



PREDIKSI HARGA KENTANG DI WONOSOBO DENGAN MENGGUNAAN METODE LONG SHORT TERM MEMORY (LSTM)

Ahmad Rifai, Muslim Hidayat, Nulngafan

Teknik Informatika, Fakultas Teknik dan Ilmu Komputer

Email: ahmmd.riffai@mhs.fastikom-unsiq.ac.id

Diterima : 31 Juli 2024 ; Disetujui : 25 Agustus 2024 ; Dipublikasikan : 31 Januari 2025

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan model prediksi harga kentang di Wonosobo menggunakan metode Long Short Term Memory (LSTM). Harga kentang merupakan parameter penting dalam sektor pertanian dan ekonomi lokal. Metode LSTM dipilih karena kemampuannya dalam menangani data berurutan dan ketergantungan jangka panjang. Data harga kentang dari Wonosobo dikumpulkan dan dibagi menjadi set pelatihan dan validasi. Model LSTM dijalankan pada set pelatihan dengan hasil Root Mean Square Error (RMSE) sebesar 155.87, menunjukkan kemampuan model dalam mengestimasi harga kentang pada data pelatihan. Evaluasi model pada set validasi menghasilkan RMSE sebesar 186.31, memberikan gambaran kinerja model pada data yang tidak digunakan selama pelatihan. Selain itu, Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur tingkat kesalahan relatif. Model memberikan MAPE sebesar 0.62 pada data pelatihan dan 0.82 pada data validasi. Hasil tersebut menunjukkan tingkat akurasi model dalam meramalkan perubahan harga kentang, dengan nilai yang rendah menandakan kualitas prediksi yang baik. Penelitian ini menyoroti potensi penggunaan metode LSTM dalam meramalkan harga komoditas pertanian di tingkat lokal.

Kata Kunci : Deep Learning, LSTM, Prediksi, Harga Kentang.

ABSTRACT

This study aims to develop a potato price prediction model in Wonosobo using the Long Short Term Memory (LSTM) method. Potato price is an important parameter in the agricultural sector and local economy. The LSTM method was chosen for its ability to handle sequential data and long-term dependencies. Potato price data from Wonosobo was collected and divided into training and validation sets. The LSTM model was run on the training set with a Root Mean Square Error (RMSE) of 155.87, indicating the model's ability to estimate potato prices on the training data. Evaluation of the model on the validation set resulted in an RMSE of 186.31, illustrating the model's performance on data not used during training. In addition, the Mean Absolute Percentage Error (MAPE) was used to measure the relative error rate. The model gave a MAPE of 0.62 on the training data and 0.82 on the validation data. These results indicate the accuracy of the model in forecasting potato price changes, with low values signifying good prediction quality. This research highlights the potential use of the LSTM method in forecasting agricultural commodity prices at the local level.

Keywords : Deep Learning, LSTM, Prediction, Potato Price.

1. PENDAHULUAN

Dalam beberapa dekade terakhir, perkembangan teknologi telah membawa dampak besar pada berbagai aspek kehidupan manusia. Salah satu aspek yang sangat dipengaruhi adalah bidang kecerdasan buatan (AI) dan Machine Learning (ML) [1]. Teknologi ini telah mengalami perkembangan pesat dan telah menjadi bagian penting dari banyak aplikasi dalam berbagai sektor, seperti kesehatan, finansial, transportasi, dan banyak lainnya. Perkembangan teknologi machine learning telah mengubah cara kita mengumpulkan, menganalisis, dan menggunakan data untuk mengambil keputusan yang lebih cerdas.

Salah satu sektor yang memiliki peluang menerapkan teknologi machine learning adalah bidang pertanian. Pertanian memiliki peran penting dalam pembangunan perekonomian Indonesia. Pentingnya peran pertanian menjadikan kegiatan dalam dunia usaha dimasukkan dalam pembangunan ekonomi dengan tema utama pemanfaatan pertanian. Pembangunan pertanian mengacu pada produksi pertanian untuk memenuhi kebutuhan pangan serta kebutuhan ekonomi negara, meningkatkan ekspor, meningkatkan jumlah petani yang menghasilkan pendapatan, memperluas kesempatan kerja, serta mendorong pemerataan [2].

