

Prediksi Harga Beras Super dan Medium Menggunakan LSTM dan BILSTM (*Moving Average Smoothing*)

Niki Awalloedin^{a1*}, Windu Gata^{a2}, dan Hendra Setiawan^{b1}

^aProgram Studi Ilmu Komputer (S2) Universitas Nusa Mandiri Jakarta, Indonesia.

^{*1}14002441@nusamandiri.ac.id, ²windu@nusamandiri.ac.id

^bSistem Informasi STMIK Bani Saleh, Indonesia.

³hendrasetiawan@stmik-banisaleh.ac.id

Abstrak

Salah satu komoditas pangan yang penting karena banyak dikonsumsi di Indonesia adalah beras, inflasi harga pangan akan mempengaruhi nilai beli masyarakat, untuk itu penulis mencoba menerapkan algoritma LSTM dan BILSTM dalam memprediksi harga beras khususnya beras dengan kategori Beras Kualitas Medium I dan Beras Kualitas Super I. Prediksi harga pangan akan sangat bermanfaat bagi konsumen maupun produsen, untuk pemerintah hal ini dapat menjadi penunjang keputusan dalam mengambil langkah yang tepat untuk menjamin harga beras tetap terjangkau oleh masyarakat. Dalam penelitian ini menggunakan data history time series tahun 2017 – 2022 yang terdapat pada situs Pusat Informasi Harga Pangan Strategis Nasional (PIHPSN). Dua data series beras tersebut akan melalui proses smoothing Moving Average dan selanjutnya digunakan algoritma LSTM dan BILSTM untuk menghasilkan prediksi, dai hasil penelitian model terbaik adalah LSTM, untuk Beras Kualitas Super I MSE (6.651) nilai RMSE (0.986) dan pada Beras Kualitas Medium I MSE (4.862) nilai RMSE (0.989).

Kata Kunci— *Harga Beras, LSTM, BILSTM, Moving Average*

Abstract

One of the important food commodities widely consumed in Indonesia is rice, price inflation will affect the purchase value, for that the author tries to apply the LSTM and BILSTM algorithms in predicting the price of rice, especially rice with the category of Medium Quality I and Super Quality Rice I. Prediction of food prices will be very beneficial for consumers and producers, for the government this can be a decision support in taking appropriate action to ensure prices remain affordable by the community. In this study, historical time series data for 2017 – 2022 are used on the National Strategic Food Price Information Center (PIHPSN) site. The two rice data series will go through the Moving Average smoothing process and then use the LSTM and BILSTM algorithms to generate predictions, from the results of the research the best model is LSTM, for Super Quality Rice I MSE (6,651) RMSE value (0.986) and for Medium Quality Rice I MSE (4.862) RMSE value (0.989).

Keywords— *Rice Prices, LSTM, BILSTM, Moving Average*

1. PENDAHULUAN

Saat ini harga pangan global naik berturut-turut kenaikan terjadi pada harga pangan dipicu oleh kenaikan harga minyak mentah dunia. Kenaikan harga Bahan Bakar Minyak (BBM) dipastikan akan berpengaruh pada harga sembako yang juga akan mempengaruhi turunnnya daya beli masyarakat. Pusat Informasi Harga Pangan Strategis Nasional sejak tahun 2017 sampai saat ini telah melakukan survei langsung dari 82 kota/kabupaten data harga di pasar tradisional untuk 10 komoditas pangan nasional yang cukup banyak dikonsumsi masyarakat, informasi hasil survei

harga pangan atau harga sembako nasional tersebut dipublikasikan secara resmi dan dapat diakses pada alamat website <https://hargapangan.id/>

perubahan harga sebuah komoditas dipengaruhi oleh beberapa faktor seperti kondisi perekonomian, laju inflasi, penawaran dan permintaan konsumsi masyarakat, serta factor-faktor yang lain. Menurunnya daya beli masyarakat dapat mengindikasikan terjadinya peningkatan inflasi, karena hal ini menunjukkan adanya ketidak mampuan masyarakat dalam menjangkau harga yang mengalami kenaikan terus menerus[1]. Menentukan prediksi harga komoditas beras, khususnya perubahan harga beras yang bergerak harian, memerlukan metode, model, atau pendekatan yang harus teruji akurasi. Akurasi yang baik dan teruji dari suatu model untuk peramalan jangka pendek akan diminati untuk digunakan dan diterapkan oleh para pengambil keputusan.


