

## Prediksi Penjualan Untuk Optimasi Stock Produk Menggunakan Algoritma *Long Short Term Memory*

<sup>1</sup>Dani Susilo; <sup>\*2</sup>Ahmad Chusyairi; <sup>3</sup>Muhammad Ikhwani Saputra

<sup>1, \*2, 3</sup> Informatika, Universitas Siber Asia, Jl. Harsono RM, Pasar Minggu Jakarta Selatan

<sup>1</sup>Email : [danidansusilo@gmail.com](mailto:danidansusilo@gmail.com)

<sup>\*2</sup>Email : [ahmadchusyairi@lecturer.unsia.ac.id](mailto:ahmadchusyairi@lecturer.unsia.ac.id)

<sup>3</sup>Email : [muhammadikhwani@lecturer.unsia.ac.id](mailto:muhammadikhwani@lecturer.unsia.ac.id)

### ABSTRACT

*Distribution companies bear the responsibility for the goods distribution process and serve as intermediaries between producers and consumers. A primary challenge frequently encountered by distribution companies pertains to inventory procurement, which can lead to either stock surpluses or shortages. Research related to goods distribution focuses more on simple approaches or modeling based on classical methods that are less effective in forecasting sales with a high level of accuracy. Therefore, the development of prediction models based on deep learning algorithms such as Long Short-Term Memory (LSTM) that can handle long-term dependencies on time series data is still limited in the context of distribution companies, especially in improving stock management efficiency and reducing stock procurement errors. This research aims to develop a sales prediction model using the Long Short Term Memory (LSTM) algorithm to enhance inventory management efficiency at distribution company XYZ. By leveraging historical sales data in time series format, this study forecasts future sales, generating predictions per product and per month. Model evaluation using the Mean Absolute Percentage Error (MAPE) yielded an average error rate of 3.60%, this indicates that the model demonstrates a high degree of accuracy. The prediction results are integrated into the inventory procurement system to optimize stock procurement recommendations during the purchasing process. This study demonstrates that the application of LSTM in sales prediction can serve as an effective solution for distribution companies in inventory management and operational cost efficiency.*

**Keywords:** LSTM, MAPE, Sales Prediction, Stock Management, Time Series

### ABSTRAKS

Perusahaan distribusi menjadi pihak yang bertanggung jawab atas proses penyaluran barang dan menjadi perantara antara produsen dengan konsumen. Permasalahan utama yang sering dihadapi perusahaan distribusi adalah terkait dalam pengadaan stok barang yang dapat menyebabkan kelebihan atau kekurangan stok. Penelitian terkait distribusi barang lebih fokus pada pendekatan sederhana atau pemodelan berbasis metode klasik, yang kurang efektif dalam meramalkan penjualan dengan tingkat akurasi yang tinggi. Oleh karena itu, pengembangan model prediksi berbasis algoritma deep learning, seperti Long Short-Term Memory (LSTM), yang dapat menangani dependensi jangka panjang dalam data time series, masih terbatas dalam konteks perusahaan distribusi, khususnya dalam meningkatkan efisiensi pengelolaan stok barang dan pengurangan kesalahan pengadaan stok. Tujuan penelitian ini untuk mengembangkan model prediksi penjualan menggunakan algoritma *Long Short Term Memory* (LSTM) guna meningkatkan efisiensi pengelolaan stok barang pada perusahaan distribusi XYZ. Dengan memanfaatkan data historis penjualan yang berbentuk *time series*, penelitian ini memprediksi penjualan di masa depan dan menghasilkan prediksi per produk dan per bulan. Evaluasi model menggunakan *Mean Absolute Percentage Error* (MAPE) menghasilkan tingkat kesalahan rata-rata sebesar 3,60%, hal ini menunjukkan bahwa model memiliki akurasi yang sangat akurat. Hasil prediksi ini diintegrasikan kedalam sistem pengadaan stok untuk mengoptimalkan rekomendasi pengadaan stok dalam proses pembelian barang. Penelitian ini menunjukkan bahwa penerapan LSTM dalam prediksi penjualan dapat menjadi solusi efektif bagi perusahaan distribusi dalam pengelolaan stok dan efisiensi biaya operasional.

**Kata Kunci:** LSTM, MAPE, Pengelolaan Stok, Prediksi Penjualan, Time Series

## 1. Pendahuluan

Distributor memiliki peran penting dalam rantai pasokan sebagai pihak yang bertanggung jawab atas proses penyaluran barang serta perantara antara produsen dengan konsumen [1]. Berdasarkan observasi pada perusahaan XYZ, dengan ketersediaan pasokan yang optimal terbukti memberikan dampak yang positif terhadap kepuasan pelanggan dan kinerja operasional perusahaan. Permasalahan utama dalam perusahaan XYZ adalah terkait dengan pengadaan pasokan barang. Jika stok terlalu banyak, terutama untuk produk seperti makanan ringan dan minuman dapat menyebabkan produk kadaluarsa atau rusak selama penyimpanan di gudang.

Jika pasokan terlalu sedikit, akan terjadi kekurangan barang yang berdampak pada pasokan ke pelanggan yang tidak dapat terpenuhi, akibatnya pelanggan berpotensi kehilangan keuntungan, dan bagi perusahaan mengalami kerugian serta dikenakan denda *Service Level* dari pelanggan. Oleh karena itu, diperlukan sistem yang mampu memprediksi penjualan dengan akurat agar perusahaan dapat mengoptimalkan pengelolaan pasokan barang.

Prediksi (*forecasting*) merupakan disiplin ilmu yang bertujuan untuk memperkirakan kejadian di masa depan dengan menganalisa data historis dan menggunakannya sebagai dasar untuk proyeksi masa depan[2]. Pada perusahaan XYZ, histori data penjualan dimanfaatkan untuk menganalisa target penjualan dan sebagai dasar dalam perencanaan pembelian barang dari prinsipal. Data penjualan perusahaan XYZ berupa data *time series* per produk dan per bulan, sehingga sesuai untuk digunakan dalam proses prediksi penjualan. Prediksi penjualan pada perusahaan XYZ saat ini belum bisa maksimal karena hanya menggunakan rata-rata penjualan per tiga bulan.

Pada penelitian ini menggunakan algoritma *Long Short Term Memory* (LSTM) yang merupakan salah satu jenis *Recurrent Neural Network* (RNN) yang dapat menghubungkan informasi dari waktu sebelumnya ke waktu berikutnya dan efektif dalam menyimpan informasi jangka panjang yang diperlukan untuk pemrosesan data *time series*[3]. LSTM efektif dalam menghubungkan informasi historis dengan informasi terkini sehingga proses prediksi penjualan menjadi lebih akurat [4]. Untuk mengevaluasi hasil prediksi pada penelitian ini digunakan *Mean Absolute Percentage Error* (MAPE) untuk mengukur rata-rata kesalahan persentase absolut antara nilai hasil prediksi dan nilai actual [5].

Penelitian ini diharapkan bisa digunakan untuk rekomendasi penggunaan histori penjualan per produk untuk mendukung proses prediksi penjualan di masa mendatang dengan akurat. Dengan penggunaan model prediksi penjualan menggunakan algoritma *Long Sort Term Memory* (LSTM), diharapkan bisa mengoptimalkan hasil prediksi penjualan agar sesuai dengan kebutuhan dan mendekati aktual penjualan. Dengan demikian hasil prediksi penjualan per produk bisa direkomendasikan untuk pengadaan stok dengan proses pembelian barang ke prinsipal.

## 2. Tinjauan Pustaka

### Pengumpulan Dataset

*Dataset* adalah Kumpulan data yang dapat digunakan sebagai bahan percobaan riset atau penelitian[5]. Struktur *dataset* dalam penelitian ini terdiri dari beberapa elemen utama [6]:

1. Baris dan Kolom: Data umumnya disusun dalam bentuk *table* yang terdiri dari baris dan kolom. Setiap baris merepresentasikan entitas atau observasi, sedangkan setiap kolom menggambarkan atribut atau *variable*.
2. *Variable*: Kolom dalam *dataset* merepresentasikan *variable* yang berisi informasi tertentu, seperti nama, usia atau jumlah penjualan.
3. *Observasi*: Baris dalam *dataset* menunjukkan suatu kejadian, objek atau entitas tertentu. Sebagai contoh, dalam data penjualan, setiap observasi dapat merepresentasikan satu transaksi.

## **Processing Dataset**

*Processing Dataset* merupakan proses yang digunakan untuk memvalidasi *dataset* yang akan digunakan agar bersih, konsisten dan sesuai dengan format yang dibutuhkan [5]. Berikut tahapan *Processing Dataset* yang dilakukan:

### **1. Data Cleaning**

Data *cleaning* ialah proses yang bertujuan untuk menghilangkan ketidakkonsistenan atau informasi yang tidak relevan dalam data. Proses ini mencakup penanganan data yang hilang, tidak valid, atau bisa juga salah dalam pengetikan. Data yang dianggap tidak relevan akan dihapus atau sering disebut proses *cleaning* guna memastikan kualitas data yang lebih baik [7].

### **2. Normalisasi Data**

Normalisasi data ialah proses perubahan nilai dari *dataset* tertentu agar dapat digunakan dalam proses prediksi [5]. Data mentah sering kali mengandung berbagai pola dasar yang perlu dianalisis. Tahap ini bagian penting dalam penelitian sebelum data diterapkan pada algoritma, karena dapat berisi nilai null, nilai yang terlalu tinggi, atau ambiguitas yang memerlukan tahap pra pemrosesan data [8].

### **3. Integrasi Data**

Integrasi data ialah proses menggabungkan beberapa *dataset* menjadi satu kesatuan data yang terintegrasi. Proses integrasi data ini penting agar *dataset* yang digunakan sesuai dengan data yang dibutuhkan dalam proses penelitian [9].

## **Pemilihan Atribut (Variable)**

Entity merupakan objek dalam dunia nyata yang memiliki identitas unik dan dapat dibedakan dari objek lainnya. Dalam konteks database, entity merepresentasikan objek yang datanya akan disimpan dalam database, seperti produk, karyawan, atau pelanggan. Setiap entity memiliki atribut yang berperan dalam mendeskripsikan karakteristik entity tersebut. Berikut beberapa jenis atribut yang biasa digunakan [10]:

### **1. Atribut kunci**

Atribut kunci merupakan digunakan untuk mengidentifikasi data penting, bentuk atribut biasanya berupa numerik. Contohnya seperti Nomor KTP, Nomor Induk Mahasiswa (NIM), dan NPWP.

### **2. Atribut simple**

Atribut simple ialah atribut bernilai tunggal dan tidak dapat dirubah lagi. Contohnya seperti alamat kantor dan penerbit.

### **3. Atribut multivali**

Atribut multivali ialah atribut yang dapat memiliki nilai lebih dari satu. Contohnya sebuah artikel di website dapat memiliki lebih dari satu penulis.

### **4. Atribut gabungan**

Atribut gabungan ialah gabungan beberapa atribut kecil yang memiliki makna tertentu. Sebagai contoh, nama seseorang yang terdiri dari nama depan dan nama belakang.

### **5. Atribut derivative**

Atribut *derivative* merupakan atribut yang diperoleh dari atribut lain dan tidak bersifat wajib untuk dicantumkan. Contohnya meliputi selisih harga, usia, dan kelas.

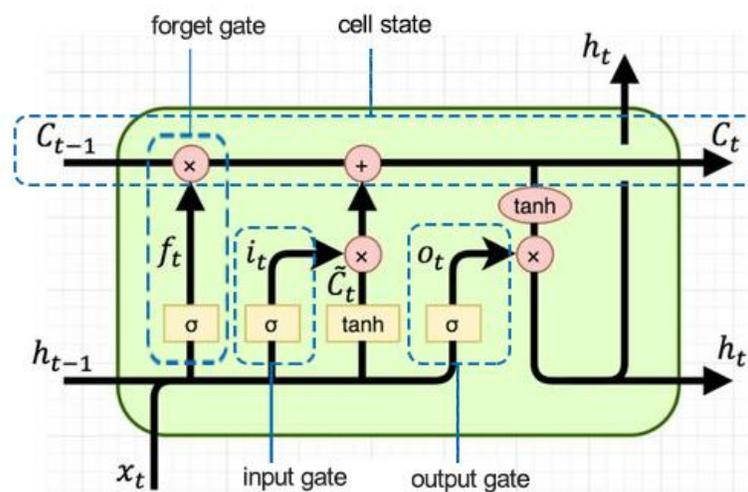
## **Data Training dan Data Testing**

Data *training* ialah data historis yang sesuai dengan fakta yang ada, sedangkan data *testing* ialah data yang digunakan untuk mengevaluasi sejauh mana model dapat mengklasifikasikan data dengan akurat. Proporsi antara data *training* dan data *testing* menjadi faktor penting yang menentukan akurasi model, sehingga kesalahan dalam pembagiannya dapat mempengaruhi hasil akurasi yang diperoleh[11].

## **Model LSTM**

*Recurrent Neural Network* (RNN) melibatkan data sebelumnya untuk proses input. RNN menggunakan *multi-layer* dan perulangan dalam pemrosesan data *time series*, sehingga dikategorikan kedalam *deep learning*. Namun, RNN memiliki keterbatasan dalam menangani

data *time series* jangka panjang, sehingga lebih optimal untuk data dengan ketergantungan pendek [2]. *Long Sort Term Memory* (LSTM) ialah salah satu RNN yang dirancang untuk menganalisis data historis atau *time series*. Sebagai algoritma *deep learning* yang kompleks, LSTM unggul dalam menangkap dan mempertahankan informasi jangka panjang secara lebih efektif[12]. Arsitektur LSTM terdiri dari tiga lapisan utama, yaitu lapisan *input*, lapisan tersembunyi, dan lapisan *output* [13].



Gambar 1. Struktur LSTM [14]

Tahapan yang dilalui dalam proses model LSTM berdasarkan Gambar 1 sebagai berikut [13]:

1. *Forget gate* ( $f_t$ )

*Forget gate* berperan dalam menentukan data mana saja yang perlu dihapus dan mengoptimalkan waktu latensi untuk *input* selanjutnya. Persamaan fungsi aktivasi sigmoid yang digunakan adalah sebagai berikut:

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (1)$$

Keterangan:

- $f_t$  = *forget gate*
- $\sigma$  = fungsi aktivasi sigmoid
- $W_f$  = bobot *forget gate*
- $h_{t-1}$  = nilai *hidden state cell* sebelum
- $X_t$  = nilai *input*
- $b_f$  = bias *forget gate*

2. *Input gate* ( $i_t$ )

*Input gate* berfungsi sebagai pintu masuk bagi data dari luar dan mengolah data yang diterima. Berikut adalah persamaan dari dua fungsi aktivasi:

$$i_t = \sigma(W_i [h_{t-1}, X_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c [h_{t-1}, X_t] + b_c) \quad (3)$$

Keterangan:

- $i_t$  = *input gate*
- $W_i$  = bobot *input gate*
- $b_i$  = bias *input gate*
- $\tilde{C}_t$  = *candidate gate*
- $\tanh$  = fungsi aktivasi  $\tanh$
- $W_c$  = bobot *candidate gate*
- $b_c$  = bias *candidate gate*

### 3. Cell state ( $C_t$ )

Cell state berfungsi untuk memperbaharui nilai pada *memory cell* dengan menggantikan nilai sebelumnya dengan nilai yang baru. Persamaan yang digunakan dalam fungsi *cell state* adalah sebagai berikut:

$$C_t = (i_t * \bar{C}_t + f_t * C_{t-1}) \quad (4)$$

Keterangan:

- $C_t$  = cell gate
- $i_t$  = input gate
- $\bar{C}_t$  = candidate gate
- $f_t$  = forget gate
- $C_{t-1}$  = nilai cell state sebelumnya

### 4. Output gate ( $o_t$ )

Output gate berperan dalam mengatur proses perhitungan serta mengelola input *output* dalam sel LSTM. Berikut adalah persamaan fungsi yang digunakan pada *output gate*:

$$o_t = \sigma(W_o \cdot [h_{t-1} \cdot X_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

Keterangan:

- $o_t$  = output gate
- $W_o$  = bobot output gate
- $b_o$  = bias output gate
- $h_t$  = hidden state
- $X_t$  = nilai input
- $C_t$  = cell gate

## Evaluasi Model

Evaluasi model bertujuan untuk mengukur sejauh mana ketepatan dari model yang telah dikembangkan. Dalam penelitian ini, evaluasi dilakukan menggunakan *Mean Absolute Percentage Error* (MAPE) [15]. Tujuan utama penelitian ini menerapkan MAPE bukan untuk membandingkan evaluasi, evaluasi diambil MAPE karena kecenderungan pada perusahaan XYZ melihat selisih nya, bukan akurasi berapa persen, oleh karena itu lebih mudah dianalisa menggunakan model MAPE. MAPE adalah matriks yang banyak digunakan dalam peramalan untuk menilai tingkat akurasi suatu model dalam memprediksi nilai tertentu [2]. Persamaan MAPE sebagai berikut [16]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \times 100\% \quad (7)$$

Keterangan:

- $y_i$  = Nilai *actual*.
- $\hat{y}_i$  = Nilai hasil prediksi
- $n$  = Jumlah data

Kriteria nilai MAPE yang digunakan untuk menilai model ditunjukkan pada Tabel 1.

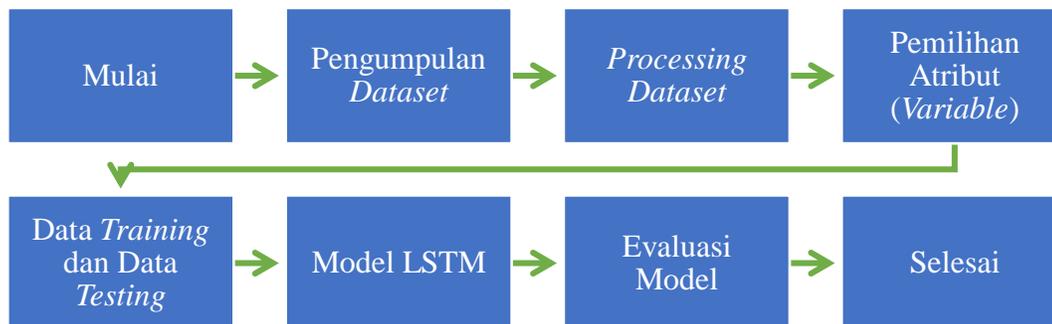
Nilai MAPE (%)	Kriteria
< 10	Sangat Akurat
10-20	Akurat
20-50	Cukup
> 50	Tidak Akurat

## Deployment

Deployment merupakan tahapan akhir dalam pengembangan model, dimana model telah melalui proses pengujian dan menghasilkan perfoma terbaik. Tahap selanjutnya model diterapkan kedalam pembuatan aplikasi yang mengacu pada algoritma yang sudah diuji dan terbukti berhasil [17].

### 3. Metode Penelitian

Metodologi penelitian ini menggunakan kerangka kerja seperti terlihat pada Gambar 2 dengan langkah-langkah dimulai dari pengumpulan *dataset* sampai dengan *deployment* [5]. Langkah langkah penelitian ditunjukkan pada Gambar 2 berikut:



Gambar 2. Kerangka Kerja Penelitian

#### Pengumpulan *Dataset*

Berikut aspek-aspek yang digunakan dalam pengumpulan *dataset*:

1. *Dataset* diperoleh dengan cara pengambilan data dari perusahaan XYZ dalam periode 1 Januari 2020 sampai dengan 31 Desember 2024, data berjumlah 6.960 *row*. Data sudah diolah sehingga sudah berbeda dengan data aslinya, hal ini untuk menghindari data penting dan rahasia perusahaan tersebar.
2. *Dataset* berupa data transaksi penjualan perusahaan XYZ yang di *summary* per produk dan per bulan.
3. Pada Tabel 2 merupakan contoh *dataset* penjualan. Berikut keterangan atribut-atributnya:
  - a. Tanggal: Identifikasi *time series* penjualan dengan interval bulanan.
  - b. Nama\_produk: Produk yang dijual.
  - c. Harga: Nilai harga jual produk dalam satuan terkecil.
  - d. Stok: Jumlah persediaan penjualan.
  - e. Qty\_jual: Jumlah penjualan.
  - f. *Gross\_sales*: Harga produk dikalikan dengan jumlah penjualan.
  - g. Diskon: Persentase diskon dalam penjualan.
  - h. *Net\_sales*: Nilai bersih dari *gross sales* dikurangi diskon.

Tabel 2. *Dataset* Penjualan

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	<i>Gross Sales</i>	Diskon	<i>Net Sales</i>
1	1/1/2020	Alang Sari Jeruk Manis Box 6x7g	1.374,27	3.489	3.404	4,68	0,22	4,46
2	1/1/2020	Alang Sari Jeruk Nipis 6x7g	1.443,23	3.120	3.044	4,39	0,11	4,28
4	1/1/2020	Bihun Instan Bihunku Asam Pedas 55g/40	2.880,15	95.167	92.846	267,41	3,8	263,61
5	1/1/2020	Bihun Instan Bihunku Ayam Bawang 55g/40	2.869,71	82.617	80.602	231,3	5,74	225,56
6	1/1/2020	Bihun Instan Bihunku Bakso 55g/40	2.927,24	10.503	10.247	30	0,33	29,67
7	1/1/2020	Bihun Instan Bihunku Goreng 60g/40	3.301,37	45.133	44.032	145,37	0,54	144,82

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
	...							
6954	1/12/2024	Taro Net Seaweed Family Pack 62g/30	6.272,68	339.574	331.292	2.078,09	51,95	2.026,14
6955	1/12/2024	Taro Net Seaweed Jumbo Pack 115g/16	10.627,01	159.481	155.591	1,653,47	41,34	1.612,13
6956	1/12/2024	Taro Net Seaweed Medium Pack 32g/36	3.779,31	108.453	105.808	399,88	10,00	389,88
6957	1/12/2024	Taro Nett Cowboy Steak Medium Pack 32g/36	3.827,9	10.273	10.022	38,36	0,96	37,40
6958	1/12/2024	Taro Tempe Chicken Onion 55g/36	6.053,65	9.853	9.613	58,19	1,45	56,74
6959	1/12/2024	Taro Tempe Chicken Teriyaki Barbeque 55g/36	5.849,35	1.909	1.862	10,89	0,27	10,62
6960	1/12/2024	Taro Tempe Himalayan Salt 50g/36	5.905,28	108.253	105.613	623,67	15,59	608,08

### Processing Dataset

#### 1. Data Cleaning

Proses pembersihan *dataset* yang rusak disebabkan oleh *error* koneksi saat *input* data atau data rusak akibat dilakukan perbaikan data yang kurang sempurna. Data *error* atau rusak yang dimaksud adalah data yang tidak dapat digunakan untuk proses model, seperti nama produk yang kosong atau *blank*. Data-data rusak dihapus dari *dataset*, sehingga didapatkan *dataset* yang bersih.

#### 2. Normalisasi Data

Normalisasi data dilakukan untuk atribut-atribut data yang hilang informasinya, dan sangat penting untuk proses algoritma model. Normalisasi data dilakukan untuk data-data yang tidak seharusnya. Seperti atribut harga, stok, qty\_jual, gross\_sales, diskon, dan net\_sales yang seharusnya terisi angka numerik tetapi berisi *null*. Hal ini dapat terjadi karena perbaikan-perbaikan data yang tidak sempurna. Untuk mengatasi hal tersebut dilakukan normalisasi dari nilai-nilai yang tidak seharusnya ke nilai yang benar, dari *null* menjadi 0. Normalisasi nominal juga dilakukan dengan membagi satu juta nilai gross\_sales, diskon, dan net\_sales agar nilai nominal lebih kecil sehingga lebih memudahkan proses model. Tabel 3 merupakan contoh normalisasi atribut diskon yang bernilai *null* diganti menjadi 0 dan nilai atribut gross\_sales, diskon, dan nett\_sales dibagi satu juta agar nilai lebih kecil.

Tabel 3. Normalisasi Data Error

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
1	1/1/2020	Alang Sari Jeruk Manis Box 6x7g	1.374,27	3.489	3.404	4,68	0,22	4,46
2	1/1/2020	Alang Sari Jeruk Nipis 6x7g	1.443,23	3.120	3.044	4,39	0,11	4,28
3	1/1/2020	Bihun Instan Bihunku Asam Pedas 55g/40	2.880,15	95.167	92.846	267,41	null	263,61

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
4	1/1/2020	Biskies Black Cracker Sandwich Vanilla 72g/24	4.806,09	148.096	144.484	694,40	23,71	670,69
5	1/1/2020	Biskies Cheezy Cracker Cheese 96gr/24	4.883,53	15.051	14.684	71,71	0,82	70,89
6	1/1/2020	Biskies Cracker Sandwich Cheese 96gr/24	5.369,86	110.318	107.627	577,94	7,16	570,78
7	1/1/2020	Biskies Cracker Sandwich Chocolate 96gr/24	5.381,06	25.250	24.634	132,56	null	131,94
8	1/1/2020	Biskies Cracker Sandwich Vanilla 96gr/24	5.386,90	66.472	64.851	349,35	8,12	341,23
9	1/1/2020	Cem Cem Pop Corn Keju Bakar 75gr/30	6853,82	49.066	47.869	328,09	12,38	315,71
10	1/1/2020	Cemcem Corn Shots Ayam Goreng 55g/30	4561,7	19.562	19.085	87,06	1,35	85,71

### 3. Integrasi Data

Integrasi data dilakukan untuk menggabungkan beberapa *dataset* yang diperlukan untuk proses model. Pada penelitian ini digunakan dua sumber *dataset*, yaitu penjualan dan stok. Data stok digunakan untuk membantu performa model untuk mengetahui berapa stok tersedia pada saat terjadinya penjualan.

#### Pemilihan Atribut (*Variable*)

Pemilihan atribut dilakukan untuk memilih atribut mana saja yang akan digunakan untuk proses model. Atribut yang digunakan pada penelitian ini adalah tanggal, nama\_produk, harga, stok, qty\_jual, gross\_sales, diskon, dan net\_sales. Berikut penjelasan nilai dan fungsi dalam model masing masing atribut:

1. Tanggal: Atribut data tanggal dengan interval bulanan, data diwakili tanggal 1 pada setiap bulannya yang merupakan indek data *time series*.
2. Nama\_produk: Atribut data yang menjelaskan produk yang akan di prediksi penjualannya.
3. Harga: Atribut data yang memiliki nilai desimal yang digunakan dalam fitur prediksi.
4. Stok: Atribut data yang memiliki nilai integer yang digunakan dalam fitur prediksi.
5. Qty\_jual: Atribut data yang memiliki nilai integer yang digunakan dalam fitur prediksi.
6. Gross\_sales: Atribut data yang memiliki nilai desimal yang digunakan dalam fitur prediksi.
7. Diskon: Atribut data yang memiliki nilai desimal yang digunakan dalam fitur prediksi.
8. Net\_sales: Atribut data yang memiliki nilai desimal yang digunakan dalam fitur prediksi.

#### Data Training dan Data Testing

Data *training* dan data *testing* dibentuk kedalam 2 file excel yang berbeda, yaitu data\_training.xlsx dan data\_test.xlsx. Data *training* ditunjukkan pada Tabel 4, data diambil dari *dataset* penjualan periode 1 Januari 2020 – 31 Desember 2023 yang terdiri dari 5.568 row.

Tabel 4. Data Training

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
1	1/1/2020	Alang Sari Jeruk Manis Box 6x7g	1.374,27	3.489	3.404	4,68	0,22	4,46
2	1/1/2020	Alang Sari Jeruk Nipis 6x7g	1.443,23	3.120	3.044	4,39	0,11	4,28
3	1/1/2020	Bihun Instan Bihunku Asam Pedas 55g/40	2.880,15	95.167	92.846	267,41	3,80	263,61

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
4	1/1/2020	Bihun Instan Bihunku Ayam Bawang 55g/40	2.869,71	82.617	80.602	231,30	5,74	225,56
5	1/1/2020	Bihun Instan Bihunku Bakso 55g/40	2.927,24	10.503	10.247	30,00	0,33	29,67
6	1/1/2020	Bihun Instan Bihunku Goreng 60g/40	3.301,37	45.133	44.032	145,37	0,54	144,82
7	1/1/2020	Bihun Instan Bihunku Japchae 55g/40	4.417,77	1.675	1.634	7,22	0,12	7,10
...								
5562	12/1/2023	Taro Net Seaweed Family Pack 62g/30	6.272,68	339.567	331.285	2.078,04	51,95	2.026,09
5563	12/1/2023	Taro Net Seaweed Jumbo Pack 115g/16	10.627,01	159.505	155.615	1.653,72	41,34	1.612,38
5564	12/1/2023	Taro Net Seaweed Medium Pack 32g/36	3.779,31	108.458	105.813	399,90	10,00	389,90
5565	12/1/2023	Taro Nett Cowboy Steak Medium Pack 32g/36	3.827,90	10.252	10.002	38,29	0,96	37,33
5566	12/1/2023	Taro Tempe Chicken Onion 55g/36	6.053,65	9.875	9.634	58,32	1,46	56,86
5567	12/1/2023	Taro Tempe Chicken Teriyaki Barbeque 55g/36	5.849,35	1.915	1.868	10,93	0,27	10,65
5568	12/1/2023	Taro Tempe Himalayan Salt 50g/36	5.905,28	108.252	105.612	623,67	15,59	608,08

Data *testing* ditunjukkan pada Tabel 5, data diambil dari *dataset* penjualan periode 1 Januari 2024 - 31 Desember 2024 yang terdiri dari 1.392 *row* atau data *testing* 25% dari data *training*.

Tabel 5. Data *Testing*

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
1	1/1/2024	Alang Sari Jeruk Manis Box 6x7g	1.374,27	3.476	3.391	4,66	0,19	4,47
2	1/1/2024	Alang Sari Jeruk Nipis 6x7g	1.443,23	3.124	3.048	4,40	0,15	4,25
3	1/1/2024	Bihun Instan Bihunku Asam Pedas 55g/40	2.880,15	95.155	92.834	267,38	9,83	257,54
4	1/1/2024	Bihun Instan Bihunku Ayam Bawang 55g/40	2.869,71	82.607	80.592	231,28	3,44	227,84
5	1/1/2024	Bihun Instan Bihunku Bakso 55g/40	2.927,24	10.492	10.236	29,96	0,37	29,59
6	1/1/2024	Bihun Instan Bihunku Goreng 60g/40	3.301,37	45.122	44.021	145,33	7,16	138,17
7	1/1/2024	Bihun Instan Bihunku Japchae 55g/40	4.417,77	1.668	1.627	7,19	0,26	6,93
...								
1385	12/1/2024	Taro Net Potato Barbeque Medium Pack 32g/36	3.802,10	31.260	30.498	115,96	2,90	113,06

No	Tanggal	Nama Produk	Harga	Stok	Qty Jual	Gross Sales	Diskon	Net Sales
1386	12/1/2024	Taro Net Seaweed Family Pack 62g/30	6.272,68	339.574	331.292	2.078,09	51,95	2.026,14
1387	12/1/2024	Taro Net Seaweed Jumbo Pack 115g/16	10.627,01	159.481	155.591	1.653,47	41,34	1.612,13
1388	12/1/2024	Taro Net Seaweed Medium Pack 32g/36	3.779,31	108.453	105.808	399,88	10,00	389,88
1389	12/1/2024	Taro Nett Cowboy Steak Medium Pack 32g/36	3.827,90	10.273	10.022	38,36	0,96	37,40
1390	12/1/2024	Taro Tempe Chicken Onion 55g/36	6.053,65	9.853	9.613	58,19	1,45	56,74
1391	12/1/2024	Taro Tempe Chicken Teriyaki Barbeque 55g/36	5.849,35	1.909	1.862	10,89	0,27	10,62
1392	12/1/2024	Taro Tempe Himalayan Salt 50g/36	5.905,28	108.253	105.613	623,67	15,59	608,08

### Model LSTM

Dalam tahap ini dibuat model LSTM dan memproses data *training* untuk pelatihan model dan mengujinya dengan memproses data *testing* untuk mendapatkan prediksi penjualan per bulan dalam satu tahun 2024. Pada setting parameter ini dapat dilakukan perubahan perubahan nilai untuk mencapai hasil prediksi yang maksimal dan akurat. Berikut skenario parameter yang digunakan dalam proses model LSTM, seperti terlihat pada Gambar 3:

1. *Layer input*

*Layer* dengan 64 neuron (*units*) menangkap pola dari data penjualan sekuensial dengan urutan waktu perbulan. *Input shape*[1] merupakan data *training* penjualan yang berjumlah 5.568 dan *shape*[2] merupakan jumlah atribut yang digunakan proses prediksi penjualan, atribut yang digunakan adalah harga, stok, *gross\_sales*, diskon, dan *net\_sales*. Set parameter *return\_sequence* bernilai *true* yang bertujuan agar layer LSTM berikutnya menerima *output* dari setiap *timestep* untuk proses selanjutnya. *Dropout* 20% untuk mengurangi *overfitting* selama pelatihan atau mengurangi model belajar terlalu kompleks sehingga hasilnya kurang akurat saat diterapkan pada data baru.

2. *Hidden layer*

*Layer* dengan 32 neuron (*units*) untuk menangkap pola data penjualan sekuensial dengan urutan waktu perbulan. Set parameter *return\_sequences* bernilai *false* agar *layer* ini mengembalikan *output* dari *timestep* terakhir sebagai representasi prediksi akhir. *Dropout* 20% untuk mengurangi *overfitting* dengan cara mengabaikan 20% neuron secara acak.

3. *Output layer*

*Output layer* dense 1 yang berarti hanya memiliki 1 neuron sehingga menghasilkan 1 *output*. *Activation* menggunakan *linear* jadi tidak ada transformasi pada *output*, karena berupa nilai kontinu atau angka *real* bukan probabilitas. Dalam penelitian ini *output* berupa prediksi qty penjualan.

4. Kompilasi model

*Optimizer* menggunakan *adam* untuk memperbaharui model dengan cara pembelajaran secara adaptif untuk setiap bobot. *Loss* menggunakan *mean\_absolute\_error* untuk mengukur seberapa baik memprediksi qty penjualan dibandingkan dengan qty aktual penjualan. Parameter *loss mean\_absolute\_error* dipilih karena pola data penjualan tidak terlalu banyak *outlier* atau pola data yang berada terlalu jauh dari pola umum dalam *dataset* nya.

5. Melatih model

Epoch 100, model akan dilatih selama maksimal 100 *epoch*. Dengan tambahan parameter *early\_stopping* yang digunakan untuk nilai *loss* dari model selama pelatihan, jika setelah 5 *epoch* berturut-turut tidak ada perbaikan maka pelatihan dihentikan dan bobot model akan diatur ulang ke bobot terbaik yang ditemukan selama proses latihan.

6. Prediksi dengan data *testing*.

Pada tahap ini dilakukan pengetestan untuk memprediksi model menggunakan data *testing*. *X\_test* merupakan data historis penjualan baru yang tidak dilihat model selama pelatihan. *y\_pred* hasil prediksi penjualan untuk tiap sampel dalam *X\_test*.

```

83 #1. Layer input, set jumlah neuron dan urutan array waktu
84 model.add(Input(shape=(X_train.shape[1], X_train.shape[2])))
85 model.add(LSTM(units=64, return_sequences=True))
86 model.add(Dropout(0.2))
87
88 #2. Hidden Layer
89 model.add(LSTM(units=32, return_sequences=False))
90 model.add(Dropout(0.2))
91
92 #3. Output Layer
93 model.add(Dense(1, activation='linear'))
94
95 #4. Kompilasi model dengan mae
96 model.compile(optimizer='adam', loss='mean_absolute_error')
97
98 #5. Melatih model
99 early_stopping = EarlyStopping(monitor='loss', patience=5, restore_best_weights=True)
100 lr_scheduler = ReduceLROnPlateau(monitor='loss', factor=0.2, patience=3, verbose=1, min_lr=0.0001)
101 model.fit(X_train, y_train, epochs=100, batch_size=32, verbose=2, callbacks=[early_stopping, lr_scheduler])
102
103 #6. Melakukan prediksi pada data testing
104 y_pred = model.predict(X_test)

```

Gambar 3. Setting Parameter Model LSTM

**Evaluasi Model**

Pada tahap ini dilakukan evaluasi terhadap kinerja model LSTM dengan menggunakan *Mean Absolute Percentage Error* (MAPE). Pengecekan data selisih antara aktual *vs* prediksinya dilakukan per produk dan per bulan. Hal ini penting karena dibutuhkan ketepatan prediksi per produknya. Pada Tabel 6 kolom *mape*(%) menunjukkan berapa besar nilai MAPE pada tiap produknya. Dari *mape* dapat dihitung berapa rata-rata MAPE untuk mendapatkan akurasi keberhasilan prediksi secara keseluruhan. Perhitungan rata-rata MAPE dalam prediksi menggunakan *summary* nilai dari kolom *mape*(%) per produk dibagi dengan jumlah data *testing* atau data yang akan prediksi. *Summary* kolom *mape*(%) pada hasil prediksi adalah 5.006,93 dan jumlah data *testing* 1.392. Berikut perhitungannya:

$$MAPE = \frac{5.006,93}{1.392} = 3,60 \%$$

Tabel 6. *Summary* MAPE Prediksi

No	Tanggal	Nama Produk	Qty Jual	Qty Prediksi	Selisih Prediksi	mape
1	1/1/2024	Alang Sari Jeruk Manis Box 6x7g	3.391	3.586	195	5,75
2	1/1/2024	Alang Sari Jeruk Nipis 6x7g	3.048	3.250	202	6,63
3	1/1/2024	Bihun Instan Bihunku Asam Pedas 55g/40	92.834	90.785	(2.049)	2,21
4	1/1/2024	Bihun Instan Bihunku Ayam Bawang 55g/40	80.592	78.802	(1.790)	2,22
5	1/1/2024	Bihun Instan Bihunku Bakso 55g/40	10.236	10.203	(33)	0,32
...						
1388	12/1/2024	Taro Net Seaweed Medium Pack 32g/36	105.808	103.480	(2.328)	2,20
1389	12/1/2024	Taro Nett Cowboy Steak Medium Pack 32g/36	10.022	9.972	(50)	0,50
1390	12/1/2024	Taro Tempe Chicken Onion 55g/36	9.613	9.521	(92)	0,96
1391	12/1/2024	Taro Tempe Chicken Teriyaki Barbeque 55g/36	1.862	2.006	144	7,73
1392	12/1/2024	Taro Tempe Himalayan Salt 50g/36	105.613	103.287	(2.326)	2,20
Summary						5.006,93

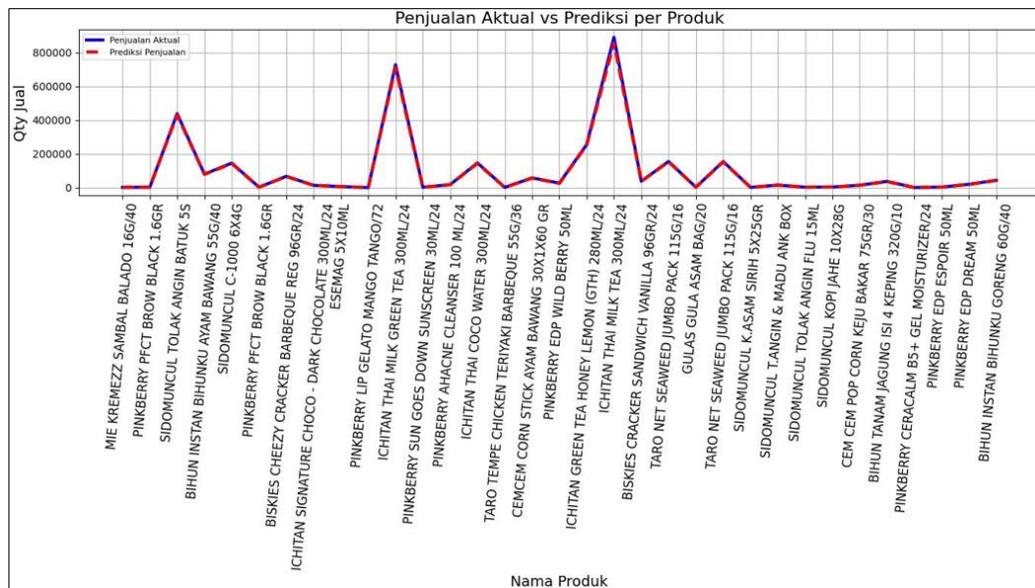
#### 4. Hasil dan Pembahasan

Berdasarkan skenario yang digunakan didapatkan hasil prediksi dari model LSTM seperti pada Tabel 7. Pada tabel terlihat prediksi dilakukan untuk menghasilkan data per produk dan per bulan selama tahun 2024. Atribut *qty\_prediksi* yang menjadi hasil prediksi model dengan kolom *selisih\_prediksi* dan *mape* dalam persentase yang memberikan gambaran selisih prediksi *vs* aktual penjualan.

Tabel 7. Hasil Prediksi Penjualan

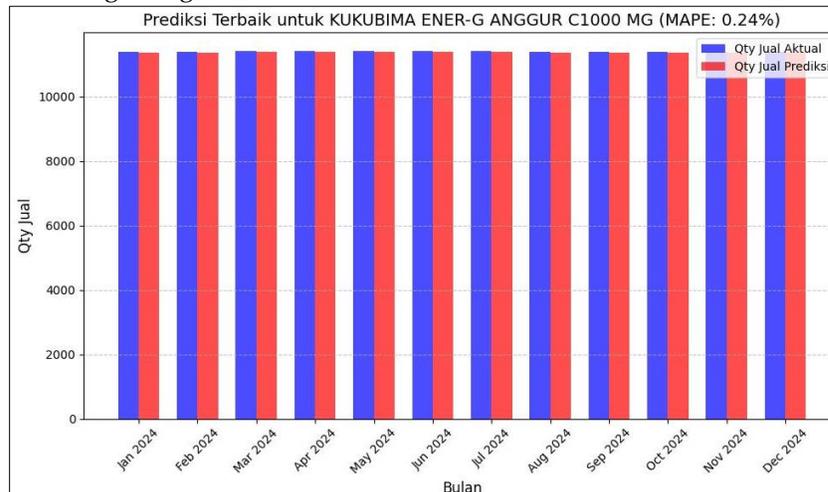
No	Tanggal	Nama Produk	Qty Jual	Qty Prediksi	Selisih Prediksi	mape
1	1/1/2024	Alang Sari Jeruk Manis Box 6x7g	3.391	3.586	195	5,75
2	1/1/2024	Alang Sari Jeruk Nipis 6x7g	3.048	3.250	202	6,63
3	1/1/2024	Bihun Instan Bihunku Asam Pedas 55g/40	92.834	90.785	(2.049)	2,21
4	1/1/2024	Bihun Instan Bihunku Ayam Bawang 55g/40	80.592	78.802	(1.790)	2,22
5	1/1/2024	Bihun Instan Bihunku Bakso 55g/40	10.236	10.203	(33)	0,32
...						
1388	12/1/2024	Taro Net Seaweed Medium Pack 32g/36	105.808	103.480	(2.328)	2,20
1389	12/1/2024	Taro Nett Cowboy Steak Medium Pack 32g/36	10.022	9.972	(50)	0,50
1390	12/1/2024	Taro Tempe Chicken Onion 55g/36	9.613	9.521	(92)	0,96
1391	12/1/2024	Taro Tempe Chicken Teriyaki Barbeque 55g/36	1.862	2.006	144	7,73
1392	12/1/2024	Taro Tempe Himalayan Salt 50g/36	105.613	103.287	(2.326)	2,20

Pada Gambar 4 dapat dilihat grafik perbandingan antara data penjualan aktual dengan hasil prediksi penjualan yang dihasilkan oleh model LSTM untuk setiap produk. Sumbu vertikal *qty jual* menunjukkan jumlah penjualan, sedangkan sumbu horizontal nama produk menunjukkan nama-nama produk yang di prediksi. Garis biru menunjukkan penjualan aktual atau penjualan sebenarnya dari masing masing produk, sedangkan garis merah menunjukkan hasil prediksi penjualan. Jika garis biru dan garis merah terlihat tumpang tindih atau berdekatan, ini menunjukkan bahwa model memiliki akurasi yang baik dalam memprediksi penjualan. Perbedaan letak garis biru dan merah yang berbeda secara signifikan menunjukkan bahwa model kurang akurat dalam memprediksi penjualan.



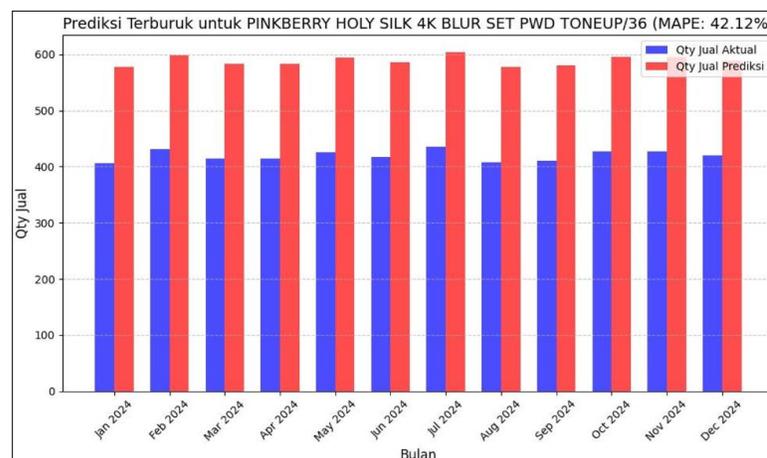
Gambar 4. Grafik Hasil Prediksi Penjualan Aktual *vs* Pediksi

Pada Gambar 5 ditunjukkan produk dengan akurasi prediksi terbaik. Sumbu vertikal menunjukkan jumlah penjualan dan sumbu horizontal menunjukkan aktual *vs* prediksi pada tiap bulannya. Produk “Kukubima Ener-G Anggur C1000 mg” memiliki tingkat kesalahan prediksi 0,24%. Pada gambar diagram batang dapat dilihat bahwa warna biru menunjukkan jumlah penjualan aktual dan warna merah menunjukkan hasil dari prediksi penjualan. Warna biru dan warna merah yang hampir sejajar menunjukkan bahwa akurasi prediksi untuk produk “Kukubima Ener-G Anggur C-1000 mg” sangat akurat.



Gambar 5. Produk Dengan Akurasi Prediksi Terbaik

Pada Gambar 6 ditunjukkan produk dengan akurasi prediksi terburuk. Produk “Pinkberry Holy Silk 4K Blur Set Pwd ToneUp/36” memiliki tingkat kesalahan prediksi 42,12%. Pada gambar diagram batang warna biru yang merupakan penjualan aktual dan warna merah yang merupakan hasil prediksi, pada gambar menunjukkan bahwa ada perbedaan cukup jauh antara warna biru dan warna merah. Berdasarkan kriteria MAPE yang sudah dibuat, jarak yang terlalu jauh dengan nilai antara 20%-50% menunjukkan bahwa produk memiliki akurasi prediksi dalam kategori cukup.



Gambar 6. Produk Dengan Akurasi Prediksi Terendah

### Pengukuran Hasil Prediksi Dengan MAPE

Hasil prediksi diukur dengan menggunakan MAPE sesuai dengan kriteria nilai MAPE yang sudah ditentukan sebelumnya. Pengukuran nilai MAPE ini dilakukan baik per produk maupun rata-rata secara keseluruhan, hal ini untuk mendapatkan gambaran berapa besar akurasi prediksi per produk dan juga seberapa berhasil prediksi model secara keseluruhan. Dari hasil perhitungan MAPE rata-rata adalah 3,60%, berdasarkan tabel nilai kriteria MAPE, hasil ini < 10 yang berarti model memprediksi dengan sangat akurat.

### Matriks Korelasi Fitur

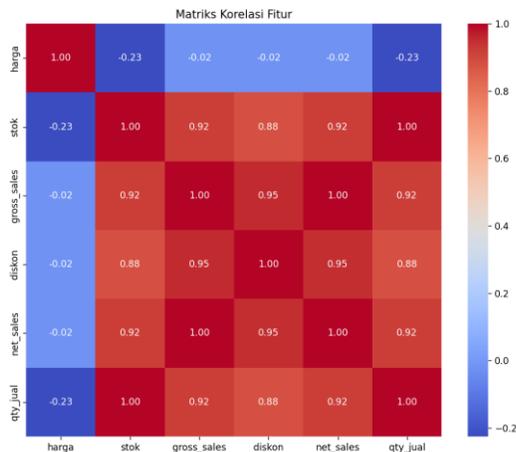
Korelasi matriks fitur merupakan gambaran yang digunakan untuk melihat seberapa kuat hubungan antar fitur yang digunakan dalam model. Pada Gambar 7 ditunjukkan seberapa kuat korelasi antar fitur. Angka dalam setiap sel matriks menunjukkan koefisien korelasi antara dua variabel, nilai berkisar antara -1 hingga 1. Angka yang mendekati 1 menunjukkan korelasi yang positif sedangkan angka yang mendekati 0 menunjukkan korelasi negatif. Berikut keterangan warnanya:

1. Merah tua: Korelasi positif kuat antar fitur, semakin tua warna akan kuat korelasi positifnya.
2. Merah muda: Korelasi positif yang lemah atau tidak signifikan antar fitur.
3. Biru muda: Korelasi negatif yang lemah atau tidak signifikan antar fitur.
4. Biru tua: Korelasi negatif yang kuat antar fitur. Semakin tua warna biru maka semakin kuat korelasi negatifnya.

Analisa korelasi antar fitur sebagai berikut :

1. Harga: Memiliki korelasi negatif dan lemah dengan stok (-0,23), *gross\_sales* (-0,02), diskon (-0,02), *net\_sales* (-0,02), dan *qty\_jual* (-0,23).
2. Stok: Memiliki korelasi positif dan sangat kuat dengan *gross\_sales* (0,92), diskon (0,88), *net\_sales* (0,92), dan *qty\_jual* (1).
3. *Gross\_sales*: Memiliki korelasi positif dan sangat kuat dengan diskon (0,95), *net\_sales* (1), dan *qty\_jual* (0,92).
4. Diskon: Memiliki korelasi positif dan sangat kuat dengan *net\_sales* (0,95) dan *qty\_jual* (0,88).
5. *Net\_sales*: Memiliki korelasi positif dan sangat kuat dengan *qty\_jual* (0,92).
6. Diskon terhadap stok (0,88) lebih kecil dari diskon terhadap *gross\_sales* (0,95) dan *net\_sales* (0,95) karena stok yang cenderung naik tidak diikuti diskon yang tinggi. Hal ini terjadi karena ada pembatasan pembelian dan kondisi diskon untuk produk tertentu.

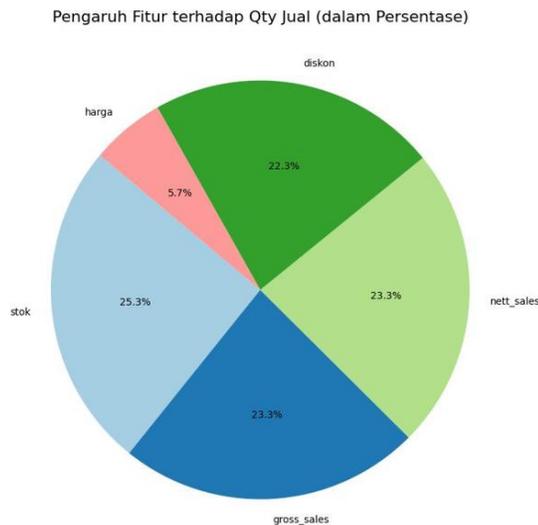
Dari Gambar 14 dapat disimpulkan bahwa stok, *gross\_sales*, diskon, dan *net\_sales* memiliki pengaruh yang sangat besar terhadap kinerja model. Sedangkan harga menunjukkan korelasi yang kurang baik terhadap fitur yang lain.



Gambar 7. Matriks Korelasi Fitur

### Fitur Paling Berpengaruh Dalam Proses Prediksi

Dari hasil prediksi dan korelasi matriks di dapat urutan fitur mana saja yang paling berpengaruh sampai dengan yang tidak berpengaruh. Pada Gambar 8 dapat dilihat persentase pengaruh fitur dari yang paling tinggi sampai yang terendah. Fitur stok memiliki 25,3% pengaruh, kemudian *gross\_sales* dan *net\_sales* masing masing memiliki 23,3% pengaruh, diskon memiliki 22,3% pengaruh, dan harga memiliki pengaruh yang paling kecil yaitu 5,7%.



Gambar 8. Fitur Paling Berpengaruh

## 5. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, penggunaan data historis penjualan per produk dapat digunakan untuk memprediksi penjualan masa mendatang. Penggunaan algoritma LSTM untuk model prediksi dengan tuning parameter dan fitur-fitur seperti stok, harga, gross sales, diskon, dan net sales didapatkan hasil yang sangat akurat. Hal ini dapat terlihat dari evaluasi model menggunakan MAPE yang masuk kedalam kategori sangat akurat berdasarkan tabel kriteria MAPE. Dengan demikian hasil prediksi dapat digunakan sebagai rekomendasi pembelian stok barang ke prinsipal.

## Daftar Pustaka

- [1] D. S. Mera and D. Ernawati, "Penerapan Metode Distribution Requirement Planning Sebagai Upaya untuk Meminimumkan Bullwhip Effect pada Distributor Minyak Goreng (Studi kasus PT. Surya Mandiri Distribusi)," *Jurnal Manajemen Teknologi dan Teknik Industri (JURMATIS)*, vol. 5, no. 1, pp. 22–35, Jan. 2023, doi: 10.30737/jurmatis.v5i1.2530.
- [2] F. Yanti, B. Nurina Sari, S. Defiyanti, K. H. Jl Ronggo Waluyo, and T. Timur, "Implementasi Algoritma LSTM Pada Peramalan Stok Obat (Studi Kasus: Puskesmas Beber)," *Jurnal Mahasiswa Teknik Informatika (JATI)*, vol. 8, no. 4, pp. 6082–6089, Aug. 2024.
- [3] B. Raharjo, *Deep Learning Dengan Phyton*. Semarang: Yayasan Prima Agus Teknik, 2022. Accessed: Nov. 22, 2024. [Online]. Available: <https://digilib.stekom.ac.id/ebook/view/deep-learning-dengan-python>
- [4] E. S. Putri and M. Sadikin, "Prediksi Penjualan Produk Untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA," *Jurnal Teknik Informatika*, vol. 10, no. 2, pp. 162–171, 2021.
- [5] F. C. Yulianto and N. Latifah, "Peramalan Penjualan Laptop Menggunakan Metode Long Short Term Memory (LSTM)," *Jurnal Fasilkom*, vol. 14, no. 2, pp. 428–436, Aug. 2024, doi: <https://doi.org/10.37859/jf.v14i2.7337>.

- [6] Anita, A. Wicaksono, and T. N. Padilah, "Pengaruh Jumlah Record Dataset Terhadap Algoritma Klasifikasi Berdasarkan Data Customer Churn," *Jurnal Ilmiah Informatika*, vol. 6, no. 1, pp. 1–10, Jun. 2021, doi: 10.35316/jimi.v6i1.1223.
- [7] I. Gede Iwan Sudipa *et al.*, *Data Mining*. Padang: PT Global Eksekutif Teknologi, 2023. Accessed: Jan. 06, 2025. [Online]. Available: <https://repository.uinjkt.ac.id/dspace/handle/123456789/71093>
- [8] F. Riza, "Analisis dan Prediksi Data Penjualan Menggunakan Machine Learning dengan Pendekatan Ilmu Data," *Data Sciences Indonesia (DSI)*, vol. 1, no. 2, pp. 62–68, Jan. 2022, doi: 10.47709/dsi.v1i2.1308.
- [9] S. A. Pranoto and N. Majid, "Strategi Integrasi Data : Analisis Data Digital Dan Hard File Dalam Proses Monitoring Tagihan Kesehatan & Kesejahteraan Pegawai Dan Pensiunan PT PLN (Persero) Jawa Timur," *Jurnal Ekonomi & Bisnis (Ekbis)*, vol. 12, no. 2, pp. 196–201, Dec. 2024, doi: <https://doi.org/10.56689/ekbis.v12i2.1493>.
- [10] B. Raharjo, *Sistem Manajemen Database*. Semarang: Yayasan Prima Agus Teknik, 2021. Accessed: Mar. 12, 2025. [Online]. Available: [https://digilib.stekom.ac.id/assets/dokumen/ebook/feb\\_359c7c4e0f24927791ebf52cc3389d4ca536325b\\_1653034131.pdf](https://digilib.stekom.ac.id/assets/dokumen/ebook/feb_359c7c4e0f24927791ebf52cc3389d4ca536325b_1653034131.pdf)
- [11] Baiq Nurul Azmi, Arief Hermawan, and Donny Avianto, "Analisis Pengaruh Komposisi Data Training dan Data Testing pada Penggunaan PCA dan Algoritma Decision Tree untuk Klasifikasi Penderita Penyakit Liver," *Jurnal Teknologi Informasi dan Multimedia (JTIM)*, vol. 4, no. 4, pp. 281–290, Feb. 2023, doi: 10.35746/jtim.v4i4.298.
- [12] F. Fadzlul Rahman and H. Saputra, *Artificial Intelligence dalam Pelayanan Kesehatan*. Selayo: Mitra Cendekia Media, 2023.
- [13] D. Rizkya, H. Roosaputri, and C. Dewi, "Perbandingan Algoritma ARIMA, Prophet, dan LSTM dalam Prediksi Penjualan Tiket Wisata Taman Hiburan (Studi Kasus: Saloka Theme Park)," vol. 4, no. 3, pp. 507–517, Jul. 2022.
- [14] Nendi Sunendar, Harjono P. Putro, and Rizki Hesnananda, "Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU," *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 4, no. 1, pp. 113–126, Feb. 2025, doi: 10.55123/insologi.v4i1.4868.
- [15] G. Budiprasetyo, M. Hani'ah, and D. Z. Aflah, "Prediksi Harga Saham Syariah Menggunakan Algoritma Long Short-Term Memory (LSTM)," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 3, pp. 164–172, Jan. 2022, doi: 10.25077/teknosi.v8i3.2022.164-172.
- [16] D. I. Puteri, "Implementasi Long Short Term Memory (LSTM) dan Bidirectional Long Short Term Memory (BiLSTM) Dalam Prediksi Harga Saham Syariah," *Euler: Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 1, pp. 35–43, May 2023, doi: 10.34312/euler.v11i1.19791.
- [17] A. Ahmad, W. Gata, and S. Panggabean, "Sentimen Analisis dengan Long Short-Term Memory dan Synthetic Minority Over Sampling Technic Pada Aplikasi Digital Perbankan," *Jurnal Teknologi Informasi dan Komunikasi*, vol. 8, no. 4, pp. 973–984, Jul. 2024, doi: 10.35870/jti.