaik dengan satu neuron tersembunyi, berdasarkan evaluasi RMSE dan MAPE sebelumnya. Hasil prediksi terhadap data yang telah dimodifikasi digunakan untuk menilai konsistensi kinerja model, sebagaimana disajikan pada Tabel 4.7.

Tabel 4.6 Modifikasi Data *Cluster Kedua*

Bulan	aktual	Aktual +5%
Januari	1446	1518
Februari	1268	1331
Maret	1450	1523
April	1388	1457
Mei	2122	2228
Juni	1883	1977
Juli	1685	1769
Agustus	1408	1478
September	1768	1856
Oktober	2248	2360
November	2198	2308
Desember	1989	2088

Tabel 4.8 tersebut menyajikan data permintaan aktual bulanan dan penambahan sebesar 5% dari nilai aktual sebagai bentuk antisipasi fluktuasi permintaan. Setelah dilakukan penambahan sebesar 5% terhadap data aktual, proses uji sensitivitas dilanjutkan dengan menerapkan model *Artificial Neural Network* (ANN) terbaik yang sebelumnya diperoleh pada konfigurasi neuron ke-1.



Gambar 4.11 Uji Sensitivitas Model ANN *Cluster Kedua*

Gambar 4.11 menjelaskan hasil uji sensitivitas terhadap inner Goint pada cluster kedua menunjukkan bahwa model ANN mampu mengikuti pola kenaikan permintaan sebesar 5% dari data aktual dengan cukup stabil. Meskipun terdapat beberapa deviasi antara garis prediksi dan data aktual modifikasi, model tetap menunjukkan tren yang konsisten pada sebagian besar bulan. Hal ini

mencerminkan bahwa konfigurasi ANN dengan nilai MAPE 10.78% yang digunakan memiliki adaptabilitas yang baik terhadap perubahan input ringan tanpa pelatihan ulang. Hasil ini memperkuat keyakinan terhadap keandalan model dalam menghadapi dinamika fluktuasi permintaan di masa mendatang.

4.7 Prediksi Permintaan Menggunakan Model Artificial Neural Network

Model *Artificial Neural Network* (ANN) yang diterapkan dalam penelitian ini dirancang berdasarkan hasil identifikasi lag signifikan yang diperoleh melalui analisis *Partial Autocorrelation Function* (PACF) terhadap data time series yang telah dinormalisasi untuk setiap kluster. Pemilihan lag sebagai variabel input pada model ANN disesuaikan dengan nilai lag yang menunjukkan korelasi parsial yang signifikan, sebagaimana ditunjukkan oleh hasil analisis PACF.

1. Prediksi Permintaan Model ANN Cluster Pertama

Tahap selanjutnya dilakukan pengamatan prediksi permintaan Inner Clack untuk satu tahun ke depan menggunakan model *Artificial Neural Network* (ANN) dengan tingkat akurasi ditunjukkan oleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 10,55%. Grafik prediksi menampilkan estimasi permintaan bulanan selama 12 bulan ke depan, yang disusun berdasarkan pola historis. Setiap titik prediksi dilengkapi dengan rentang estimasi berupa batas atas dan bawah yang dihitung berdasarkan deviasi $\pm$ MAPE, sehingga memberikan gambaran yang lebih komprehensif terhadap potensi fluktuasi permintaan. Berikut contoh perhitungan bulan januari dan februari berdasarkan rumus tersebut

$$P_n = \text{Prediksi} \pm (\text{Prediksi} \times \text{Mape})$$

Januari (n) :

$$P_{jan} = 8118 \pm (8118 \times 0,1055) = [7262, \quad 8974]$$


Februari (n) :

$$P_{feb} = 7287 \pm (7287 \times 0,1055) = [6518, \quad 8056]$$

Tabel 4.7 Prediksi Permintaan 1 TahunSelanjutnya Berdasarkan MAPE Cluster Pertama