Salah satu bagian dari machine learning adalah deep learning dan salah satu metode didalamnya yang sering digunakan untuk peramalan menggunakan data rentang waktu (time series) seperti harga beras adalah LSTM. Langkah dasar untuk menyelesaikan masalah time series adalah mengumpulkan dan memilih variabel yang tepat, lalu memilih model terbaik yang memberikan akurasi terbaik[2], LSTM merupakan pengembangan dari Recurrent Neural Network (RNN) metode yang pada tahun 1997 dikenalkan oleh Sepp Hochreiter dan Jurgen Schmidhuber, RNN memiliki keterbatasan yaitu memori jangka pendek, sehingga tidak dapat membawa informasi yang diperoleh sebelumnya ke proses selanjutnya. LSTM merupakan metode yang seringkali digunakan untuk mengatasi keterbatasan RNN ini. [3].

BILSTM adalah perkembangan dari model LSTM, di dalam BILSTM terdapat dua lapisan yang prosesnya saling berkebalikan arah, sehingga model ini sangat baik karena dengan adanya lapisan dua arah yang saling berlawanan ini maka model dapat memahami dan mengambil perspektif dari informasi terdahulu maupun informasi terdepan, hal ini akan memungkinkan proses pembelajaran menjadi semakin dalam[4].

Penelitian mengenai prediksi data *time series* sudah banyak dilakukan oleh peneliti-peneliti sebelumnya, berdasarkan hasil pengujian, LTSM mampu memprediksi harga saham pada tahun 2017-2019 dengan performa yang baik, hal ini ditunjukkan dengan tingkat kesalahan yang kecil[3].

2. METODE PENELITIAN

Dalam penelitian ini menggunakan desain atau rancangan metodologi seperti terlihat pada Gambar 1. Data sumber yang akan digunakan diambil dari Pusat Informasi Harga Pangan Strategis Nasional, proses selanjutnya adalah melakukan preprocessing data dengan dilakukan cleaning dan menambahkan data *moving average* untuk proses *smoothing*, selain itu dilakukan juga uji stasioneritas *Augmented Dickey-Fuller* (ADF) terhadap data deret waktu (*time series*) untuk mengetahui apakah data tersebut stasioner atau tidak, jika data sudah stationer dataset siap digunakan. Pemilihan attributes data juga dilakukan sebelum proses pemodelan. Proses pemodelan dilakukan dengan dua model yaitu LSTM dan BISTM, dan selanjutnya untuk mengetahui performa akan dilakukan proses evaluasi masing-masing model tersebut.



Gambar 1. Alur Penelitian

2.1. Preprocessing Data

Pada penelitian ini menggunakan dataset yang bersumber dari publikasi Pusat Informasi Harga Pangan Strategis Nasional, dataset *history* harian harga beras dengan kategori Beras Kualitas Medium I dan Beras Kualitas Super I, yang berbasis *time series* data, selama kurun waktu dari tahun 01-08-2017 sampai dengan tahun 10-04-2022 atau selama kurun waktu 1417 hari.

	tanggal_data	Beras Kualitas Medium I (kg)	Beras Kualitas Super I (kg)
0	2017-08-01	11250.0	12750.0
1	2017-08-02	11250.0	12750.0
2	2017-08-03	11250.0	12700.0
3	2017-08-04	11250.0	12750.0
4	2017-08-05	11250.0	12750.0
...
1709	2022-04-06	11800.0	13100.0
1710	2022-04-07	11800.0	13050.0
1711	2022-04-08	11800.0	13100.0
1712	2022-04-09	11800.0	13100.0
1713	2022-04-10	11800.0	13100.0

1714 rows x 3 columns

Gambar 2. Dataset Beras 01-08-2017 s.d. 10-04-2022

Tahapan persiapan data yang pertama adalah mengisi nilai kosong (*NAN*) yang terdapat pada dataset dengan cara mengisi data yang kosong dengan data sehari sebelumnya, selanjutnya dilakukan delakukan proses *smoothing moving average* untuk membuat data menjadi lebih halus dan stationer dengan menghitung harga rata-rata dalam periode waktu tertentu.

$$\begin{aligned}
 SMA_k &= \frac{p_{n-k+1} + p_{n-k+2} \cdots + p_n}{k} \\
 &= \frac{1}{k} \sum_{i=n-k+1}^n p_i \dots\dots\dots(1)
 \end{aligned}$$

