

# PERBANDINGAN LSTM DAN ELM DALAM MEMPREDIKSI HARGA PANGAN KOTA TASIKMALAYA

Andry Winata<sup>1)</sup> Manatap Sitorus<sup>2)</sup> Teny Handhayani<sup>3)</sup>

<sup>1)</sup> Teknik Informatika Universitas Tarumanagara  
Jl. Letjen S. Parman No.1, Jakarta 11440 Indonesia  
email : [andry.535190070@stu.untar.ac.id](mailto:andry.535190070@stu.untar.ac.id)

<sup>2)</sup> Teknik Informatika Universitas Tarumanagara  
Jl. Letjen S. Parman No.1, Jakarta 11440 Indonesia  
email : [manataps@fti.untar.ac.id](mailto:manataps@fti.untar.ac.id)

<sup>3)</sup> Teknik Informatika Universitas Tarumanagara  
Jl. Letjen S. Parman No.1, Jakarta 11440 Indonesia  
email : [tenyh@fti.untar.ac.id](mailto:tenyh@fti.untar.ac.id)

## ABSTRACT

*Humans have needs that must be met, one of which is the need for food, but food prices often change. Factors that affect price changes occur because the amount of demand is high while the supply is small. Making predictions about price changes will be very helpful to get an idea of the pattern of price changes. Therefore making predictions from price patterns is useful for providing information to the public. Predictions regarding price changes can be made using many methods. Long Short-Term Memory (LSTM) and Extreme Learning Machine (ELM) are several methods that can be used to predict time series data, these two methods can provide an overview of the predictions made. The results of the study show that both algorithms have good results in terms of the the evaluation value. The evaluation results showed no significant difference between the two algorithms. The evaluation value of the rice commodity showed that ELM tended to be better with MAE values of 6,721, MAPE 0.061%, MSE 115,281, RMSE 10,737 and CV 3,699%, while LSTM with MAE 31,707, MAPE 0.286%, MSE 1927.633, RMSE 43.905 and CV 3.655%. However, for other commodities, LSTM can produce a better evaluation value.*

## Key words

*Teknik Informatika, LSTM, ELM, Maching learning*

## 1. Pendahuluan

Kebutuhan pokok manusia pertama kali diperkenalkan oleh International Labour Organization pada tahun 1976 meliputi kebutuhan akan pakaian, makanan dan tempat tinggal [1]. Di Indonesia, kebutuhan pokok dikenal sebagai sandang, pangan, dan papan. Pangan sendiri memiliki arti segala sesuatu yang digunakan sebagai bahan konsumsi manusia [2]. Kebutuhan pangan menjadi salah satu kebutuhan

terpenting bagi manusia, tanpa makanan, manusia tidak akan memiliki energi untuk beraktifitas. Harga pangan yang berubah-ubah dapat mempengaruhi kualitas pembelian masyarakat, terutama bagi masyarakat miskin.

Kota Tasikmalaya merupakan salah satu kota dengan persentase kemiskinan tertinggi di Provinsi Jawa Barat [3]. Oleh karena itu, prediksi terhadap kenaikan harga pangan dari dataset yang ada akan sangat membantu masyarakat mendapat gambaran mengenai kenaikan harga komoditas pangan, dengan begitu, masyarakat dapat mengetahui perubahan pola harga yang terjadi.

Ada beberapa metode yang dapat digunakan untuk melakukan prediksi perubahan harga seperti Long Short-Term Memory (LSTM) dan Extreme Learning Machine (ELM). Kedua metode tersebut dapat digunakan untuk memprediksi data bertipe timeseries. Prediksi yang dilakukan dengan menggunakan dua metode tersebut diharapkan dapat memberikan gambaran yang lebih jelas mengenai perubahan harga yang terjadi. Dalam penelitian ini, akan dilakukan perbandingan antara kedua metode untuk mendapatkan hasil yang dapat dibandingkan.