Terdapat banyak komoditas pertanian yang ada di Indonesia dan salah satu komoditas yang unggul adalah kentang. Kentang merupakan salah satu pangan utama dunia setelah padi, gandum, dan jagung. Kentang termasuk kedalam tanaman hortikultura yang dibudidayakan dan dikembangkan oleh masyarakat luas untuk pemenuhan kebutuhan. Kentang merupakan salah satu komoditas hortikultura yang dapat menggantikan beras, dikarenakan umbi kentang memiliki karbohidrat, vitamin, dan mineral yang cukup tinggi [3].

Kentang juga merupakan salah satu komoditas pertanian unggulan, menduduki posisi penting dalam sektor pertanian Indonesia. Tanaman ini merupakan tanaman dengan tingkat produksi yang tinggi di seluruh negeri [4], dan menjadi salah satu pilar ekonomi pertanian yang kuat. Dengan produksi yang melimpah, kentang memberikan kontribusi signifikan terhadap

pasokan pangan nasional dan pendapatan para petani.

Kabupaten Wonosobo sebagai salah satu penghasil kentang di Jawa Tengah menjadikan kentang sebagai komoditas unggul yang memiliki nilai ekonomi tinggi dan terus diupayakan dalam pengembangannya. Menurut Badan Pusat Statistik Kabupaten Wonosobo pada tahun 2018 sampai 2020 rata-rata hasil produksi tanaman kentang di Wonosobo mencapai 539.983 ton dengan luas lahan mencapai 3.498 hektar [5]. Dengan produksi yang cukup banyak menjadikan kentang sebagai komoditi yang cukup menjajikan. Namun dengan adanya fluktuasi harga pada kentang menyebabkan harga kentang sulit untuk diprediksi, sehingga petani dan pedagang tidak dapat mengetahui secara pasti harga pasaran kentang yang naik turun dan menyebabkan susahya petani dan pedagang dalam memprediksi dan memperhitungkan keuntunganya saat panen.

Fluktuasi harga kentang memiliki dampak yang sangat luas pada ekonomi lokal dan nasional. Dinas Pertanian dan Perkebunan Provinsi Jawa Tengah mencatat rata-rata harga kentang (per kg) di Wonosobo mencapai Rp. 14.000 per kg dari data per Sabtu, 08 Juli 2023 dan turun cukup drastis pada Kamis, 13 Juli 2023 yang mencapai harga Rp.11.000 per kg (Dinas Pertanian dan Perkebunan, 2023). Grafik penurunan harga kentang seperti pada gambar 1.1 yang merupakan grafik dari harga kentang dari Januari 2021 sampai Desember 2023.

Para petani kentang di Wonosobo bergantung pada pendapatan dari penjualan hasil panen mereka, dan fluktuasi harga dapat memengaruhi pendapatan mereka. Selain itu, harga kentang yang tidak stabil juga dapat memengaruhi daya beli masyarakat, mengganggu kestabilan pasar, dan bahkan memengaruhi ketahanan pangan di daerah tersebut [6].

Sejumlah faktor berkontribusi pada fluktuasi harga kentang di Wonosobo. Faktor cuaca seperti faktor politik, perubahan kebijakan perdagangan serta panen raya yang dilakan oleh petani dapat memengaruhi harga. Semua faktor ini menciptakan lingkungan yang sangat dinamis, di mana prediksi harga menjadi sangat penting. Metode tradisional yang digunakan untuk meramalkan harga kentang,

seperti analisis statistik dan regresi linear sederhana (Fluktuasi et al., n.d.) [7], cenderung tidak mampu mengatasi kompleksitas fluktuasi harga yang disebabkan oleh faktor-faktor tersebut. Karena itu, penggunaan teknik-teknik kecerdasan buatan, seperti Recurent Neural Network (RNN) dengan Long Short Term Memory (LSTM), telah menjadi fokus penelitian yang menarik.

LSTM adalah salah satu jenis RNN yang terkenal karena kemampuannya dalam memodelkan data sekuensial dan memahami pola temporal yang rumit. Dengan menggunakan LSTM, kita dapat memanfaatkan data historis (data Time Series) harga kentang untuk menghasilkan prediksi yang lebih akurat. Model LSTM mampu mengingat informasi masa lalu yang relevan, sementara juga mampu mengadaptasi diri terhadap perubahan tren yang mungkin terjadi (Sherstinsky, 2020) [8].

2. METODE

Penelitian ini bertujuan untuk memprediksi harga kentang di Wonosobo menggunakan metode Long Short Term Memory (LSTM). Dalam kerangka pemikiran ini, penelitian akan berfokus pada analisis data historis harga kentang, Data historis harga kentang di Wonosobo akan digunakan sebagai dasar untuk melatih dan menguji model LSTM yang kemudian model dari hasil training akan diimplementasikan ke dalam website sederhana.

2.1. Pengumpulan Data

Pada tahap ini dilakukan pengumpulan data yang akan digunakan pada tugas akhir ini. Data yang digunakan adalah data harian perkembangan harga kentang yang ada di Wonosobo periode 1 Januari 2021 – 07 Desember 2023 berjumlah 838 data yang diambil dari situs web Sistem Informasi Pasar Dinas Pertanian dan Peternakan Provinsi Jawa Tengah. Berikut tautan dari data website tersebut.

2.2. Data Preprocessing

Data preprocessing merujuk pada serangkaian langkah atau proses yang dilakukan pada dataset sebelum dataset tersebut digunakan untuk analisis atau pembuatan model dalam konteks machine learning atau analisis data.

2.2.1. Imputasi Data

Dalam dataset mentah harga kentang terdapat beberapa missing value data, dan untuk mengatasi permasalahan missing values, metode yang paling umum dilakukan adalah dengan melakukan sebuah imputasi terhadap missing values tersebut. Metode imputasi yang diterapkan menggunakan imputasi median dengan periode tertentu untuk mengisi data yang hilang. Imputasi data median dengan periode tertentu merupakan suatu metode untuk menggantikan nilai-nilai yang hilang atau missing values dalam suatu dataset dengan nilai median dari suatu periode waktu atau rentang tertentu.

2.2.2. Feature Scaling

Setelah data yang hilang diganti dengan data baru selanjutnya adalah melakukan feature scaling yang merupakan suatu teknik dalam analisis data dan machine learning yang digunakan untuk mengubah skala nilai-nilai fitur atau variabel dalam dataset. Tujuan utama dari feature scaling adalah untuk memastikan bahwa variabel-variabel dengan skala yang berbeda-beda memiliki dampak yang seimbang pada analisis atau model yang dibangun.

Pada penelitian ini untuk feature scaling menggunakan min-max normalization, yang mana ini dapat mengubah nilai-nilai fitur sehingga mereka berada dalam rentang tertentu, sering kali antara 0 dan 1 (Sklearn.Preprocessing.MinMaxScaler, n.d.).

$$X_{norm} = \frac{X - min}{max - min}$$

Di mana X adalah nilai asli, min adalah nilai minimum, dan max adalah nilai maksimum dari fitur tersebut.

2.2.3. Pembagian Dataset

Pada tahap ini dataset dibagi menjadi subset yang berbeda untuk berbagai tujuan seperti pelatihan (training), validasi, dan validasi (validasi) dalam konteks machine learning.


Pembagian dataset menjadi bagian-bagian ini penting untuk mengukur kinerja model dan mencegah overfitting, yaitu ketika model terlalu baik menyesuaikan diri dengan data pelatihan tetapi tidak dapat umumkan hasilnya pada data baru. Pada penelitian ini data dibagi menjadi 80% dari keseluruhan data digunakan untuk proses latih dan 20% sisanya untuk proses validasi dan validasi.

2.2.4. Windowing Dataset

Pada tahap ini data yang sudah diproses sebelumnya selanjutnya dilakukan Windowing Data yang berarti mengambil kumpulan data dan mempartisinya menjadi beberapa subbagian (yang meningkatkan bentuk dimensi kumpulan data). Pendekatan ini umumnya digunakan dalam analisis deret waktu dan pembuatan model machine learning untuk memprediksi nilai di masa depan berdasarkan pola di masa lalu.

2.3. Perancang Model LSTM

Metode LSTM adalah cara memprediksi data berdasarkan deret data beberapa waktu sebelumnya. Misalnya akan memprediksi data pada urutan kelima berdasarkan empat waktu sebelumnya, maka beberapa waktu sebelumnya adalah urutan kesatu, kedua, ketiga, dan keempat. Sehingga data yang sudah dilakukan windowing dataset akan dimasukkan ke dalam input layer yang kemudian di teruskan ke layer LSTM. Arsitektur LSTM untuk prediksi harga kentang adalah 60 node di layer input, 60 node di layer hidden LSTM pertama, 60 node di layer hidden LSTM kedua, kemudian 30 lapisan neural network dense layer dengan activation function ReLu , dan 1 node di layer output. Berikut merupakan arsitektur yang akan dibangun pada penelitian ini :



Gambar 1. Rancangan Arsitektur LSTM Prediksi Harga Kentang

2.4. Train dan Evaluasi Model

Setelah membuat model LSTM dengan menggunakan, kemudian latih data yang ada ke dalam model yang sudah dirancang. Pelatanganan model menggunakan metode SGD (Stochastic Gradient Descen) yang merupakan salah satu algoritma optimasi yang digunakan untuk melatih model machine learning. SGD termasuk dalam kategori optimasi berbasis gradien yang bertujuan untuk menemukan nilai parameter model yang meminimalkan fungsi kerugian (loss function).


Proses utama dari SGD adalah mengupdate parameter model dengan menyesuakannya ke arah yang berlawanan dari gradien fungsi kerugian terhadap parameter tersebut. Secara stokastik, SGD memilih satu sampel data secara acak pada setiap iterasi untuk menghitung gradien dan melakukan pembaruan. Pendekatan ini membuat SGD lebih efisien dan lebih cepat konvergensinya terutama pada dataset besar.

Kemudian untuk mengukur optimasi pada model digunakan metode Huber loss, juga dikenal sebagai Huber regression loss atau smooth L1 loss, adalah suatu fungsi kerugian (loss function) yang digunakan dalam pemodelan statistik dan machine learning, khususnya pada regresi. Fungsi ini dirancang untuk mengatasi masalah sensitivitas terhadap outlier yang dapat terjadi dengan menggunakan fungsi kerugian kuadrat (MSE - Mean Squared Error).

2.5. Penerapan Model

Model yang sudah dirancang dan di latih selanjutnya akan diterpkan ke dalam website, dimulai dengan menggunakan web framework Flask. Bahasa pemrograman yang digunakan

yaitu Python. Lalu, melakukan konfigurasi pada model machine learning yang sudah dibentuk dalam format pickle ke dalam web framework Flask. Setelah itu lakukan testing pada local host untuk mengetahui apakah konfigurasi Flask yang dilakukan telah berhasil terbentuk dengan baik. Hasil akhir dari perancangan ini berupa sebuah website yang memiliki data dari prediction machine learning model. Berikut merupakan perancangan pada penerapan model ke dalam sebuah webseb dengan menggunakan python.



Gambar 2. Rancangan Penerapan Model

3. HASIL DAN PEMBAHASAN

3.1. Penyiapan Data

Data harga kentang di Wonosobo diambil dari data yang sudah tersedia di dalam website Dinas Pertanian dan Perkebunan, data mentah yang digunakan terdiri dari beberapa data harga berbagai sayuran yang tersimpan dalam bentuk data spreadsheed.

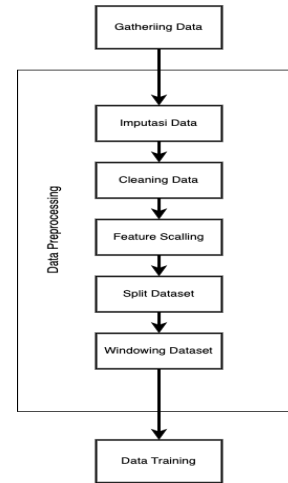
Id	Tgl	Kab/Kota	Tingkat Harga	BMB	BMK	BPI	BPL	BNC	CMB	...	CRH	CRM	KEK	KTD	KLB	KLG	MTM	TMT	WRT	CHB
0 23	04 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	57000	0	9000	0	7000	0	4000	7000	NaN
1 70	05 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	65000	0	9000	0	7000	0	4000	7000	0.0
2 108	06 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	65000	0	9000	0	7000	0	4000	7000	NaN
3 135	07 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	65000	0	9000	0	7000	0	5000	7000	NaN
4 253	08 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	65000	0	9000	0	7000	0	4000	7000	NaN
5 259	11 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	65000	0	9000	0	7000	0	4000	7000	NaN
6 287	12 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	35000	66000	0	9000	0	8000	0	3000	7000	NaN
7 326	13 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	40000	60000	0	9000	0	8000	0	2500	7000	NaN
8 425	15 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	45000	60000	0	9000	0	6000	0	2500	7000	NaN
9 427	14 Januari 2021	Wonosobo	Harga Produsen	0	17000	0	13000	0	0	...	40000	60000	0	9000	0	8000	0	2500	7000	NaN

Gambar 3. Data Harga Sayur Wonosobo

3.2. Preprocessing Data

Pada tahap ini melibatkan beberapa proses karena data yang ada terdapat data yang missing value dan tipe data yang tidak sesuai, oleh karena itu pada tahap ini adalah mengubah data mentah menjadi data yang lebih bersih agar dapat digunakan untuk kebutuhan pembuatan model prediksi.

Pada penelitian ini, dilakukan penerapan tahap preprocessing data dengan 5 tahapan yaitu, Imputasi Data, Cleaning Data, Feature Scalling, Split Dataset, dan Windowing Dataset, proses preprocessing seperti pada bagan berikut.



Gambar 4. Bagan Proses Preprocessing

3.2.1. Cleaning Data

Pada tahap cleaning data ini peneliti perlu menghapus data yang memiliki duplikat dan mengisi data yang tidak ter-input pada data mentah, karena data merupakan data timeseries terdapat juga data yang tidak terisi atau ter-input kedalam dataset, seperti contoh pada tanggal 01 - 02 januari 2021 tidak terdapat datanya, maka dari itu perlu mengisi data yang tidak terisi terlebih dahulu sebelum lanjut ke proses selanjutnya. Sebelum melakukan cleaning data timeseries peneliti menentukan terlebih dahulu range data yang akan digunakan, pada penelitian ini data yang digunakan dimulai dari tanggal 01 Januari 2021 sampai tanggal 07 Desember 2023.


```

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 835 entries, 0 to 834
Data columns (total 2 columns):
#   Column   Non-Null Count  Dtype
---  ---      -
0   tanggal  835 non-null    object
1   harga    835 non-null    int64
dtypes: int64(1), object(1)
memory usage: 13.2+ KB
    
```

Gambar 5. Ringkasan Data Sebelum Proses Cleaning

3.2.2. Imputasi Data

Pada tahap cleaning data, nilai pada kolom harga pada data baru memiliki nilai kosong (missing value) atau NaN pada python, dengan data yang kosong akan membuat proses training data pada model tidak bisa berjalan dengan baik, oleh karena itu diperlukan imputasi data pada data yang kosong. Dalam proses ini dilakukan tahapan identifikasi missing values dan mengisi missing value dengan nilai mean moving average dengan periode 30 hari. Untuk mengidentifikasi missing value perlu dilakukan plotting pada data yang sudah dilakukan proses cleaning .



Gambar 6. Ploting Data Setelah Proses Cleaning

Hasil dari proses tersebut akan mengisi nilai data harga yang hilang pada data yang ada, dan akan menambah data yang awalnya berjumlah 825 bertambah menjadi 1071 data.

```
<class 'pandas.core.frame.DataFrame'>
DatetimeIndex: 1071 entries, 2021-01-01 to 2023-12-07
Data columns (total 2 columns):
#   Column  Non-Null Count  Dtype
---  -
0   tanggal  1071 non-null     datetime64[ns]
1   harga    1071 non-null     float64
dtypes: datetime64[ns](1), float64(1)
memory usage: 57.4 KB
```

Gambar 7. Ringkasan Data Sesudah Pengisian Data

3.2.3. Feature Scalling

Pada tahap ini data yang sudah bersih selanjutnya dilakukan proses feature scalling, yang mana mengubah skala nilai-nilai fitur atau variabel dalam dataset, pada penelitian ini menggunakan min-max scaler untuk mengubah nilai data data menjadi data dari range 0 dan 1, proses ini bertujuan agar pada proses pelatihan

model data yang dilatih tidak overhead karena nilai data yang terlalu besar, pada proses ini peneliti menggunakan library sklearn untuk membantu proses scaling.

data asli	min-max
11000.0	0.500000
9000.0	0.166667
11000.0	0.500000
11000.0	0.500000
12000.0	0.666667
14000.0	1.000000
8000.0	0.000000
14000.0	1.000000
14000.0	1.000000
10000.0	0.333333

Gambar 8. Hasil Scaling Minmax

3.2.4. Windowing Dataset

Pada tahap ini data yang sudah dibersihkan selanjutnya dilakukan windowing dataset, yang mana data dibagi menjadi segmen-segmen yang lebih kecil atau jendela waktu yang dapat diolah secara terpisah yang kemudian dapat digunakan untuk menentukan x dan y yang mana x menjadi data parameter dan y sebagai label. Pada penelitian ini ukuran dari data akan dibuat menjadi windowed dataset adalah 20 yang merepresentasikan model akan memprediksi harga kentang dari data 20 hari terakhir.

Hasil dari proses akan menjadikan data dari range 20 hari terakhir menjadi data parameter (x1 – x20) dan data setelah 20 hari menjadi data label (y)


learning rate yang digunakan untuk optimisasi model dengan epoch adalah 50.

Output dari perintah tersebut adalah beberapa hasil MSE dari data pelatihan dan validasi selama 50 epoch seperti pada gambar 4.18 , yang kemudian plotting hasil loss pada pelatihan dengan library matplotlib apakah model mengalami overfitting atau tidak.

```

Epoch 36/50 ----- 1s 4ms/step - loss: 7.3485e-04 - mae: 0.0101 - val_loss: 0.0010 - val_mae: 0.0182
Epoch 37/50 ----- 1s 4ms/step - loss: 7.2012e-04 - mae: 0.0099 - val_loss: 0.0010 - val_mae: 0.0113
Epoch 38/50 ----- 1s 4ms/step - loss: 7.1497e-04 - mae: 0.0099 - val_loss: 0.0010 - val_mae: 0.0112
Epoch 39/50 ----- 1s 4ms/step - loss: 6.9872e-04 - mae: 0.0093 - val_loss: 0.0011 - val_mae: 0.0134
Epoch 40/50 ----- 1s 4ms/step - loss: 7.0167e-04 - mae: 0.0093 - val_loss: 0.0011 - val_mae: 0.0130
Epoch 41/50 ----- 1s 4ms/step - loss: 7.0966e-04 - mae: 0.0099 - val_loss: 0.0011 - val_mae: 0.0109
Epoch 42/50 ----- 1s 4ms/step - loss: 7.1520e-04 - mae: 0.0104 - val_loss: 0.0010 - val_mae: 0.0117
Epoch 43/50 ----- 1s 4ms/step - loss: 7.2391e-04 - mae: 0.0106 - val_loss: 0.0010 - val_mae: 0.0099
Epoch 44/50 ----- 1s 4ms/step - loss: 6.8956e-04 - mae: 0.0088 - val_loss: 0.0010 - val_mae: 0.0111
Epoch 45/50 ----- 1s 4ms/step - loss: 6.9525e-04 - mae: 0.0091 - val_loss: 0.0010 - val_mae: 0.0133
Epoch 46/50 ----- 1s 4ms/step - loss: 7.3094e-04 - mae: 0.0109 - val_loss: 0.0010 - val_mae: 0.0111
Epoch 47/50 ----- 1s 4ms/step - loss: 7.3650e-04 - mae: 0.0110 - val_loss: 0.0010 - val_mae: 0.0097
Epoch 48/50 ----- 1s 4ms/step - loss: 7.0472e-04 - mae: 0.0097 - val_loss: 9.1907e-04 - val_mae: 0.0147
Epoch 49/50 ----- 1s 4ms/step - loss: 6.8882e-04 - mae: 0.0090 - val_loss: 0.0010 - val_mae: 0.0096
Epoch 50/50 ----- 1s 4ms/step - loss: 6.8209e-04 - mae: 0.0085 - val_loss: 0.0010 - val_mae: 0.0107
    
```

Gambar 13 . Hasil Proses Pelatihan Model



Gambar 14. Ploting Loss Training

Dilihat dari hasil plotting loss , model yang digunakan tidak mengalami overfitting , dengan melihat dari hasil loss pada trining dan validasi data memperoleh loss akhir yang bernilai sama, ini menunjukkan model yang ada tidak mengalamii overfitting.

3.4. Evaluasi dan Hasil Model

Setelah model dibuat dan data yang ada dilatih kedalam model , tahap selanjutnya adalah evaluasi model yang berguna mengukur sejauh mana model mampu memberikan hasil yang akurat dan relevan pada data yang belum pernah dilihat sebelumnya. Evaluasi model pada penelian ini menggukan Root Mean Squared Error , yang mana pemilihan adalah karena metrik ini memberikan penalti lebih besar

terhadap kesalahan prediksi yang signifikan. Output dari perintah tersebut akan menampilkan hasil RMSE yaitu sebesar 155.87 pada data pelatihan dan 186.31 pada data validasi.

```

26/26 [=====] - 0s 1ms/step
6/6 [=====] - 0s 2ms/step
Train Score: 155.87 RMSE
Test Score: 186.31 RMSE
    
```

Gambar 15. Hasil RMSE

Kemudian untuk beberapa contoh perbandingan hasil dari data aktual dan data prediksi.

tanggal	harga asli	harga predict
2021-07-06	9000.0	9021.130859
2021-09-22	10000.0	9853.324219
2021-12-19	8000.0	8039.028320
2021-06-15	9000.0	9021.130859
2021-03-24	8000.0	8039.028320
2021-10-23	10000.0	10029.090820
2022-04-12	10000.0	10045.737305
2021-06-02	9000.0	9021.130859
2021-03-14	8000.0	8039.028320
2021-09-02	9000.0	9021.130859
2021-01-22	8000.0	8048.202637
2021-05-26	9000.0	9021.130859
2022-05-18	10000.0	10029.090820
2021-03-28	8000.0	8039.028320
2022-05-15	10000.0	10029.090820
2022-01-28	9000.0	9021.130859
2022-03-01	10000.0	10045.368164
2021-05-12	9000.0	9021.130859
2021-06-07	9000.0	9021.130859
2021-04-27	9000.0	8999.106445

Gambar 16. Perbandingan Nilai Aktual dan Nilai Prediksi

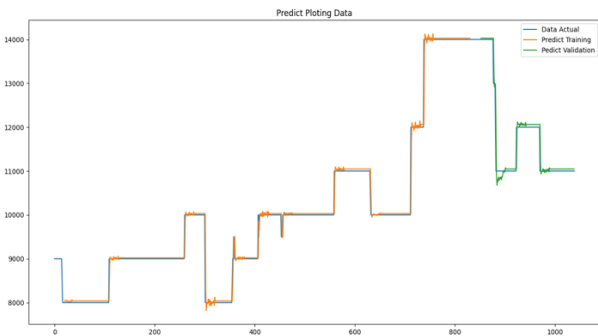
Kemudian untuk mengetahui tingkat akurasi dari hasil latih diperlukan metrik berupa MAPE yang merupakan perhitungan untuk mengetahui presentase akurasi pada model.

Untuk output dari hasil perintah tersebut akan menampilkan hasil presentase error yaitu 0.62% untuk data latih dan 0.82% untuk data validasi prediksi.

Train Score: 0.62 MAPE
 Test Score: 0.82 MAPE

Gambar 17. Hasil MAPE

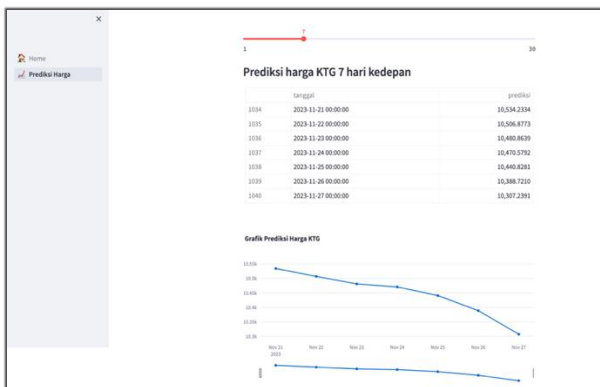
Dan untuk visualisasi dari hasil perbandingan data actual dan data traian seperti pada gambar berikut.



Gambar 18. Ploting Nilai Aktual dan Nilai Prediksi

3.5. Penerapan Model

Pada tahap ini model yang sudah dibuat dan dilatih selanjutnya diterapkan ke dalam sebuah website, Menerapkan model machine learning ke dalam sebuah website melibatkan beberapa langkah yaitu dengan export model, load model, dan membuat tampilan pengguna. Hasil dari penerapan model seperti pada gambar berikut.



Gambar 19. Hasil Tampilan Pengguna

4. PENUTUP

4.1. Kesimpulan

Berdasarkan hasil tugas akhir mengenai prediksi harga kentang di Wonosobo menggunakan metode *Long Short Term Memory* (LSTM) dapat ditarik kesimpulan sebagai berikut:

1. Model LSTM

- a. Model LSTM yang digunakan pada tugas akhir memberikan hasil yang dapat diterima dengan nilai RMSE dan MAPE yang relatif rendah.
- b. Nilai RMSE pada data pelatihan (train) sebesar 155.87 dan pada data validasi sebesar 186.31 menunjukkan bahwa model dapat memberikan prediksi yang akurat.

2. Evaluasi Kinerja

- a. Nilai MAPE pada data pelatihan sebesar 0.62 dan pada data validasi sebesar 0.82 menunjukkan tingkat kesalahan relatif yang cukup baik. Semakin rendah nilai MAPE, dan pada data testing sebanyak 5.52%, semakin akurat prediksi model.

3. Penerapan di wilayah spesifik

- a. Model ini relevan untuk diterapkan dalam konteks prediksi harga kentang di Wonosobo, sesuai dengan konteks wilayah atau pasar yang diselidiki.

4. Penerapan pada website

- a. Model dari hasil prediksi dapat diterapkan pada website dengan baik dengan menggunakan *library* streamlit pada python.
- b. Website dapat menampilkan hasil prediksi dan grafik prediksi selama 1 tahun kedepan dari tanggal 08 Desember 2023 sampai 01 Desember 2024.

4.2. Saran

Dari hasil penelitian yang dilakukan masih banyak kekurangan, dengan demikian penulis berharap penelitian ini dapat dikembangkan lagi. Beberapa saran dari penulis, yaitu :

1. Optimasi Model

Melakukan eksplorasi lebih lanjut terhadap *hyperparameter* dan arsitektur model LSTM untuk mengoptimalkan performa prediksi.

2. Data yang Lebih Komprehensif

Memperoleh data yang lebih komprehensif dan akurat, termasuk variabel tambahan yang mungkin mempengaruhi harga kentang seperti faktor cuaca, kebijakan pemerintah, atau aspek ekonomi lokal.

3. Validasi dengan Data Terbaru

Melakukan validasi model dengan menggunakan data yang lebih baru untuk memastikan keberlanjutan kinerja model di masa mendatang.

4. Interpretasi Hasil

Menganalisis lebih lanjut faktor-faktor apa yang paling memengaruhi hasil prediksi untuk memberikan wawasan lebih mendalam terhadap faktor-faktor tersebut.

5. Komunikasi Hasil

Menyajikan hasil secara jelas dan mudah dimengerti untuk stakeholder terkait, seperti petani kentang, pedagang, atau pihak-pihak yang terlibat dalam distribusi dan pemasaran.

6. Penelitian Lanjutan

Menyusun rencana untuk penelitian lanjutan, mungkin dengan menggunakan metode atau model lainnya, guna meningkatkan akurasi prediksi dan memperluas pemahaman terhadap pasar kentang di Wonosobo.

Dengan mengimplementasikan saran-saran tersebut, diharapkan hasil prediksi harga kentang dapat lebih baik lagi dan memberikan manfaat yang lebih besar dalam konteks pasar dan kegiatan ekonomi di Wonosobo.

5. DAFTAR PUSTAKA

[1] Mikelsten, D., Teigen, V., & Skalfist, P. (2022). Kecerdasan Buatan: Revolusi

Industri Keempat. Cambridge Stanford Books.

[2] Rambe, M. F. a. A., & Aslami, N. (2022). Peran Pertanian Di Indonesia Dalam Memasuki Perdagangan internasional. *Journal of Social Research*, 1(3), 169–177. <https://doi.org/10.55324/josr.v1i3.52>

[3] Sofiari, Dan, Penelitian Tanaman Sayuran, B., Tangkuban Parahu, J., & Barat, B. (2013). Perubahan Morfologi Dan Toleransi Tanaman Kentang Terhadap Suhu Tinggi (Morphological Changes And Tolerance Of Potato Plants To Heat Stress). In *J. Hort* (Vol. 23, Issue 4).

[4] Hasrialdy Qamalpasha Muchransyah, M., Sarma, Mun, & Najib, M. (2018). Analisis Internal Dan Eksternal Kentang Indonesia Dalam Menghadapi Masyarakat Ekonomi ASEAN (MEA) Indonesian Potential Internal And External Analysis In Facing The ASEAN Economic Community (MEA). *Jurnal Manajemen Dan Organisasi (JMO)*, 9(2), 115–121.

[5] BPS Provinsi Jawa Tengah.(n.d.). <https://jateng.bps.go.id/indicator/55/731/1/luas-panen-dan-produksi-kentang.html>

[6] Irawan, B. (2007). Fluktuasi Harga, Transmisi Harga Dan Marjin Pemasaran Sayuran Dan Buah. In *Analisis Kebijakan Pertanian* (Vol. 5, Issue 4).

[7] Fluktuasi, A., Transmisi, E., Kentang, H., Kabupaten, D., Maulida, M.-N., Ayomi, S., Setiawan, B. M., Roessali, W., Maulida, N., Wiludjeng, D., Program, R., Agribisnis, S. M., Peternakan, F., & Pertanian, D. (N.D.). Analisis Fluktuasi Dan Elastisitas Transmisi Harga Kentang Di Kabupaten Magelang Analyze Of Price Fluctuation And Price Transmission Elasticity Of Potato In Magelang Regency.

[8] Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/10.1016/j.physd.2019.132306>