

# Implementasi Long Short Term Memory Neural Network Untuk Prediksi Indeks Harga Perdagangan Besar

Hartini<sup>1</sup>, Fitri Insani\*<sup>2</sup>, Novriyanto<sup>3</sup>, Suwanto Sanjaya<sup>4</sup>

Teknik Informatika, Fakultas Sains dan Teknologi, UIN Sultan Syarif Kasim Riau

Email: [111651200010@students.uin-suska.ac.id](mailto:111651200010@students.uin-suska.ac.id), [fitriinsani@uin-suska.ac.id](mailto:fitriinsani@uin-suska.ac.id), [novriyanto@enreach.or.id](mailto:novriyanto@enreach.or.id),  
[suwantosanjaya@uin-suska.ac.id](mailto:suwantosanjaya@uin-suska.ac.id)

## Abstrak

Indeks Harga Perdagangan Besar (IHPB) adalah tolak ukur atau perkiraan yang digunakan untuk perputaran ekonomi negara. Penelitian IHPB bertujuan untuk bertindak sebagai deflator Produk Domestik Bruto untuk pembangunan ekonomi. Studi ini dilakukan dengan menggunakan studi kasus IHPB Indonesia dari Badan Pusat Statistik (BPS) dari Januari 2000 hingga November 2019. Peramalan ini menggunakan algoritma *Long Short Term Memory*. LSTM adalah evolusi dari algoritma jaringan saraf tiruan *Recurrent Neural Network (RNN) deep learning*. RNN memiliki kekurangan dalam pengelolaan data jangka panjang, dan LSTM dapat mengatasi masalah ini. Pada penelitian ini LSTM mampu memprediksi IHPB bulan depan. IHPB di sektor pertanian melaporkan akurasi terbaik pada pembagian pelatihan 90% dan data uji 10%, *epoch* maksimum 200, dan *learning rate* 0,07 menghasilkan MAPE 9,0862, MSE 0,0114, RMSE 0,1067, dan akurasi sebesar 90,9138%.

**Kata kunci:** BPS, IHPB, Jaringan Syaraf Tiruan, LSTM, RNN

## Abstract

*The Wholesale Price Index (IHPB) is a benchmark or estimate used for a country's economic turnover. IHPB's research aims to act as a Gross Domestic Product deflator for economic development. This study was conducted using the Indonesian WPI case study from the Central Bureau of Statistics (BPS) from January 2000 to November 2019. This forecast uses the Long Short Term Memory algorithm. LSTM is an evolution of the deep learning Recurrent Neural Network (RNN) algorithm. RNNs have drawbacks in managing long-term data, and LSTMs can overcome these problems. In this study, LSTM was able to predict next month's IHPB. IHPB in the agricultural sector reported the best accuracy at 90% training distribution and 10% test data, a maximum epoch of 200, and a learning rate of 0.07 yielded a MAPE of 9.0862, MSE of 0.0114, RMSE of 0.1067, and an accuracy of 90.9138 %.*

**Keywords:** BPS, IHPB, Artificial Neural Networks, LSTM, RNN

## 1. Pendahuluan

Indeks Harga Perdagangan Besar (IHPB) merupakan sebuah petunjuk atau perkiraan untuk menilai perkembangan perekonomian negara. IHPB juga bisa digambarkan sebagai Inflasi pada tingkat harga grosir untuk semua komoditas di suatu wilayah atau negara. Komoditas-komoditas tersebut diproduksi dari dalam negeri untuk diperdagangkan didalam negeri ataupun luar negeri[1].

