

Implementasi Algoritma LSTM untuk Prediksi Harga Cabai Merah Keriting di Yogyakarta

Arieska Restu Harpian Dwika ^{1*}, Donny Avianto ²

^{1,2} Program Studi Informatika, Fakultas Sains & Teknologi, Universitas Teknologi Yogyakarta, Kabupaten Sleman, Provinsi Daerah Istimewa Yogyakarta, Indonesia.

Corresponding Email: arieskarestu02@gmail.com ^{1*}

Histori Artikel:

Dikirim 11 November 2023; *Diterima dalam bentuk revisi* 25 November 2023; *Diterima* 10 Desember 2023; *Diterbitkan* 10 Januari 2024. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

Abstrak

Cabai merah keriting merupakan salah satu tanaman hortikultura yang bernilai ekonomi tinggi. Cabai merah keriting dapat menyebabkan inflasi karena harganya yang sangat berfluktuasi dan cenderung naik. Tujuan penelitian adalah untuk memprediksi harga di masa depan dengan cepat dan akurat sehingga pemerintah dan konsumen dapat melakukan tindakan preventif terhadap permasalahan yang ada. Penelitian ini akan menggunakan algoritma LSTM dan dataset harga cabai merah keriting di Yogyakarta dari tanggal 9 Oktober 2017 hingga 27 Oktober 2023. Berdasarkan pengujian dari penelitian ini, hasil terbaik yang didapatkan adalah dengan menggunakan rasio pembagian data 70%:30%, epoch 150, batch size 48, learning rate 0.001, jumlah neuron 30, fungsi aktivasi ReLU, dan fungsi optimasi Adam yang menghasilkan nilai MAPE 3.6995%, dan akurasi 96.3005%. Diharapkan dengan adanya sistem ini dapat membantu pihak terkait mendapatkan prediksi harga cabai merah keriting yang akurat.

Kata Kunci: Prediksi; Harga Cabai Merah Keriting; Time Series; LSTM.

Abstract

Curly red chili is one of the horticultural crops with high economic value. Curly red chili can cause inflation because the price fluctuates greatly and tends to rise. The purpose of the research is to predict future prices quickly and accurately so that the government and consumers can take preventive action against existing problems. This research will use the LSTM algorithm and a dataset of curly red chili prices in Yogyakarta from October 9, 2017 to October 27, 2023. Based on the testing of this research, the best results obtained are by using a data division ratio of 70%: 30%, epoch 150, batch size 48, learning rate 0.001, number of neurons 30, activation function ReLU, and the optimization function Adam which produces a MAPE value of 3.6995%, and an accuracy of 96.3005%. It is hoped that this system can help related parties get accurate curly red chili price predictions.

Keyword: Prediction; Curly Red Chili Price; Time Series; LSTM.

1. Pendahuluan

Sektor pertanian memegang peranan penting dalam memenuhi kebutuhan perekonomian Indonesia [1]. Peran sektor pertanian dalam perekonomian Indonesia adalah sebagai sumber lapangan pekerjaan, sumber modal atau investasi, dan sebagai pasar untuk produk industri lainnya, serta berperan sebagai penghasil atau pemasok bahan pangan [2]. Cabai merah keriting merupakan salah satu tanaman hortikultura yang bernilai ekonomi tinggi [3]. Masyarakat mengkonsumsi cabai merah keriting setiap hari untuk berbagai keperluan, seperti dijadikan sayur, bumbu masakan, dan pewarna makanan. Selain untuk makanan, cabai merah juga digunakan untuk bahan baku industri farmasi [4]. Cabai merah keriting termasuk komoditas pangan yang mempunyai masalah fluktuasi harga, tidak terkecuali di Yogyakarta [5]. Berikut ini adalah grafik harga cabai merah keriting di Yogyakarta tahun 2017 sampai 2023.



Gambar 1. Grafik Harga Cabai Merah Keriting di Yogyakarta

Gambar 1 menunjukkan bahwa harga cabai merah keriting di Yogyakarta selalu berubah sangat fluktuatif hampir setiap hari. Hal ini disebabkan tingginya permintaan dan pasokan. Semakin tinggi pasokan, maka semakin murah harga cabai merah keriting akan. Sedangkan semakin sedikit pasokan, maka semakin mahal harganya [6]. Harga cabai yang berfluktuasi dapat mengakibatkan kerugian bagi petani maupun konsumen. Ketika harga cabai terlalu tinggi, konsumen harus mengeluarkan banyak uang untuk mendapatkannya. Selain konsumen, petani juga akan mengalami kerugian jika harga cabai terlalu tinggi. Hal ini disebabkan oleh sedikitnya konsumen yang akan membeli sehingga petani tidak mendapatkan Kembali modal yang telah digunakan untuk menanam tanaman tersebut [7].

Fluktuasi dan tren harga cabai merah keriting yang tinggi juga dapat menyebabkan terjadinya inflasi [8]. Inflasi adalah kondisi dimana harga-harga terus meningkat. Kenaikan harga pangan yang bersifat musiman, menjelang hari raya, atau hanya terjadi sekali dan tidak memiliki dampak yang berkelanjutan tidak dapat dikatakan sebagai inflasi [9]. Inflasi dapat mempengaruhi pertumbuhan ekonomi secara signifikan dan negatif yang berakibat pada menurunnya minat beli masyarakat karena tingginya harga pangan [10]. Harga komoditas pangan memiliki dampak yang signifikan terhadap tingkat inflasi [11]. Oleh karena itu, cabai merah keriting dapat menyebabkan inflasi karena harganya yang sangat berfluktuasi dan cenderung naik. Pemerintah dapat menerapkan beberapa kebijakan untuk mengatasi permasalahan tersebut, salah satunya yaitu pengendalian harga. Dalam rangka menstabilkan harga komoditas pangan, pemerintah membuat Harga Eceran Tertinggi (HET) untuk komoditas pangan seperti komoditas cabai merah keriting. Rumusan masalah dalam penelitian ini didasarkan pada permasalahan sebelumnya yaitu sulitnya memprediksi naik turunnya harga cabai merah keriting yang cenderung naik yang dapat menyebabkan inflasi dan kerugian bagi petani dan konsumen sehingga diperlukan suatu sistem yang mampu memprediksi harga cabai merah keriting di masa depan secara akurat.