Masalah yang diidentifikasi dalam penelitian ini adalah bahwa perubahan harga dapat mempengaruhi pembelian masyarakat, kenaikan harga akan berdampak buruk pada kalangan masyarakat miskin, dan sedikitnya informasi mengenai prediksi yang dapat menjadi acuan terhadap perubahan harga. Untuk memfokuskan pembahasan penelitian, batasan masalah akan berfokus pada dataset harga pangan harian dari pasar tradisional di Kota Tasikmalaya mulai dari tanggal 3 April 2017 hingga 28 Februari 2022.

Adapun beberapa penelitian yang relevan. Penelitian oleh Teny Handhayani berjudul "An integrated analysis of air pollution and meteorological conditions in Jakarta", 2023. Penelitian menemukan keterkaitan antara pencemaran udara dan kondisi meteorologi di Jakarta dengan analisis integrasi menggunakan LSTM dan GRU

[4]. Penelitian oleh Tyas Ismi Zahrani dengan judul “Food Commodity Price Prediction in East Java Using Extreme Learning Machine (ELM) Method”, 2019. Penelitian ini memprediksi harga pangan di Jawa Timur dengan menggunakan metode Extreme Learning Machine (ELM) dengan dataset yang diperoleh dari Pusat Informasi Harga Pangan Strategis Nasional berupa data harian 10 komoditas pokok dengan rata-rata tingkat error 1,21% [5].

## 2. Metode Penelitian

Metode yang digunakan adalah LSTM dan ELM. Rancangan penelitian ini dibagi menjadi beberapa tahap yaitu pengumpulan data, pra pemrosesan data, normalisasi data, implementasi algoritma dan evaluasi.

### 2.1 Pengumpulan Data

Dataset yang digunakan adalah data bertipe deret waktu/timeseries yang diambil dari Pusat Informasi Harga Pangan Strategis Nasional melalui <https://www.bi.go.id/hargapangan/>. Data yang diambil adalah data dari pasar tradisional Kota Tasikmalaya mulai dari tanggal 3 April 2017 hingga 28 Februari 2023. Variabel yang digunakan adalah harga beberapa komoditas yaitu beras, daging ayam, telur ayam, bawang merah, bawang putih dan cabai merah.

### 2.2 Pra Pemrosesan Data

Setelah mengumpulkan data, berikutnya adalah tahap pra pemrosesan data. Pada tahap ini data yang sudah dikumpulkan akan diperiksa terlebih dahulu untuk melihat apakah ada kekosongan/missing value pada data yang diambil. Missing value adalah kondisi hilangnya sebagian informasi pada dataset yang ada [6]. Missing value yang ada akan diisi terlebih dahulu dengan mencari nilai tengah suatu data yang kosong menggunakan rumus interpolasi linear yang ditunjukkan pada persamaan (1).

$$f(x) = f(x_0) + \frac{f(x_1) - f(x_0)}{x_1 - x_0} (x - x_0) \quad (1)$$

Keterangan:

$f(x)$  = data yang dicari

$f(x_0)$  = data titik awal

$f(x_1)$  = data titik akhir

$x$  = nomor yang dicari

$x_0$  = nomor titik awal

$x_1$  = nomor titik akhir

### 2.3 Normalisasi Data

Tahap ketiga adalah menormalisasi data. Data sering kali memiliki perbedaan skala yang besar antara nilai data terbesar dan terkecil yang dapat mempersulit perhitungan, karenanya nilai data perlu diskala ulang dengan tujuan untuk menyederhanakan nilai dengan

menskala ulang nilai menjadi rentang 1 dan 0 menggunakan min-max normalization [7], rumus normalisasi ditunjukkan pada persamaan (2).

$$x' = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (2)$$

Keterangan:

$x_i$  = nilai yang akan dinormalisasi

$x'$  = nilai yang telah dinormalisasi

$\min(x)$  = nilai minimal data


$\max(x)$  = nilai maksimal data

### 2.4 Implementasi Algoritma

Setelah melakukan pra prosesi data dan juga menormalisasi data, langkah berikutnya adalah menerapkan algoritma LSTM dan juga ELM terhadap data yang ada. Data yang telah siap akan diproses kedalam kedua metode.