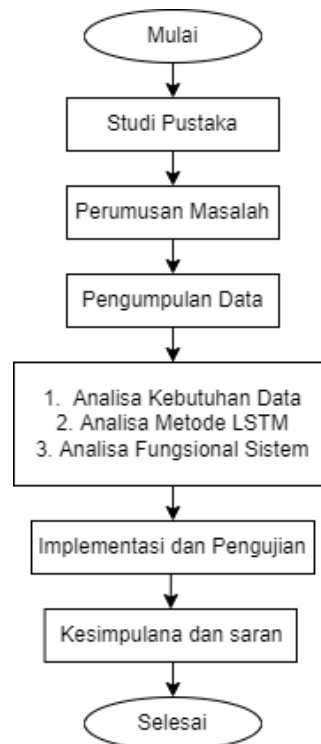
IHPB tersedia dalam bentuk indeks angka dan terbagi menjadi enam sektoral. Perdagangan besar juga diartikan sebagai pedagang yang membeli barang dalam jumlah tanpa batasan langsung pada produsennya[2]. Data IHPB digunakan sebagai acuan untuk meramalkan kondisi inflasi ke depan. Komoditas yang dihitung dalam IHPB dibagi menjadi beberapa sektor dan masing-masing sektor dibagi menjadi beberapa subsektor antara lain pertanian, pertambangan dan penggalian, industri, impor, dan total ekspor dibagi menjadi dua subsektor yaitu ekspor non migas dan ekspor migas, indeks umum dibagi menjadi empat subsektor indeks umum tanpa ekspor migas, indeks umum tanpa ekspor, indeks umum tanpa impor migas, dan indeks umum tanpa impor dan ekspor[3]. Oleh karena itu, diperlukan keputusan untuk mendapatkan inflasi IHPB dengan melakukan estimasi atau peramalan dengan jaringan syaraf tiruan menggunakan algoritma LSTM.

Berdasarkan latar belakang yang dijelaskan dalam penelitian ini akan dilakukan implementasi LSTM untuk melakukan prediksi IHPB dengan tujuan mengetahui performansi arsitektur LSTM untuk mendapatkan hasil *error* yang terkecil. Semakin kecil hasil *error* maka semakin kecil pula *error* jaringan syaraf tiruan dalam melakukan sebuah peramalan. Data

masukan yang digunakan dalam studi ini adalah data *time series* IHPB bulanan dari Januari 2000 hingga November 2019. Data tersebut dikelola dengan menggunakan algoritma LSTM untuk memberikan keluaran berupa sistem yang dapat memprediksi IHPB bulan depan.

## 2. Metode Penelitian

Metodologi penelitian merupakan langkah penelitian yang paling penting karena memuat langkah-langkah kerja yang telah disiapkan. Peneliti berharap bahwa metode ini akan memberikan hasil yang diinginkan. Pada Gambar 1 dijelaskan tentang metodologi penelitian ini.



Gambar 1. Metodologi Penelitian

### 2.1. Pengumpulan data

Tahapan ini menggunakan 2 tahap yaitu pertama tahap penggunaan data yang dikumpulkan oleh BPS pada bulan Januari 2000 sampai bulan November 2019 dan tahap kedua melakukan studi pustaka sebagai bahan referensi pada penelitian yang dilakukan.

### 2.2 Analisa Kebutuhan Data

Kebutuhan data pada tahap ini adalah data Indeks Harga Perdagangan Besar Indonesia bulanan dari Januari 2000 sampai dengan November 2019 sebanyak 239 data asli. Pada tahap ini, peneliti akan mulai menjalankan *time series*. Data yang digunakan pada pola *time series* ini adalah data asli IHPB pertanian Indonesia, dan total data setelah *time series* adalah 227 data. Meliputi X1, X2, X3, X4, X5, X6, X7, X8, X9, X10, X11, X12 dan Januari tahun berikutnya (Y). Di bawah ini contoh target indeks harga bulan Januari 2001 dimana variabel masukannya adalah 12 bulan terakhir dari Januari 2000 sampai Desember 2000. Tabel 1 menunjukkan bahwa pola data *time series* disusun.