Penelitian terkait prediksi harga cabai rawit telah dilakukan menggunakan Metode *Long-Short Term Memory* [12]. Selain itu, penelitian mengenai peramalan harga cabai juga telah dilakukan dengan menggunakan dua metode, dimana salah satu metodenya yakni *Bidirectional-LSTM* [13]. Algoritma LSTM tidak hanya dapat digunakan untuk memprediksi harga cabai merah keriting saja, namun juga dapat digunakan untuk memprediksi harga minyak goreng curah dan kemasan [14]. Penelitian ini juga telah dilakukan menggunakan algoritma LSTM dari dua algoritma yang digunakan untuk memprediksi

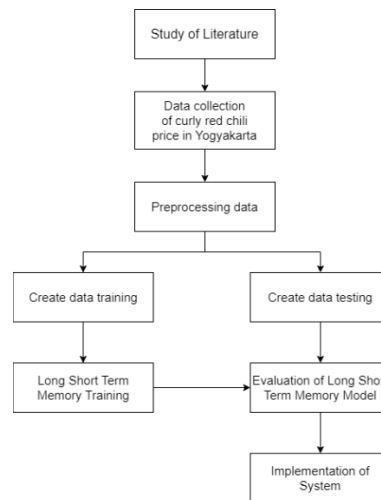
harga minyak goreng di Indonesia [15]. Algoritma LSTM telah digunakan juga pada penelitian mengenai prediksi harga komoditas pangan [16]. Metode ini juga telah diimplementasikan untuk memprediksi harga bahan pokok nasional [17]. Penelitian mengenai memprediksi harga bahan pangan di kota Tasikmalaya juga menggunakan algoritma LSTM dari kedua algoritma yang digunakan [13]. Metode LSTM juga telah digunakan untuk prediksi harga bahan baku pupuk [18]. Selain digunakan dalam prediksi harga, metode LSTM juga dapat digunakan untuk memprediksi data berjenis time series. Metode ini telah digunakan dalam penelitian mengenai prediksi harga saham sektor perbankan [19]. Penelitian prediksi menggunakan LSTM dan data time series dari data saham Bank BRI telah dilakukan [20]. Penelitian mengenai peramalan harga cryptocurrency juga telah dilakukan dengan algoritma LSTM [21].

Berdasarkan penelitian-penelitian tersebut, algoritma LSTM sangat efektif jika digunakan untuk menyelesaikan masalah tentang peramalan atau prediksi data yang bergantung pada waktu yang sering disebut dengan forecasting. Algoritma LSTM merupakan pengembangan lebih lanjut dari algoritma RNN [22]. Dengan algoritma ini, informasi dari data time series dan jangka panjang, serta sekuensial dapat diekstrak. Algoritma LSTM mampu mengatasi vanishing gradient atau keadaan nilai gradien adalah 0 atau mendekati 0 dengan mekanisme gate [23]. Arsitektur algoritma LSTM dapat digunakan untuk pengolahan, peramalan, dan klasifikasi data time series karena algoritma ini dirancang untuk menyimpan data dalam jangka waktu yang lama. Dari permasalahan sebelumnya dan kelebihan algoritma LSTM yang dapat memprediksi data berjenis time series, maka penelitian ini menggunakan algoritma LSTM untuk meramalkan harga terdekat dari harga cabai merah keriting di Yogyakarta agar perubahan harga dapat dengan mudah diprediksi.

Struktur selanjutnya dari penelitian ini yaitu metode penelitian, hasil dan pembahasan, kemudian kesimpulan. Bab selanjutnya metode penelitian akan menjelaskan tentang metodologi penelitian yang diterapkan dalam penelitian ini, dimulai proses studi literatur, proses pengumpulan data, preprocessing data, pembuatan data training dan testing, proses training, dan proses evaluasi, serta proses implementasi (*deployment*). Bab hasil dan analisis menjelaskan tentang hasil pengujian. Setelah pengujian selesai, hasilnya ditampilkan secara grafis sehingga hasil pengujian dapat dibandingkan dengan kondisi parameter yang berbeda untuk mengetahui seberapa baik algoritma dapat bekerja secara optimal dalam menjawab pertanyaan-pertanyaan dalam penelitian ini. Sedangkan pada bab terakhir menjelaskan bagaimana menarik kesimpulan dari hasil percobaan pada penelitian ini dan menyarakannya kepada peneliti selanjutnya.

2. Metode Penelitian

Algoritma LSTM akan digunakan dalam penelitian ini untuk memprediksi harga cabai merah keriting. Dalam hal ini, peneliti menggunakan data harga cabai merah keriting di Yogyakarta dari tanggal 9 Oktober 2017 hingga 27 Oktober 2023. Data yang digunakan diambil dari website PIHPS Nasional. Tahapan penelitian dalam penelitian ini yaitu ditunjukkan pada Gambar 2 berikut ini.



Gambar 2. Tahapan-tahapan penelitian

Berdasarkan pada Gambar 2, berikut ini adalah penjelasan dari setiap proses yang akan dilakukan.

2.1 Study of Literature

Pada tahap pertama, dilakukan proses pemahaman terhadap penelitian yang akan dilakukan dalam rangka membuat dan memperbaiki model untuk memprediksi harga cabai merah keriting sesuai dengan perumusan masalah, batasan ruang lingkup, dan tujuan dari penelitian ini.

2.2 Data Collection of Curly Red Chili Price in Yogyakarta

Data yang digunakan yaitu data harga cabai merah keriting di Yogyakarta periode 9 Oktober 2017 hingga 27 Oktober 2023.

Proses pengumpulan dataset dilakukan dengan cara menyalin data langsung dari website PIHPS Nasional dengan link <https://www.bi.go.id/hargapangan/TabelHarga/PasarTradisionalDaerah> yang diakses pada 27 Oktober 2023. Proses pengumpulan data ini menghasilkan 1580 data. Tabel 1 adalah tabel yang berisi beberapa data yang akan digunakan.

