

## Purchasing Prediction Using Machine Learning Algorithms for Optimizing Inventory Management

Reza Hamdi Prayetno<sup>1)</sup>, Rani Destika Purba<sup>2)</sup>, Kyrene Wirawan<sup>3)</sup>, Kelvin Sweet<sup>4)</sup>, Evta Indra<sup>5\*)</sup>

<sup>1)2)3)4)5)</sup> Prodi Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Prima Indonesia

<sup>\*)</sup>Correspondence author: [evtaindra@unprimdn.ac.id](mailto:evtaindra@unprimdn.ac.id), Medan, Indonesia

DOI: <https://doi.org/10.37012/jtik.v11i1.2522>

### Abstract

Effective inventory management is a crucial element in company operations, especially in maintaining a balance between demand and supply. Good inventory management can reduce storage costs, increase product availability, and maximize company profits. However, the challenges that companies often face are the uncertainty of market demand and changes in trends that are difficult to predict. Along with technological developments, traditional methods of inventory management are starting to be replaced by data-based approaches and machine learning algorithms. The use of machine learning is not only limited to predicting purchasing needs, but can also be applied in various other business aspects. This research aims to optimize HP spare parts inventory management at Store X using the Long Short-Term Memory (LSTM) method. By analyzing sales data for 2023 which consists of 96,630 lines, the research applies systematic stages: data acquisition, preprocessing, exploratory data analysis, model building, and evaluation. The LSTM method is used to predict spare parts stock with significant accuracy, demonstrated through evaluation metrics: Mean Absolute Error (MAE) 12%, Mean Squared Error (MSE) 2%, and Root Mean Square Error (RMSE) 15%. The model successfully captured seasonal patterns and trends in sales data, proving its ability to forecast stock requirements. The research results show that the LSTM-based machine learning approach is effective in supporting inventory management decision making, helps reduce the risk of losses due to stock uncertainty, and increases the efficiency of managing HP spare parts inventory.

**Keywords:** Long Short-Term Memory, Inventory Management, Stock Prediction, Machine Learning

### Abstrak

Manajemen *inventory* yang efektif merupakan salah satu elemen krusial dalam operasional perusahaan, terutama dalam menjaga keseimbangan antara permintaan dan persediaan. Pengelolaan *inventory* yang baik mampu mengurangi biaya penyimpanan, meningkatkan ketersediaan produk, serta memaksimalkan laba perusahaan. Namun, tantangan yang sering dihadapi oleh perusahaan adalah ketidakpastian permintaan pasar dan perubahan *tren* yang sulit diprediksi. Seiring dengan perkembangan teknologi, metode tradisional dalam manajemen *inventory* mulai tergantikan oleh pendekatan berbasis data dan algoritma *machine learning*. Penggunaan *machine learning* tidak hanya terbatas pada prediksi kebutuhan *purchasing*, tetapi juga dapat diterapkan dalam berbagai aspek bisnis lainnya. Penelitian ini bertujuan mengoptimalkan manajemen *inventory sparepart* HP di Toko X menggunakan metode Long Short-Term Memory (LSTM). Dengan menganalisis data penjualan tahun 2023 yang terdiri dari 96.630 baris, penelitian menerapkan tahapan sistematis: akuisisi data, *preprocessing*, analisis *exploratory* data, pembangunan model, dan evaluasi. Metode LSTM digunakan untuk memprediksi stok *sparepart* dengan akurasi yang signifikan, ditunjukkan melalui metrik evaluasi: Mean Absolute Error (MAE) 12%, Mean Squared Error (MSE) 2%, dan Root Mean Square Error (RMSE) 15%.

---

Model berhasil menangkap pola musiman dan *tren* data penjualan, membuktikan kemampuannya dalam meramalkan kebutuhan stok. Hasil penelitian menunjukkan bahwa pendekatan *machine learning* berbasis LSTM efektif dalam mendukung pengambilan keputusan manajemen *inventory*, membantu mengurangi risiko kerugian akibat ketidakpastian stok, dan meningkatkan efisiensi pengelolaan persediaan *sparepart* HP.

**Kata Kunci:** Long Short-Term Memory, Manajemen Inventory, Prediksi Stok, Machine Learning

## PENDAHULUAN

Manajemen *inventory* yang efektif merupakan salah satu elemen krusial dalam operasional perusahaan, terutama dalam menjaga keseimbangan antara permintaan dan persediaan. Pengelolaan *inventory* yang baik mampu mengurangi biaya penyimpanan, meningkatkan ketersediaan produk, serta memaksimalkan laba perusahaan (Tamami & Arifin, 2024). Namun, tantangan yang sering dihadapi oleh perusahaan adalah ketidakpastian permintaan pasar dan perubahan *tren* yang sulit diprediksi (Radite Putra & Hendry, 2022). Oleh karena itu, prediksi kebutuhan *purchasing* yang akurat menjadi penting untuk optimalisasi manajemen *inventory*.

