

Peramalan Penjualan Laptop Menggunakan Metode *Long Short Term Memory* (LSTM)

Fernando Candra Yulianto¹, Noor Latifah²

¹Sistem Informasi, Teknik, Universitas Muria Kudus

²Sistem Informasi, Teknik, Universitas Muria Kudus

¹202153090@std.umk.ac.id*, ²noor.latifah@umk.ac.id

Abstract

The laptop sales industry is not only affected by technological advances, but also by rapid changes in consumer preferences and changes in people's economic conditions. The demand for laptops from consumers varies significantly over time, which is influenced by several factors such as product quality, product price, brand image, and the speed of launching new models. The instability of these factors makes laptop sellers experience difficulties in restocking goods in their stores, from several existing cases laptop sellers often experience overstock or stockout. One method that can be used to predict sales of goods is the Long Short Term Memory (LSTM) method. Where in making the model is divided into 3 categories, namely low-end category, mid-end category and high-end category. The low-end category has price criteria $\leq$ Rp. 8,000,000 while the mid-end category has price criteria $>$ Rp. 8,000,000 and $\leq$ Rp. 16,000,000 and for the high-end category has price criteria $>$ Rp. 16,000,000. To optimize the prediction results, the Adaptive Moment Gradient (ADAM) optimization method is used. Based on trials using this method, the results obtained are RMSE (low-end category): 166.71 and MAPE (low-end category): 4.79%, RMSE (mid-end category): 39.77 and MAPE (mid-end category): 0.68%, and RMSE (high-end category): 18.56 and MAPE (high-end category): 0.50%.

Keywords: LSTM, prediction, adaptive moment gradient, laptop sales

Abstrak

Industri penjualan laptop tidak hanya dipengaruhi oleh kemajuan teknologi, tetapi juga dipengaruhi oleh perubahan cepat dalam preferensi konsumen dan perubahan kondisi ekonomi seseorang. Permintaan laptop dari konsumen bervariasi secara signifikan dari waktu ke waktu, yang dipengaruhi oleh beberapa faktor seperti kualitas produk, harga produk, citra merek, dan kecepatan peluncuran model baru. Ketidakstabilan faktor tersebut membuat penjual laptop mengalami kesulitan dalam melakukan *restock* barang di tokonya, dari beberapa kasus yang ada penjual laptop sering mengalami *overstock* ataupun *stockout*. Salah satu metode yang dapat digunakan untuk memprediksi penjualan barang adalah metode *Long Short Term Memory* (LSTM). Dimana dalam pembuatan model tersebut dibagi menjadi 3 *category* yaitu *low-end category*, *mid-end category* dan *high-end category*. Untuk *low-end category* memiliki kriteria harga $\leq$ Rp. 8.000.000 sedangkan *mid-end category* memiliki kriteria harga $>$ Rp. 8.000.000 dan $\leq$ Rp. 16.000.000 dan untuk *high-end category* memiliki kriteria harga $>$ Rp. 16.000.000. Untuk pengoptimalan hasil prediksi digunakanlah metode optimasi *Adaptive Moment Gradient* (ADAM). Berdasarkan uji coba dengan menggunakan metode tersebut didapatkan hasil berupa RMSE (*low-end category*): 166.71 dan MAPE (*low-end category*): 4.79%, RMSE (*mid-end category*): 39.77 dan MAPE (*mid-end category*): 0.68%, dan RMSE (*high-end category*): 18.56 dan MAPE (*high-end category*): 0.50%.

Kata kunci: LSTM, prediksi, *adaptive moment gradient*, penjualan laptop

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

1. Pendahuluan

Laptop merupakan alat yang sangat diperlukan bagi para pelajar maupun bagi para pekerja kantor karena kelebihanannya dibandingkan dengan komputer [1]. Seiring berkembangnya zaman laptop saat ini mempunyai beragam merek dan spesifikasi yang berbeda-beda, bahkan setiap tahunnya akan ada laptop baru yang bermunculan. Ukuran pasar laptop berkembang pesat dalam beberapa tahun terakhir, menurut *The Business Research Company*, tingkat pertumbuhan tahunan gabungan (CAGR) pada tahun 2024 mengalami kenaikan sebesar 6,0% dan angka tersebut diprediksi akan terus bertambah sampai tahun 2028 dengan presentase CAGR sebesar 7,3% [2]. Selera konsumen dalam pembelian laptop sering kali berubah-ubah. Hal tersebut membuat industri

penjualan laptop tidak hanya dipengaruhi oleh kemajuan teknologi tetapi juga dipengaruhi oleh perubahan cepat preferensi konsumen dan perubahan kondisi seseorang. Permintaan laptop dari konsumen bervariasi secara signifikan dari waktu ke waktu, yang dipengaruhi oleh beberapa faktor seperti harga produk, kualitas produk, citra merek dan kecepatan peluncuran.

Menurut data yang diambil dari *website Top Brand Award* menunjukkan bahwa adanya perubahan *index* penjualan yang cukup signifikan mulai tahun 2020 sampai 2023 dari beberapa merek seperti Acer, Apple, Asus, Hp, dan Lenovo [3]. Ketidakstabilan tersebut membuat penjual laptop mengalami kesulitan dalam melakukan *restock* barang dari tokonya, dari beberapa kasus yang ada para penjual laptop sering mengalami *overstock* ataupun *stockout*.