Tabel 1. Tabel Beberapa Harga Cabai Merah Keriting di Yogyakarta

Tanggal	Harga	Tanggal	Harga	Tanggal	Harga
26/09/2023	38750	6/10/2023	35750	18/10/2023	40000
27/09/2023	38750	9/10/2023	35750	19/10/2023	40000
28/09/2023	35000	10/10/2023	38250	20/10/2023	40000
29/09/2023	37500	11/10/2023	38250	23/10/2023	40000
2/10/2023	37500	12/10/2023	38250	24/10/2023	40000
3/10/2023	35000	13/10/2023	38250	25/10/2023	40000
4/10/2023	35000	16/10/2023	38250	26/10/2023	40000
5/10/2023	35750	17/10/2023	39500	27/10/2023	47500

2.3 Preprocessing Data

Pada tahap ini, dilakukan proses data *cleaning* dan proses normalisasi pada dataset. Data *cleaning* adalah proses untuk membersihkan atau menghilangkan data yang noise [24]. Dimana data noise adalah data yang nilai atributnya hilang (*missing value*), data yang tidak konsisten, serta terdapat duplikasi data [25]. *Missing value* dapat diatasi dengan dua cara, yaitu menghapusnya seluruh baris yang nilainya hilang dan menghitung nilai pengganti (*imputasi*) [26]. Setelah itu dilakukan proses normalisasi pada dataste. Dataset diubah menjadi rentang 0 hingga 1 menggunakan metode Min-Max. Normlasisasi Min-Max adalah teknik penskalaan yang mengubah nilainya ke dalam skala 0 hingga 1

atau -1 hingga 1 menggunakan nilai minimum dan maksimum dari fitur [27]. Berikut ini adalah rumus dari normalisasi Min-Max yang akan digunakan [28].

$$x_{new} = \frac{x_{old} - x_{min}}{x_{max} - x_{min}}$$

2.4 Create Data Training & Testing

Pada tahap ini, membuat dataset latih dan dataset uji. Train dan test dataset dibuat menjadi 10 fitur dan 1 label, dimana 10 fitur tersebut merupakan harga pada hari-hari sebelumnya. Dataset latih yang akan digunakan sebanyak 1342 data. Sedangkan untuk dataset test sebanyak 150 data. Tabel 2 dan Tabel 3 berikut adalah beberapa data yang ada pada dataset latih dan dataset uji.

Tabel 2. Tabel Beberapa Data dari Train Dataset

X-10	X-9	X-8	X-7	X-6	X-5	X-4	X-3	X-2	X-1	X
0.1104	0.1104	0.1066	0.0952	0.0857	0.0857	0.0857	0.0819	0.0761	0.0761	0.0933
76	76	67	38	14	14	14	05	9	9	33
0.1104	0.1066	0.0952	0.0857	0.0857	0.0857	0.0819	0.0761	0.0761	0.0933	0.0952
76	67	38	14	14	14	05	9	9	33	38
0.1066	0.0952	0.0857	0.0857	0.0857	0.0819	0.0761	0.0761	0.0933	0.0952	0.0952
67	38	14	14	14	05	9	9	33	38	38
0.0952	0.0857	0.0857	0.0857	0.0819	0.0761	0.0761	0.0933	0.0952	0.0952	0.0952
38	14	14	14	05	9	9	33	38	38	38
0.0857	0.0857	0.0857	0.0819	0.0761	0.0761	0.0933	0.0952	0.0952	0.0952	0.0952
14	14	14	05	9	9	33	38	38	38	38
0.0857	0.0857	0.0819	0.0761	0.0761	0.0933	0.0952	0.0952	0.0952	0.0952	0.0952
14	14	05	9	9	33	38	38	38	38	38
0.0857	0.0819	0.0761	0.0761	0.0933	0.0952	0.0952	0.0952	0.0952	0.0952	0.0971
14	05	9	9	33	38	38	38	38	38	43
0.0819	0.0761	0.0761	0.0933	0.0952	0.0952	0.0952	0.0952	0.0952	0.0971	0.1009
05	9	9	33	38	38	38	38	38	43	52
0.0761	0.0761	0.0933	0.0952	0.0952	0.0952	0.0952	0.0952	0.0971	0.1009	0.08
9	9	33	38	38	38	38	38	43	52	

Tabel 3. Tabel Beberapa Data dari Test Dataset

X-10	X-9	X-8	X-7	X-6	X-5	X-4	X-3	X-2	X-1	X
X-10	X-9	X-8	X-7	X-6	X-5	X-4	X-3	X-2	X-1	X
0.2285	0.2285	0.2285	0.2285	0.2285	0.2380	0.2285				0.1809
71	71	71	71	71	95	71	0.2	0.2	0.2	52
0.2285	0.2285	0.2285	0.2285	0.2380	0.2285				0.1809	0.1809
71	71	71	71	95	71	0.2	0.2	0.2	52	52
0.2285	0.2285	0.2285	0.2380	0.2285				0.1809	0.1809	0.1714
71	71	71	95	71	0.2	0.2	0.2	52	52	29
0.2285	0.2285	0.2380	0.2285				0.1809	0.1809	0.1714	0.1714
71	71	95	71	0.2	0.2	0.2	52	52	29	29
0.2285	0.2380	0.2285				0.1809	0.1809	0.1714	0.1714	0.1714
71	95	71	0.2	0.2	0.2	52	52	29	29	29
0.2380	0.2285				0.1809	0.1809	0.1714	0.1714	0.1714	0.1714
95	71	0.2	0.2	0.2	52	52	29	29	29	29
0.2285				0.1809	0.1809	0.1714	0.1714	0.1714	0.1714	0.1485
71	0.2	0.2	0.2	52	52	29	29	29	29	71
			0.1809	0.1809	0.1714	0.1714	0.1714	0.1714	0.1485	0.1485
0.2	0.2	0.2	52	52	29	29	29	29	71	71

2.5 Long Short-Term Memory Training

Pada tahap ini, dilakukan proses pembangunan model dan tuning parameter untuk mendapatkan hasil yang optimal. Kemudian melakukan *training* pada model.

2.6 Evaluation of Long Short-Term Memory

Tahap ini mengevaluasi kualitas dan efektivitas model. Selain itu, analisis data uji coba dari model yang telah dibuat juga dilakukan pada tahap ini. Evaluasi model dilakukan dengan menggunakan metrik MAPE untuk mengukur seberapa bagus model. *Mean Absolute Percentage Error* (MAPE) merupakan penghitungan kesalahan estimasi pada setiap periode waktu, dengan cara mengurangi nilai aktual dari estimasi dan menjadikannya absolut, kemudian membaginya dengan nilai aktual ekonomis dan dikalikan dengan 100% [29]. Berikut adalah rumus perhitungan MAPE dan akurasi [30].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_{true_t} - Y_{pred_t}}{Y_{true_t}} \right|$$

$$Akurasi = 100\% - MAPE$$

2.7 Implementation of System

Pada tahap ini dilakukan proses pembuatan aplikasi dari sistem Prediksi Harga Cabai Merah Keriting di Yogyakarta menggunakan Algoritma LSTM. Implementasi dari sistem ini akan diimplementasikan ke dalam sebuah website dengan menggunakan *HTML, Python, Tensorflow, Tailwind CSS*, dan *Flask*.