#### 1. Long Short-Term Memory(LSTM)

Long Short-Term Memory (LSTM) adalah sistem penyimpanan data yang dapat memproses, memprediksi, dan mengklasifikasikan informasi yang telah disimpan dalam jangka waktu lama [8]. Pada arsitektur LSTM terdapat 3 gerbang, arsitektur dari LSTM dapat dilihat pada Gambar 1[8].



Gambar 1 Arsitektur LSTM

Gerbang pertama adalah forget gate yang berfungsi untuk memutuskan informasi harus dibuang atau diteruskan. Rumus dari forget gate terdapat pada persamaan (3)[8].

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

Keterangan:

$f_t$  = forget gate

$\sigma$  = fungsi sigmoid

$W_f$  = bobot forget gate

$h_{t-1}$  = output timestep 1

$x_t$  = timestep terkini

$b_f$  = bobot bias forget gate

Gerbang kedua adalah input gate. Gerbang ini berfungsi untuk menentukan informasi mana yang akan dijadikan *new knowledge* dan disimpan. Rumus dari input gate dan *new knowledge* masing-masing dapat dilihat pada persamaan (4) dan persamaan (5) [8].

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

$$c'_t = \tanh(WC \cdot [h_{t-1}, x_t] + bC) \quad (5)$$

Keterangan:

$it$  = input gate  
 $\sigma$  = sigmoid  
 $Wi$  = bobot input gate  
 $ht_{-1}$  = output timestep 1  
 $xt$  = timestep terkini  
 $bi$  = bobot bias input gate  
 $C't$  = kandidat baru cell state  
 $tanh$  = fungsi tanh  
 $WC$  = bobot cell state  
 $bC$  = bobot bias cell state

Hasil dari perhitungan sebelumnya akan menjadi komponen untuk menentukan cell state(new knowlegde) yang baru. Rumus dari cell state dapat dilihat pada persamaan (6) [8].

$$Ct = ft * Ct_{-1} + it * C't \quad (6)$$

Keterangan:

$Ct$  = cell state  
 $ft$  = forget gate  
 $Ct_{-1}$  = cell state timestep 1  
 $it$  = input gate  
 $C't$  = kandidat baru cell state

Gerbang terakhir dalam arsitektur LSTM adalah Output gate, gerbang ini berfungsi untuk menghasilkan output dari perhitungan yang sudah dijalankan. Rumus dari output gate dapat dilihat pada persamaan (7) [8].

$$ot = \sigma(Wo.[ht_{-1}, xt] + bo) \quad (7)$$


Keterangan:

$ot$  = output gate  
 $\sigma$  = fungsi sigmoid  
 $Wo$  = bobot output gate  
 $ht_{-1}$  = output timestep 1  
 $xt$  = timestep terkini  
 $bo$  = bobot bias output gate

## 2. Extreme Learning Machine(ELM)

Extreme Learning Machine(ELM) merupakan salah satu jenis jaringan syaraf tiruan dengan satu lapisan tersembunyi yang disebut dengan single hidden layer feedforward neural network (SLFN). Metode ini memiliki kecepatan pembelajaran yang lebih baik jika dibandingkan dengan metode jaringan syaraf tiruan konvensional. Parameter dari input weight dan hidden bias dilakukan dengan acak dari hal tersebut algoritma ELM dapat memiliki kelebihan dalam learning speed yang sangat tinggi dan menghasilkan kinerja generalisasi yang baik karena dapat menghasilkan output dengan hasil benar pada input yang belum pernah dimasukkan dalam proses pelatihan [9].

ELM memiliki 3 bagian dalam arsitekturnya yaitu input layer, hidden layer dan output layer. ELM sendiri terdiri dari 2 tahap pengerjaan dengan rumus yang berbeda yaitu tahap training dan tahap testing. Arsitektur ELM dapat dilihat pada Gambar 2.