Keterangan :

SMA = Moving Average

P = Keseluruhan Penjumlahan dari semua data periode waktu yang diperhitungkan

k = Jumlah Periode Rata-rata bergerak

Data *time series* dipengaruhi tren atau musiman untuk itu perlu diuji, salah satu metode yang digunakan untuk pengujian menggunakan Augmented-Dickey Fuller (ADF) test.

$$y_t = c + \beta t + \alpha y_{t-1} + \phi \Delta Y_{t-1} + e_t \dots\dots\dots(2)$$

y(t-1) = lag 1 dari time series

delta Y(t-1) = perbedaan pertama dalam series pada waktu (t-1)

Tahapan selanjutnya melakukan *normalization* data, metode ini digunakan untuk mengubah ukuran data dari rentang asli sehingga semua nilai berada dalam kisaran pada rentang tertentu, dalam penelitian ini data dinormalisasi dengan nilai interval - 1 dan 1[5]. Setelah tahap persiapan data selesai, tahap selanjutnya membagi dataset menjadi dua yaitu dataset training dan dataset testing[6].

Tabel 1. Pembagian Data

Training (80%)	Testing (20%)
1371 Data	343 Data
01-08-2017 s.d. 01-05-2021	02-05-2017 s.d. 10-04-2022

Untuk keperluan proses pada model LSTM dan BILSTM data training dan testing di-reshape menjadi 3 dimensi[7].

2.2. Model LSTM dan BILSTM

Pada LSTM terdapat empat *gates* yaitu *forget gate*, *input gate*, *cell gate* dan *output gate*. Proses pertama yang dilakukan oleh LSTM adalah menentukan nilai yang tidak digunakan (*forget gate*) dengan rumus sebagai berikut[8].

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \dots\dots\dots(3)$$

Selanjutnya proses menentukan data masukan (*input gates*).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \dots\dots\dots(4)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \dots\dots\dots(5)$$

Selanjutnya proses menentukan data masukan (*input gates*).

$$C_t = f_t * C_{t-1} + i_t * C_t \dots\dots\dots(6)$$

Selanjutnya proses menentukan nilai keluaran (*output gates*). Terdapat dua proses pada proses menentukan nilai keluaran[9].

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \dots\dots\dots(7)$$

$$h_t = o_t * \tanh(C_t) \dots\dots\dots(8)$$

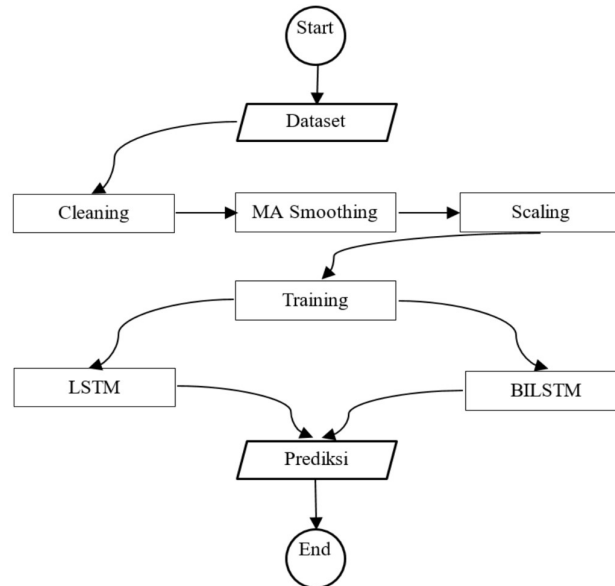
Parameter model LSTM dan BILSTM yang akan digunakan pada Tabel 2, Pertama model LSTM dan BILSTM dibangun dengan fungsi *sequential()*, kemudian dibuat *input layer* dengan 32 neuron, *layer* selanjutnya berisi 128 *neuron* yang di lanjutkan dengan *dropout* sebesar 0.2, *layer* yang ke 3 berisi 64 *neuron* dan nilai *dropout* sebesar 0.2, *layer* terakhir adalah *output layer* yang hanya memiliki 1 *neuron*.