Penjualan laptop mengalami perubahan setiap waktunya, sehingga untuk memprediksi penjualan tersebut dapat menggunakan deret waktu. Data deret waktu merupakan data yang dikumpulkan berdasarkan urutan dan interval waktu tertentu [4]. Prediksi data deret waktu merupakan prediksi suatu peristiwa dimasa yang akan datang berdasarkan pola data yang telah digali sebelumnya. *Long Short Term Memory* (LSTM) merupakan salah satu metode dari prediksi data deret waktu. Metode *Long Short Term Memory* (LSTM) merupakan perkembangan dari metode *Recurrent Neural Network* (RNN), yang dapat memprediksi data deret waktu dengan baik [5]. Untuk melihat akurasi model yang dibuat digunakanlah perhitungan dengan *parameter Root Mean Squared Error* (RMSE), dimana semakin rendah nilai RMSE yang dihasilkan maka akurasi yang dihasilkan semakin akurat [6]. Selain itu digunakanlah *Mean Absolute Percentage Error* (MAPE) dimana nilai tersebut didapatkan dari rata-rata nilai *absolute* kemudian dikalikan dengan 100%.

Metode ini telah diimplementasikan oleh peneliti sebelumnya [7] dalam memprediksi *index* harga produsen pertanian karet di Indonesia didapatkan hasil nilai *Root Mean Squared Error* (RMSE) 384,20 untuk *training* dan 306,01 untuk nilai *test*, sedangkan untuk nilai *Mean Absolute Percentage Error* (MAPE) didapatkan nilai latih 1,25% dan 1,09% untuk nilai uji, hasil itu menunjukkan bahwa nilai MAPE mendapatkan nilai *error* yang baik dikarenakan nilai tersebut kurang dari 10%. Pada penelitian lainnya yang dilakukan oleh [8] dalam memprediksi penjualan produk PT. Metiska Farma didapatkan hasil nilai *Root Mean Squared Error* (RMSE) sebesar 13,762,154 dengan *Mean Absolute Percentage Error* (MAPE) yang cukup kecil sebesar 12%, tentu hasil MAPE tersebut masih dalam kondisi yang tidak begitu bagus dikarenakan nilai MAPE yang lebih dari 10% untuk itu masih diperlukan peningkatan performa model agar didapatkan hasil yang baik. Dapat disimpulkan bahwa penggunaan model LSTM ini sangat efektif diterapkan untuk studi kasus ini dikarenakan memiliki nilai MAPE yang cukup kecil.

Metode *Long Short Term Memory* (LSTM) pada penelitian ini digunakan untuk memprediksi penjualan laptop perminggunya berdasarkan penjualan data di bulan sebelumnya dengan membaginya ke dalam 3 *category* yaitu *low-end category*, *mid-end category* dan *high-end category* dengan kriteria *low-end category* memiliki harga kurang dari sama dengan Rp. 8.000.000, *mid-end category* dengan harga lebih dari Rp. 8.000.000 dan kurang dari sama dengan Rp. 16.000.000 dan *high-end category* dengan harga lebih dari Rp. 16.000.000. Tujuan dilakukannya penelitian ini untuk mengetahui performa metode *Long Short Term Memory* (LSTM) dalam memprediksi penjualan laptop.

2. Metode Penelitian

Pada metode penelitian ini akan memberikan suatu kerangka kerja yang jelas tentang bagaimana penelitian ini dilakukan, mulai dari langkah-langkah yang akan diambil, teknik yang akan digunakan, sampai dengan testing model yang telah dibuat. Serangkaian langkah sistematis tersebut yang digunakan peneliti untuk merencanakan, melaksanakan, dan menganalisis suatu penelitian dengan tujuan untuk mencapai hasil yang valid ditunjukkan oleh gambar 1 berikut.




Gambar 1. Langkah-langkah Penelitian

Perumusan masalah sudah dijelaskan sebelumnya, sedangkan untuk kajian pustaka adalah suatu proses analisis informasi yang bersumber dari literatur, jurnal ilmiah, artikel, buku, atau sumber pengetahuan lainnya yang relevan dengan topik penelitian tertentu. Tujuan dari kajian pustaka ini adalah untuk menyajikan kerangka kerja konseptual yang mendalam dengan memahami perkembangan penelitian sebelumnya untuk mengidentifikasi kekurangan pengetahuan, serta untuk merumuskan pertanyaan yang spesifik.

2.1. Pengumpulan Dataset

Dataset merupakan sekumpulan data yang dapat digunakan untuk bahan percobaan riset atau penelitian [9]. Pada penelitian ini *dataset* penjualan laptop dikumpulkan dari *repository* github.com, *dataset* tersebut dapat diakses melalui link [https://github.com/C4AnN/Laptop_Lens/blob/main/M L/Dataset/Gathering%20Dataset.csv](https://github.com/C4AnN/Laptop_Lens/blob/main/M%20L/Dataset/Gathering%20Dataset.csv), memuat tentang informasi data penjualan laptop dari tahun 2013 sampai dengan 2017 berisi sebanyak 103.000 data, data tersebut merupakan data penjualan *e-commerce* dari *platform* shoppe dan tokopedia yang memuat beberapa merek laptop seperti acer, asus, lenovo, hp, dell, dan msi. Grafik penjualan tersebut dapat dilihat pada gambar 2 berikut.