3. Hasil dan Pembahasan

3.1 Long Short-Term Memory Training

Setelah data disiapkan, proses selanjutnya adalah membuat model. Model dibuat menggunakan Tensorflow dengan bahasa Python. Pengujian pada sistem ini dijalankan dengan berbagai macam rasio data *train* dan *test* yang berbeda. Rasio-rasio tersebut adalah 70%:30%, 80%:20%, dan 90%:10%. Pada setiap pengujian akan dilakukan percobaan terhadap parameter-parameter algoritma LSTM, seperti epoch, batch size, learning rate, jumlah neuron, fungsi aktivasi, dan fungsi optimasi. Hasil eksperimen prediksi harga cabai merah keriting adalah sebagai berikut.

3.1.1 Test with 70%:30% Comparison Ratio

Pengujian pertama dijalankan dengan rasio 70%:30%. Tabel 4 di bawah ini adalah tabel hasil percobaan dari pengujian pertama.

Tabel 4. Tabel Eksperimen Pertama

Epoch	Batch Size	Learning Rate	Jumlah Neuron	Activation Function	Optimization Function	MAPE (%)	Accuracy (%)
150	50	0.001	50	ReLU	sgd	9.3071	90.6929
50	12	0.05	10	sigmoid	sgd	5.8612	94.1388
150	12	0.001	20	sigmoid	sgd	12.2982	87.7018
150	24	0.001	50	ReLU	sgd	8.9951	91.0049
150	50	0.001	50	ReLU	sgd	9.3071	90.6929
100	24	0.001	20	ReLU	rmsprop	5.6335	94.3665
150	24	0.001	50	ReLU	rmsprop	6.8059	93.1941
50	12	0.05	10	sigmoid	adam	12.2682	87.7318
50	12	0.05	20	sigmoid	adam	11.7987	88.2013
50	24	0.05	50	sigmoid	adam	5.5759	94.4241
100	24	0.05	50	sigmoid	adam	21.0238	78.9762

100	24	0.001	50	sigmoid	adam	8.8949	91.1051
150	24	0.001	50	sigmoid	adam	7.985	92.015
50	12	0.05	10	ReLU	adam	8.3559	91.6441
50	24	0.05	10	ReLU	adam	6.5946	93.4054
50	24	0.001	10	ReLU	adam	5.3283	94.6717
100	24	0.001	10	ReLU	adam	4.7276	95.2724
150	24	0.001	50	ReLU	adam	4.2441	95.7559
150	24	0.001	30	ReLU	adam	3.8258	96.1742
150	48	0.001	30	ReLU	adam	3.6995	96.3005

Berdasarkan Tabel 4 di atas, akurasi terbaik yang dihasilkan dengan menggunakan rasio pembagian data 70%:30% adalah sebesar 96.3005%. Akurasi tertinggi ini didapatkan dengan menggunakan epoch sebanyak 150, batch size 48, learning rate 0.001, jumlah neuron 30, fungsi aktivasi ReLU, dan fungsi optimasi yang digunakan adalah Adam. Pengujian yang dilakukan dengan menggunakan parameter tersebut mendapatkan nilai MAPE sebesar 3.6995% dan akurasi sebesar 91.7861%.

3.1.2 Test with 80%:20% Comparison Ratio

Pengujian kedua menggunakan rasio 80%:20%. Tabel 5 di bawah ini adalah tabel hasil percobaan dari pengujian kedua.

Tabel 5. Tabel Eksperimen Kedua

Epoch	Batch Size	Learning Rate	Jumlah Neuron	Activation Function	Optimization Function	MAPE (%)	Accuracy (%)
50	12	0.05	10	sigmoid	sgd	7.3676	92.6324
100	24	0.05	10	sigmoid	sgd	5.5402	94.4598
100	24	0.001	10	sigmoid	sgd	9.2865	90.7135
150	24	0.001	50	sigmoid	sgd	7.2242	92.7758
50	12	0.05	10	ReLU	sgd	6.4402	93.5598
50	12	0.05	10	ReLU	rmsprop	16.1281	83.8719
50	24	0.05	10	sigmoid	rmsprop	17.7326	82.2674
100	24	0.05	10	ReLU	rmsprop	8.9642	91.0358
100	24	0.001	10	ReLU	rmsprop	6.0696	93.9304
150	24	0.001	20	ReLU	rmsprop	5.0814	94.9186
150	48	0.001	20	ReLU	rmsprop	6.8982	93.1018
150	48	0.001	50	ReLU	rmsprop	8.6672	91.3328
50	12	0.05	10	sigmoid	adam	29.092	70.908
50	12	0.05	10	ReLU	adam	36.8405	63.1595
50	12	0.001	10	sigmoid	adam	12.7071	87.2929
100	24	0.001	50	sigmoid	adam	13.1369	86.8631
100	24	0.001	50	ReLU	adam	5.7087	94.2913
150	24	0.001	50	ReLU	adam	5.1889	94.8111
150	24	0.001	50	sigmoid	adam	12.8637	87.1363
150	48	0.001	50	ReLU	adam	4.4987	95.5013

Dapat dilihat dari Tabel 5 bahwa akurasi terbaik yang didapatkan dengan menggunakan rasio pembagian data 80%:20% adalah 95.5013%. Akurasi tertinggi ini didapatkan dengan menggunakan epoch 150, batch size 24, learning rate 0.001, jumlah neuron 50, fungsi aktivasi ReLU, dan fungsi optimasi yang digunakan adalah RMSProp. Pengujian yang dilakukan dengan menggunakan parameter tersebut mendapatkan nilai MAPE sebesar 4.4987% dan akurasi sebesar 95.5013%.

3.1.3 Test with 90%:10% Comparison Ratio

Pengujian berikutnya menggunakan rasio 90%:10%. Tabel 6 di bawah ini adalah tabel hasil percobaan dari pengujian ketiga.