Gambar 2 Arsitektur ELM

Tahap Training meliputi inisialisasi bobot input weight ( $W$ ) dengan rentang -1 hingga 1, tentukan juga nilai bias dengan rentang 0 hingga 1 secara acak. Berikutnya hitung matriks keluaran ( $H_{init}$ ) pada hidden layer dengan rumus pada persamaan 8 [10].

$$H_{init} = X_{training} \cdot W^T + bias \quad (8)$$

Keterangan:

$H_{init}$  = matriks keluaran  
 $X_{training}$  = matriks nilai data training  
 $W^T$  = matriks transpose dari input weight  
 $bias$  = nilai bias

Menghitung keluaran hidden layer ( $H$ ) Proses perhitungan ini dilakukan dengan memakai fungsi aktivasi dari nilai  $H_{init}$  sebelumnya. Rumus menghitung keluaran hidden layer dapat dilihat pada persamaan 9[10].

$$H = \frac{1}{1 + \exp(-H_{init})} \quad (9)$$

Keterangan:

$H$  = matriks keluaran hidden layer  
 $\exp$  = Basis untuk bilangan euler dengan angka pembulatan 2,71828183  
 $H_{init}$  = matriks keluaran

Menghitung matriks Moore-Penrose Generalized Inverse ( $H^+$ ), rumus dapat dilihat pada persamaan 10 [10].

$$H^+ = (H^T \cdot H)_{-1} \cdot H^T \quad (10)$$

Keterangan:

$H^+$  = matriks Moore-Penrose Generalized Inverse  
 $H^T$  = matriks transposisi nilai  $H$   
 $(H^T \cdot H)_{-1}$  = Inversi dari perkalian matriks transposisi  $H$  dengan  $H$

Menghitung output weight dengan rumus pada persamaan 11 [10].

$$\beta = H^+ \cdot Y \quad (11)$$

Keterangan:

$\beta$  = matriks output weight pada hidden layer  
 $H^+$  = matriks Moore-Penrose Generalized Inverse  
 $Y$  = matriks target

Lalu setelah melakukan tahap training, berikutnya dilakukan tahap testing. Pertama menyimpan nilai input weight ( $W$ ),  $bias$ , dan matriks output weight ( $\beta$ ) dari hasil proses training data dan menghitung nilai  $H_{init}$  dengan rumus pada persamaan 12 [10].

$$H_{init} = X_{testing} \cdot W^T + bias \quad (12)$$

Keterangan:

$H_{init}$  = matriks keluaran  
 $X_{testing}$  = matriks nilai data testing  
 $W^T$  = matriks transpose dari input weight  
 $bias$  = nilai bias

Menghitung keluaran hidden layer ( $H$ ). Nilai  $H$  testing didapatkan dari perhitungan  $H_{init}$  sebelumnya. Rumus dapat dilihat pada persamaan 13 [10].

$$H = \frac{1}{1 + \exp(-H_{init})} \quad (13)$$

Keterangan:

$H$  = matriks keluaran hidden layer  
 $\exp$  = Basis untuk bilangan euler dengan angka pembulatan 2,71828183  
 $H_{init}$  = matriks keluaran

Menghitung hasil prediksi ( $Y$ ) dengan rumus pada persamaan 14 [10].

$$Y = H \cdot \beta \quad (14)$$

Keterangan:

$Y$  = matriks hasil prediksi  
 $H$  = matriks keluaran hidden layer  
 $\beta$  = matriks output weight pada hidden layer

## 2.5 Evaluasi

Terakhir hasil prediksi akan dievaluasi menggunakan MAE, MAPE, MSE, RMSE dan dilihat tingkat keragaman datanya menggunakan CV. Mean Absolute Error (MAE) merupakan perhitungan evaluasi untuk mendapatkan nilai absolut dari menghitung selisih antara nilai prediksi dengan data aktual [11]. Mean Absolute Percentage Error (MAPE) adalah proses untuk mengevaluasi nilai yang bertujuan untuk mengetahui suatu nilai error dari proses uji atau testing dengan cara mencari kesalahan absolut pada tiap periode dengan melihat selisih antara nilai hasil aktual dengan nilai hasil prediksi yang dilakukan dalam bentuk persentase [10]. Mean Square Error (MSE) adalah perhitungan nilai penjumlahan kuadrat error berdasarkan selisih antara nilai aktual dan nilai prediksi yang kemudian dibagi dengan jumlah waktu peramalan [12]. Root Mean Square Error (RMSE) adalah akar dari perhitungan nilai kuadrat error (MSE) berdasarkan selisih antara nilai aktual dan

nilai prediksi, kemudian dibagi dengan banyaknya waktu peramalan [12]. Koefisien variasi adalah suatu distribusi probabilitas yang dinormalkan persebarannya. Semakin kecil nilai koefisien variasinya maka tingkat risiko harga yang dihadapi juga semakin rendah [13].