Gambar 2 Grafik Penjualan Laptop Tahun 2013 - 2017

2.2. Preprocessing Dataset

Dataset yang telah dikumpulkan pada proses sebelumnya akan melalui tahapan berikutnya yaitu tahapan *preprocessing dataset*. *Preprocessing dataset* adalah proses untuk memastikan *dataset* yang akan digunakan dalam keadaan bersih, konsisten dan berada pada format yang tepat [10]. Pada tahapan ini akan dilakukan 2 tahapan, yaitu *cleaning dataset* dan normalisasi data.

2.2.1. Cleaning Dataset

Cleaning dataset merupakan proses mengidentifikasi, memperbaiki dan menghapus data yang tidak akurat, tidak lengkap dan tidak relevan terhadap *format dataset* tersebut [11]. Pada proses ini *dataset* yang telah dikumpulkan sebelumnya akan dilakukan proses *cleaning data* yang bertujuan untuk memastikan data tersebut konsisten dan sesuai dengan *format dataset*.

2.2.2. Normalisasi Data

Normalisasi data merupakan proses transformasi nilai dari suatu *dataset* tertentu ke dalam rentang nilai tertentu [12]. Sebelum itu *dataset* akan dibedakan menjadi 3 kategori yaitu: kriteria *low-end category* memiliki harga $\leq$ Rp. 8.000.000, *mid-end category* dengan harga $>$ Rp. 8.000.000 dan $\leq$ Rp. 16.000.000 dan *high-end category* dengan harga $>$ Rp. 16.000.000. Pada tahapan ini normalisasi data akan dilakukan dengan menggunakan metode *min-max scaller* dari *scikit-learn*. Metode ini akan mengubah nilai data ke *range* antara 0 sampai 1. Berikut merupakan rumus *min-max scaller*.

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

Keterangan rumus :

x' = hasil normalisasi data

x = nilai data aktual

x_{max} = nilai terbesar dari keseluruhan *dataset*

x_{min} = nilai terkecil dari keseluruhan *dataset*

2.3. Pemilihan Atribut Data

Pemilihan atribut data dilakukan untuk meningkatkan performa model yang akan dibangun [13]. Pada

tahapan pemilihan atribut data ini terbagi menjadi 2 tahap, yaitu :

2.3.1. Dataset Awal

Pada tahapan ini akan dijelaskan semua atribut dari *dataset*. Pada tabel 1 menunjukkan semua atribut dari *dataset* yang digunakan.

Tabel 1 Atribut <i>Dataset</i> Awal		
No	Attribute	Keterangan
1	Name	Nama barang
2	Price	Harga satuan barang
3	Date	Tanggal laptop terjual
4	Sales	Jumlah laptop yang terjual


2.3.2. Pemilihan Atribut (Variable)

Pada pemilihan atribut ini menggunakan teknik *Autocorrelation Function* (ACF), teknik ini merupakan teknik statistik yang digunakan untuk mengukur seberapa kuat hubungan anatara nilai dalam suatu deret waktu dengan nilai sebelumnya [14]. Pada penelitian ini dipilih 2 *variable* data, yakni *date* dan *sales*. *Variable* data tersebut ditunjukkan tabel 2 berikut.

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

2.4. Data Training dan Data Testing

Pada tahapan ini *dataset* akan dilakukan pemisahan menjadi 2 data, yaitu data *training* dan data *testing* dengan presentase 75% untuk data *training* dan 25% untuk data *testing*. Data *training* tersebut digunakan untuk melatih model, selama proses pelatihan model akan menyesuaikan bobot serta biasanya untuk meminimalkan kesalahan prediksi pada data *training*. Data *testing* digunakan untuk mengevaluasi kinerja model setelah dilakukan pelatihan. Pembagian data tersebut ditunjukkan oleh gambar 3 berikut.




Gambar 3 Presentase Data *Training* dan Data *Testing*

2.5. Model Long Short-Term Memory (LSTM)

Pada penelitian ini menggunakan metode *Long Short Term Memory* (LSTM) yang masih menjadi bagian dari metode *Recurrent Neural Network* (RNN) [15]. Model ini dibangun untuk memprediksi penjualan laptop di

minggu setelahnya berdasarkan data penjualan sebelumnya. Model yang dibangun memiliki arsitektur yang ditunjukkan oleh gambar 4 berikut.



Gambar 4 Arsitektur Model Long Short Term Memory (LSTM)

2.5. Evaluasi Model Long Short-Term Memory (LSTM)

Pada tahapan berikutnya setelah proses pemodelannya dibuat akan dilakukan evaluasi model yang bertujuan untuk mengukur performa prediksi yang dihasilkan. Pada penelitian ini akan menggunakan 2 evaluasi pemodelan, yaitu :

2.5.1. Root Mean Square Error (RMSE)

Root Mean Squared Error (RMSE) digunakan untuk menghitung antara nilai harapan dengan nilai aktual, dimana semakin minim nilai RMSE yang dihasilkan maka semakin akurat hasilnya [16]. Berikut merupakan rumus perhitungan dari RMSE.

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

Keterangan rumus :

$\hat{y}_i$ = nilai harapan (nilai prediksi)

y_i = nilai aktual

n = banyak data

2.5.2. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) dihitung dari rata-rata nilai absolute kemudian dikali dengan 100% [17]. Berikut merupakan rumus perhitungan dari MAPE.

$$MAPE = \frac{100\%}{n} \sum \left| \frac{y - \hat{y}}{y} \right|$$
 (3)

Keterangan rumus :

$\hat{y}$ = nilai harapan (nilai prediksi)

y = nilai aktual

n = banyak data

3. Hasil dan Pembahasan

3.1. Tools

Pada penelitian ini ada beberapa tools yang digunakan dalam pembuatan model, tools tersebut ditunjukkan oleh tabel 3 berikut.

Tabel 3 Tools Pembuatan Model		
No	Tools	Fungsi
1	Phyton	Bahasa pemrograman yang dipakai sebagai pembuatan model.
2	Jupyter Notebook dan Google Colab	Processing dataset dan testing model machine learning.
3	Numpy, Pandas dan Scikit-learn	Library yang digunakan untuk memanipulasi data, menganalisis dan processing.
4	Matplotlib dan Pandas	Untuk file handling dan visualisasi data.
5	Tensorflow dan Tensorflow Lite	Untuk membangun, melatih dan mengevaluasi model machine learning.
6	Github	Untuk mencari dataset dan repository pembuatan project.
7	Visual Studio Code	Untuk menguji model yang telah dibuat dengan Bahasa pemrograman javascript.

3.2. Pengumpulan Dataset

Pada tahapan awal dataset ini memiliki 4 atribut utama yang ditunjukkan oleh tabel 1, dimana dataset tersebut berisikan sebanyak 103.000 data mulai tahun 2013 sampai 2017 persebaran datanya ditunjukkan oleh gambar 2. Untuk isi dari dataset tersebut ditunjukkan oleh gambar 5 berikut.

	name	price	date	sales
1	Lemari Lamin 1540 - 17 8750H 16GB 512GB 1TB GTX1660Ti 8GB W10 144Hz	18990000	2013-01-01	13
2	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18990000	2013-01-02	11
3	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	28200000	2013-01-03	14
4	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	30990000	2013-01-04	13
5	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18990000	2013-01-05	10
6	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	24500000	2013-01-06	12
7	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	17490000	2013-01-07	10
8	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	29190000	2013-01-08	9
9	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18490000	2013-01-09	12
10	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	20533000	2013-01-10	9
11	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	31990000	2013-01-11	9
12	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	13700000	2013-01-12	7
13	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18990000	2013-01-13	10
14	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18490000	2013-01-14	12
15	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	19700000	2013-01-15	5
16	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	25497000	2013-01-16	7
17	ASUS ROG G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz			

Gambar 5 Hasil Pengumpulan Dataset Tahun 2013-2017

3.3. Preprocessing Dataset

Dataset yang sudah dikumpulkan akan memasuki tahapan preprocessing dataset, dimana pada tahapan ini dataset akan dilakukan beberapa tahapan berikutnya, yaitu :

3.3.1. Cleaning Dataset

Pada tahapan cleaning dataset ini bertujuan untuk memastikan data tersebut konsisten dan sesuai dengan format dataset. Hasil dari cleaning dataset tersebut ditunjukkan oleh gambar 6 berikut.

	name	price	date	sales
1	ACER ASPIRE 3 A311-31	3875000	2013-01-01	14
2	ACER ASPIRE 3 A311-31	4849000	2013-01-01	11
3	ACER ASPIRE 3 A311-31	3999000	2013-01-01	10
4	ACER ASPIRE 3 A311-31	3400000	2013-01-01	39
5	ACER ASPIRE 3 A311-31	1799000	2013-01-01	4
6	ACER ASPIRE 3 A311-31	3799000	2013-01-01	11
7	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	25990000	2013-01-01	9
8	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	11920000	2013-01-01	34
9	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	23790000	2013-01-01	34
10	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	14000000	2013-01-01	9
11	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	13040000	2013-01-01	20
12	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18520000	2013-01-01	9
13	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	15990000	2013-01-01	20
14	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18990000	2013-01-01	7
15	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	18990000	2013-01-01	7
16	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz	13990000	2013-01-01	26
17	ASUS ROG HERO 2 G531GU-68602T 6 9300H8GB512GB SSDGTX1660Ti 8GB120Hz			

Gambar 6 Hasil Cleaning Dataset

3.3.2. Normalisasi Data

Langkah awal pada normalisasi data ini yaitu mengkategorikan dataset tersebut ke dalam 3 kategori sesuai kriteria pada proses 2.2.2 sebelumnya. Hasil dari pengkategorian dataset tersebut ditunjukkan oleh gambar 7 berikut.

id	name	price	date	sales	category
1	ACER ASPIRE 3 A314-311	3675000	2013-01-01	14	low
2	ACER ASPIRE 3 A314-311 INTEL N4120/4GB/500GB/14" W/Windows 10	4580000	2013-01-01	11	low
3	ACER ASPIRE 3 A314-311 INTEL N4120/4GB/500GB/14" W/Windows 10	2990000	2013-01-01	10	low
4	ACER ASPIRE 3 A314-311 INTEL N4120/4GB/500GB/14" W/Windows 10	3400000	2013-01-01	39	low
5	ACER ASPIRE 3 A314-311 INTEL N4120/4GB/500GB/14" W/Windows 10	3700000	2013-01-01	4	low
6	ACER ASPIRE 3 A314-311 INTEL N4120/4GB/500GB/14" W/Windows 10	3700000	2013-01-01	11	low
7	ACER ASPIRE 3 A314-311 INTEL N4120/4GB/500GB/14" W/Windows 10	2990000	2013-01-01	9	high
8	ASUS ROG HERO II G7310W - 17" IPS 144Hz 1440p - 1TB SSD - RTX 2070 - RGB	11920000	2013-01-01	34	mid
9	ASUS ROG HERO II G7310W - 17" IPS 144Hz 1440p - 1TB SSD - RTX 2070 - RGB	23790000	2013-01-01	34	high
10	ASUS ROG STRIX G15 G502L-PRO - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 2070 - RGB	14320000	2013-01-01	9	mid
11	ASUS ROG STRIX G15 G502L-PRO - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 2070 - RGB	15500000	2013-01-01	20	mid
12	ASUS TUF A15 FX506H-RTX1650 - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 1650 - RGB	16520000	2013-01-01	9	high
13	ASUS TUF A15 FX506H-RTX1650 - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 1650 - RGB	19800000	2013-01-01	20	mid
14	ASUS VIVOBOOK A412FL - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 1650 - RGB	9500000	2013-01-01	7	mid
15	ASUS VIVOBOOK A412FL - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 1650 - RGB	10900000	2013-01-01	7	mid
16	ASUS VIVOBOOK A412FL - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 1650 - RGB	10900000	2013-01-01	20	mid
17	ASUS VIVOBOOK A412FL - 15.6" IPS 144Hz 1440p - 1TB SSD - RTX 1650 - RGB	10900000	2013-01-01	20	mid

Gambar 7 Pengkategorian Dataset

Pada langkah berikutnya *dataset* akan dilakukan perhitungan *min-max scaler* sesuai dengan rumus 1, dimana perhitungan tersebut akan dilakukan dengan menggunakan *google colab*. Perhitungan tersebut dibagi menjadi 3 kategori yaitu *low*, *mid* dan *high*. berikut merupakan hasil dari perhitungan.

Scaled Train Data (low):				
sales_diff	week_1	week_2	week_3	week_4
0	0.125000	-0.079710	0.132850	0.047705
1	-0.117754	0.125000	-0.079710	0.132850
2	0.358696	-0.117754	0.125000	-0.079710
3	-0.294082	0.358696	-0.117754	0.125000
4	0.484903	-0.294082	0.358696	-0.117754
Scaled Test Data (low):				
sales_diff	week_1	week_2	week_3	week_4
0	0.434179	-0.044082	-0.358092	-0.086957
1	-0.536836	0.434179	-0.044082	-0.358092
2	0.091184	-0.536836	0.434179	-0.044082
3	0.118961	0.091184	-0.536836	0.434179
4	0.027778	0.118961	0.091184	-0.536836

Gambar 8 Hasil Min-Max Scaller (low-category)

Scaled Train Data (mid):				
sales_diff	week_1	week_2	week_3	week_4
0	0.014979	0.288160	-0.054922	-0.543509
1	-0.367332	0.014979	0.288160	-0.054922
2	-0.495720	-0.367332	0.014979	0.288160
3	0.686876	-0.495720	-0.367332	0.014979
4	-0.510699	0.686876	-0.495720	-0.367332
Scaled Test Data (mid):				
sales_diff	week_1	week_2	week_3	week_4
0	-0.884451	-0.563481	0.315977	-0.059914
1	0.432953	-0.884451	-0.563481	0.315977
2	0.569900	0.432953	-0.884451	-0.563481
3	0.079886	0.569900	0.432953	-0.884451
4	-0.388017	0.079886	0.569900	0.432953

Gambar 9 Hasil Min-Max Scaller (mid-category)

Scaled Train Data (high):				
sales_diff	week_1	week_2	week_3	week_4
0	0.214090	0.187367	-0.093835	0.473428
1	0.509262	0.214090	0.187367	-0.093835
2	0.145460	0.509262	0.214090	0.187367
3	0.209232	0.145460	0.509262	0.214090
4	0.542666	0.209232	0.145460	0.509262
Scaled Test Data (high):				
sales_diff	week_1	week_2	week_3	week_4
0	0.514121	0.064075	0.053143	0.092013
1	0.127847	0.514121	0.064075	0.053143
2	-0.571819	0.127847	0.514121	0.064075
3	0.512906	-0.571819	0.127847	0.514121
4	0.435166	0.512906	-0.571819	0.127847


Gambar 10 Hasil Min-Max Scaller (high-category)

Keterangan : *min-max scaler* pada pembuatan model ini dibuat rentang antara -1 sampai 1. Nilai *sales_diff* didapatkan dari perhitungan perbedaan antara penjualan pada minggu tersebut dengan minggu sebelumnya. Pada perhitungan tersebut dibagi menjadi 4 minggu.


3.4. Pemilihan Atribut Data

Pada proses pemilihan atribut data ini digunakanlah metode *Autocorrelation Function* (ACF) yang sudah dijelaskan pada proses 2.3. Hasil dari pemilihan atribut


data dengan menggunakan metode *Autocorrelation Function* (ACF) ditunjukkan oleh gambar 11 untuk *low category*, gambar 12 untuk *mid category* dan gambar 13 untuk *high category*.



Gambar 11 Autocorrelation Function (ACF) Low Category



Gambar 12 Autocorrelation Function (ACF) Mid Category



Gambar 13 Autocorrelation Function (ACF) High Category

Pada grafik *plot Autocorrelation Function* (ACF) yang ditampilkan masing-masing kategori menunjukkan adanya pola temporal dalam penjualan. Pola tersebut dapat digunakan untuk membuat prediksi yang lebih akurat tentang prediksi penjualan di masa depan.

3.5. Data Training dan Data Testing

Pada tahapan ini *dataset* akan dibagi menjadi 2 data, yaitu data *training* dan data *testing*. Pembagian tersebut memiliki presentase sebesar 75% untuk data *training* dan 25% untuk data *testing*. Hasil pembagian ini dapat dilihat pada gambar 3.

3.5. Model Long Short-Term Memory (LSTM)

Pada proses ini pembuatan model dilakukan dengan menggunakan 2 variabel yang telah dipilih pada proses sebelumnya yakni *date* dan *sales*. Setelah itu akan dilakukan proses pembuatan *hyperparameter* agar didapatkan performa model yang baik. *Hyperparameter* ini merupakan penjelasan dari gambar 4. Pembuatan *hyperparameter* tersebut ditunjukkan oleh tabel 4 berikut.

No	Jenis	Nilai
1	Input Layer (windows size)	12
2	LSTM Layer 1	200
3	Activation	Tanh
4	Dropout Layer	0.3
5	LSTM Layer 2	100
6	Activation	Tanh
7	Dense Layer	1
8	Loss Function	MSE
9	Optimizer	Adam
10	Epochs	200
11	Batch	16
12	Validation Split	4

3.6. Evaluasi Model LSTM

Pada proses ini setelah proses pemodelannya dibuat akan dilakukan evaluasi model yang bertujuan untuk mengukur performa prediksi yang dihasilkan. Untuk pengukuran performa tersebut menggunakan *Root Mean Square Error (RMSE)* dan *Mean Absolute Percentage Error (MAPE)* dengan membaginya kedalam 3 kategori yaitu *low-end category*, *mid-end category* dan *high-end category*.

1. Low-End Category

Pada *low-end category* memiliki kriteria harga $\leq$ Rp. 8.000.000. Evaluasi model *low-end category* tersebut mendapatkan hasil nilai RMSE dan MAPE seperti yang ditunjukkan oleh tabel 5 berikut.

Kategori	RMSE	MAPE
Low-End	166.71	4.79%

Hasil RMSE 166.71 menunjukkan bahwa model tersebut memiliki kesalahan rata-rata sebesar 166.71 unit penjualan. Pada kategori ini memiliki nilai MAPE sebesar 4.79% menandakan bahwa kesalahan rata-rata sebesar 4.79% dari nilai penjualan sebenarnya.

2. Mid-End Category

Pada *mid-end category* memiliki kriteria harga $>$ Rp. 8.000.000 dan $\leq$ Rp. 16.000.000. Evaluasi model *mid-end category* tersebut mendapatkan hasil nilai

RMSE dan MAPE seperti yang ditunjukkan oleh tabel 6 berikut.

Kategori	RMSE	MAPE
Mid-End	39.77	0.68%

Hasil RMSE 39.77 menunjukkan bahwa model tersebut memiliki kesalahan rata-rata sebesar 39.77 unit penjualan. Pada kategori ini memiliki nilai MAPE sebesar 0.68% menandakan bahwa kesalahan rata-rata sebesar 0.68% dari nilai penjualan sebenarnya.

3. High-End Category

Pada *high-end category* memiliki kriteria harga $>$ Rp. 16.000.000. Evaluasi model *high-end category* tersebut mendapatkan hasil nilai RMSE dan MAPE seperti yang ditunjukkan oleh tabel 7 berikut.

Kategori	RMSE	MAPE
High-End	18.56	0.50%

Hasil RMSE 18.56 menunjukkan bahwa model tersebut memiliki kesalahan rata-rata sebesar 18.56 unit penjualan. Pada kategori ini memiliki nilai MAPE sebesar 0.50% menandakan bahwa kesalahan rata-rata sebesar 0.50% dari nilai penjualan sebenarnya.

3.7. Hasil Analisis Model LSTM

Hasil analisis model LSTM ini didapatkan dari hasil evaluasi model LSTM pada proses sebelumnya. Berikut merupakan hasil analisis tersebut .

1. Hasil Model Low-End Category

Hasil dari model ini ditunjukkan oleh gambar 14 berikut.



Gambar 14 Hasil Analisis Model LSTM Low-End Category

Pada gambar 14 menunjukkan hasil dari model analisis yang ditampilkan dengan *plot*, *line plot* yang berwarna biru menunjukkan penjualan sesungguhnya sedangkan *line plot* yang berwarna orange menunjukkan prediksi penjualan.

2. Hasil Model Mid-End Category

Hasil dari model ini ditunjukkan oleh gambar 15 berikut.



Gambar 15 Hasil Analisis Model LSTM Mid-End Category

Pada gambar 15 menunjukkan hasil dari model analisis yang ditampilkan dengan *plot*, *line plot* yang berwarna biru menunjukkan penjualan sesungguhnya sedangkan *line plot* yang berwarna orange menunjukkan prediksi penjualan.

3. Hasil Model High-End Category

Hasil dari model ini ditunjukkan oleh gambar 16 berikut.



Gambar 16 Hasil Analisis Model LSTM High-End Category

Pada gambar 16 menunjukkan hasil dari model analisis yang ditampilkan dengan *plot*, *line plot* yang berwarna biru menunjukkan penjualan sesungguhnya sedangkan *line plot* yang berwarna orange menunjukkan prediksi penjualan.

3.8. Hasil Prediksi Penjualan Laptop


Pada proses berikutnya model tersebut akan dikonversi dalam bentuk *javascript* dengan menggunakan *tensorflowjs*. Pada proses berikutnya model yang sudah dikonversi akan diuji dengan menggunakan bahasa pemrograman *javascript*. Pada pengujian ini akan diambil sampel penjualan data aktual mulai tanggal 20 November sampai 31 Desember 2017 serta akan ditampilkan hasil prediksinya. Data aktual tersebut dipakai sebagai pembandingan dengan hasil prediksi penjualan nantinya, selain itu akan ditampilkan juga hasil prediksi masa depannya dalam kurun waktu 1 minggu kedepannya yaitu pada tanggal 1 sampai 7 januari 2018. Hasil pengujian tersebut ditampilkan pada tabel 8 untuk kategori *low-end*, tabel 9 untuk kategori *mid-end* dan tabel 10 untuk kategori *high-end* berikut ini.

1. Hasil Prediksi Low-End Category

Hasil prediksi ditunjukkan oleh tabel 8 berikut.

Tanggal	Nilai Aktual	Hasil Prediksi
20-26 Nov 2017	15.935	890
27 Nov – 3 Des 2017	13.786	2.548
4-10 Des 2017	11.489	2.665
11-17 Des 2017	11.129	3.291
18-24 Des 2017	10.891	2.250
25-31 Des 2017	11223	479
1-7 Jan 2018	-	899

Berikut ini merupakan hasil prediksinya dalam bentuk *line plot* yang dibuat dengan menggunakan bahasa pemrograman *javascript* dengan memuat model yang sudah dikonversi sebelumnya.




Gambar 17 Grafik Prediksi Low-End Category

2. Hasil Prediksi Mid-End Category

Hasil prediksi ditunjukkan oleh tabel 9 berikut.

Tanggal	Nilai Aktual	Hasil Prediksi
20-26 Nov 2017	15.834	1.718
27 Nov – 3 Des 2017	13.576	5.086
4-10 Des 2017	11.347	5.146
11-17 Des 2017	11502	5.153
18-24 Des 2017	11.149	5.692
25-31 Des 2017	11.436	894
1-7 Jan 2018	-	1574

Berikut ini merupakan hasil prediksinya dalam bentuk *line plot* yang dibuat dengan menggunakan bahasa pemrograman *javascript* dengan memuat model yang sudah dikonversi sebelumnya.



Gambar 18 Grafik Prediksi Mid-End Category


3. Hasil Prediksi High-End Category

Hasil prediksi ditunjukkan oleh tabel 10 berikut.

Tanggal	Nilai Aktual	Hasil Prediksi
20-26 Nov 2017	15.807	1.010
27 Nov – 3 Des 2017	13.335	3.781
4-10 Des 2017	11.404	3.794
11-17 Des 2017	11.549	2.965
18-24 Des 2017	11.115	3.287
25-31 Des 2017	11.287	639
1-7 Jan 2018	-	1.278

Berikut ini merupakan hasil prediksinya dalam bentuk *line plot* yang dibuat dengan menggunakan bahasa

pemrograman *javascript* dengan memuat model yang sudah dikonversi sebelumnya.



Gambar 19 Grafik Prediksi *High-End Category*

Hasil prediksi dari ke tiga kategori di atas masih jauh dengan nilai aktual datanya hal tersebut disebabkan oleh keterbatasan *library* yang tersedia di *javascript* untuk memuat model tersebut, sehingga struktur *code* untuk memuat model tersebut dalam *javascript* masih belum bisa maksimal. Hal tersebut dapat dibuktikan dengan nilai RMSE dan MAPE pada proses evaluasi model didapatkan nilai yang sangat baik. Untuk evaluasi kedepannya alangkah baiknya model tersebut diuji secara langsung dengan menggunakan bahasa pemrograman *python* dimana bahasa pemrograman tersebut sesuai dengan bahasa pemrograman sewaktu model tersebut dibuat. Selain itu, *library* yang tersedia untuk bahasa pemrograman *python* sangat lengkap sehingga hal tersebut cukup bagus dalam membuat struktur *code* untuk memuat model yang telah dibuat agar didapatkan hasil yang maksimal.

4. Kesimpulan

Berdasarkan penelitian tersebut maka didapatkan beberapa kesimpulan, yaitu :

1. Kesalahan Prediksi Pada Evaluasi Model

Nilai RMSE lebih tinggi pada kategori *low-end* dibandingkan dengan kategori *mid-end* dan *high-end* menunjukkan bahwa fluktuasi penjualan pada kategori *low-end* lebih besar sehingga model kurang mampu menangkap pola dalam data tersebut. Nilai MAPE yang rendah pada kategori *mid-end* dan *high-end* menunjukkan bahwa model sangat efektif dalam memprediksi penjualan.

2. Akurasi Prediksi Pada Evaluasi Model

Model tersebut memberikan hasil prediksi yang cukup akurat untuk ketiga kategori harga, terutama pada kategori *mid-end* dan *high-end* yang memiliki nilai MAPE sangat rendah (0.68% dan 0.50%). Kategori *low-end* memiliki kesalahan prediksi yang lebih tinggi dibandingkan dua kategori lainnya, baik dalam nilai RMSE ataupun MAPE itu menunjukkan bahwa model mengalami kesulitan dalam menangani variabilitas data pada kategori harga rendah.

Secara keseluruhan dari hasil 3 model tersebut, model LSTM yang diterapkan untuk memprediksi penjualan laptop memberikan performa yang baik, terutama untuk kategori harga *mid-end* dan *high-end*. Pada kategori *low-end* memiliki kesalahan yang lebih tinggi, baik dalam ukuran *absolute* maupun presentase, yang menunjukkan bahwa perlu adanya peningkatan model ataupun penggunaan teknik tambahan untuk mengurangi kesalahan prediksi pada kategori *low-end* tersebut.

3. Hasil Prediksi Penjualan Laptop

Hasil prediksi yang diuji dengan menggunakan bahasa pemrograman *javascript* masih jauh dari data aktual hal tersebut disebabkan oleh keterbatasan *library* pada bahasa pemrograman *javascript* sehingga sangat sulit untuk membuat konturksi *code* yang tepat untuk memuat model tersebut, sehingga didapatkan hasil prediksi yang kurang maksimal. Untuk evaluasi kedepannya model tersebut sebaiknya diuji dengan menggunakan bahasa pemrograman *python* yang memiliki *library* lebih lengkap agar model tersebut dapat dimuat dengan baik sehingga didapatkan hasil prediksi yang maksimal.

Daftar Rujukan

- [1] N. N. Nuraeni and M. R. Firdaus, "Pemilihan Laptop Terbaik Menggunakan Metode Simple Additive Weighting," *JIKO (Jurnal Informatika dan Komputer)*, vol. 6, no. 2, p. 218, 2022, doi: 10.26798/jiko.v6i2.622.
- [2] The Business Research Company, 2024. *Laptops Global Market Report* [Online] (Update 14 Juli 2024) Tersedia di: <https://www.thebusinessresearchcompany.com/report/lapt-ops-global-market-report> [Accessed 15 Juli 2024].
- [3] Komparasi Brand, 2024. *Top Brand Award* [Online] (Update 10 Juli 2024) Tersedia di: https://www.topbrand-award.com/komparasi_brand/bandingkan?id_award=1&id_kategori=10&id_subkategori=368 [Accessed 14 Juli 2024].
- [4] D. Ruhiat and C. Suwanda, "PERAMALAN DATA DERET WAKTU BERPOLA MUSIMAN MENGGUNAKAN METODE REGRESI SPEKTRAL (Studi Kasus: Debit Sungai Citarum-Nanjung)," *TEOREMA : Teori dan Riset Matematika*, vol. 4, no. 1, p. 1, 2019, doi: 10.25157/teorema.v4i1.1887.
- [5] A. Cardova and A. Hermawan, "Implementasi Metode LSTM Untuk Mengklasifikasi Berita Palsu Pada PolitiFact," *Jurnal Fasilkom*, vol. 13, no. 3, pp. 471–479, 2023, doi: 10.37859/jf.v13i3.6175.
- [6] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 346, 2023, doi: 10.26418/justin.v11i2.57395.
- [7] R. Firdaus, "Prediksi Indeks Harga Produsen Pertanian Karet Di Indonesia Menggunakan Metode LSTM," *Jurnal Fasilkom*, vol. 13, no. 01, pp. 1–6, 2023, doi: 10.37859/jf.v13i01.4851.
- [8] L. Wiranda and M. Sadikin, "Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma," *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 8, no. 3, pp. 184–196, 2019, doi: <https://doi.org/10.23887/janapati.v8i3.19139>.
- [9] Y. Yuliska and K. U. Syaliman, "Literatur Review Terhadap Metode, Aplikasi dan Dataset Peringkasan Dokumen Teks Otomatis untuk Teks Berbahasa Indonesia," *IT Journal Research and Development*, vol. 5,

- no. 1, pp. 19–31, 2020, doi: 10.25299/itjrd.2020.vol5(1).4688.
- [10] Sabar Sautomo and Hilman Ferdinandus Pardede, “Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM),” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.
- [11] M. Ikhsan, “Analisis Sentimen Terhadap Kenaikan Harga Bahan Bakar Minyak Menggunakan Long Short-Term Memory,” *The Indonesian Journal of Computer Science Research*, vol. 2, no. 1, pp. 31–41, 2023, doi: 10.59095/ijcsr.v2i1.29.
- [12] N. Selle, N. Yudistira, and C. Dewi, “Perbandingan Prediksi Penggunaan Listrik dengan Menggunakan Metode Long Short Term Memory (LSTM) dan Recurrent Neural Network (RNN),” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 1, pp. 155–162, 2022, doi: 10.25126/jtiik.2022915585.
- [13] A. Agusta, I. Ernawati, and A. Muliawati, “Prediksi Pergerakan Harga Saham Pada Sektor Farmasi Menggunakan Algoritma Long Short-Term Memory,” *Informatik : Jurnal Ilmu Komputer*, vol. 17, no. 2, p. 164, 2021, doi: 10.52958/iftk.v17i2.3651.
- [14] Y. R. M. Ferdinandus, K. Kusriani, and T. Hidayat, “Gold Price Prediction Using the ARIMA and LSTM Models,” *Sinkron*, vol. 8, no. 3, pp. 1255–1264, 2023, doi: 10.33395/sinkron.v8i3.12461.
- [15] A. Marhaendra Kusuma, R. Alexandro Harianto, and E. Pramana, “Prediksi Stok Produk Sari Roti Untuk Penjualan Online Melalui Whatsapp Menggunakan Metode LightGBM dan LSTM,” *Joutica*, vol. 8, no. 2, pp. 45–50, 2023, doi: 10.30736/informatika.v8i2.1083.
- [16] M Devid Alam Carnegie and Chairani, “Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan,” *Jurnal Media Informatika Budidarma*, vol. 7, no. 3, pp. 1022–1032, 2023, doi: 10.30865/mib.v7i3.6213.
- [17] A. Suwandi, “Prediksi Harga Emas Menggunakan Metode Single Moving Average,” *JITEKH*, vol. 8, no. 1, pp. 32–36, 2020, doi: 10.35447/jitek.v8i1.194.