Tabel 1. Data Time Series IHPB Pertanian Januari 2000 – November 2019

Data	X1	X2	X3	...	X10	X11	X12	Y
1	98,13	97,26	95,75	...	101,43	102,84	105,58	106,86
2	97,26	95,75	97,19	...	102,84	105,58	106,86	108,37
3	95,75	97,19	98,74	...	105,58	106,86	108,37	110,17

4	97,19	98,74	99,95	...	106,86	108,37	110,17	112,34
5	98,74	99,95	101,34	...	108,37	110,17	112,34	114,02

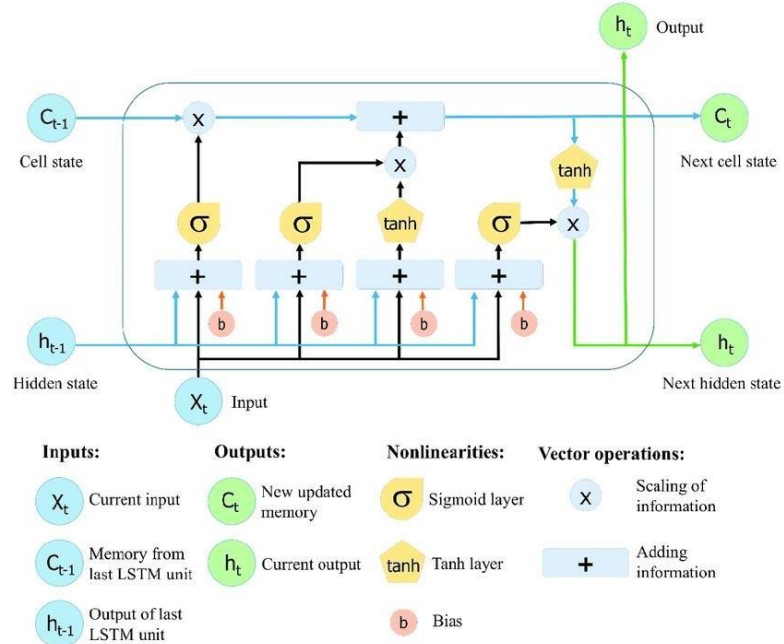
100	255,77	264,50	277,69	...	196,40	199,20	200,46	201,70
101	264,50	277,69	287,11	...	199,20	200,46	201,70	206,03
102	277,69	287,11	289,71	...	200,46	201,70	206,03	206,61
103	287,11	289,71	291,11	...	201,70	206,03	206,61	208,74
104	289,71	291,11	288,90	...	206,03	206,61	208,74	212,45
...	...	...	...	...	...	...	...	...
223	373,42	371,45	366,47	...	364,46	372,77	375,93	377,71
224	371,45	366,47	366,92	...	372,77	375,93	377,71	379,19
225	366,47	366,92	365,69	...	375,93	377,71	379,19	372,05
226	366,92	365,69	367,63	...	377,71	379,19	372,05	370,31
227	365,69	367,63	369,31	...	379,19	372,05	370,31	368,95

### 2.3 Analisa Metode Long Short Term Memory

Analisa berikut membantu peneliti memahami data dan algoritma yang diperlukan untuk membangun sistem. Menggunakan data dari BPS sejak Januari 2000 hingga November 2019. Tujuannya untuk mengetahui akurasi dan *error minimum* dari LSTM. Berdasarkan tabel masukan dan target yang diinginkan, arsitektur LSTM dapat digambarkan sebagai prediksi IHPB semua komoditas. Pada Gambar 2, variabel X1, X2, X3, X4, X5, X6, X7, X8, X9, X10, X11, dan X12 merupakan variabel input yang berisi data IHPB yang dinormalisasi, diikuti dengan gerbang lapisan tersembunyi yaitu gerbang *forget*(1), gerbang *input*(2), gerbang *cell state* (3), dan Gerbang *output*(4)[4].