Seiring dengan perkembangan teknologi, metode tradisional dalam manajemen *inventory* mulai tergantikan oleh pendekatan berbasis data dan algoritma *machine learning*. *Machine Learning* (ML) adalah aplikasi kecerdasan buatan yang membuat sistem memiliki kemampuan belajar yang berjalan secara otomatis kemudian dapat meningkatkan kemampuannya berdasarkan pengalaman tanpa deprogram secara *eksplisit*. Menurut ilustrasi yang terdapat pada situs [ibm.com](https://www.ibm.com), ML merupakan salah satu sub bagian dari *Artificial Intelligence* (AI), pendekatannya berupa mempelajari pola dari data yang kemudian diingat dalam memori dalam bentuk model, dan model tersebut digunakan untuk memprediksi data yang baru (Nugraha & Mahendra, 2023). Oleh karena itu untuk membuat model *machine learning* diperlukan dataset yang dijadikan proses *training*, serta dataset yang dijadikan contoh bahan uji untuk menghitung seberapa akurat model tersebut. Contoh penerapan ML yang sekarang sudah banyak adalah model pendeteksian penyakit jantung, alat prediksi cuaca, sistem untuk memprediksi jumlah pelanggan dan masih banyak lagi (Nurchayyo et al., 2024). Penggunaan *machine learning* tidak hanya terbatas pada prediksi kebutuhan *purchasing*, tetapi juga dapat diterapkan dalam berbagai aspek bisnis lainnya (Setiawan & Lestari, 2021).

Menyoroti penggunaan berbagai model pembelajaran mesin untuk memprediksi pendapatan bagi perusahaan teknologi India, menekankan pentingnya peramalan yang akurat dalam meningkatkan pengambilan keputusan keuangan.

Penelitian yang membahas analisis prediksi menggunakan metode *Long Short-Term Memory* (LSTM) telah banyak dilakukan sebelumnya namun dengan *case* yang berbeda, penelitian tersebut sebagai berikut:

1. *Peramalan Produksi Pertanian Menggunakan Model Long Short-Term Memory* (Mukhlis et al., 2021).
2. *Comparative Analysis Of Machine Learning Algorithms For Forecasting Of Basic Goods Products* (Avinash et al., 2024).
3. *Prediksi Penjualan Obat Herbal Hp Pro Menggunakan Algoritma Neural Network* (Wibowo, 2018).
4. *Prediksi Penjualan Produk Untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA* (E. S. Putri & Sadikin, 2021).

Berdasarkan latar belakang di atas, penulis tertarik untuk membuat penelitian dengan judul “*Prediksi Kebutuhan Purchasing Menggunakan Algoritma Machine Learning untuk Optimalisasi Manajemen Inventory*”. Dalam penelitian ini, data historis mengenai penjualan, persediaan, dan variabel terkait lainnya akan dianalisis menggunakan model LSTM (*Long Short Term Memory*) yang dikembangkan, sehingga memberikan estimasi kebutuhan *purchasing* yang akurat dan dapat membantu dalam mengoptimalkan manajemen *inventory* mereka (Afrizal et al., 2023). Dengan demikian, perusahaan dapat lebih proaktif dalam merespons perubahan permintaan pasar, mengurangi biaya operasional, dan meningkatkan kepuasan pelanggan. Manajemen strategis yang efektif sangat penting untuk menavigasi kompleksitas lingkungan bisnis yang berubah dengan cepat, memungkinkan perusahaan untuk mengantisipasi dan menanggapi perubahan preferensi konsumen dan kondisi pasar.

---

## METODE

### Analisa Metode

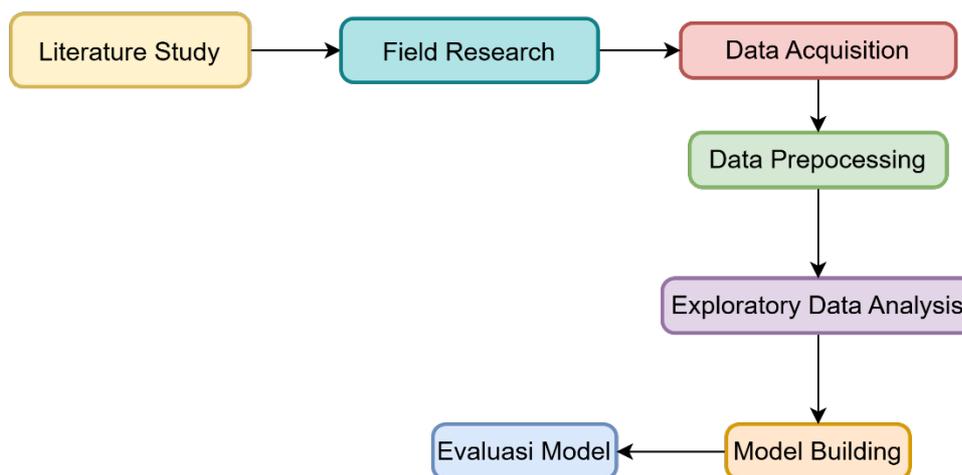
Prediksi merupakan teknik proyeksi nilai masa depan berdasarkan analisis data historis dan *tren* yang ada. Metode ini menggunakan pendekatan statistik, matematis, atau pembelajaran mesin untuk mengidentifikasi pola dan hubungan dalam dataset sebelumnya. Tujuan utamanya adalah mendukung pengambilan keputusan strategis dengan memberikan estimasi yang akurat.

Melalui pemahaman pola masa lalu, prediksi memungkinkan pembuatan keputusan yang lebih terarah dalam berbagai bidang seperti manajemen produksi, persediaan, dan keuangan. Ia menjadi instrumen kunci dalam berbagai disiplin ilmu, mulai dari ekonomi hingga sains terapan. *Long Short-Term Memory* (LSTM) merupakan teknik kecerdasan buatan canggih untuk menganalisis data berurutan, khususnya data deret waktu. Metode ini dirancang untuk mengatasi keterbatasan jaringan saraf tiruan konvensional dalam memproses informasi jarak jauh. Setiap unit LSTM memiliki mekanisme matematika unik yang memungkinkannya menyimpan dan mengontrol informasi dalam jangka panjang. Kemampuan ini membuatnya sangat efektif dalam menangkap pola kompleks pada dataset.