Tabel 2. Parameter Model LSTM dan BILSTM

Parameter	Jumlah
Total Layer	4 Layer
Jumlah Input Layer	Layer 1, 32 <i>neuron</i>
Hidden Layer	Layer 2, 128 <i>neuron</i> Dropout, 0.2 Layer 3, 64 <i>neuron</i> Dropout, 0.2
Output Layer	Layer 4, 1 <i>neuron</i>
Jumlah Epoch	70 dan 140

2.3. Training

Dataset yang telah dikumpulkan dilanjutkan dengan dilanjutkan dengan tahap *preprocessing* data yang terdiri dari cleaning data, smoothing moving average, dan scaling data. Langkah selanjutnya adalah proses training data menggunakan algoritma LSTM dan BILSTM. Hasil proses training tersebut menghasilkan nilai prediksi dan kemudian ditentukan performa terbaik menggunakan Mean Square Error (MSE) dan Root Mean Square Error (RMSE), alur dapat dilihat pada Gambar 3 dibawah.



Gambar 3. Alur Model Pelatihan

2.4. Testing dan Evaluasi

Pengujian dalam penelitian ini akan dilakukan pada 2 data kategori beras yaitu Beras Kualitas Super I dan Beras Kualitas Medium I yang masing masing kategori akan diproses dengan model LSTM dan BILSTM, jumlah skenario ada 24, yaitu dengan merubah parameter jumlah hari pada moving average dan jumlah epoch yang berguna untuk menganalisa dampak tiap parameter terhadap akurasi yang didapat. Skenario pengujian dapat dilihat pada Tabel 3. Untuk tes performa model pertama menggunakan MSE adalah rata-kata kesalahan kuadrat diantara nilai aktual dan nilai peramalan. Metode ini digunakan untuk mengecek estimasi berapa nilai kesalahan pada peramalan. Nilai MSE yang rendah atau mendekati nol menunjukkan bahwa hasil peramalan sesuai dengan data aktual dan bisa dijadikan untuk perhitungan peramalan di periode mendatang[10].

$$MSE = \frac{\sum_{t=1}^n (At - Ft)^2}{n} \dots\dots\dots(9)$$

- At = Nilai data Aktual
- Ft = Nilai hasil peramalan
- N = banyaknya data
- Σ = Summation (Jumlahkan keseluruhan nilai)

Selanjutnya menggunakan RMSE, adalah jumlah dari kesalahan kuadrat atau selisih antara nilai sebenarnya dengan nilai prediksi yang telah ditentukan[10]. Berikut adalah formula untuk menghitung RMSE.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (A_t - F_t)^2}{n}} \dots\dots\dots(10)$$

Keterangan:

- At = Nilai data Aktual
- Ft = Nilai hasil peramalan
- N = banyaknya data
- Σ = Summation (Jumlahkan keseluruhan nilai)

Tabel 3. Skenario penelitian

Kategori Beras	Model	Skenario	Smoothing	Epoch
Beras Kualitas Super I	LSTM	1	Normal	70
		2	MA 7 hari	70
		3	MA 14 hari	70
		4	Normal	140
		5	MA 7 hari	140
		6	MA 14 hari	140
	BILSTM	7	Normal	70
		8	MA 7 hari	70
		9	MA 14 hari	70
		10	Normal	140
		11	MA 7 hari	140
		12	MA 14 hari	140
Beras Kualitas Medium I	LSTM	13	Normal	70
		14	MA 7 hari	70
		15	MA 14 hari	70
		16	Normal	140
		17	MA 7 hari	140
		18	MA 14 hari	140
	BILSTM	19	Normal	70
		20	MA 7 hari	70
		21	MA 14 hari	70
		22	Normal	140
		23	MA 7 hari	140
		24	MA 14 hari	140

3. HASIL DAN PEMBAHASAN

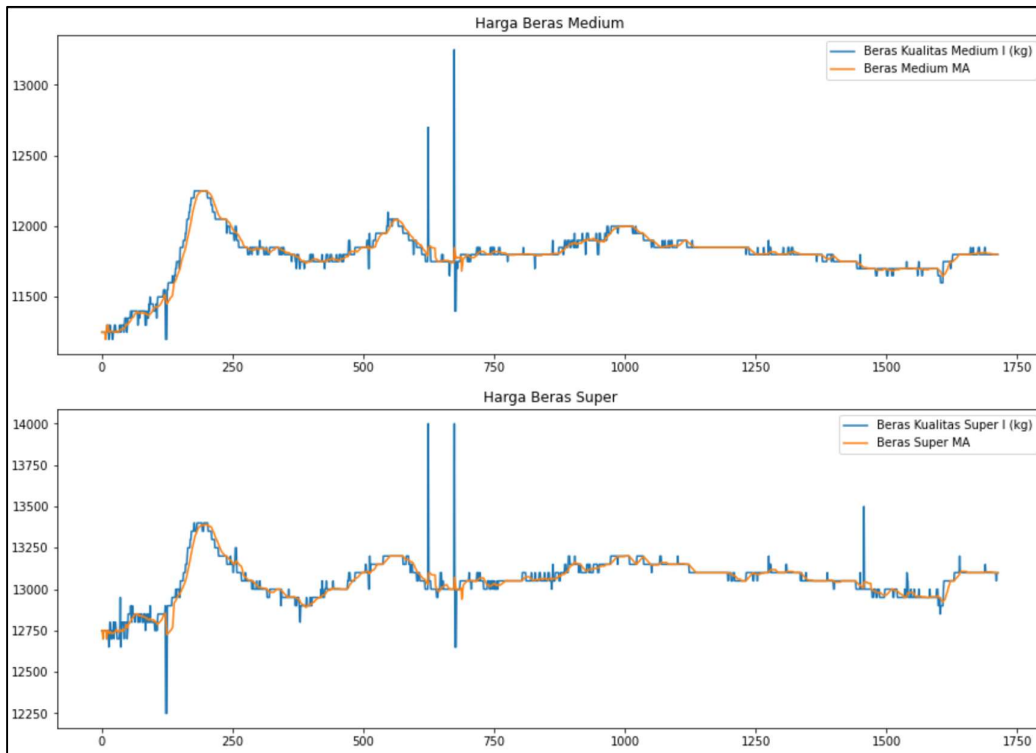
3.1. Preprocessing Data

Dataset diambil dari publikasi Pusat Informasi Harga Pangan Strategis Nasional dalam kurun waktu tahun 2017 - 2022 yang didapatkan dari survei harga beras pada kabupaten dan kota diseluruh Indonesia. Terdapat 7 variabel data beras, dari variabel tersebut untuk permodelan dan

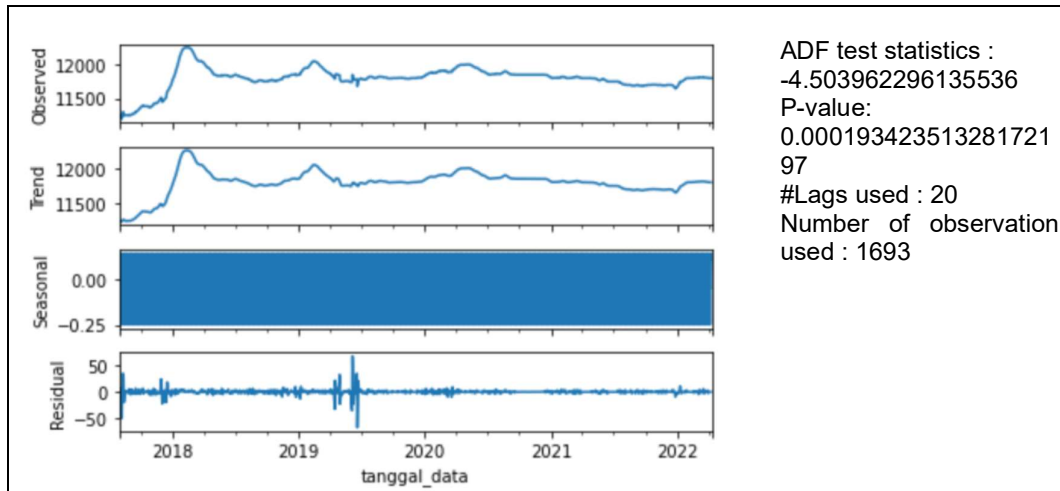
prediksi digunakan 3 variabel saja, yaitu Tanggal, Beras Kualitas Super I dan Beras Kualitas Medium I. Proses awal adalah dilakukannya konversi tanggal dan jam, menjadi format Datetime.

Tahapan selanjutnya proses pembersihan dari data yang kosong (*NAN*), dengan cara mengisi data yang *NAN* dengan data sehari sebelumnya. Setelah itu dilakukan proses *smoothing* dengan perhitungan rata-rata pergerakan harga mingguan (7 hari) dan dua mingguan (14 hari) pada masing-masing kategori beras. Data yang sudah dilakukan transformasi ditunjukkan di gambar 6 dibawah.

Gambar 4. Visualisasi data dengan MA 14 hari



Setelah proses diatas karena data time series dipengaruhi tren atau musiman untuk itu perlu diuji, salah satu metode yang digunakan untuk pengujian menggunakan Augmented-Dickey Fuller (ADF) test, hasil tes tersebut pada Gambar 5 dibawah.



Gambar 5. Uji Augmented-Dickey Fuller (ADF)

Pada hasil pengujian nilai P bernilai 0.00019342351328172197 hal ini menandakan hasil yang baik karena bernilai ≤ 0.05 dan data sudah stasioner. Tahap selanjutnya melakukan normalisasi data dengan nilai interval - 1 dan 1. Setelah proses normalisasi data selesai adalah membagi dataset menjadi dua yaitu dataset training 80% (1371 data) dan dataset testing 20% (374 data).

3.2. Pengujian Pada Data Beras Kualitas Super I

Hasil uji pada data Beras Kualitas Super I ada 12 skenario dengan hasil pada Tabel 4.

Tabel 4. Uji Data Beras Kualitas Super I

Kategori Beras	Model	Skenario	Smoothing	Epoch	MSE	RMSE
Beras Kualitas Super I	LSTM	1	Normal	70	1555.767	39.443
		2	MA 7 hari	70	55.471	7.448
		3	MA 14 hari	70	18.712	4.326
		4	Normal	140	1624.452	40.304
		5	MA 7 hari	140	101.312	10.065
		6	MA 14 hari	140	6.651	0.986
	BILSTM	7	Normal	70	1572.47	39.654
		8	MA 7 hari	70	54.35	7.372
		9	MA 14 hari	70	19.562	4.423
		10	Normal	140	1606.794	40.085
		11	MA 7 hari	140	61.601	7.849
		12	MA 14 hari	140	21.408	4.627



Gambar 6. Data Beras Kualitas Super I Model LSTM Skenario 6

Dapat dilihat pada model LSTM dengan nilai Epoch 70, proses *smoothing moving average* mempengaruhi nilai performa dari model nilai MSE dan RMSE terus menurun skenario 3 RMSE (4.326) lebih kecil dari skenario 1 RMSE (39.443). pada perlakuan nilai Epoch 140 nilai MSE dan RMSE semakin baik dapat dilihat pada Gambar 6. skenario 6, dimana nilai MSE (6.651) nilai RMSE (0.986).

Selanjutnya pada model BILSTM dengan nilai Epoch 70, proses *smoothing* menaikan nilai performa dari model nilai MSE dan RMSE terus menurun skenario 12 RMSE (4.423) lebih kecil dari skenario 7 RMSE (39.654). pada perlakuan nilai Epoch 140 nilai MSE dan RMSE semakin baik dapat dilihat pada Gambar 6 skenario 6, dimana nilai MSE (21.408) nilai RMSE (4.627).

Pada uji data Beras Kualitas Super I performa model LSTM lebih baik dari Model BILSTM, nilai MSE (21.408) nilai RMSE (4.627) pada model BILSTM lebih besar dibandingkan dengan Model LSTM dengan nilai MSE (6.651) nilai RMSE (0.986).

3.3. Pengujian Pada Data Beras Kualitas Medium I

Selanjutnya pengujian pada data Beras Kualitas Medium I, terlihat pada Tabel 5 dibawah

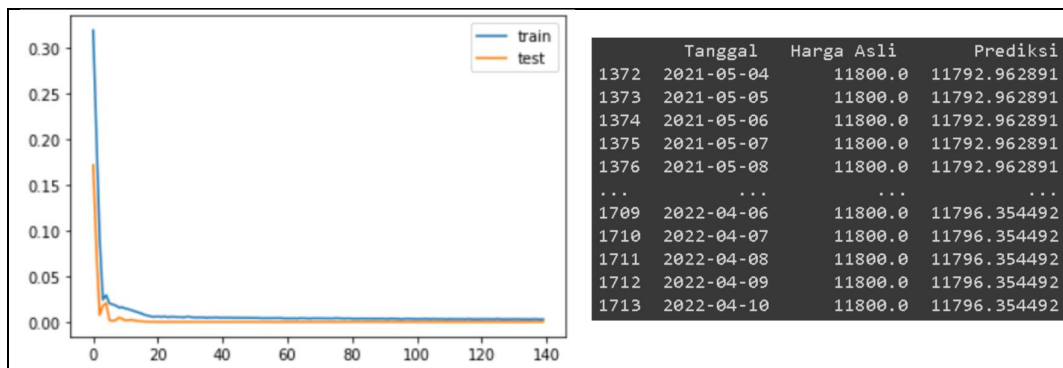
Tabel 5. Uji Data Beras Kualitas Medium I

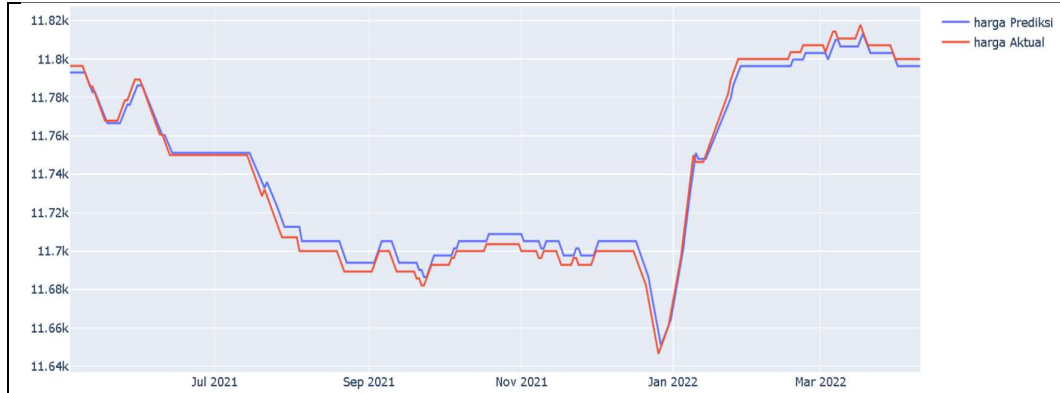
Kategori Beras	Model	Skenario	Smoothing	Epoch	MSE	RMSE
Beras Kualitas Medium I	LSTM	13	Normal	70	644.092	25.379
		14	MA 7 hari	70	93.465	9.668
		15	MA 14 hari	70	22.426	4.736
		16	Normal	140	30.934	0.636
		17	MA 7 hari	140	5.833	0.986
		18	MA 14 hari	140	4.862	0.989
	BILSTM	19	Normal	70	607.298	24.643
		20	MA 7 hari	70	59.343	7.703
		21	MA 14 hari	70	20.309	4.507
		22	Normal	140	427.778	20.683
		23	MA 7 hari	140	32.818	5.729
		24	MA 14 hari	140	81.441	9.024

Dapat dilihat pada Tabel 5 pada model LSTM dengan nilai Epoch 70, proses *smoothing moving average* juga mempengaruhi nilai performa model nilai MSE dan RMSE terus menurun skenario 15 nilai RMSE (4.736) lebih kecil dari skenario 13 nilai RMSE (25.379). pada perlakuan nilai Epoch 140 nilai MSE dan RMSE semakin baik dapat dilihat pada skenario 18 nilai MSE (4.862) nilai RMSE (0.989).

Selanjutnya pada model BILSTM dengan nilai Epoch 70, proses *smoothing* juga menaikkan nilai performa dari model nilai MSE dan RMSE terus menurun skenario 21 RMSE (4.507) lebih kecil dari skenario 19 RMSE (24.643). pada perlakuan nilai Epoch 140 nilai MSE dan RMSE semakin baik dapat dilihat pada skenario 24 nilai MSE (81.441) nilai RMSE (9.024).

Pada uji data Beras Kualitas Medium I performa model LSTM lebih baik dari Model BILSTM, nilai MSE (81.441) nilai RMSE (9.024) pada model BILSTM lebih besar dibandingkan dengan Model LSTM dengan nilai MSE (4.862) nilai RMSE (0.989).





GAMBAR 7. DATA BERAS KUALITAS MEDIUM I MODEL LSTM SKENARIO 18

4. KESIMPULAN

Dari hasil pengujian diatas *smoothing* data dengan *moving average* menunjukkan dapat meningkatkan performa model baik model LSTM maupun model BILSTM. Pada data Beras Kualitas Super I model LSTM dengan nilai Epoch 140 nilai MSE dan RMSE semakin baik, dapat dilihat pada skenario 6 nilai MSE (6.651) nilai RMSE (0.986), dan untuk model BILSTM nilai Epoch yang sama dapat dilihat pada skenario 12 nilai MSE (21.408) nilai RMSE (4.627), untuk data Beras Kualitas Super I performa model LSTM lebih unggul dari pada BILSTM.

Dengan data Beras Kualitas Medium I model LSTM dengan nilai Epoch 140 nilai MSE dan RMSE nilai terbaik pada skenario 18 nilai MSE (4.862) nilai RMSE (0.989), dan untuk model BILSTM nilai Epoch 140 pada skenario 24 nilai MSE (81.441) nilai RMSE (9.024), untuk data Beras Kualitas Medium I performa model LSTM juga lebih unggul dari pada BILSTM.

5. SARAN

Hasil Penelitian ini diharapkan dapat menjadi referensi untuk pengembangan penelitian lainnya, hasil model yang dibuat masih dapat dikembangkan lagi dengan proses *tunning* parameter LSTM dan BILSTM agar menghasilkan model yang lebih akurat.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen dan rekan-rekan mahasiswa Universitas Nusa Mandiri yang telah memberi dukungan terhadap penelitian ini.

DAFTAR PUSTAKA

- [1] O. Helbawanti, W. A. Saputro, and A. N. Ulfa, "Pengaruh Harga Bahan Pangan Terhadap Inflasi Di Indonesia," *AGRISAINTEFIKA J. Ilmu-Ilmu Pertan.*, vol. 5, no. 2, p. 107, 2021, doi: 10.32585/ags.v5i2.1859.
- [2] J. K. Lubis and I. Kharisudin, "Metode Long Short Term Memory dan Generalized Autoregressive Conditional Heteroscedasticity untuk Pemodelan Data Saham," *Prism. Pros. Semin. Nas. ...*, vol. 4, pp. 652–658, 2021, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/article/view/44897>

- [3] A. Arfan and L. ETP, "Perbandingan Algoritma Long Short-Term Memory dengan SVR Pada Prediksi Harga Saham di Indonesia," *Petir*, vol. 13, no. 1, pp. 33–43, 2020, doi: 10.33322/petir.v13i1.858.
- [4] H. F. Fadli and A. F. Hidayatullah, "Identifikasi Cyberbullying Pada Media Sosial Twitter Menggunakan Metode Klasifikasi Random Forest," 2019.
- [5] J. Manullang, A. J. Santoso, and A. W. R. Emanuel, "Prediksi Kunjungan Wisatawan Taman Nasional Gunung Merbabu dengan Time Series Forecasting dan LSTM," *J. Buana Inform.*, vol. 11, no. 2, p. 131, 2020, doi: 10.24002/jbi.v11i2.3825.
- [6] M. L. Ashari and M. Sadikin, "Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi Lstm," *J. Nas. Pendidik. Tek. Inform.*, vol. 9, no. 1, p. 1, 2020, doi: 10.23887/janapati.v9i1.19140.
- [7] S. Sen, D. Sugiarto, and A. Rochman, "Prediksi Harga Beras Menggunakan Metode Multilayer Perceptron (MLP) dan Long Short Term Memory (LSTM)," *Ultim. J. Tek. Inform.*, vol. 12, no. 1, pp. 35–41, 2020, doi: 10.31937/ti.v12i1.1572.
- [8] M. W. P. Aldi, Jondri, and A. Aditsania, "Analsis dan Implementasi Long Short Term Memory Neural Network Untuk Prediksi Harga Bekicot," *J. Inform.*, vol. 5, No, no. 2, p. 3548, 2018, [Online]. Available: <http://openlibrarypublications.telkomniversity.ac.id>
- [9] A. R. Isnain, A. Sihabuddin, and Y. Suyanto, "Bidirectional Long Short Term Memory Method and Word2vec Extraction Approach for Hate Speech Detection," *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 14, no. 2, p. 169, 2020, doi: 10.22146/ijccs.51743.
- [10] Khalis Sofi, Aswan Supriyadi Sunge, Sasmitoh Rahmad Riady, and Antika Zahrotul Kamalia, "Perbandingan Algoritma Linear Regression, Lstm, Dan Gru Dalam Memprediksi Harga Saham Dengan Model Time Series," *Seminastika*, vol. 3, no. 1, pp. 39–46, 2021, doi: 10.47002/seminastika.v3i1.275.