Pada penelitian ini, kami menggunakan algoritma LSTM, sebuah algoritma yang dievolusi dari *Deep Learning RNN*. LSTM juga dapat mengatasi kekurangan RNN dalam kemampuannya mengelola data dari waktu ke waktu. LSTM dikenal lebih unggul dalam membuat peramalan atau peramalan jangka panjang dibandingkan algoritma lainnya, sehingga sering dipilih untuk *time series* atau peramalan berbasis waktu.[5].

LSTM pertama kali diperkenalkan oleh oleh Hochreiter & Schmidhuber pada tahun 1997. Hingga saat ini penelitian terus dilakukan untuk mengembangkan arsitektur LSTM dalam berbagai bidang terutama dibidang *Speech recognition* dan *forecasting*, karena dengan adanya LSTM masalah ketergantungan waktu jangka panjang dapat diatasi[6].



Gambar 2. Arsitektur Algoritma LSTM

Berikut merupakan tahapan LSTM:

- 1) Normalisasi data mengubah rentang data dari data asli menjadi *range* data mulai dari 0 hingga 1. Normalisasi pada penelitian ini menggunakan *MinMaxScaler*. Persamaan *MinMaxScaler* diuraikan pada persamaan berikut.

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

Keterangan :

- $y$  = hasil setelah di normalisasikan
- $x$  = masukan (*inputan*)
- $Min$  = data terkecil
- $Max$  = data terbesar

- 2) Menentukan parameter optimal  
 Setelah menormalisasikan data IHPB menjadi pola data *time series*, peneliti kemudian menentukan parameter lainnya seperti pembagian data, *epoch*, dan *learning rate*, yang terbaik untuk membantu dalam proses latih data.

- 3) Tahapan metode LSTM  
 Setelah normalisasi dan menentukan parameter optimal, Proses ini dilanjutkan dengan pembelajaran menggunakan metode LSTM untuk mendapatkan nilai akurasi tertinggi dan tingkat kesalahan terendah. Berikut penjelasan tahapan untuk mempelajari algoritma LSTM.

1. Tahap *training* atau pelatihan

- a. Tahap *feedforward* LSTM

Langkah awal adalah menentukan informasi atau data sel apa yang dihapus LSTM dari status sel. Keputusan ini dibuat oleh lapisan *sigmoid*, atau lapisan gerbang *forget*. Di bawah ini adalah rumus untuk gerbang *forget*.

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

Keterangan:

- $f_t$  = gerbang *forget*
- $\sigma$  = fungsi untuk *sigmoid*
- $W_f$  = nilai bobot atau *weight*
- $h_{t-1}$  = *output* atau keluaran sebelumnya
- $x_t$  = *input* atau masukan pada berikutnya
- $b_f$  = bias pada gerbang *forget*

Berikut persamaan *sigmoid* diuraikan.

$$\sigma(x) = 1/(1 + e^{-x}) \quad (3)$$

Keterangan:

- $x$  = masukan data
- $\epsilon$  = konstanta (2,71828 18284 59045 23536 02874)

Berikut persamaan mencari nilai *weight* (bobot).

$$W = - \frac{1}{\sqrt{d}} \frac{1}{\sqrt{d}} \quad (4)$$

Keterangan:

- $W$  = bobot
- $d$  = data keseluruhan

Langkah kedua adalah menentukan informasi atau data sel apa yang akan disimpan LSTM. Langkah ini terdiri dari dua bagian. Bagian awal, lapisan *sigmoid* yaitu lapisan gerbang *input* yang menentukan nilai mana yang akan diperbarui. Berikut penjelasan gerbang *input*.

$$i_t = \sigma (W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

Keterangan:

$i_t$  = gerbang *input*  
 $\sigma$  = fungsi untuk *sigmoid*  
 $W_i$  = nilai bobot atau *weight*  
 $h_{t-1}$  = keluaran sebelumnya  
 $x_t$  = masukan pada orde berikutnya  
 $b_i$  = bias

Persamaan dari status sel baru.

$$\zeta_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

Keterangan:

$\zeta_t$  = nilai baru yang diperoleh  
 $\tanh$  = fungsi untuk *tanh*  
 $W_c$  = nilai bobot atau *weight* untuk *sel*  
 $h_{t-1}$  = keluaran sebelumnya  
 $x_t$  = masukan pada orde berikutnya  
 $b_t$  = bias

Berikut penjelasan *tanh* diuraikan.

$$\tanh(x) = 2\sigma(2x) - 1 \quad (7)$$

Keterangan:

$\sigma$  = fungsi aktivasi *sigmoid*  
 $x$  = data input

Langkah ketiga adalah LSTM memperbarui status sel yang lama  $C_{t-1}$ , menjadi status sel yang baru. Persamaan status sel berikut.

$$C_t = f_t * C_{t-1} + i_t * \zeta_t \quad (8)$$

Keterangan:

$C_t$  = status sel  
 $f_t$  = gerbang *forget*  
 $C_{t-1}$  = status sel sebelumnya  
 $i_t$  = gerbang *input*  
 $\zeta_t$  = hasil sel baru yang dapat ditambahkan ke *status sel*

Langkah terakhir merupakan langkah dari algoritma LSTM yang bertujuan untuk menentukan hasil keluaran. Di bawah ini adalah persamaan untuk gerbang keluaran yang dijelaskan.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

Keterangan:

$o_t$  = gerbang *output*  
 $\sigma$  = fungsi untuk *sigmoid*  
 $W_o$  = nilai bobot atau *weight*  
 $h_{t-1}$  = keluaran sebelumnya  
 $x_t$  = masukan pada orde berikutnya  
 $b_o$  = bias

Berikut penjelasan hasil *output* orde t.

$$h_t = \sigma_o * \tanh(C_t) \quad (10)$$

Keterangan:

$h_t$  = *output* orde t  
 $o_t$  = gerbang keluaran atau hasil *output*  
 $\tanh$  = fungsi untuk *tanh*  
 $C_t$  = status sel

b. Tahap *backward* LSTM

Pada proses ini akan dilakukan update bobot dan meminimalkan *error* antara nilai output dan mendekati pada nilai ekspektasi atau rill. Dimulai dengan perhitungan parsial fungsi L2 terhadap variable x pada nilai loss.

$$x E(x, x) = x - x^{\wedge} \quad (11)$$

c. Tahap update parameter bobot dan bias dengan acuan fungsi SGD

$$W^{new} = W^{old} - \lambda * \delta W^{old} \quad (12)$$

2. Tahap pengujian

Setelah bobot dan bias baru ditentukan selama proses pelatihan, sehingga tahap selanjutnya yaitu tahap uji. Hasil Bobot dan bias dari perhitungan *feedforward* digunakan pada tahap pengujian untuk mendapatkan nilai MSE, RMSE, MAPE dan akurasi.