## 3. Hasil Percobaan

Penelitian yang dilakukan menggunakan tools google colab dan bahasa pemrograman yang digunakan adalah Python. Menggunakan 2 metode yaitu LSTM dan ELM, data yang digunakan meliputi 6 macam komoditas pangan yaitu beras, daging ayam, telur ayam, bawang merah, bawang putih dan cabai merah dengan dataset harian sebanyak 2158 hari.

Mula-mula data yang ada dilakukan pra prosesi data dengan mengatasi missing value yang ada, kemudian data yang telah siap digunakan akan dinormalisasi untuk menyederhanakan nilai agar membuat perhitungan menjadi lebih mudah. Kemudian data dibagi menjadi 80% data latih dan 20% data uji.

Pada percobaan LSTM, model terdiri dari 3 layer dan menggunakan aktivasi sigmoid.

Table 1 Konfigurasi Model LSTM

Percobaan	Layer 1	Layer 2	Layer 3	Epoch
Ke-1	16	8	4	10
Ke-2	16	8	4	25
Ke-3	32	16	8	10
Ke-4	32	16	8	25

Pada percobaan ELM digunakan konfigurasi banyak neuron pada hidden layer yang berbeda, bias acak dan menggunakan fungsi aktivasi sigmoid.

Table 2 Konfigurasi Model ELM

Percobaan	Banyak Neuron
Ke-1	3
Ke-2	5
Ke-3	10
Ke-4	15

Berikut adalah hasil evaluasi percobaan ke-1 hingga percobaan ke-4 tiap komoditas dari algoritma LSTM dan ELM.

Table 3 Evaluasi Prediksi Harga Beras

Percobaan	Evaluasi	LSTM	ELM
Ke-1	MAE	299.334	209.906
	MAPE	2.636%	1.870%
	MSE	225030.117	86640.341
	RMSE	474.373	294.347
	CV	3.655%	3.70%
Ke-2	MAE	11.098	219.093
	MAPE	0.097%	2.026%
	MSE	1116.696	83853.702
	RMSE	33.417	289.575
	CV	3.655%	3.70%
Ke-3	MAE	266.795	92.215

	MAPE	2.338%	0.816%
	MSE	202824.604	19183.759
	RMSE	450.361	138.505
	CV	3.655%	3.70%
Ke-4	MAE	31.707	24.656
	MAPE	0.285%	0.227%
	MSE	1927.633	1574.964
	RMSE	43.905	39.686
	CV	3.655%	3.70%

Table 4 Evaluasi Prediksi Harga Daging Ayam

Percobaan	Evaluasi	LSTM	ELM
Ke-1	MAE	3207.555	5149.268
	MAPE	8.983%	14.701%
	MSE	13719696.164	33085294.739
	RMSE	3704.011	5751.982
	CV	6.013%	6.062%
Ke-2	MAE	362.950	2436.752
	MAPE	1.042%	6.891%
	MSE	358394.124	8575973.379
	RMSE	598.660	2928.476
	CV	6.013%	6.062%
Ke-3	MAE	3092.492	131.577
	MAPE	8.660%	0.382%
	MSE	12773916.087	27097.012
	RMSE	3574.062	164.612
	CV	6.013%	6.062%
Ke-4	MAE	386.256	154.290
	MAPE	1.101%	0.443%
	MSE	397967.980	40853.235
	RMSE	630.847	202.122
	CV	6.013%	6.062%

Table 5 Evaluasi Prediksi Harga Telur Ayam

Percobaan	Evaluasi	LSTM	ELM
Ke-1	MAE	2824.707	1599.594
	MAPE	10.751%	6.016%
	MSE	10290171.396	3362579.333
	RMSE	3207.830	1833.734
	CV	10.409%	10.386%
Ke-2	MAE	235.265	520.211
	MAPE	0.931%	1.962%
	MSE	84381.958	431351.793
	RMSE	290.486	656.774
	CV	10.409%	10.386%
Ke-3	MAE	2629.242	92.323
	MAPE	10.108%	0.348%
	MSE	8976147.827	25659.683
	RMSE	2996.022	160.186
	CV	10.409%	10.386%
Ke-4	MAE	213.137	143.497
	MAPE	0.846%	0.538%
	MSE	72149.637	64461.307
	RMSE	268.607	253.892
	CV	10.409%	10.386%

Table 6 Evaluasi Prediksi Harga Bawang Merah

Percobaan	Evaluasi	LSTM	ELM
-----------	----------	------	-----

Ke-1	MAE	6582.541	6997.186
	MAPE	15.467%	16.395%
	MSE	109546617.711	125159231.41
	RMSE	10466.452	11187.459
	CV	26.109%	26.092%
Ke-2	MAE	794.228	2657.063
	MAPE	1.90%	6.889%
	MSE	2533906.399	13282634.055
	RMSE	1591.825	3644.535
	CV	26.109%	26.092%
Ke-3	MAE	6738.067	574.634
	MAPE	15.920%	1.507%
	MSE	110982505.003	700162.523
	RMSE	10534.823	836.757
	CV	26.109%	26.092%
Ke-4	MAE	637.325	252.317
	MAPE	1.486%	0.566%
	MSE	1799952.186	301230.839
	RMSE	1341.623	548.845
	CV	26.109%	26.092%

Table 7 Evaluasi Prediksi Harga Bawang Putih

Percobaan	Evaluasi	LSTM	ELM
Ke-1	MAE	4849.604	5084.958
	MAPE	18.068%	19.157%
	MSE	25131360.516	35591425.412
	RMSE	5013.118	5965.854
	CV	7.793%	7.920%
Ke-2	MAE	786.222	2505.228
	MAPE	2.829%	9.277%
	MSE	937163.170	8600076.558
	RMSE	968.072	2932.589
	CV	7.793%	7.920%
Ke-3	MAE	5520.0178	1684.163
	MAPE	20.583%	6.222%
	MSE	32139243.069	5824855.081
	RMSE	5669.148	2413.474
	CV	7.793%	7.920%
Ke-4	MAE	470.533	1098.082
	MAPE	1.716%	4.071%
	MSE	603125.237	2105906.251
	RMSE	776.611	1451.174
	CV	7.793%	7.920%

Table 8 Evaluasi Prediksi Harga Cabai Merah

Percobaan	Evaluasi	LSTM	ELM
Ke-1	MAE	13402.672	15173.983
	MAPE	19.952%	22.686%
	MSE	411127786.692	516821314.15
	RMSE	20276.286	22733.704
	CV	35.285%	35.251%
Ke-2	MAE	1356.047	16952.335
	MAPE	2.338%	25.049%
	MSE	6040586.348	668283671.88
	RMSE	2457.760	25851.183
	CV	35.285%	35.251%
Ke-3	MAE	11183.878	19898.887
	MAPE	16.770%	28.841%

	MSE	287112350.721	1031332101.6
	RMSE	16944.390	32114.360
	CV	35.285%	35.251%
Ke-4	MAE	1266.957	19786.539
	MAPE	2.160%	29.163%
	MSE	5793328.927	1089482495.6
	RMSE	2406.934	33007.310
	CV	35.285%	35.251%

Dapat dilihat bahwa pada percobaan terakhir rata-rata komoditas menghasilkan nilai evaluasi yang paling baik, hal ini menandakan bahwa semakin tinggi nilai pada konfigurasi model maka hasil yang didapatkan juga akan semakin baik. Pada LSTM, menambahkan nilai epoch sangat berpengaruh terhadap kualitas prediksi yang ada, sedangkan pada ELM, banyaknya neuron berpengaruh besar terhadap hasil prediksi.

#### 4. Kesimpulan

Berdasarkan beberapa percobaan yang dilakukan, dapat dilihat bahwa kedua algoritma dapat memperoleh hasil yang baik.

1. Pada LSTM, jumlah epoch terlihat sangat mempengaruhi hasil prediksi yang ada, terlihat bahwa menggunakan epoch yang lebih besar menghasilkan nilai evaluasi yang baik.
2. Pada ELM terlihat bahwa jumlah neuron yang semakin banyak menghasilkan prediksi yang lebih baik, hampir setiap prediksi harga komoditas mendapat hasil evaluasi yang baik.
3. Kedua algoritma menghasilkan prediksi dan evaluasi yang sama-sama baik, pada beberapa kondisi hasil evaluasi dari LSTM lebih baik dan kadang sebaliknya. Namun hasil prediksi dari kedua algoritma tergolong baik, bahkan hasil MAPE bisa mencapai nilai dibawah 1%.grafik

#### REFERENSI

- [1] International Labour Office (Geneva), 1976, "Employment, growth, and basic needs : a one-world problem : report of the Director-General of the International Labour Office", Geneva : International Labour Office.
- [2] Kementerian Pertahanan Republik Indonesia, Undang-Undang Republik Indonesia Nomor 18 Tahun 2018 Tentang Pangan, <https://www.kemhan.go.id/ppid/wp-content/uploads/sites/2/2016/09/uu18-2012bt.pdf>.
- [3] Badan Pusat Statistik Provinsi Jawa Barat, 2023, "Persentase Penduduk Miskin (Persen)", 2020-2022, <https://jabar.bps.go.id/indicator/23/51/1/persentase-penduduk-miskin.html>.
- [4] Triyanna Widiyaningtyas, Ilham Ari Elbaith Zaeni, Tyas Ismi Zahrani, 2020, "Food Commodity Price Prediction in East Java Using Extreme Learning Machine (ELM) Method", [https://www.researchgate.net/publication/346423292\\_Foo](https://www.researchgate.net/publication/346423292_Foo)

- d\_Commodity\_Price\_Prediction\_in\_East\_Java\_Using\_Extreme\_Learning\_Machine\_ELM\_Method/.
- [5] Teny Handhayani, 2023, "An integrated analysis of air pollution and meteorological conditions in Jakarta", <https://www.nature.com/articles/s41598-023-32817-9>.
- [6] Kristoko Dwi Hartomo, 2006, "Implementasi Metode Interpolasi Linear untuk Pembesaran Resolusi Citra", TEKNOIN, Vol. 11, No.3.
- [7] Inggih Permana, Febi Nur Salisah, 2022, "Pengaruh Normalisasi Data Terhadap Performa Hasil Klasifikasi Algoritma Backpropagation", Indonesian Journal of Informatic Research and Software Engineering (IJIRSE), Vol. 2. No.1.
- [8] Rizki Trisna Rully Abadi, dan Irwan Budi, 2021, "Penerapan metode long short term memory dalam memprediksi jumlah kasus covid-19", <http://etheses.uin-malang.ac.id/32662/>.
- [9] Guang-Bin Huang, Qin-Yu Zhu, Chee-Kheong Siew, 2006, "Extreme learning machine: Theory and applications", Neurocomputing, Vol.70, No.1-3.
- [10] Galih Ariwanda, 2019, "Prediksi Harga Cabai Rawit di Kota Malang Menggunakan Algoritme Extreme Learning Machine (ELM)", Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 3, No. 6.
- [11] Agus Sulaiman, Asep Juarna, 2021, "Peramalan Tingkat Pengangguran di Indonesia Menggunakan Metode Time Series dengan Model Arima dan Holt-Winters", Jurnal Ilmiah Informatika Komputer, Vol. 26, No. 1.
- [12] Haldi Budiman, 2016, "Analisis dan Perbandingan Akurasi Model Prediksi Rentet Waktu Support Vector Machines dengan Support Vector Machines Particle Swarm Optimization untuk Arus Lalu Lintas Jangka Pendek", Information System and Informatics Journal (SYSTEMIC), Vol.2, No.1.
- [13] Adi Setiawan, 2012, "Perbandingan Koefisien Variasi Antara 2 Sampel dengan Metode Bootstrap", d'CARTESIAN:Jurnal Matematika dan Aplikasi, