

Penggunaan LSTM dalam Membangun Prediksi Penjualan untuk Aplikasi Laptop Lens

Ghuftron Tamami¹, Muhammad Arifin²

¹Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus

²Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus

¹202153111@std.umk.ac.id*, ²arifin.m@umk.ac.id

Abstract

Laptops are important tools that support flexibility and productivity in the business world, especially in the field of effective stock management. Sales forecasting is a main aspect in stock management, and this forecasting can help companies determine future strategies to remain competitive. Effective stock management is very important to ensure product availability in accordance with market demand trends, this can help companies maintain their competitive advantage. This research aims to test the Long Short-Term Memory (LSTM) model in forecasting sales by utilizing data in time series format. The forecasting results will later be categorized into three categories, namely low-end, mid-end and high-end. This division into categories will help a company make strategic decisions. The evaluation results show quite varied performance in each category. In the low-end category, the model achieved a Root Mean Square Error (RMSE) of 91.2161 and an R-squared (R²) of 0.8247, indicating a loss rate of 91 units with a variation of 82.47% from sales data. For the mid-end category, the model shows excellent performance with an RMSE of 22.3920 and an R² of 0.9890, indicating a loss rate of 22 units and a variation of 98.90%. In the high-end category, the model achieved an RMSE of 96.8210 and an R² of 0.8432, with a loss rate of 96 units and a variation of 84.32%. This research shows that the LSTM model is effective in predicting sales trends in all price categories, so it can help companies in stock management and more strategic marketing planning.

Keywords: laptop, LSTM, sales, data, prediction

Abstrak

Laptop adalah alat penting yang mendukung fleksibilitas dan produktivitas dalam dunia bisnis, terutama pada bidang manajemen pengelolaan stok barang yang efektif. Peramalan penjualan menjadi aspek utama dalam melakukan manajemen stok barang, dan peramalan ini dapat membantu perusahaan untuk menentukan strategi masa depan agar tetap dapat bersaing. Pengelolaan stok barang yang efektif sangat penting untuk memastikan ketersediaan produk sesuai dengan tren permintaan pasar, hal ini dapat membantu perusahaan untuk tetap mempertahankan keunggulan kompetitif mereka. Penelitian ini bertujuan untuk menguji model *Long Short-Term Memory (LSTM)* dalam melakukan peramalan penjualan dengan memanfaatkan data dengan format *time series*. Hasil peramalan nantinya akan dikategorikan menjadi tiga kategori, yaitu *low-end*, *mid-end* dan *high-end*. Pembagian kategori ini akan membantu keputusan suatu perusahaan yang bersifat strategis. Hasil evaluasi menunjukkan performa yang cukup bervariasi di setiap kategori. Pada kategori *low-end*, model mencapai *Root Mean Square Error (RMSE)* sebesar 91.2161 dan *R-squared (R²)* sebesar 0.8247, menunjukkan tingkat loss 91 unit dengan variasi 82.47% dari data penjualan. Untuk kategori *mid-end*, model menunjukkan performa sangat baik dengan *RMSE* sebesar 22.3920 dan *R²* sebesar 0.9890, menandakan tingkat loss 22 unit dan variasi 98.90%. Pada kategori *high-end*, model mencapai *RMSE* sebesar 96.8210 dan *R²* sebesar 0.8432, dengan tingkat loss 96 unit dan variasi 84.32%. Penelitian ini menunjukkan bahwa model *LSTM* efektif dalam memprediksi tren penjualan di semua kategori harga, sehingga dapat membantu perusahaan dalam manajemen stok dan perencanaan pemasaran yang lebih strategis.

Kata kunci: laptop, LSTM, penjualan, data, prediksi

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Laptop merupakan salah satu alat yang dapat menunjang aktivitas kerja, dengan desain yang compact dan dapat dibawa kemana saja, sehingga memberikan kesan fleksibilitas kepada para penggunanya. Laptop juga membantu untuk memecahkan masalah dan pengolahan data baik pada perkantoran ataupun perusahaan [1]. Dalam dunia bisnis modern terutama *e-business*, laptop menjadi alat yang mendukung produktivitas yang sangat penting di berbagai aspek strategis suatu perusahaan.

Dalam penerapan strategi pemasaran, cara menarik minat pelanggan, komunikasi dengan pelanggan dan

pemasok, jangkauan pasar yang sangat luas, serta pentingnya pengelolaan stok barang dan distribusi produk menjadi hal yang sangat perlu diperhatikan untuk menunjang strategi pemasaran suatu produk. Khususnya dalam *e-business*, pengelolaan stok barang didasari pada analisis struktur pasar, dengan mengamati perkembangan tren barang di pasar tertentu. Pengelolaan stok barang menjadi sangat penting, karena membantu pelaku usaha untuk memastikan ketersediaan suatu produk sesuai permintaan pasar [2]. Manajemen stok barang menjadi inti strategi yang membantu pelaku usaha membentuk dan mempertahankan keunggulan kompetitif mereka.

Akan tetapi, terdapat sebuah permasalahan yang

memiliki dampak pada pengelolaan stok yaitu ketidakpastian permintaan pasar [3]. Ketidakpastian ini dapat mengakibatkan *over stock* atau *less stock* bagi para penjual laptop, hal ini dapat mengakibatkan kerugian karena tren pasar yang berubah. Oleh karena itu diperlukan sebuah *platform* yang dapat meramalkan tren penjualan laptop yang efektif agar para penjual laptop dapat melakukan manajemen stok barang dengan lebih efisien.

Peramalan merupakan sumber informasi yang dapat menentukan strategi ke depan yang lebih baik untuk suatu perusahaan. Peramalan penjualan akan menjadi langkah suatu perusahaan untuk bersaing dan meningkatkan laba perusahaan, peramalan ini melibatkan perbedaan waktu antara sekarang dengan masa lalu [4]. Salah satu metode *data mining* yang dapat digunakan untuk peramalan ini adalah *Long Short-Term Memory (LSTM)*.

LSTM adalah turunan dari *Recurrent Neural Network (RNN)* yang dapat memprediksi data *time series* dengan cukup efektif. *RNN* dapat mengolah *dataset* berukuran besar, tetapi terdapat masalah yaitu adanya *vanishing gradient*. Untuk mengatasinya digunakan vektor regresi untuk memungkinkan prediksi waktu yang lebih akurat. Peramalan dengan *LSTM* bertujuan untuk mengurangi kesalahan prediksi, dengan menggunakan indikator *Root Mean Squared Error (RMSE)*. Berikut disajikan beberapa penelitian terdahulu yang menggunakan metode prediksi *LSTM* di bawah ini.

Pertama, penelitian yang telah dilakukan oleh Marie Luthfi Ashari dan Mujiono Sadiki mengenai prediksi data transaksi penjualan perusahaan farmasi [5]. Masalah dalam kasus ini adalah memprediksi penjualan obat di masa depan dengan menggunakan data penjualan tiga tahun yaitu tahun 2017, 2018 dan 2019. Metode yang digunakan dalam prediksi ini adalah dengan Regresi *LSTM* untuk mengetahui nilai *Root Mean Squared Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)*. Hasil prediksi dari Regresi *LSTM* pada penelitian ini adalah 286.465.424 untuk data training dan 187.013.430 untuk data testing. Sedangkan hasil *MAPE* sebesar 787% dan 309% untuk data training dan data testing secara berurutan. Pada penelitian ini menunjukkan prediksi *LSTM* dapat diterima tetapi masih diperlukan peningkatan model dikarenakan nilai *MAPE* yang cukup tinggi.


Kedua, perbandingan algoritma *machine learning* yang dilakukan oleh Amalia Kurniawati, dkk. Penelitian tentang perbandingan algoritma *LSTM* dan algoritma *ARIMA* pada prediksi penjualan produk untuk estimasi bahan baku *frozen food* yang digunakan sebagai tolak ukur algoritma [6]. Dalam penelitian ini menggunakan data penjualan harian dari objek penelitian tersebut. Hasil penelitian menunjukkan bahwa metode *LSTM* lebih unggul dari metode *ARIMA*. Dengan hasil rata-rata *RMSE* metode *LSTM* adalah 0,22 dan rata-rata metode *ARIMA* adalah 60,21. Sedangkan hasil *MAPE* menghasilkan rata-rata metode *LSTM* adalah 29,57%

dan rata-rata metode *ARIMA* adalah 73%. Dapat disimpulkan bahwa penggunaan metode *LSTM* sangat efektif karena memiliki akurasi yang lebih tinggi untuk kasus ini.

Penelitian ini bertujuan untuk mengembangkan dan menguji model prediksi dengan menggunakan *Long Short-Term Memory (LSTM)* pada kasus manajemen stok laptop. Penelitian ini juga mengevaluasi performa *LSTM* untuk beberapa pengkategorian jenis laptop. Penelitian ini diharapkan memberikan hasil yang baik untuk peramalan penjualan dengan metode *LSTM*.

2. Metode Penelitian

Metode penelitian ini menggunakan pendekatan data kuantitatif dengan desain eksperimental. Data penjualan historis akan digunakan untuk melatih dan menguji model *LSTM*. Desain penelitian ini mencakup beberapa tahapan-tahapan seperti pada gambar 2.1. Data bersumber dari data penjualan laptop di suatu *online shop* di Indonesia dengan harga yang bervariasi. Data tersebut akan diproses untuk menghasilkan sebuah label baru yang akan digunakan sebagai pengkategorian jenis laptop berdasarkan harga laptop tersebut.

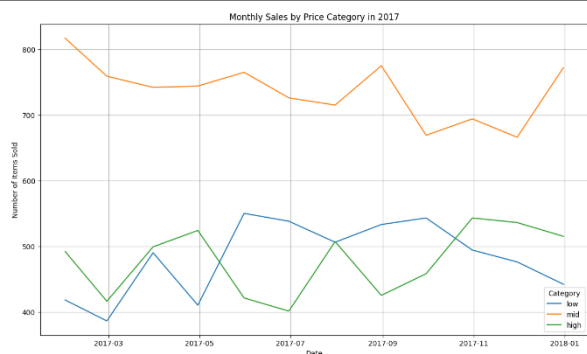


Gambar 1. Tahapan Penelitian

2.1. Dataset

Penelitian ini menggunakan *dataset* penjualan tahunan yang bersumber dari *platform open source Kaggle* (<https://www.kaggle.com/datasets/artakusuma/laptope-commerce>).

Penjualan laptop dengan rentang waktu 2013 sampai 2017 dari *platform online shop* berjumlah 102.655 data yang terdiri dari harga laptop yang bervariasi. Pada penelitian ini dilakukan *sampling* dengan menggunakan data penjualan tahun 2017, sehingga total data yang akan digunakan sejumlah 20.367 data penjualan laptop. Data ini akan dibagi menjadi beberapa kategori: harga < Rp. 8.000.000 adalah *low*, harga < Rp. 16.000.000 adalah *mid* dan harga > Rp. 16.000.000 adalah *high*. Tren penjualan dari tiap kategori laptop tersebut selama tahun 2017 dapat dilihat pada gambar 2berikut.



Gambar 2. Pembagian *Dataset* Penjualan Laptop

Berdasarkan gambar 2 tersebut menunjukkan bahwa grafik *history* 3 bulanan pada penjualan laptop, yang selalu mengalami perubahan tren setiap bulannya. Dengan penjualan laptop kategori *mid* adalah yang tertinggi dengan total 8.844 laptop terjual, diikuti dengan kategori *low* sebanyak 5.786 laptop dan kategori *high* dengan total penjualan yaitu 5.737 laptop.

2.2. Preprocessing Data

Setelah data yang diperlukan sudah terkumpul dan telah diidentifikasi, maka tahapan selanjutnya adalah tahapan *preprocessing data*. *Preprocessing data* merupakan langkah yang sangat penting dalam pembuatan model *LSTM*, karena hal ini dapat mempengaruhi hasil akhir analisis prediksi secara signifikan [7]. Pada tahap *preprocessing data* ini dilakukan langkah-langkah *cleaning data*, normalisasi data dan transformasi data.

2.2.1. Cleaning Data

Cleaning data diperlukan agar data yang akan diolah dapat dimanfaatkan dengan baik dan memastikan data tersebut berkualitas [8]. Pada tahapan ini akan dilakukan pembersihan data untuk mengatasi permasalahan *missing value*, *null value* dan *noise* pada *dataset* [9].

2.2.2. Transformasi Data

Pada tahapan ini, data akan ditransformasikan untuk mengubah nilai atribut awal pada *dataset* menjadi nilai atribut yang sesuai dengan kebutuhan data pada proses pengolahan menggunakan model *LSTM* [10]. Data akan dinormalisasikan agar semua data akan memiliki panjang rentang yang sama dan memudahkan model untuk belajar dengan efektif [11].

Metode normalisasi yang digunakan pada penelitian ini adalah *Min-Max Scalling* menggunakan *library python*, *scikit learn* dan *MinMaxScaler*. Perubahan nilai pada *Min-Max Scalling* dapat dihitung menggunakan rumus persamaan berikut :

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dimana x' adalah hasil normalisasi data, sedangkan x_i adalah data yang akan dinormalisasi. x_{max} dan x_{min} adalah data terbesar dan data terkecil dari keseluruhan *dataset*.

2.2.3. Pembagian *Dataset Training* dan *Testing*

Data yang telah diproses akan dibagi menjadi dua data, yaitu data *training* dan data *testing*. Data *training* akan digunakan untuk melatih model *LSTM*, sedangkan data *testing* akan digunakan untuk menguji performa model *LSTM*. Pembagian dilakukan dengan menggunakan data penjualan tahun 2017 yang telah diproses, dengan proporsi 80% untuk data *training* dan 20% untuk data *testing*.

2.3. Pemilihan Atribut

Untuk menghasilkan performa model yang baik dari suatu prediksi dapat dilakukan dengan meningkatkan proses pemilihan *variable* pada *dataset* [12].

Berikut adalah tahapan proses pemilihan *attribute* pada penelitian ini, yaitu :

2.3.1. Selected Attribute

Pada penelitian ini, variabel yang relevan adalah *date* dan *sales*, yang akan digunakan untuk analisis penjualan laptop. Karena penjualan berhubungan dengan tren dari waktu-waktu tertentu, maka dapat difokuskan dengan metode *time series analysis* [13]. Salah satu teknik yang akan digunakan pada penelitian ini adalah *Autocorrelation Function (ACF)*, untuk mengidentifikasi observasi *time series* dengan *lag* yang berbeda.


Tabel 1. Selected Attribute

No	Attribute	Keterangan
1	Date	Tanggal laptop terjual
2	Sales	Jumlah laptop yang terjual

2.4. Long Short-Term Memory (LSTM)

Penelitian ini menggunakan model jaringan saraf *Long Short-Term Memory (LSTM)* untuk memprediksi penjualan mingguan berdasarkan kategori harga. Setiap kategori harga akan diolah secara terpisah, data mingguan dikumpulkan dan selisih penjualan mingguan dihitung untuk membuat data dapat diolah oleh model *LSTM* [14].

Model *LSTM* yang digunakan memiliki arsitektur dengan 1 *input*, 2 *output* dan 2 *hidden layers*. Lapisan pertama *LSTM* memiliki 200 unit, diikuti dengan lapisan *dropout* dengan tingkat *dropout* sebesar 30%, dan lapisan *LSTM* kedua memiliki 100 unit. Model ini dilatih menggunakan *optimizer 'adam'* dan *loss function Mean Squared Error (MSE)*, dengan maksimum *epoch* adalah 200. Pada gambar 3 merupakan contoh dari ilustrasi *LSTM* dengan dua *hidden layer*.



Gambar 3. Ilustrasi Arsitektur *LSTM* Dengan Dua *Hidden Layer*

2.5. Evaluasi Model

Prediksi ini dilakukan pada *testing data*, dan hasil prediksinya akan dibandingkan dengan nilai *actual*

data untuk menghitung *Root Mean Squared Error (RMSE)* dan *R² Score*.

2.5.1. Mean Squared Error (MSE)

Pendekatan *MSE* akan mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan tersebut nantinya akan dikuadratkan untuk mengevaluasi kinerja model regresi. *MSE* akan menghitung rata-rata selisih dari selisih kuadrat antara *actual data* dan *prediction data* [12]. Berikut adalah rumus perhitungan *MSE* :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Dimana *n* adalah jumlah sampel, sedangkan *y_i* adalah *actual data* dan *ŷ_i* adalah *prediction data*. Semakin kecil nilai *MSE*, maka kinerja model akan sangat baik dalam melakukan prediksi data.

2.5.2. Root Mean Squared Error (RMSE)

RMSE akan memberikan informasi terkait seberapa dekat prediksi yang dihasilkan dengan *actual data* [15]. Berikut adalah rumus perhitungannya :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

Dimana *n* adalah jumlah sampel, sedangkan *y_i* adalah *actual data* dan *ŷ_i* adalah *prediction data*. Semakin kecil nilai *RMSE*, maka kinerja model akan sangat baik dalam melakukan prediksi data.

2.5.3. R² Score

R² Score atau koefisien determinasi adalah ukuran statistik regresi untuk menilai seberapa baik model memprediksi suatu nilai data. *R² Score* didapat dengan cara membagi varians pada model dengan total varians [16]. Berikut rumus perhitungan *R² Score*, yaitu :

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Dimana *n* adalah jumlah sampel, sedangkan *y_i* adalah *actual data*, lalu *ŷ_i* adalah *prediction data* dan *ȳ* adalah nilai rata-rata dari *actual data*. *R² Score* akan memberikan informasi tentang sejauh mana nilai yang diamati dengan nilai yang diprediksi dalam model regresi ini [15].

2.6. Tools

Pada penelitian ini digunakan beberapa alat bantu untuk mempermudah proses pengembangan model *LSTM*. Berikut adalah penjelasan dari tiap *tools* yang digunakan.

2.6.1. Python

Python adalah bahasa pemrograman yang digunakan untuk mengembangkan model pada penelitian ini, *python* mendukung *library* yang sangat cocok untuk analisis data.

2.6.2. Google Colab

Google Colab adalah layanan berbasis *cloud* untuk menjalankan kode dalam format *Jupyter Notebook* dengan akses ke GPU secara gratis untuk menjalankan model *machine learning* yang dikembangkan.

2.6.3. Kaggle

Kaggle adalah *platform* yang menyediakan *dataset* publik secara *open source*, data dari *platform* ini akan dianalisis oleh model *machine learning*.

2.6.4. Pandas

Pandas adalah *library Python* yang akan digunakan untuk memanipulasi dan menganalisis data pada *dataset* tabular.

2.6.5. NumPy

NumPy adalah *library Python* yang mendukung data *array* dan matriks yang besar, serta fungsi matematika untuk operasi data *array* pada penelitian ini.

2.6.6. Scikit Learn

Scikit Learn adalah *library machine learning* yang digunakan untuk memproses data, algoritma pembelajaran mesin dan evaluasi model pada penelitian ini.

2.6.7. Tensorflow dan Keras

Tensorflow adalah *library open source* untuk membuat model *machine learning*. Sedangkan *Keras* adalah bagian dari *tensorflow* yang menggunakan *API* untuk membangun dan melatih model jaringan saraf.

2.6.8. Matplotlib

Matplotlib adalah *library* yang digunakan untuk memvisualisasikan data hasil *machine learning* dalam bentuk grafik dan plot.

2.6.9. TensorflowJS

Model yang telah dilatih akan disimpan kedalam format *TensorflowJS*. Pendekatan ini akan memastikan bahwa model yang telah dihasilkan dapat diterapkan ke berbagai *platform* dan memudahkan integrasi dengan aplikasi berbasis web [17].

3. Hasil dan Pembahasan

3.1. Gathering Dataset

Dataset yang telah dikumpulkan terdapat 4 atribut yang merupakan data penjualan laptop tahun 2013 sampai 2017 dengan jumlah 102.655 data. Pada gambar 3.1 merupakan tampilan hasil pengumpulan *dataset*. Pada *dataset* ini nantinya akan melalui proses pemilahan pada tahapan *preprocessing data* untuk menggunakan data penjualan tahun 2017.

Gambar 4. Hasil Pengumpulan Data

3.2. Preprocessing Data

Preprocessing data merupakan tahapan yang sangat krusial dalam penelitian ini. Data yang telah dikumpulkan akan disiapkan secara baik agar dapat diolah dengan efisien melalui beberapa tahapan berikut.

3.2.1. Cleaning Data

Cleaning data adalah langkah pertama preprocessing. Tahapan ini mencakup langkah proses penghapusan duplikat, menangani missing values dan outlier. Serta pada tahapan ini dataset akan dipilah agar menampilkan data tahun 2017 saja. Dengan menggunakan library pandas permasalahan tersebut dapat diselesaikan. Berikut hasil cleaning data yang ditampilkan pada gambar 5 ini.

Gambar 5. Hasil Cleaning Data

3.2.2. Transformasi Data

Pada tahapan ini data akan dipisah menjadi tiga kategori harga yaitu low-end, mid-end dan high-end. Ketiga kategori tersebut akan menjadi label baru yaitu category pada dataset. Berikut adalah hasil penambahan label baru yang ditunjukkan pada gambar 6 ini.

Gambar 6. Pembuatan Label Category

Kemudian dengan menggunakan rumus *min-max scalling* pada rumus 1, maka diperoleh hasil normalisasi data seperti pada tabel 2 berikut.

Tabel 2. Normalisasi Data

Tanggal	Normalisasi
2017-01-01	0.244676
2017-01-02	0.010421
2017-01-03	0.072950
2017-01-04	0.092886
⋮	⋮
2017-12-28	0.207975
2017-12-29	0.273222
2017-12-30	0.304939
2017-12-31	0.399638

3.2.3. Pembagian Data Training dan Testing

Dataset yang telah dilakukan preprocessing akan dibagi dengan proporsi data training sebanyak 80% dan data testing sebanyak 20%. Pembagian dataset dapat dilihat pada tabel 3.1 berikut.

3.3. Pemilihan Attribute

Proses pemodelan LSTM dengan selected variable yaitu date dan sales dengan menggunakan metode autocorrelation function (ACF) untuk mengevaluasi pengaruh variabel terhadap target prediksi. Berikut adalah hasil ACF dengan library pandas yang ditunjukkan pada tabel 3 ini.

Tabel 3. Nilai ACF Variabel Dataset

No	Variabel	Nilai	Tanda
1	Lag 1	0.126298	Positif
2	Lag 2	0.094562	Positif
3	Lag 3	0.108412	Positif
4	Lag 4	0.106929	Positif
5	Lag 5	0.120142	Positif
6	Lag 6	0.100058	Positif

Berdasarkan hasil ACF pada tabel 3 tersebut, menunjukkan bahwa semua nilai memiliki korelasi yang positif antara nilai penjualan pada suatu waktu dengan nilai penjualan di waktu sebelumnya.

3.4. LSTM Model Development

Pada tahapan ini dilakukan pembuatan model LSTM dan melatihnya dengan data yang telah di proses sebelumnya. Pada penelitian ini akan menggunakan selected variable yaitu date dan sales.

Setelah tahapan preprocessing data, maka akan dibuat regularisasi dengan inputan hyperparameter yang telah

disesuaikan agar performa model menjadi baik. Berikut *inputan hyperparameter* yang telah disesuaikan seperti pada tabel 4 ini.

Tabel 4. *Hyperparameter* Pemodelan

No	Jenis	Nilai/Uraian
1	Units Layer 1	200
2	Dropout	0.3
3	Activation	Tanh
4	Units Layer 2	100
5	Dense Units	1
6	Optimizer	Adam
7	Loss Function	MSE
8	Epochs	200
9	Batch	16
10	Validation Split	4

Proses pemodelan pada *dataset* dijalankan dengan melakukan *split dataset*, yaitu 80% untuk *training data* dan 20% untuk *testing data*. *Training data* akan digunakan untuk melatih model *LSTM*. Kemudian hasil *training* tersebut akan diuji dengan *testing data*, sebagai bentuk evaluasi performa model *machine learning*.

Pada penelitian ini proses pemodelan *LSTM* menggunakan dua *hidden layer* untuk mendapatkan hasil pemodelan yang lebih baik.

3.5. Evaluasi Model

Pada tahapan ini model yang telah dibuat akan dievaluasi dengan *loss function RMSE* dan *R² Score* untuk mengetahui performa model *machine learning* yang telah dikembangkan. Tiap kategori model yaitu *low-end*, *mid-end* dan *high-end* akan dievaluasi sesuai parameter yang telah digunakan sebagai *nput*. Berikut adalah evaluasinya.

1. Evaluasi Model *Low-End*

Model *low-end* ini akan memproses prediksi untuk laptop dengan harga di bawah 8 juta. Berikut adalah hasil perhitungan *RMSE* dan *R² Score* untuk kategori *low-end* yang ditunjukkan pada tabel 5. ini.

Tabel 5. Hasil Evaluasi Model *Low-End*

Kategori	MSE	RMSE	R ² Score
<i>Low-End</i>	8320.3809	91.2161	0.8247

Berdasarkan tabel 5 tersebut, hasil *RMSE* sebesar 91,2161 menunjukkan bahwa model memiliki tingkat *loss* sebesar 91 unit dalam prediksi kategori *low-end*, yang berarti performa model untuk kategori ini cukup baik. Sedangkan *R² Score* sebesar 0.8247 yang berarti bahwa model memiliki variasi sekitar 82,4% dari data penjualan pada kategori ini.

2. Evaluasi Model *Mid-End*

Model *mid-end* ini akan memproses prediksi untuk laptop dengan harga di antara 8 juta sampai 16 juta. Berikut adalah hasil perhitungan *RMSE* dan *R² Score* untuk kategori *mid-end* yang ditunjukkan pada tabel 6. ini.

Tabel 6. Hasil Evaluasi Model *Mid-End*

Kategori	MSE	RMSE	R ² Score
<i>Mid-End</i>	501.3998	22.3920	0.9890

Berdasarkan tabel 6 tersebut, hasil *RMSE* sebesar 22,3920 menunjukkan bahwa model memiliki tingkat *loss* sebesar 22 unit dalam prediksi kategori *mid-end*, yang berarti performa model sangat baik ketika memprediksi kategori ini. Sedangkan *R² Score* sebesar 0.9890 yang berarti bahwa model memiliki akurasi variasi sekitar 98,9% dari data penjualan pada kategori ini.

3. Evaluasi Model *High-End*

Model *high-end* ini akan memproses prediksi untuk laptop dengan harga di atas 16 juta. Berikut adalah hasil perhitungan *RMSE* dan *R² Score* untuk kategori *high-end* yang ditunjukkan pada tabel 7 ini.

Tabel 7. Hasil Evaluasi Model *High-End*

Kategori	MSE	RMSE	R ² Score
<i>High-End</i>	9374.3096	96.8210	0.8432


Berdasarkan tabel 7 tersebut, hasil *RMSE* sebesar 96,8210 menunjukkan bahwa model memiliki tingkat *loss* sebesar 38 unit dalam prediksi kategori *high-end*, yang berarti performa model cukup baik ketika memprediksi kategori ini. Sedangkan *R² Score* sebesar 0.8432 yang berarti bahwa model memiliki akurasi variasi sekitar 84,3% dari data penjualan pada kategori ini.

3.6. Result Analysis

Berdasarkan hasil evaluasi yang telah dilakukan sebelumnya, dapat diketahui bahwa performa model prediksi *machine learning LSTM* berjalan cukup baik dengan nilai *RMSE* yang cukup kecil dan nilai *R² Score* yang mendekati angka 1. Berikut adalah hasil analisis dari ketiga kategori model yang telah dikembangkan.

1. Model *Low-End*

Berikut adalah grafik hasil prediksi kategori *low-end* yang ditunjukkan pada gambar 7 ini.




Gambar 7. Hasil Prediksi *Low-End*

Berdasarkan nilai *RMSE* yaitu 91,2161 dan *R² Score* yaitu 0,8247. Dapat disimpulkan bahwa model menunjukkan performa yang cukup baik, dengan variasi yang cukup baik.

2. Model *Mid-End*

Berikut adalah grafik hasil prediksi kategori *mid-end* yang ditunjukkan pada gambar 8 ini.




Gambar 8. Hasil Prediksi *Mid-End*

Berdasarkan nilai *RMSE* yaitu 22,3920 dan *R² Score* yaitu 0,9890. Dapat disimpulkan bahwa model menunjukkan performa yang sangat baik, dengan variasi yang sangat baik hingga mendekati angka 1. Sehingga prediksi pada kategori sangat akurat.

3. Model *High-End*

Berikut adalah grafik hasil prediksi kategori *low-end* yang ditunjukkan pada gambar 9 ini.



Gambar 9. Hasil Prediksi *High-End*

Berdasarkan nilai *RMSE* yaitu 96,8210 dan *R² Score* yaitu 0,8432. Dapat disimpulkan bahwa model menunjukkan performa yang cukup baik sama seperti model *low-end*, dengan variasi yang cukup baik.

4. Kesimpulan

Dalam penelitian ini, *Long Short-Term Memory (LSTM)* diimplementasikan pada *dataset* penjualan *e-commerce* laptop tahun 2017 untuk memprediksi tren penjualan di masa depan. Prediksi dilakukan pada tiga kategori harga, yaitu *low-end*, *mid-end* dan *high-end*. Hasil evaluasi menunjukkan performa model yang berbeda di tiap kategorinya, dengan hasilnya adalah sebagai berikut:

1. Model *Low-End*

Hasil evaluasi menunjukkan bahwa model memiliki tingkat *loss* mencapai 91 unit dan memiliki variasi 82,4% dalam data penjualan kategori ini. Hal ini berarti performa model cukup baik untuk memprediksi penjualan laptop di rentang harga kurang dari 8 juta rupiah.

2. Model *Mid-End*

Hasil evaluasi menunjukkan bahwa model memiliki tingkat *loss* mencapai 22 unit dan memiliki variasi 98,9% dalam data penjualan kategori ini. Hal ini berarti performa model sangat baik dan sangat akurat untuk memprediksi penjualan laptop di rentang antara 8 juta hingga 16 juta rupiah.

3. Model *High-End*

Hasil evaluasi menunjukkan bahwa model memiliki tingkat *loss* mencapai 96 unit dan memiliki variasi

84,3% dalam data penjualan kategori ini. Hal ini berarti performa model cukup baik untuk memprediksi penjualan laptop di rentang harga lebih dari 16 juta rupiah.

Dari ketiga hasil evaluasi tersebut, dapat disimpulkan bahwa model *LSTM* memiliki hasil prediksi yang baik untuk semua kategori harga. Penelitian ini menunjukkan bahwa penggunaan metode *LSTM* akan membantu perusahaan dalam melakukan manajemen stok dan perencanaan pemasaran yang lebih informatif dan strategis.

Akan tetapi, perlu diketahui juga bahwa tren penjualan dapat tiba-tiba berubah dikarenakan beberapa faktor eksternal yang tidak bisa diprediksi. Oleh karena itu, perusahaan perlu untuk membuat *backup planning* agar dapat tetap bertahan pada saat perubahan pasar yang tiba-tiba. Berdasarkan kekurangan itu untuk meningkatkan akurasi prediksi, penelitian selanjutnya bisa mempertimbangkan untuk menggunakan data tambahan agar hasil prediksi bisa lebih akurat

Daftar Rujukan

- [1] F. Wiranto, H. Latipa Sari, and L. Elfianty, "Penerapan Metode Semi Average Dalam Peramalan Penjualan Laptop Di Toko Big Computer," *J. Sci. Soc. Res.*, vol. 4307, no. 3, pp. 796–806, 2023, [Online]. Available: <http://jurnal.goretanpena.com/index.php/JSSR>
- [2] M. Zhan, H. Gao, H. Liu, Y. Peng, D. Lu, and H. Zhu, "Identifying market structure to monitor product competition using a consumer-behavior-based intelligence model," *Asia Pacific J. Mark. Logist.*, vol. 33, no. 1, pp. 99–123, 2021, doi: 10.1108/APJML-08-2019-0497.
- [3] S. N. R. Sika and Putri Aisyiyah Rakhma devi, "Sistem Informasi Persediaan Stok Barang Berbasis Web Pada Toko Putra Gresik," *J. Fasilkom*, vol. 11, no. 3, pp. 157–164, 2021, doi: 10.37859/jf.v11i3.3163.
- [4] R. C. N. Sugiraharjo, S., & Santi, "8341-25287-1-Pb," vol. 7, no. 1, 2021.
- [5] M. L. Ashari and M. Sadikin, "Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi Lstm," *J. Nas. Pendidik. Tek. Inform.*, vol. 9, no. 1, p. 1, 2020, doi: 10.23887/janapati.v9i1.19140.
- [6] P. Studi, T. Informatika, F. I. Komputer, and U. M. Buana, "https://lib.mercubuana.ac.id/," 2020.
- [7] I. M. Hamdani, A. Karman, N. F. A. H, and A. Hermina, "INTISARI Jurnal Inovasi Pengabdian Masyarakat Edukasi dan Pelatihan Data Science dan Data Preprocessing," vol. 2, pp. 19–26, 2024, doi: 10.58227/intisari.v2i1.125.
- [8] I. Hidayat, A. I. Tolago, R. D. R. Dako, and J. Ilham, "Analisis Data Eksploratif Capaian Indikator Kinerja Utama 3 Fakultas Teknik," *Jambura J. Electr. Electron. Eng.*, vol. 5, no. 2, pp. 185–191, 2023, doi: 10.37905/jjee.v5i2.18397.
- [9] H. Mukhtar, Y. Rizki, F. A. Wenando, and M. Abdul Al Aziz, "Prediksi Kunjungan Wisatawan Ke Indonesia Dengan Reduksi Noise Pada Mesin Pencari Menggunakan Metode Hilbert Huang Transform," *J. Fasilkom*, vol. 12, no. 3, pp. 152–159, 2022, doi: 10.37859/jf.v12i3.4332.
- [10] C. Nas, "Data Mining Prediksi Minat Calon Mahasiswa Memilih Perguruan Tinggi Menggunakan Algoritma C4.5," *J. Manaj. Inform.*, vol. 11, no. 2, pp. 131–145, 2021, doi: 10.34010/jamika.v11i2.5506.
- [11] M. A. Ridla, N. Azise, and M. Rahman, "Perbandingan Model Time Series Forecasting Dalam Memprediksi Jumlah Kedatangan Wisatawan Dan Penumpang Airport," *Simkom*, vol. 8, no. 1, pp. 1–14, 2023, doi: 10.51717/simkom.v8i1.103.

-
- [12] Sabar Sautomo and Hilman Ferdinandus Pardede, "Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.
- [13] B. D. Prasetya, F. S. Pamungkas, and I. Kharisudin, "Pemodelan dan Peramalan Data Saham dengan Analisis Time Series menggunakan Python," *Prism. Pros. Semin. Nas. Mat.*, vol. 3, pp. 714–718, 2020, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/article/view/38116>
- [14] Arnes Anandita and Tri Wahyuningsih, "PREDIKSI INDEKS SAHAM SYARIAH MENGGUNAKAN MODEL LONG SHORT-TERM MEMORY (LSTM) Arnes Anandita Tri Wahyuningsih," *J. Ilmu Manaj.*, vol. 9, no. 1, pp. 60–69, 2024, [Online]. Available: <https://id.investing.com/>.
- [15] A. V Tatachar, "Comparative Assessment of Regression Models Based On Model Evaluation Metrics," *Int. Res. J. Eng. Technol.*, vol. 8, no. 9, pp. 853–860, 2021, [Online]. Available: www.irjet.net
- [16] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *J. Sist. dan Teknol. Inf.*, vol. 11, no. 2, p. 346, 2023, doi: 10.26418/justin.v11i2.57395.
- [17] Pipit Dewi Arnesia, Naufal Arif Pratama, and Fitri Sjafrina, "4243-Article Text-16553-1-10-20220302," *Apl. Artif. Intell. Untuk Mendeteksi Objek Berbas. Web Menggunakan Libr. Tensorflow Js, React Js Dan Coco Dataset*, vol. 9, no. 1, pp. 62–69, 2022.