3. Tahap denormalisasi

$$x_d = \frac{((x_p - 0.1)(x_{0max} - x_{0min}))}{0.8} + x_{0min} \quad (13)$$

## 2.4 Analisa Fungsional Sistem

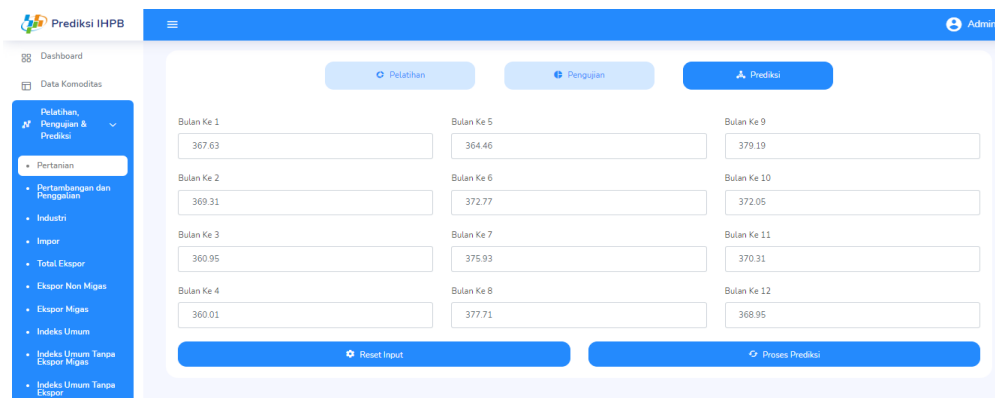
Analisis dan perancangan sistem didasarkan pada pemodelan UML (*Unified Modeling Language*). UML digunakan untuk memodelkan sistem dengan konsep berorientasi objek. Membangun model UML membutuhkan analisis berupa *use case diagram*, *spesifikasi use case*, *sequence diagram*, dan *class diagram*.

## 3. Hasil dan Pembahasan

Implementasi adalah penerapan yang berjalan pada hasil analisis dan desain yang diselesaikan sebelumnya. Selama tahapan ini diharapkan fungsional sistem sesuai dengan yang diharapkan.

### 3. 1. Implementasi Sistem

Implementasi sistem prediksi Indeks Harga Perdagangan Besar menggunakan bahasa pemrograman PHP dengan *framework Yii*. Gambar 3 menunjukkan salah satu halaman menu yang mendemonstrasikan proses tahapan LSTM dengan memasukkan data dalam *format Excel* dan menjalankan proses normalisasi. Selain itu, proses pelatihan dilakukan dengan memasukkan parameter optimal yaitu 12 bulan terakhir. Halaman pengujian menampilkan halaman perhitungan data pengujian default dengan menggunakan nilai bobot dan bias baru yang diperoleh dari proses pelatihan. Hasilnya adalah nilai ramalan untuk bulan berikutnya.



Gambar 3. Implementasi Sistem Prediksi IHPB

### 3.2 Pengujian Parameter

Tujuan dari tahap ini adalah untuk memperoleh pengetahuan dari seberapa besar pengaruh *epoch* maksimum yang digunakan terhadap nilai parameter *LR*, lalu data-data yang telah dibagi menjadi data pelatihan dan pengujian, serta perolehan nilai akurasi oleh algoritma LSTM. Berdasarkan data yang diperoleh sebanyak 227 data, maka dibuat pembagian data untuk data uji dan data latih. Berikut merupakan pembagian data IHPB pada salah satu komoditas yaitu pertanian.

Tabel 2. Pembagian Data IHPB

Data Latih		Data Uji	
60%	136	40%	91
70%	159	30%	68
80%	182	20%	45
90%	204	10%	23

Pengujian tingkat *error* dilakukan dengan cara memasukkan nilai *learning rate* yang berbeda dan jumlah *epoch* yang sama.

Tabel 3. Data *Epoch* dan *Learning Rate*

<i>Epoch</i>	<i>Learning Rate</i>
100,200	Range 0.01, -0,01

Selain *epoch* dan *learning rate* diperlukan juga bobot dan bias yang di dapat dari data random (0,07, -0,07). Bobot dan bias digunakan untuk melakukan perhitungan LSTM.

Tabel 4. Data Random Bobot dan Bias

Bobot ( <i>Weight</i> )		Bias	
Wc	-0,0474	Bc	0,1
Wi	-0,0129	Bi	0,2
Wf	0,0083	Bf	0,1
Wo	-0,0555	Bo	0,2

Hasil dari analisa dan pengujian pada semua komoditas, maka didapatkan data akurasi paling tinggi berikut ini.