No	Bulan	Prediksi	Prediksi MAPE (10,55 %)
1	Januari	8118	(7262, 8974)
2	Februari	7287	(6518, 8056)
3	Maret	7855	(7026, 8684)
4	April	8590	(7683, 9496)
5	Mei	7783	(6962, 8604)
6	Juni	6806	(6088, 7524)
7	Juli	8139	(7280, 8998)
8	Agustus	6179	(5527, 6831)
9	September	6392	(5718, 6465)
10	Oktober	6750	(6038, 7462)
11	November	7393	(6613, 8173)
12	Desember	8118	(7262, 8974)

Tabel 4.9 menyajikan hasil prediksi bulanan permintaan inner untuk satu tahun ke depan disertai dengan rentang estimasi berdasarkan nilai MAPE sebesar 10,55%. Prediksi tertinggi terjadi pada bulan April sebesar 8.590 unit, sementara prediksi terendah terdapat pada bulan September sebesar 6.392 unit. Setiap nilai prediksi dilengkapi dengan batas bawah dan atas untuk mengantisipasi potensi deviasi akibat ketidakpastian, yang dihitung menggunakan persentase MAPE. Rentang ini memberikan panduan estimasi yang lebih realistis, sehingga dapat membantu pengambilan keputusan dalam perencanaan persediaan dan manajemen permintaan yang lebih adaptif. Berikut visualisasi grafik 1 tahun kedepan pada gambar di bawah ini.



Gambar 4.12 Visualisasi Grafik Prediksi 12 Bulan Pada Cluster Pertama

Gambar 4.13 menunjukkan visualisasi grafik prediksi permintaan komponen Inner Clack pada tahun 2025 berdasarkan pola historis menggunakan model *Artificial Neural Network* (ANN) dengan tingkat akurasi MAPE sebesar 10,55%. Garis putus-putus berwarna oranye menggambarkan estimasi jumlah permintaan tiap bulan, sedangkan area berwarna oranye muda di sekeliling garis tersebut menunjukkan rentang ketidakpastian (batas atas dan bawah prediksi) sesuai nilai MAPE

2. Prediksi Permintaan model Cluster Kedua

Tahap selanjutnya dilakukan pengamatan prediksi permintaan Inner Goint untuk satu tahun ke depan menggunakan model *Artificial Neural Network* (ANN) dengan tingkat akurasi ditunjukkan oleh nilai *Mean Absolute Percentage Error* (MAPE) sebesar 10,78%. Grafik prediksi menampilkan estimasi permintaan bulanan selama 12 bulan ke depan, yang disusun berdasarkan pola historis. Setiap titik prediksi dilengkapi dengan rentang estimasi berupa batas atas dan bawah yang dihitung berdasarkan deviasi $\pm$ MAPE, sehingga memberikan gambaran yang lebih komprehensif terhadap potensi fluktuasi permintaan. Berikut contoh perhitungan bulan januari dan februari berdasarkan rumus tersebut

$$P_n = \text{Prediksi} \pm (\text{Prediksi} \times \text{Mape})$$

Januari (n) :

$$P_{jan} = 1305 \pm (1305 \times 0,1078) = [1164, \quad 1446]$$

Februari (n) :

$$P_{feb} = 1145 \pm (1145 \times 0,1078) = [1022, \quad 1268]$$

Tabel 4.8 Prediksi Permintaan 1 Tahun Selanjutnya Berdasarkan MAPE Cluster Kedua

No	Bulan	Prediksi	Prediksi MAPE (10,78 %)
1	Januari	1305	(1164, 1446)
2	Februari	1145	(1022, 1268)
3	Maret	1309	(1168, 1450)
4	April	1253	(1178, 1388)
5	Mei	1916	(1709, 2123)
6	Juni	1700	(1517, 1883)

Tabel 4.8 Prediksi Permintaan 1 Tahun Selanjutnya Berdasarkan MAPE Cluster Kedua (lanjutan)

No	Bulan	Prediksi	Prediksi MAPE (10,78 %)
7	Juli	1521	(1357, 1685)
8	Agustus	1271	(1134, 1408)
9	September	1596	(1424, 1768)
10	Oktober	2029	(1810, 2248)
11	November	1983	(1769, 2197)
12	Desember	1795	(1601, 1988)

Tabel 4.10 menyajikan hasil prediksi permintaan bulanan komponen Inner Goint untuk tahun 2025 menggunakan model ANN, dengan tingkat akurasi ditunjukkan oleh nilai MAPE sebesar 10,78%. Prediksi permintaan tertinggi terjadi pada bulan Oktober sebesar 2.029 unit, sementara yang terendah terdapat pada bulan Februari sebesar 1.145 unit. Setiap prediksi dilengkapi dengan rentang kepercayaan berupa batas bawah dan atas estimasi, yang dihitung berdasarkan deviasi $\pm 10,78\%$ dari nilai prediksi. Rentang ini mencerminkan tingkat ketidakpastian yang wajar dalam estimasi dan dapat menjadi acuan penting dalam perencanaan kebutuhan dan pengelolaan persediaan yang lebih akurat. Berikut visualisasi grafik 1 tahun kedepan pada gambar di bawah ini.



Gambar 4.13 Visualisasi Grafik Prediksi 12 Bulan Pada Cluster Kedua

Gambar 4.14 menunjukkan visualisasi grafik prediksi permintaan komponen Inner Goint pada tahun 2025 berdasarkan pola historis menggunakan model *Artificial Neural Network* (ANN) dengan tingkat akurasi MAPE sebesar 10,78%. Garis putus-putus berwarna oranye menggambarkan estimasi jumlah permintaan

tiap bulan, sedangkan area berwarna oranye muda di sekeliling garis tersebut menunjukkan rentang ketidakpastian (batas atas dan bawah prediksi) sesuai nilai MAPE.

4.8 Analisis Safety Stok

Setelah proses pemodelan permintaan menggunakan algoritma *Artificial Neural Network* (ANN) diselesaikan, tahap selanjutnya adalah melakukan perhitungan *safety stock* sebagai bagian dari strategi pengendalian persediaan.

1. Analisa Safety Stok Cluster Pertama

Safety stock atau persediaan pengaman dalam penelitian ini dimanfaatkan sebagai cadangan stok yang berfungsi untuk mengantisipasi ketidakpastian permintaan serta meminimalkan risiko terjadinya kekurangan persediaan di gudang. Perhitungan safety stock dilakukan secara kuantitatif berdasarkan hasil prediksi permintaan yang dihasilkan oleh model *Artificial Neural Network* (ANN) terbaik, dengan tingkat akurasi ditunjukkan melalui nilai *Mean Absolute Percentage Error* (MAPE) out-sample sebesar 10,55%. Berikut contoh perhitungan safety stok dan total stok yang disarankan untuk persediaan Gudang dalam 2 bulan selanjutnya :

Rumus *Safety Stok*

$$SS = P \times MAPE \times Z$$

Rumus Total Stok

$$Total\ Stok = Prediksi + Safety\ stok$$

Bulan Januari

$$SS = 8118 \times 0,1055 \times 1.75 = 1499$$

$$Total\ Stok = 8118 + 1499 = 9617$$

Bulan Februari

$$SS = 7287 \times 0,1055 \times 1.75 = 1345$$

$$Total\ Stok = 7287 + 1345 = 8632$$

Jadi diketahui safety stok pada 2 bulan selanjutnya, ialah 1499 pcs (bulan januari) dan 1345 pcs (bulan februari). Selain itu, total stok 2 bulan selanjutnya dengan hasil bulan januari 9615 pcs dan bulan februari 8632 pcs. Hasil ini sebagai dasar pengambilan keputusan dalam pengelolaan stok gudang secara efisien dan adaptif.

Tabel 4.9 Safety Stok Dan Total Stok Yang Disarankan Cluster Pertama

No	Bulan	Prediksi ANN	Safety Stock (pcs)	Total Stok Disarankan
1	Januari	8118	1499	9617
2	Februari	7287	1345	8632
3	Maret	7855	1450	9305
4	April	8590	1586	10176
5	Mei	7783	1437	9220
6	Juni	6806	1257	8063
7	Juli	8139	1503	9642
8	Agustus	6179	1141	7320
9	September	6392	1180	7572
10	Oktober	6750	1246	7996
11	November	7393	1365	8758
12	Desember	8118	1499	9617

Tabel 4.9 menunjukkan hasil prediksi kebutuhan bulanan Inner Clack tahun 2025 menggunakan model ANN yang dilengkapi dengan perhitungan *safety stock* untuk menentukan total stok yang disarankan. Setiap bulan memiliki jumlah *safety stock* yang bervariasi, disesuaikan dengan prediksi permintaan dan tingkat ketidakpastian. Nilai stok tertinggi disarankan pada bulan April sebesar 10.176 pcs, sedangkan yang terendah terdapat pada bulan September sebesar 7.572 pcs. Hasil ini dapat digunakan sebagai dasar perencanaan pengadaan dan pengelolaan persediaan yang lebih optimal.

2. Analisa Safety Stok Cluster Kedua

Safety stock atau persediaan pengaman dalam penelitian ini dimanfaatkan sebagai cadangan stok yang berfungsi untuk mengantisipasi ketidakpastian permintaan serta meminimalkan risiko terjadinya kekurangan persediaan di gudang. Perhitungan *safety stock* dilakukan secara kuantitatif berdasarkan hasil prediksi permintaan yang dihasilkan oleh model *Artificial Neural Network* (ANN) terbaik,

dengan tingkat akurasi ditunjukkan melalui nilai *Mean Absolute Percentage Error* (MAPE) out-sample sebesar 10,78%. Adapun hasil perhitungan *safety stock* serta total persediaan yang disarankan untuk dua bulan ke depan disajikan sebagai dasar pengambilan keputusan dalam pengelolaan stok gudang secara efisien dan adaptif.

Rumus *Safety stock*

$$SS = P \times MAPE \times Z$$

Rumus total stok

$$Total\ Stok = Prediksi + Safety\ stok$$

- Bulan Januari

$$SS = 1305 \times 0,1078 \times 1.75 = 246,19$$

$$Total\ Stok = 1305 + 246 = 1551$$

- Bulan Februari

$$SS = 1145 \times 0,1078 \times 1.75 = 216$$

$$Total\ Stok = 1145 + 216 = 1361$$

Hasil diketahui *safety stock* pada 2 bulan selanjutnya, ialah 343 pcs (bulan januari) dan 366 pcs (bulan februari). Selain itu, total stok 2 bulan selanjutnya dengan hasil bulan januari 1639 pcs dan bulan februari 2423 pcs.

Tabel 4.10 *Safety Stock* Dan Total Stok Yang Disarankan Cluster Kedua

No	Bulan	Prediksi ANN	Safety Stock (unit)	Total Stok Disarankan
1	Januari	1305	246	1551
2	Februari	1145	216	1361
3	Maret	1309	247	1556
4	April	1253	236	1489
5	Mei	1916	361	2277
6	Juni	1700	321	2021
7	Juli	1521	287	1808
8	Agustus	1271	240	1511
9	September	1596	301	1897
10	Oktober	2029	383	2412
11	November	1983	374	2357
12	Desember	1795	339	2134

Tabel 4.10 menunjukkan hasil prediksi kebutuhan bulanan Inner Goint tahun 2025 menggunakan model ANN yang dilengkapi dengan perhitungan safety stock untuk menentukan total stok yang disarankan. Setiap bulan memiliki jumlah safety stock yang bervariasi, disesuaikan dengan prediksi permintaan dan tingkat ketidakpastian. Nilai stok tertinggi disarankan pada bulan Oktober sebesar 2412 pcs, sedangkan yang terendah terdapat pada bulan Februari sebesar 1361 pcs. Hasil ini dapat digunakan sebagai dasar perencanaan pengadaan dan pengelolaan persediaan yang lebih optimal..

BAB V

PENUTUP

5.1 Kesimpulan

Dari penelitian tentang *Artificial neural network* dengan klasterisasi data *time series* untuk optimalisasi *safety stock* dan prediksi persediaan gudang, diperoleh hasil sebagai berikut:

1. Penelitian ini menunjukkan bahwa penerapan model *Artificial neural network* (ANN) sangat efektif dan mampu menghasilkan prediksi permintaan gudang dengan tingkat akurasi yang tinggi. Hasil evaluasi model menggunakan *Mean Absolute Percentage Error* (MAPE) pada data out-sample menunjukkan bahwa ANN mampu mencapai akurasi prediksi terbaik dengan nilai MAPE sebesar 10,55% pada cluster pertama dan 10,78% pada cluster kedua.
2. Implementasi klasterisasi terhadap data permintaan bulanan berhasil membedakan pola permintaan berdasarkan jenis produk (Inner Clack dan Inner Goint). Proses ini membantu mengurangi keberagaman data dan memungkinkan model ANN dilatih secara lebih fokus pada masing-masing klaster. Hasil prediksi pada masing-masing klaster menunjukkan adanya perbedaan karakteristik pola permintaan, yang jika dianalisis secara terpisah dapat meningkatkan ketepatan model prediksi.
3. Perhitungan *safety stock* yang dilakukan berdasarkan hasil prediksi model ANN dan nilai akurasi (MAPE) menghasilkan stok pengaman yang adaptif terhadap ketidakpastian permintaan. Melalui pendekatan ini, diperoleh total stok disarankan yang mampu meminimalkan risiko kehabisan stok (*stockout*) maupun kelebihan stok (*overstock*), sekaligus meningkatkan efisiensi dalam pengelolaan persediaan gudang.

5.2 Saran

Berdasarkan hasil penelitian dan pengembangan *Artificial neural network* dengan klasterisasi data *time series* untuk optimalisasi *safety stock* dan prediksi persediaan gudang, beberapa saran berikut dapat dipertimbangkan untuk pengembangan lebih lanjut dan aplikasi praktis:

1. Pengembangan model prediksi dapat ditingkatkan dengan menambahkan variabel eksternal seperti tren penjualan, musim, promosi, atau faktor logistik yang mungkin memengaruhi permintaan. Integrasi variabel-variabel ini ke dalam model ANN berpotensi meningkatkan akurasi prediksi.
2. Implementasi sistem prediksi dan *safety stock* secara real-time disarankan agar hasil penelitian ini dapat diterapkan langsung dalam proses pengambilan keputusan manajemen gudang. Penggunaan dashboard visual dan sistem monitoring otomatis berbasis data historis dan aktual akan sangat membantu efisiensi operasional.

DAFTAR PUSTAKA

- Anggraeni, D. P. (2024). Optimisation of Inventory Management Through Time Series Analysis of Inventory Data with Double Exponential Smoothing Method. *Journal of Computer Networks, Architecture and High Performance Computing*, 6(3), 1693–1700. <https://doi.org/10.47709/cnahpc.v6i3.4410>
- Anggraeni, D. P. (2024). *Optimisation of inventory management through time series analysis of inventory data with double exponential smoothing method*. *Jurnal Manajemen Operasi dan Logistik*, 9(1), 55–62.
- Ckristina Nainggolan, & Fitri Boy. (2023). *Penerapan Machine Learning dalam Pengelolaan Data Produk Variatif pada Industri Manufaktur*. *Jurnal Teknologi dan Industri*, 15(2), 88–97.
- Deng, J., Wang, H., & Li, Y. (2021). *Inventory challenges in manufacturing supply chains: A strategic review*. *International Journal of Production Economics*, 234, 107989. <https://doi.org/10.1016/j.ijpe.2021.107989>
- Gopal, R. (2024). *Artificial intelligence in supply chain planning: A data-driven approach*. New York: Springer Nature.
- Hanny Setyaningrum, Prasetyo, B., & Andriyani, T. (2025). *Inventory optimization model using artificial neural network method and continuous review (s,Q)*. *Procedia Computer Science*, 219, 512–519.
- Kilborn, J. P., Jones, D. L., Peebles, E. B., & Naar, D. F. (2017). Resemblance profiles as clustering decision criteria: Estimating statistical power, error, and correspondence for a hypothesis test for multivariate structure. *Ecology and Evolution*, 7(7), 2039–2057. <https://doi.org/10.1002/ece3.2760>
- Kilborn, L., Zhang, W., & Miller, T. (2017). *Time series clustering for supply chain data*. *Journal of Forecasting*, 36(4), 487–500.
- Mahya Seyedan, Johnson, R., & Kiani, R. (2023). *Order up to level inventory optimization model using time series demand forecasting with ensemble deep learning*. *Computers & Industrial Engineering*, 177, 108970.
- Moroff, J., Lin, Y., & Sharma, K. (2021). *Strategic warehouse inventory planning and its impact on manufacturing efficiency*. *International Journal of Logistics Systems and Management*, 40(3), 273–289.
- Muhammad Miftah Arzaq Rahmansyah, & Tedjo Sukmono. (2024). *Implementation of fuzzy inventory method and artificial neural network in*

- determining safety inventory of bag products*. Journal of Intelligent Systems, 18(1), 33–45.
- Namir, M., Hossain, A., & Latief, R. (2021). *Inventory optimization in multi-echelon supply chain systems*. Journal of Supply Chain Management, 57(2), 114–126.
- Nasution, R., Yuniarti, D., & Ismail, M. (2022). *Optimalisasi safety stock dalam manajemen rantai pasok manufaktur*. Jurnal Teknik Industri, 20(1), 14–22.
- Passalis, N., Tefas, A., & Pitas, I. (2020). *Improved min–max normalization techniques for deep learning and time series forecasting*. IEEE Transactions on Neural Networks and Learning Systems, 31(10), 4200–4211.
- Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2020). *Adaptive Normalization For Forecasting Limit Order Book Data Using Convolutional Neural Networks* Faculty of Information Technology and Communication , Tampere University , Finland Department of Informatics , Aristotle University of Thessaloniki , Greece D. *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 1713–1717.
- Prathyusha, C., & Reddy, R. S. (2021). *Normalization techniques in deep neural network-based forecasting models*. International Journal of Computational Intelligence Systems, 14(3), 509–518.
- Prathyusha, K. S., & Reddy, B. E. (2021). *Normalization methods for multiple sources of data*. *Proceedings - 5th International Conference on Intelligent Computing and Control Systems, ICICCS 2021, Iccics*, 1013–1019. <https://doi.org/10.1109/ICICCS51141.2021.9432142>
- Rizkiawan, A., Fadillah, R., & Munir, H. (2023). *Implementasi artificial intelligence dalam manajemen rantai pasok industri manufaktur di Indonesia*. Jurnal Teknologi dan Rekayasa Industri, 11(2), 97–108.
- Sabharwal, P., Bhattacharya, A., & Singh, R. (2024). *Clustering-based time series analysis for improved inventory forecasting*. Expert Systems with Applications, 235, 120135.
- Sanket, A., Sinha, S., Mandagiri, Y., & Chikop, D. S. A. (2024). *Sales Forecasting and Inventory Optimization at Big Mart using Time Series Technique: A Survey*. *Iarjset*, 11(6), 306–314. <https://doi.org/10.17148/iarjset.2024.11643>

Sumekar, A., Erlina, E., Br. Bukit, R., & Situmeang, C. (2022). Meningkatkan Kinerja Perusahaan Logistik Dengan Pendekatan Pengendalian Operasional. *Prosiding Fakultas Ekonomi Dan Bisnis Universitas Dharmawangsa*, 1(1), 9–14. <https://doi.org/10.46576/prosfeb.v1i1.31>

DAFTAR LAMPIRAN

Lampiran 1. Bukti submit jurnal