Tabel 6. Tabel Eksperimen Ketiga

Epoch	Batch Size	Learning Rate	Jumlah Neuron	Activation Function	Optimization Function	MAPE (%)	Accuracy (%)
50	12	0.05	10	sigmoid	sgd	5.8062	94.1938
100	24	0.001	10	sigmoid	sgd	9.9093	90.0907
100	24	0.001	10	ReLU	sgd	8.947	91.053
150	24	0.001	50	sigmoid	sgd	7.775	92.225
150	24	0.001	50	ReLU	sgd	7.7528	92.2472
50	12	0.05	10	sigmoid	rmsprop	14.0075	85.9925
50	24	0.05	10	sigmoid	rmsprop	3.8626	96.1374
50	24	0.001	10	ReLU	rmsprop	4.6592	95.3408
100	24	0.001	20	ReLU	rmsprop	4.1808	95.8192
100	24	0.001	50	ReLU	rmsprop	4.2504	95.7496
150	24	0.001	50	ReLU	rmsprop	3.7537	96.2463
50	12	0.05	10	sigmoid	adam	21.8099	78.1901
50	12	0.05	10	ReLU	adam	23.0208	76.9792
50	24	0.05	10	ReLU	adam	17.0324	82.9676
50	24	0.05	10	sigmoid	adam	15.7333	84.2667
100	24	0.001	10	sigmoid	adam	5.0565	94.9435
100	24	0.001	50	ReLU	adam	4.4441	95.5559
100	24	0.001	50	sigmoid	adam	7.9656	92.0344
150	24	0.001	50	ReLU	adam	4.0806	95.9194
150	50	0.001	50	ReLU	adam	4.8619	95.1381

Berdasarkan data pada Tabel 6, didapatkan bahwa akurasi tertinggi yang dihasilkan dengan menggunakan rasio pembagian data 90%:10% adalah sebesar 96.2463%. Akurasi tertinggi ini didapatkan dengan epoch sebanyak 150, batch size 24, learning rate 0.001, jumlah neuron 50, fungsi aktivasi ReLU, dan fungsi optimasi yang digunakan adalah RMSProp. Pengujian yang dilakukan dengan menggunakan parameter-parameter tersebut didapatkan nilai MAPE sebesar 3.1339% dan akurasi sebesar 96.2463%.

3.2 Evaluation of Long Short-Term Memory Model

Selanjutnya dilakukan analisis prediksi harga cabai merah keriting dengan memanfaatkan data uji menggunakan model dengan algoritma LSTM yang menghasilkan akurasi terbaik. Tabel 7 berikut merupakan hasil prediksi dari penelitian ini menggunakan harga cabai merah keriting di Yogyakarta.

Tabel 7. Tabel Perbandingan Data Asli dengan Prediksi pada Tahun 2023

Tanggal	Harga	Prediksi	Tanggal	Harga	Prediksi	Tanggal	Harga	Prediksi
31/08/2023	44250	44300	20/09/2023	29500	30000	10/10/2023	38250	35800
01/09/2023	43000	44200	21/09/2023	29500	29900	11/10/2023	38250	38500
04/09/2023	42000	42800	22/09/2023	27000	29800	12/10/2023	38250	38400
05/09/2023	37000	41700	25/09/2023	37500	27000	13/10/2023	38250	38400
06/09/2023	35000	35900	26/09/2023	38750	36300	16/10/2023	38250	38200

07/09/2023	33750	34100	27/09/2023	38750	38500	17/10/2023	39500	38200
08/09/2023	32500	33000	28/09/2023	35000	38700	18/10/2023	40000	39500
11/09/2023	28250	31900	29/09/2023	37500	34800	19/10/2023	40000	40100
12/09/2023	27000	27200	02/10/2023	37500	37300	20/10/2023	40000	40100
13/09/2023	27000	26400	03/10/2023	35000	37300	23/10/2023	40000	40000
14/09/2023	27000	26600	04/10/2023	35000	34700	24/10/2023	40000	40000
15/09/2023	27000	26800	05/10/2023	35750	34700	25/10/2023	40000	40000
18/09/2023	29500	27000	06/10/2023	35750	35600	26/10/2023	40000	39900
19/09/2023	29500	29900	09/10/2023	35750	35700	27/10/2023	47500	40000


Tabel 7 merupakan tabel data asli dan data prediksi harga cabai merah keriting dengan menggunakan rasio pembagian data 70%:30% dan dengan arsitektur terbaik yang didapatkan dari hasil percobaan, seperti yang dapat dilihat selisih harga antara data asli dan data prediksi tidak terlalu besar, sehingga dapat disimpulkan bahwa algoritma LSTM bekerja dengan cukup baik dalam melakukan prediksi terhadap data prediksi dan siap untuk diimplementasikan ke dalam sebuah sistem.

3.3 Implementation of System

Pada penelitian ini berhasil dibuat sebuah sistem dari hasil implementasi algoritma LSTM untuk prediksi harga cabai merah keriting. Sistem ini dibangun dengan menggunakan HTML, Python, Tensorflow, Tailwind CSS, dan Flask. Pembuatan prototipe ini melalui beberapa tahap, yaitu tahap input data, tahap menampilkan grafik data, tahap pelatihan model, tahap evaluasi model, dan tahap prediksi harga di masa mendatang. Berikut ini adalah implementasi sistem pada setiap tahapan.

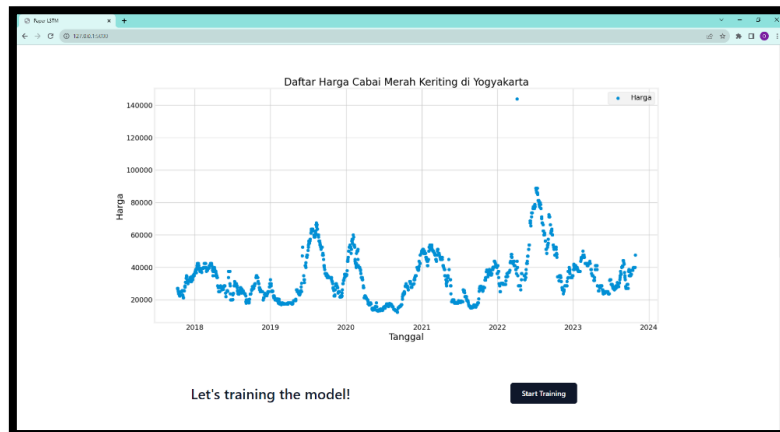
3.3.1 Tampilan Awal Sistem

Gambar 3 di bawah ini menampilkan halaman beranda sistem saat pertama kali dijalankan.



Gambar 3. Tampilan Awal Sistem

Berdasarkan Gambar 3, sistem ini memiliki 1 fitur untuk mengupload file. Pengguna harus memasukkan file data dalam bentuk csv dengan menekan tombol *Choose File*, kemudian memilih datanya. Setelah itu, pengguna menekan tombol *Load Data*. Kemudian, sistem akan memproses data yang diinputkan, lalu sistem akan menampilkan grafik dari data yang diinputkan dan menampilkan fitur mulai pelatihan seperti yang ditunjukkan pada Gambar 4. Jika format file yang dimasukkan bukan bertipe csv, maka akan muncul pesan kesalahan dan pengguna harus mengupload file kembali.



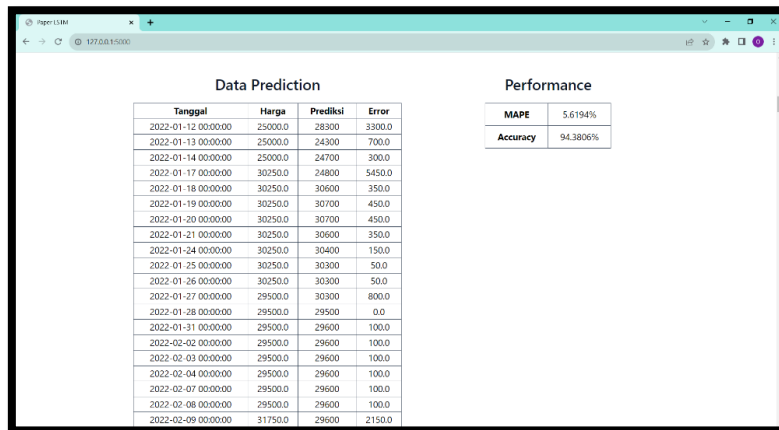
Gambar 4. Tampilan Sistem Setelah User Upload Data

3.3.2 Fitur Start Training pada Sistem

Fitur start training pada sistem ini merupakan fitur yang digunakan untuk menjalankan proses training dan testing model. Fitur ini akan muncul setelah pengguna menjalankan fitur pertama, yaitu upload data. Gambar 4 menunjukkan tampilan sistem ketika fitur start training muncul. Ketika tombol Start Training diklik, maka sistem akan melakukan beberapa tahapan, yaitu *preprocessing* data, *modeling*, dan *evaluation*. Tahap pertama adalah preprocessing data dimana sistem melakukan persiapan data, seperti menghilangkan missing value, melakukan normalisasi, membuat data train, dan test. Selanjutnya adalah modeling. Pada proses ini, sistem akan membuat arsitektur model dan melatih model. Langkah selanjutnya adalah evaluation dimana dilakukan pengujian menggunakan data test. Pengujian dilakukan dengan menggunakan metrik MAPE. Setelah ketiga tahapan tersebut selesai, sistem akan menampilkan grafik hasil pengujian yang ditunjukkan pada Gambar 5, menampilkan tabel prediksi dan tabel performa model pada Gambar 6, dan fitur prediksi seperti pada Gambar 7.

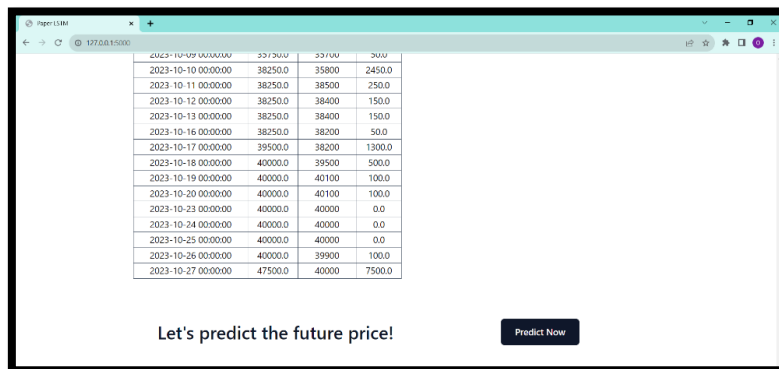


Gambar 5. Grafik Hasil Pengujian Model



Data Prediction				Performance	
Tanggal	Harga	Prediksi	Error	MAPE	Accuracy
2022-01-12 00:00:00	25000.0	28300	3300.0	5.6194%	94.3806%
2022-01-13 00:00:00	25000.0	24300	700.0		
2022-01-14 00:00:00	25000.0	24700	300.0		
2022-01-17 00:00:00	30250.0	24800	5450.0		
2022-01-18 00:00:00	30250.0	30600	350.0		
2022-01-19 00:00:00	30250.0	30700	450.0		
2022-01-20 00:00:00	30250.0	30700	450.0		
2022-01-21 00:00:00	30250.0	30600	350.0		
2022-01-24 00:00:00	30250.0	30400	150.0		
2022-01-25 00:00:00	30250.0	30300	50.0		
2022-01-26 00:00:00	30250.0	30300	50.0		
2022-01-27 00:00:00	29500.0	30300	800.0		
2022-01-28 00:00:00	29500.0	29500	0.0		
2022-01-31 00:00:00	29500.0	29600	100.0		
2022-02-02 00:00:00	29500.0	29600	100.0		
2022-02-03 00:00:00	29500.0	29600	100.0		
2022-02-04 00:00:00	29500.0	29600	100.0		
2022-02-07 00:00:00	29500.0	29600	100.0		
2022-02-08 00:00:00	29500.0	29600	100.0		
2022-02-09 00:00:00	31750.0	29600	2150.0		

Gambar 6. Tabel Prediksi dan Tabel Performa Model



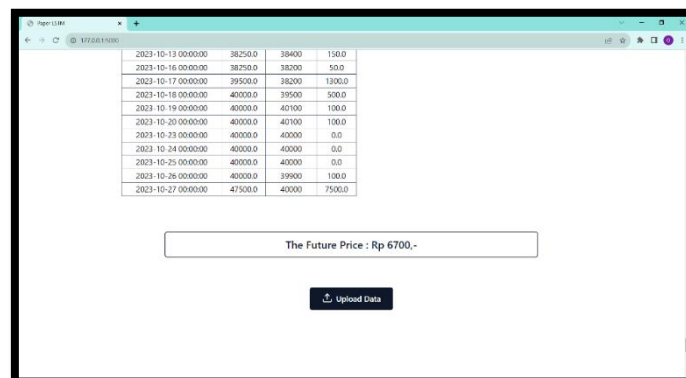
Tanggal	Harga	Prediksi	Error
2023-10-10 00:00:00	38250.0	35800	2450.0
2023-10-11 00:00:00	38250.0	38500	250.0
2023-10-12 00:00:00	38250.0	38400	150.0
2023-10-13 00:00:00	38250.0	38400	150.0
2023-10-16 00:00:00	38250.0	38200	50.0
2023-10-17 00:00:00	39500.0	38200	1300.0
2023-10-18 00:00:00	40000.0	39500	500.0
2023-10-19 00:00:00	40000.0	40100	100.0
2023-10-20 00:00:00	40000.0	40100	100.0
2023-10-23 00:00:00	40000.0	40000	0.0
2023-10-24 00:00:00	40000.0	40000	0.0
2023-10-25 00:00:00	40000.0	40000	0.0
2023-10-26 00:00:00	40000.0	39900	100.0
2023-10-27 00:00:00	47500.0	40000	7500.0

Let's predict the future price! Predict Now

Gambar 7. Fitur Prediksi

3.3.3 Fitur Predict pada Sistem

Fitur predict pada sistem ini merupakan fitur untuk meramalkan harga pada masa yang akan datang. Fitur ini akan muncul setelah pengguna menjalankan fitur pertama dan kedua. Gambar 7 menunjukkan tampilan sistem ketika fitur predict muncul. Ketika pengguna menekan tombol Predict Now, sistem akan menjalankan proses yang menggunakan model yang telah dibuat, dilatih, dan diberi nilai pada proses sebelumnya untuk memprediksi harga di masa depan. Setelah itu, sistem akan menampilkan prediksi harga seperti yang terlihat pada Gambar 8.



Tanggal	Harga	Prediksi	Error
2023-10-13 00:00:00	38250.0	38400	150.0
2023-10-16 00:00:00	38250.0	38200	50.0
2023-10-17 00:00:00	39500.0	38200	1300.0
2023-10-18 00:00:00	40000.0	39500	500.0
2023-10-19 00:00:00	40000.0	40100	100.0
2023-10-20 00:00:00	40000.0	40100	100.0
2023-10-23 00:00:00	40000.0	40000	0.0
2023-10-24 00:00:00	40000.0	40000	0.0
2023-10-25 00:00:00	40000.0	40000	0.0
2023-10-26 00:00:00	40000.0	39900	100.0
2023-10-27 00:00:00	47500.0	40000	7500.0

The Future Price : Rp 6700,-

Upload Data

Gambar 8. Tampilan Setelah Fitur Prediksi Dijalankan

4. Kesimpulan

Berdasarkan hasil pengujian pada penelitian ini, penulis menuliskan beberapa kesimpulan. Prediksi harga cabai merah keriting berhasil dilakukan. Dari proses pengujian dapat diketahui nilai parameter yang optimal pada proses prediksi harga cabai merah keriting dengan menggunakan algoritma LSTM. Dari hasil percobaan sistem, akurasi terbaik didapatkan dengan menggunakan rasio split data sebesar 70%:30%. Parameter yang digunakan pada model yang menghasilkan akurasi terbaik adalah epoch 150, batch size 48, learning rate 0.001, jumlah neuron 30, fungsi aktivasi ReLU, dan fungsi optimasi yang digunakan adalah Adam. Jumlah atribut yang digunakan pada data training dan testing adalah 10. Model dengan parameter tersebut mendapatkan nilai MAPE sebesar 3.6995 % dan akurasi sebesar 96.3005%. Penelitian ini tentunya masih memiliki kekurangan, seperti terbatasnya jumlah fitur untuk melakukan prediksi yang dapat mempengaruhi fluktuasi harga, sehingga untuk pengembangannya dapat menambahkan faktor-faktor lain yang mempengaruhi harga cabai merah keriting. Selain itu, untuk pengembangannya sistem ini dapat diaplikasikan ke berbagai platform selain website sehingga pengguna dapat mengakses sistem ini dengan mudah dan dapat diakses dimanapun dari berbagai platform.

5. Daftar Pustaka

- [1] Hamidah, K., Syahni, R., & Sari, R. (2020). Analisis Permintaan Cabai Merah Besar di Kota Padang, Sumatra Barat. DOI: <https://doi.org/10.23960/jsp.Vol2.No1.2020.49>.
- [2] Yutriani, Y., Muis, A., & Asih, D. N. (2020). FAKTOR-FAKTOR YANG MEMENGARUHI PERMINTAAN CABAI MERAH KERITING DI KOTA PALU. *AGROTEKBIS: E-JURNAL ILMU PERTANIAN*, 8(2), 466-472.
- [3] Oping, J. M. (2023). Saluran Pemasaran Dan Margin Pemasaran Cabai Merah Keriting Di Desa Kamanga Dua Kecamatan Tompasso Kabupaten Minahasa. *Jurnal Multidisiplin Ukita*, 1(3), 194-198.
- [4] Anjayani, D., & Ambarwati, E. (2021). Mutu dan Daya Simpan Buah Cabai Merah (*Capsicum annuum* L.) sebagai Tanggapan terhadap Berbagai Jenis Pupuk Hayati. *Vegetalika*, 10(3), 159-173. DOI: <https://doi.org/10.22146/veg.47817>.
- [5] Pradana, R. S. (2021). Penerapan Analisis Jalur Dalam Mengidentifikasi Penyebab Fluktuasi Harga Cabai Merah Di Kabupaten Aceh Jaya. *Jurnal Agricra*, 14(1), 20-32.
- [6] Wulandari, S. A. (2020). Fluktuasi harga cabai merah di masa pandemi Covid 19 di Kota Jambi. *Jurnal MeA (Media Agribisnis)*, 5(2), 112-120. DOI: <http://dx.doi.org/10.33087/mea.v5i2.82>.
- [7] Ariwanda, G., Cholissodin, I., & Tibyani, T. (2019). Prediksi Harga Cabai Rawit di Kota Malang Menggunakan Algoritme Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(6), 5291-5298.
- [8] Hidayati, N., Anwar, S., & Rahmah, R. (2022). Peramalan Harga Cabai Merah Sebagai Upaya Menjaga Stabilitas Inflasi Kota Banda Aceh. *AGRIEKONOMIKA*, 11(1), 31-42. DOI: <https://doi.org/10.21107/agriekonomika.v11i1.11380>.

- [9] Azwina, R., & Syahbudi, M. (2023). Pengaruh Fluktuasi Harga Komoditas Pangan Terhadap Inflasi di Provinsi Sumatera Utara tahun (2019-2021). *El-Mal: Jurnal Kajian Ekonomi & Bisnis Islam*, 4(1), 238-249.
- [10] Salim, A., Fadilla, F., & Purnamasari, A. (2021). Pengaruh Inflasi Terhadap Pertumbuhan Ekonomi Indonesia. *Ekonomika Sharia: Jurnal Pemikiran dan Pengembangan Ekonomi Syariah*, 7(1), 17-28. DOI: <https://doi.org/10.36908/esha.v7i1.268>.
- [11] Rahmanta, R., & Maryunianta, Y. (2020). Pengaruh harga komoditi pangan terhadap inflasi di kota Medan. *Jurnal Agrica*, 13(1), 35-44. DOI: 10.31289/agrica.v13i1.3121.
- [12] David, M., Cholissodin, I., & Yudistira, N. (2023). Prediksi Harga Cabai menggunakan Metode Long-Short Term Memory (Case Study: Kota Malang). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 7(3), 1214-1219.
- [13] Winata, A., Lauro, M. D., & Handhayani, T. (2023). PERBANDINGAN LSTM DAN ELM DALAM MEMREDIKSI HARGA PANGAN KOTA TASIKMALAYA. *Jurnal Ilmu Komputer dan Sistem Informasi*, 11(2). DOI: <https://doi.org/10.24912/jiksi.v11i2.26015>.
- [14] Hasibuan, L. S., & Novialdi, Y. (2022). Prediksi Harga Minyak Goreng Curah dan Kemasan Menggunakan Algoritme Long Short-Term Memory (LSTM). *Jurnal Ilmu Komputer dan Agri-Informatika*, 9(2), 149-157. <https://doi.org/10.29244/jika.9.2.149-157>.
- [15] Sholeh, M. A. (2022). Perbandingan Model LSTM dan GRU untuk Memprediksi Harga Minyak Goreng di Indonesia. *EDUSAINTEK: Jurnal Pendidikan, Sains dan Teknologi*, 9(3), 800-811. DOI: <https://doi.org/10.47668/edusaintek.v9i3.593>.
- [16] Adi, R. M. S., & Sudioanto, S. (2022). Prediksi Harga Komoditas Pangan Menggunakan Algoritma Long Short-Term Memory (LSTM). *Building of Informatics, Technology and Science (BITS)*, 4(2), 1137-1145. DOI: <https://doi.org/10.47065/bits.v4i2.2229>.
- [17] Cahyani, J., Mujahidin, S., & Fiqar, T. P. Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *JUSTIN (Jurnal Sistem dan Teknologi Informasi)*, 11(2), 346-357. DOI: <http://dx.doi.org/10.26418/justin.v11i2.57395>.
- [18] Ivan, E., & Purnomo, H. D. (2022). FORECASTING PRICES OF FERTILIZER RAW MATERIALS USING LONG SHORT TERM MEMORY. *Jurnal Teknik Informatika (Jutif)*, 3(6), 1663-1673. DOI: <https://doi.org/10.20884/1.jutif.2022.3.6.433>.
- [19] Riyantoko, P. A., Fahrudin, T. M., Hindrayani, K. M., & Safitri, E. M. (2020, December). Analisis Prediksi Harga Saham Sektor Perbankan Menggunakan Algoritma Long-Short Terms Memory (Lstm). In *Seminar Nasional Informatika (SEMNASIF)* (Vol. 1, No. 1, pp. 427-435).
- [20] Karno, A. S. B. (2020). Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory). *Journal of Informatic and Information Security*, 1(1). DOI: <https://doi.org/10.31599/jiforty.v1i1.133>.
- [21] Rizkilloh, M. F., & Widiyanesti, S. (2022). Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM). *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(1), 25-31. DOI: <https://doi.org/10.29207/resti.v6i1.3630>.

- [22] Alim, M. N. (2023, March). Pemodelan Time Series Data Saham LQ45 dengan Algoritma LSTM, RNN, dan Arima. In *PRISMA, Prosiding Seminar Nasional Matematika* (Vol. 6, pp. 694-701).
- [23] Julian, R., & Pribadi, M. R. (2021). Peramalan harga saham pertambangan pada bursa efek indonesia (BEI) menggunakan long short term memory (LSTM). *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 8(3), 1570-1580. DOI: <https://doi.org/10.35957/jatisi.v8i3.1159>.
- [24] Titus, T. K., & Jajuli, M. (2022). Clustering Data Kecelakaan Lalu Lintas di Kecamatan Cileungsi Menggunakan Metode K-Means. *Generation Journal*, 6(1), 1-12. <https://doi.org/10.29407/gj.v6i1.16103>.
- [25] Handayani, N. P. R., Utami, N. W., & Putri, I. G. A. P. D. (2023, April). Prediksi Financial Distress Pada Perusahaan Yang Terdaftar Di Bursa Efek Indonesia Menggunakan Algoritma Decision Tree. In *Prosiding Seminar Nasional Teknik Elektro, Sistem Informasi, dan Teknik Informatika (SNESTIK)* (Vol. 1, No. 1, pp. 53-59). DOI: <https://doi.org/10.31284/p.snestik.2023.4102>.
- [26] Prabiantissa, C. N. (2021, June). Klasifikasi pada Dataset Penyakit Hati Menggunakan Algoritma Support Vector Machine, K-NN, dan Naïve Bayes. In *Prosiding Seminar Nasional Teknik Elektro, Sistem Informasi, dan Teknik Informatika (SNESTIK)* (Vol. 1, No. 1, pp. 263-268). DOI: <https://doi.org/10.31284/p.snestik.2021.1818>.
- [27] Adams, F., Anggoro, R., Satria, M., Oktavia, A., & Chamidah, N. (2021). PERBANDINGAN NORMALISASI DATA UNTUK KLASIFIKASI WINE MENGGUNAKAN ALGORITMA NAÏVE BAYES, DECISSION TREE, DAN SUPPORT VECTOR MACHINE. In *Prosiding Seminar Nasional Mahasiswa Bidang Ilmu Komputer dan Aplikasinya* (Vol. 2, No. 2, pp. 260-268).
- [28] Sholeh, M., Andayati, D., & Rachmawati, R. Y. (2022). DATA MINING MODEL KLASIFIKASI MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR DENGAN NORMALISASI UNTUK PREDIKSI PENYAKIT DIABETES. *TelKa*, 12(02), 77-87. <https://doi.org/10.36342/teika.v12i02.2911>.
- [29] Della, N. L. W. A., Diaz, R. A. N., & Novianti, K. D. P. (2021). Penerapan Metode Regresi Linier untuk Memprediksi Permohonan ITAS. *Jurnal Eksplora Informatika*, 10(2), 92-100. DOI: <https://doi.org/10.30864/eksplora.v10i2.380>.
- [30] Muzakki, M. A., Sabila, M. A., Sundari, S., & Wisnuadhi, B. (2021, September). Analisis Algoritma Prophet untuk Memprediksi Harga Pangan di Kota Bandung. In *Prosiding Industrial Research Workshop and National Seminar* (Vol. 12, pp. 659-664).