Tabel 5. Kesimpulan Pengujian Akurasi

Pembagian Data	<i>Epoch</i>	<i>Leraning rate</i>	MAPE %	MSE	RMSE	Akurasi %
60:40	100	0,1	17,7487	0,0388	0,1971	82,2513
	200	0,1	17,5562	0,0382	0,1954	82,4438
70:30	100	0,2	24,7504	0,0626	0,2501	75,2496
	200	0,01	24,4084	0,0618	0,2485	75,5916
80:20	100	0,1	20,8290	0,0482	0,2195	79,1710
	200	0,1	20,5936	0,0473	0,2175	79,4064
<b>90:10</b>	100	0,1	10,0789	0,0137	0,1170	89,9211
	<b>200</b>	<b>0,07</b>	<b>9,0862</b>	<b>0,0114</b>	<b>0,1067</b>	<b>90,9138</b>

Hasil studi ini menunjukkan bahwa IHPB sektor pertanian memberikan nilai akurasi terbaik pada data yang telah dibagi menjadi data latih 90% dan data uji 10%, *epoch* 200, *learning rate* 0,07 menghasilkan MAPE 9,0862, MSE 0,0114, RMSE 0,1067, dan akurasi sebesar 90,9138%.

### 4. Kesimpulan

Berdasarkan hasil penelitian algoritma LSTM untuk memprediksi IHPB Pertanian Indonesia. Berikut merupakan kesimpulan yang di dapatkan pada penelitian ini.

- Prediksi Indeks Harga Perdagangan Besar dengan menerapkan jaringan syaraf tiruan algoritma LSTM (*Long Short Term Memory*) berhasil dilakukan.
- Pada studi kasus ini menghasilkan *output system* yang dapat memprediksi Indeks Harga Perdagangan Besar pada bulan berikutnya.



- c. Hasil studi kasus ini menunjukkan bahwa IHPB sektor pertanian memberikan nilai akurasi terbaik pada data yang telah dibagi menjadi data latih 90% dan data uji 10%, *epoch* 200, *learning rate* 0,07 menghasilkan MAPE 9,0862, MSE 0,0114, RMSE 0,1067, dan akurasi sebesar 90,9138%.

#### Referensi

- [1] B. P. S. BPS, "No Title: INDEKS HARGA PERDAGANGAN BESAR INDONESIA," 2020.
- [2] T. Pasokawati and M. Y. Darsyah, "Analisis Peramalan Menggunakan Pemulusan Winter Dan ARIMA Pada Indeks Harga Perdagangan Besar Indonesia Kelompok Komoditi Pertanian Tahun 2016 — 2017," *Pros. Semin. Nas. Mhs. Unimus*, vol. 1, no. January 2018, 2018.
- [3] Z. Zulfikar, A. Wanto, and Z. M. Nasution, "Analisis dalam Melihat Perkembangan Indeks Harga Perdagangan Besar Menurut Sektor di Indonesia Menggunakan Algoritma Backpropagation," *Pros. Semin. Nas. Ris. Inf. Sci.*, vol. 1, no. November, p. 359, 2019, doi: 10.30645/senaris.v1i0.41.
- [4] Winata and Wendy, "Prakira Suhu Udara Rata-Rata Kota-Kota Besar Dunia Menggunakan Metode Long Short-Term Memory," 2018.
- [5] S. Zahara, Sugianto, and M. Bahril Ilmiddafiq, "Jurnal resti ( Prediksi Indeks Harga Konsumen menggunakan metode Long Short Term Memory (LSTM) berbasis Cloud Computing," vol. 1, no. 10, pp. 357–363, 2019.
- [6] A. Arfan and E. Lussiana, "Prediksi Harga Saham Di Indonesia Menggunakan Algoritma Long Short-Term Memory," vol. 3, 2019.
- [7] S. Sen, "Prediksi Harga Beras Menggunakan Metode Long Short Term Memory (LSTM)," pp. 32–51, 2020.
- [8] M. Rizki, S. Basuki, and Y. Azhar, "Implementasi Deep Learning Menggunakan Arsitektur Long Short Term Memory Untuk Prediksi Curah Hujan Kota Malang," vol. 2, no. 3, pp. 331–338, 2020.