Dengan kemampuan belajar dari masa lalu, LSTM telah menjadi metode prediktif terkemuka dalam berbagai aplikasi seperti pengenalan wicara, prediksi harga saham, dan peramalan cuaca.

### Tahapan Penelitian

Dalam melakukan penelitian menggunakan metode *Long Short-Term Memory* dalam memprediksi atau peramalan stok barang di toko X, peneliti melakukan beberapa tahapan sebelum melakukan penelitian, tahapan tersebut dapat dilihat pada gambar *flowchart* 1 berikut:



**Gambar 1.** *Flowchart* Alur Penelitian

### 1. *Literature Study*

*Literature study* merupakan *investigasi* sistematis peneliti terhadap karya akademis yang terkait dengan topik penelitian mereka (Firmansyah & Dede, 2022). Proses ini bertujuan mengeksplorasi pengetahuan yang telah ada, melakukan evaluasi kritis terhadap penelitian sebelumnya, menemukan kesenjangan pengetahuan, dan mengumpulkan wawasan yang mendukung penelitian yang sedang berlangsung (Susanto et al., 2024). Dalam konteks penelitian ini, *literature study* difokuskan pada pengumpulan dan analisis referensi yang berkaitan dengan metode *Long Short-Term Memory* (LSTM), dengan tujuan membangun landasan teoritis yang kuat untuk penelitian yang dilakukan.

### 2. *Field Research*

*Field research* adalah metode pengumpulan data yang dilakukan langsung di lokasi terjadinya fenomena penelitian. Tujuannya adalah memperoleh pemahaman *komprehensif* melalui observasi langsung, berinteraksi dengan subjek penelitian, dan mengumpulkan data primer dari sumbernya secara alamiah (Rustamana et al., 2024). Pendekatan ini memungkinkan peneliti mendapatkan informasi mendalam dan kontekstual tentang objek yang sedang diteliti.

### 3. Data Acquisition

Data *acquisition* adalah proses sistematis untuk mengumpulkan data dari berbagai sumber yang memiliki relevansi dengan tujuan spesifik penelitian atau analisis yang sedang dilakukan, dengan fokus pada pengambilan informasi yang akurat dan tepat guna (Liu et al., 2022). Pada penelitian ini data diperoleh dari toko X yang merupakan data stok barang *sparepart* hp di tahun 2023, data tersebut memiliki jumlah data sebanyak 5 kolom dan 96630 baris, yang dapat dilihat pada gambar 2 berikut:

	Waktu Pesanan Dibuat	Status Pesanan	Total Harga Produk	Harga Setelah Diskon	Jumlah
0	2023-01-01 22:36	Selesai	4.500	4.5	1
1	2023-01-01 22:36	Selesai	150.000	150.0	1
2	2023-01-01 22:57	Selesai	130.000	130.0	1
3	2023-01-01 22:57	Selesai	55.000	55.0	1
4	2023-01-01 23:02	Selesai	180.000	180.0	1
...	...	...	...	...	...
96625	2023-12-30 18:59	Selesai	137.000	137.0	1
96626	2023-12-30 19:00	Batal	108.000	108.0	1
96627	2023-12-30 19:09	Selesai	7.500	7.5	1
96628	2023-12-30 19:09	Selesai	55.000	55.0	1
96629	2023-12-30 19:11	Selesai	110.000	110.0	1

96630 rows x 5 columns

**Gambar 2.** Dataset Sparepart Hp Toko X

### 4. Data Preprocessing

Data *preprocessing* adalah langkah awal yang penting dalam analisis data atau *machine learning*, bertujuan untuk mempersiapkan data mentah agar siap digunakan melalui proses seperti pembersihan, transformasi, pengintegrasian, dan pengurangan data. Tahapan ini melibatkan penghapusan *noise*, menangani nilai yang hilang, normalisasi, *encoding* data kategori, serta pembagian dataset menjadi bagian pelatihan dan pengujian (Jalil et al., 2024). Dengan memastikan data berkualitas tinggi dan sesuai dengan kebutuhan algoritma, data *preprocessing* membantu meningkatkan akurasi model, mengurangi *error*, dan mempermudah analisis atau visualisasi data

### 5. Exploratory Data Analysis

*Exploratory Data Analysis* (EDA) merupakan tahap analisis awal untuk mengeksplorasi karakteristik, pola, dan hubungan dalam dataset secara sistematis. Metode ini bertujuan

menghasilkan wawasan mendalam tentang struktur data, mengidentifikasi pola tersembunyi, serta mendeteksi potensi anomali yang ada dalam kumpulan data (M. Putri & Vaoutama, 2024).

#### 6. Model *Building*

Model *Building* merupakan proses membangun representasi abstrak atau simulasi dari suatu sistem nyata untuk menganalisis, memahami, atau memprediksi perilakunya. Dalam statistik dan analisis data, ini mencakup pengembangan hubungan antara variabel menggunakan metode matematis. Di bidang kecerdasan buatan, Model *Building* melibatkan pemilihan algoritma, pelatihan, dan pengujian model guna mempelajari pola dari data (Rachim et al., 2024). Sementara itu, dalam teknik dan simulasi, proses ini digunakan untuk menciptakan model fisik atau digital suatu sistem, seperti mekanik atau kimia. Dalam bisnis, Model *Building* berfungsi sebagai alat konseptual untuk mendukung pengambilan keputusan, seperti analisis risiko atau peramalan.

#### 7. Evaluasi Model

Evaluasi model merupakan proses untuk menilai kinerja suatu model, baik dalam pembelajaran mesin, manajemen, pendidikan, maupun penelitian ilmiah, guna memastikan model tersebut efektif mencapai tujuan yang diharapkan. Dalam pembelajaran mesin, evaluasi dilakukan dengan metrik seperti akurasi atau F1-score, sedangkan di manajemen, model dievaluasi berdasarkan efisiensi dan kesesuaiannya dengan kebutuhan organisasi. Dalam pendidikan, evaluasi berfokus pada efektivitas metode pembelajaran terhadap hasil yang dicapai siswa, sementara dalam penelitian ilmiah, validitas dan generalisasi model diuji dengan data empiris (Wardani et al., 2022).

## HASIL DAN PEMBAHASAN

### Analisis Masalah Penelitian

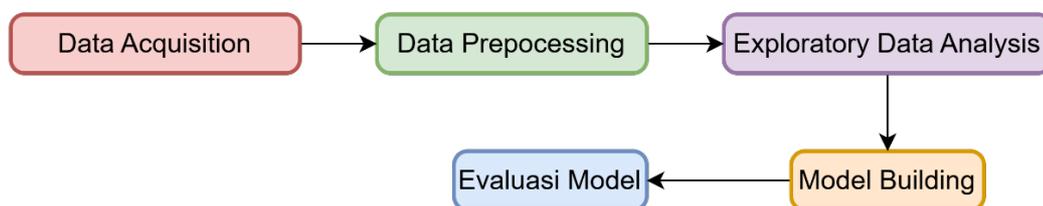
*Time series* adalah sekumpulan data yang dihasilkan dari pengukuran berulang yang dilakukan secara berurutan dalam kurun waktu tertentu. Data deret waktu sering kali dimanfaatkan untuk memanfaatkan pola dan tren yang sudah ada sebelumnya saat membuat prediksi. Pada studi kasus ini peneliti menggunakan tren dan pola pada kolom *Waktu*

<https://journal.thamrin.ac.id/index.php/jtik/article/view/2522/2352>

*Pesanan Dibuat, Status Pesanan, Total Harga Produk, Harga Setelah Diskon, Jumlah.* Perkiraan analisis tidak selalu harus 100% benar. Oleh karena itu, penting untuk menghasilkan prediksi yang sedekat mungkin dengan kondisi yang sebenarnya. Dalam penelitian ini, metode peramalan yang digunakan untuk mengatasi permasalahan tersebut adalah *Long Short-Term Memory (LSTM)*. Metode ini berfokus pada pengolahan data secara berurutan dan mampu menangani peramalan dalam jangka panjang dengan menyediakan informasi yang relevan. Penelitian ini bertujuan untuk meramalkan atau memprediksi stok *sparepart* hp toko x menggunakan metode LSTM. Hasil akhir dari penelitian yang dilakukan oleh peneliti diharapkan mampu memberikan manfaat yang berarti dalam kemajuan *Business Intelligence*, sehingga secara efektif mampu meningkatkan efisiensi penanganan stok *sparepart* hp serta mengurangi risiko kerugian dalam menumpuknya barang yang tidak terjual.

### Tahapan Pengolahan Data

Pada tahapan ini alur pengolahan data dapat dilihat pada gambar 3, yang dimana tahapan tersebut dimulai dari *Data Acquisition, Data Preprocessing, Exploratory Data Analysis, Model Building, Model Evaluasi*.



**Gambar 3.** *Flowchart* Pengolahan Data

### Data Acquisition

Pada tahapan *Data Acquisition* adalah untuk mengumpulkan informasi yang diperlukan untuk penelitian. Pada penelitian ini dataset yang diperoleh dari toko x yang berupa data *sparepart* pada tahun 2023, dimana data tersebut memiliki 5 kolom dan 96630 baris, yang dapat dilihat pada gambar berikut:

	Waktu Pesanan Dibuat	Status Pesanan	Total Harga Produk	Harga Setelah Diskon	Jumlah
0	2023-01-01 22:36	Selesai	4.500	4.5	1
1	2023-01-01 22:36	Selesai	150.000	150.0	1
2	2023-01-01 22:57	Selesai	130.000	130.0	1
3	2023-01-01 22:57	Selesai	55.000	55.0	1
4	2023-01-01 23:02	Selesai	180.000	180.0	1
...	...	...	...	...	...
96625	2023-12-30 18:59	Selesai	137.000	137.0	1
96626	2023-12-30 19:00	Batal	108.000	108.0	1
96627	2023-12-30 19:09	Selesai	7.500	7.5	1
96628	2023-12-30 19:09	Selesai	55.000	55.0	1
96629	2023-12-30 19:11	Selesai	110.000	110.0	1

96630 rows x 5 columns

**Gambar 4.** *Dataset Sparepart Toko X*

### Data Preprocessing

Pada tahapan data *preprocessing* bertujuan untuk membersihkan dataset dari data kosong atau nan, serta mengubah tipe data yang sesuai untuk digunakan model, tahapan ini memiliki peranan penting dalam pengolahan *machine learning* yang dapat meningkatkan kualitas dari dataset. Tahapan yang dilakukan sebagai berikut:

#### 1. Change Data Type

*Change Data Type* adalah proses mengubah tipe data pada kolom dataset dimana dataset tersebut bertipe data objek diubah menjadi tipe data yang dapat dikenali model dan *machine learning*. Proses tersebut dapat dilihat pada gambar berikut:

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 96630 entries, 0 to 96629
Data columns (total 5 columns):
#   Column                Non-Null Count  Dtype
---  ---                -
0   Waktu Pesanan Dibuat  96630 non-null  datetime64[ns]
1   Status Pesanan        96630 non-null  object
2   Total Harga Produk    96630 non-null  float64
3   Harga Setelah Diskon  96630 non-null  float64
4   Jumlah                96630 non-null  float64
dtypes: datetime64[ns](1), float64(3), object(1)
memory usage: 3.7+ MB
```

**Gambar 5.** *Change Data Type*

## 2. *Null Values Handling*

*Null values handling* adalah proses menganalisis data dengan tujuan mencari nilai *null* dalam dataset dilakukan dengan akurat agar tidak memengaruhi validitas dari model *machine learning*. Tahapan *Null values handling* bisa dilihat dibawah ini:

```
#missing values handling
df.isnull().sum()

0
Waktu Pesanan Dibuat    0
Status Pesanan         0
Total Harga Produk     0
Harga Setelah Diskon   0
Jumlah                 0

dtype: int64
```

**Gambar 6.** *Null Values Handling*

## 3. *Delete Missing Lines*

*Delete missing lines* adalah proses untuk menghapus NaN pada kolom *Waktu Pesanan Dibuat*, *Status Pesanan*, *Total Harga Produk*, *Harga Setelah Diskon*, *Jumlah* bertujuan untuk memudahkan model dalam membaca dataset. Tahapan *Delete missing lines* bisa dilihat dibawah ini:

```
# Delete missing lines
df_cleaned = df.dropna(subset=['Waktu Pesanan Dibuat', 'Status Pesanan', 'Total Harga Produk', 'Harga Setelah Diskon', 'Jumlah'])
```

**Gambar 7.** *Source Code Delete Missing Lines*

## 4. *Removal of Duplicate Rows*

*Removal of Duplicate Rows* adalah proses membersihkan atau menghapus sebuah baris yang sama bertujuan agar memberikan kontribusi signifikan dalam pemodelan atau analisis data pada dataset, tahapan *Removal of Duplicate Rows* bisa dilihat dibawah ini:

```
# Menghapus Baris yang duplikat
df = df.drop_duplicates()
df.head()
```

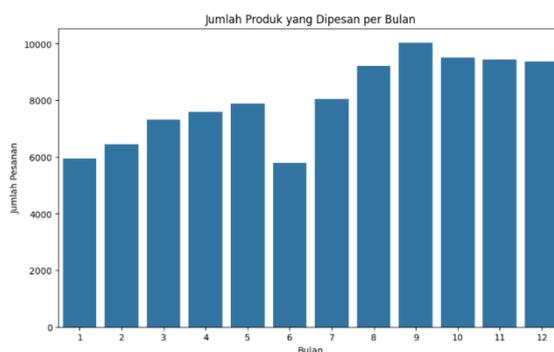
**Gambar 8.** *Source Code Removal of Duplicate Rows*

## ***Exploratory Data Analysis (EDA)***

Tahapan *Exploratory Data Analysis (EDA)* merupakan langkah untuk mengamati dan memeriksa adanya anomali pada dataset *sparepart* toko x. Pada tahapan ini dapat dilakukan beberapa *Exploratory Data* seperti berikut:

### **1. *Exploratory Data Pesanan Setahun***

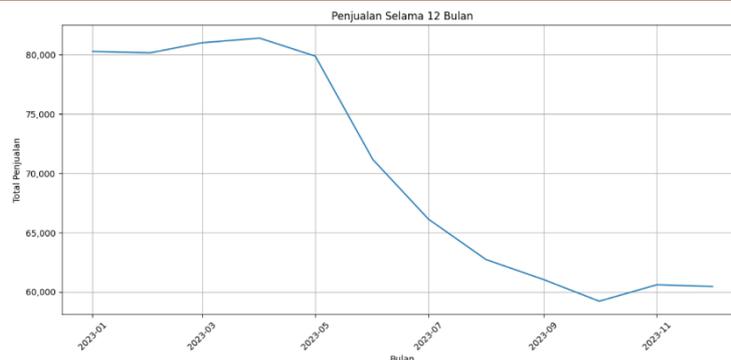
Tahapan ini melihat jumlah produk *sparepart* yang dipesan selama satu tahun, dapat dilihat produk paling banyak dipesan di bulan ke 9 dengan nilai 10.000 pesanan sedangkan pesanan terendah pada bulan ke 6 dengan nilai pesanan sebanyak 5.800 yang bisa dilihat dibawah ini:



**Gambar 9.** Plot Diagram Pesanan 1 Tahun

### **2. *Exploratory Data Penjualan Setahun***

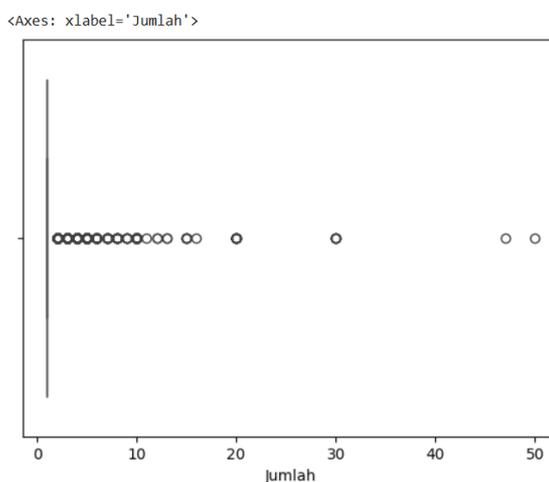
Tahapan ini bertujuan melihat data penjualan dalam kurun waktu setahun dimana penjualan memiliki *tren* yang tidak stabil pada setiap bulannya, dapat dilihat penjualan tertinggi terdapat pada bulan ke 4 tahun 2023 sebanyak 80.000 penjualan sedangkan penjualan terendah dapat dilihat pada bulan ke 10 tahun 2023 sebanyak 55.000 penjualan. Tahapan *Exploratory Data Penjualan Setahun* bisa dilihat dibawah ini:



Gambar 10. Plot Diagram Penjualan 1 Tahun

### 3. *Exploratory Data Outlier*

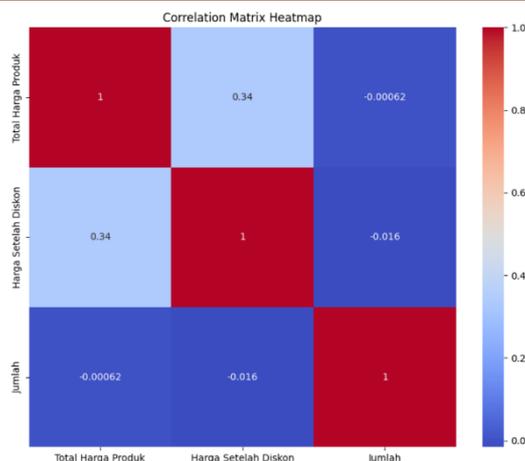
Tahapan ini berfungsi mendeteksi nilai ekstrim (*outlier*), dimana kolom jumlah memiliki outlier yang diatas kuartil atas yang terdapat pada data ke 15, 20, 30, 40 dan 50, yang dapat dilihat pada gambar berikut:



Gambar 11. Diagram *Box Plot* Jumlah

### 4. *Exploratory Data Heatmap*

Tahapan ini bertujuan melihat hubungan antar variabel atau kolom menggunakan diagram *heatmap*, dapat dilihat kolom *Total Harga Produk* berkorelasi atau berhubungan dengan kolom *Harga Setelah Diskon*, tahapan tersebut dapat dilihat pada gambar berikut:



Gambar 12. Diagram *Heatmap*

### Model *Building*

Tahapan model *building* merupakan proses mempersiapkan model pengolahan *machine learning* dimana pada tahapan ini dilakukan pembagian *variabel X* dan *variabel Y* yang digunakan dalam menentukan hasil prediksi dengan model LSTM, tahapan tersebut dapat dilihat dibawah ini:

#### 1. Mempersiapkan Data LSTM

Pada proses ini bertujuan untuk mempersiapkan model LSTM dengan memasukkan kolom waktu pesanan dibuat sebagai *variabel X* dan kolom jumlah sebagai variabel Y, tahapan ini bisa dilihat pada potongan *source code* dibawah ini:

```
data = np.sin(np.arange(100)) + np.random.normal(0,0.1, 100)
df = pd.DataFrame({'Waktu Pesanan Dibuat':data, 'Jumlah':data})

# Menyiapkan data untuk LSTM
sequence_length = 10
X, y = [], []
for i in range(len(df) - sequence_length):
    X.append(df['Waktu Pesanan Dibuat'][i:i + sequence_length])
    y.append(df['Jumlah'][i + sequence_length])

X = np.array(X)
y = np.array(y)
```

Gambar 13. *Source Code* Persiapan Model LSTM

## 2. Membagi Data menjadi Data Train dan Data Test

Pada proses ini dilakukan pembagian dataset menjadi data *train* dan data *test*, dimana data *train* merupakan data latih sedangkan data *test* merupakan data uji, pada penelitian ini dataset digunakan sebanyak 80% sebagai data *train* dan 20% sebagai data *test*, tahapan tersebut dapat dilihat pada gambar *source code* berikut:

```
# Pembagian data menjadi training dan testing
split_ratio = 0.80
split_index = int(split_ratio * len(X))

X_train, X_test = X[:split_index], X[split_index:]
y_train, y_test = y[:split_index], y[split_index:]
```

**Gambar 14.** *Source Code Data Train dan Data Test*

## 3. Membentuk Data LSTM Menjadi 3D (*Samples, Time Steps, Features*)

Pada proses ini dataset yang telah dibagi masuk pada tahap mengubah bentuk data menjadi 3D menggunakan fitur *reshape* pada variabel X, tahapan ini bisa dilihat pada potongan *source code* dibawah ini:

```
# Reshape data untuk LSTM
X_train = X_train.reshape((X_train.shape[0], X_train.shape[1], 1))
X_test = X_test.reshape((X_test.shape[0], X_test.shape[1], 1))
```

**Gambar 15.** *Source Code Reshape*

## 4. Membangun Model LSTM

Pada proses ini model lstm dibangun dengan menggunakan fitur dari *library* dari keras seperti *sequential*, *LSTM*, *dropout* dan *dense*, serta menggunakan *adam* dalam mengkompilasi hasil proses membangun model dan menggunakan *mean squared error* untuk melihat hasil *loss* model, tahapan ini bisa dilihat pada potongan *source code* dibawah ini:

```
model = Sequential()
model.add(LSTM(100, return_sequences=True, input_shape=(X_train.shape[1], 1)))
model.add(Dropout(0.2))
model.add(LSTM(100))
model.add(Dropout(0.2))
model.add(Dense(1))

# Mengkompilasi model
model.compile(optimizer='adam', loss='mean_squared_error')
```

**Gambar 16.** *Source Code Membangun Model LSTM*

## 5. Melatih Model LSTM

Pada proses ini melakukan pelatihan terhadap model LSTM dengan menggunakan *epochs* 50, *batch size* 32 dan *verbose* 1, tahapan ini bisa dilihat pada potongan *source code* dibawah ini:

```
# Melatih model
model.fit(X_train, y_train, epochs=50, batch_size=32, verbose=1)
```

Gambar 17. Source Code Pelatihan Model LSTM

## 6. Membuat Prediksi LSTM Dengan Fitur MAE, MSE, RMSE

Pada proses ini dataset dilatih dengan menggunakan model lstm, dimana dalam menentukan hasil dari prediksi model LSTM menggunakan fitur dari *sklearn* berupa *Mean Absolute Error (MAE)*, *Mean Squared Error (MSE)* dan *Root Mean Square Error (RMSE)*, setelah dilakukan prediksi diperoleh hasil dari *Mean Absolute Error* sebesar 12%, *Mean Squared Error* 2% dan *Root Mean Square Error* sebesar 15% dimana hasil tersebut cukup baik dalam melakukan prediksi stok barang dikarenakan model dapat memperkirakan pola atau *tren* yang terdapat pada dataset. Tahapan ini bisa dilihat pada potongan *source code* dibawah ini:

```
# Membuat prediksi
predictions = model.predict(X_test)

# Import the necessary function
from sklearn.metrics import mean_absolute_error, mean_squared_error

# Menghitung metrik evaluasi
mae = mean_absolute_error(y_test, predictions)
mse = mean_squared_error(y_test, predictions)
rmse = np.sqrt(mse)

mae = int((mae / np.max(y_test)) * 100)
rmse = int((rmse / np.max(y_test)) * 100)
mse = int((mse / np.max(y_test)) * 100)

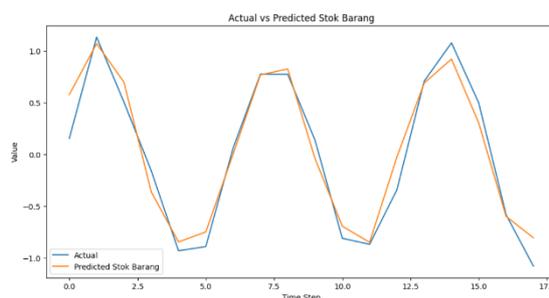
# Menampilkan hasil
print(f"MAE: {mae}%")
print(f"RMSE: {rmse}%")
print(f"MSE: {mse}%")
```

1/1 ————— 0s 328ms/step  
MAE: 12%  
RMSE: 15%  
MSE: 2%

Gambar 18. Source Code Prediksi Model LSTM

## Model Evaluasi

Pada proses ini model evaluasi dari Diagram menunjukkan perbandingan antara nilai aktual (garis biru) dan nilai prediksi stok barang (garis oranye) dalam rentang waktu tertentu. Grafik menunjukkan pola siklus dengan tiga puncak utama pada *time step* 2.5, 7.5, dan 15, serta tiga lembah pada *time step* 5, 10, dan 17.5, dengan rentang nilai antara 0.3 hingga 1.0. Model prediksi tampak bekerja dengan baik karena garis prediksi mampu mengikuti pola nilai aktual dengan cukup akurat, meskipun terdapat beberapa perbedaan kecil di beberapa titik. Hal ini menunjukkan bahwa model memiliki kemampuan yang baik dalam memprediksi pergerakan stok barang serta menangkap pola musiman yang mungkin terdapat dalam data. Hasil dari evaluasi model tersebut dapat dilihat dari gambar berikut:



**Gambar 19.** Model Evaluasi LSTM

## KESIMPULAN DAN REKOMENDASI

Penelitian ini menggunakan model LSTM untuk memprediksi stok *sparepart* HP di toko X dengan tingkat akurasi yang cukup baik, sebagaimana ditunjukkan oleh nilai MAE sebesar 12%, MSE 2%, dan RMSE 15%. Model LSTM mampu menangkap pola musiman dalam data penjualan, yang terlihat dari kemampuannya mengikuti *tren* naik-turun data aktual dengan baik. Hasil visualisasi memperlihatkan bahwa prediksi model (garis oranye) secara konsisten mengikuti pola data aktual (garis biru), membuktikan bahwa model ini dapat diandalkan untuk peramalan stok. Keberhasilan ini tidak terlepas dari proses pengolahan data yang dilakukan secara sistematis melalui tahapan *Data Acquisition*, *Preprocessing*, *Exploratory Data Analysis* (EDA), *Model Building*, dan Evaluasi, yang secara signifikan berkontribusi pada kualitas hasil prediksi.

Untuk meningkatkan akurasi prediksi di masa depan, direkomendasikan untuk menambahkan variabel input seperti faktor musiman, promosi, dan acara khusus. Model juga perlu diperbarui secara berkala dengan data terkini untuk memastikan keandalan prediksi. Implementasi sistem peringatan dini berbasis hasil prediksi dapat membantu mengantisipasi masalah stok, baik kekurangan maupun kelebihan. Untuk mengetahui efektivitas metode LSTM dalam kasus ini, perlu dilakukan perbandingan dengan algoritma *machine learning* lainnya. Pengembangan antarmuka yang *user-friendly* juga menjadi prioritas agar manajemen toko dapat lebih mudah memanfaatkan hasil prediksi dalam pengambilan keputusan.

## REFERENSI

- Afrizal, M., Siswanto, S., & Sudarsono, A. (2023). Implementation of Forecasting Sales of Electronic Goods Using the Semi Average Method at Alex Electronics Store. *Jurnal Media Computer Science*, 2(2), 319–330. <https://doi.org/10.37676/jmcs.v2i2.4433>
- Avinash, A., Widjaja, A., & Karnalim, O. (2024). Comparative Analysis Of Machine Learning Algorithms For Forecasting Of Basic Goods Products. *Jurnal Teknik Informatika Dan Sistem Informasi*, 10(2), 361-378–361 – 378. <https://doi.org/10.28932/JUTISI.V10I2.9357>
- Firmansyah, D., & Dede. (2022). Teknik Pengambilan Sampel Umum dalam Metodologi Penelitian: Literature Review. *Jurnal Ilmiah Pendidikan Holistik (JIPH)*, 1(2), 85–114. <https://doi.org/10.55927/JIPH.V1I2.937>
- Jalil, A., Homaidi, A., & Fatah, Z. (2024). Implementasi Algoritma Support Vector Machine Untuk Klasifikasi Status Stunting Pada Balita. *G-Tech: Jurnal Teknologi Terapan*, 8(3), 2070–2079. <https://doi.org/10.33379/gtech.v8i3.4811>
- Liu, Z., Kong, J., Qu, M., Zhao, G., & Zhang, C. (2022). Progress in Data Acquisition of Wearable Sensors. *Biosensors 2022*, Vol. 12, Page 889, 12(10), 889. <https://doi.org/10.3390/BIOS12100889>

- Mukhlis, M., Kustiyo, A., & Suharso, A. (2021). Peramalan Produksi Pertanian Menggunakan Model Long Short-Term Memory. *BINA INSANI ICT JOURNAL*, 8(1), 22. <https://doi.org/10.51211/BIICT.V8I1.1492>
- Nugraha, A. A. N. A., & Mahendra, I. B. M. (2023). Implementasi Long-Short Term Memory (LSTM) pada Klasifikasi Kategori Berita. *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, 12(3), 563–568. <https://ojs.unud.ac.id/index.php/JLK/article/view/92566>
- Nurchahyo, A. C., Yong, A. T. H., & Atanda, A. F. (2024). Classification of Simulated Fake Bandwidth Data Using LSTM. *TEPIAN*, 5(3), 35–47. <https://doi.org/10.51967/TEPIAN.V5I3.3106>
- Putri, E. S., & Sadikin, M. (2021). Prediksi Penjualan Produk Untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA. *Format Jurnal Ilmiah Teknik Informatika*, 10(2), 162. <https://doi.org/10.22441/FORMAT.2021.V10.I2.007>
- Putri, M., & Vaoutama, A. (2024). *Analisis Dan Visualisasi Data Untuk Meningkatkan Penjualan Menggunakan Exploratory Data Analysis Dan Looker Studio (Studi Kasus : Nies Collection)*. 12(4), 2654–5101.
- Rachim, F., Tumpu, M., & Mansyur. (2024). Research on Predicting Skilled Labor Availability to Enhance Sustainability Building Practices. *International Journal of Sustainable Development and Planning*, 19(11), 4183–4192. <https://doi.org/10.18280/ijstdp.191108>
- Radite Putra, R. B., & Hendry, H. (2022). Multivariate Time Series Forecasting pada Penjualan Barang Retail dengan Recurrent Neural Network. *INOVTEK Polbeng - Seri Informatika*, 7(1), 71. <https://doi.org/10.35314/isi.v7i1.2398>
- Rustamana, A., Hasna Sahl, K., Ardianti, D., Hisyam, A., Solihin, S., Sultan, U., Tirtayasa, A., Raya, J., No, C., & Banten, S. (2024). Penelitian dan Pengembangan (Research & Development) dalam Pendidikan. *Jurnal Bima : Pusat Publikasi Ilmu Pendidikan Bahasa Dan Sastra*, 2(3), 60–69. <https://doi.org/10.61132/BIMA.V2I3.1014>

- 
- Setiawan, E. I., & Lestari, I. (2021). Stance Classification Pada Berita Berbahasa Indonesia Berbasis Bidirectional LSTM. *Journal of Intelligent System and Computation*, 3(1), 41–48. <https://doi.org/10.52985/INSYST.V3I1.148>
- Susanto, P. C., Yuntina, L., Saribanon, E., Soehaditama, J. P., & Liana, E. (2024). Qualitative Method Concepts: Literature Review, Focus Group Discussion, Ethnography and Grounded Theory. *Siber Journal of Advanced Multidisciplinary*, 2(2), 262–275. <https://doi.org/10.38035/SJAM.V2I2.207>
- Tamami, G., & Arifin, M. (2024). *Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens*. 14(2), 301–308.
- Wardani, H. K., Darusuprapti, F., & Hajaroh, M. (2022). Model-Model Evaluasi Pendidikan Dasar (Scriven Model, Tyler Model, dan Goal Free Evaluation). *Jurnal Pendidikan : Riset Dan Konseptual*, 6(1), 36. [https://doi.org/10.28926/riset\\_konseptual.v6i1.446](https://doi.org/10.28926/riset_konseptual.v6i1.446)
- Wibowo, D. A. (2018). PREDIKSI PENJUALAN OBAT HERBAL HP PRO MENGGUNAKAN ALGORITMA NEURAL NETWORK. *Technologia: Jurnal Ilmiah*, 9(1), 33. <https://doi.org/10.31602/TJI.V9I1.1100>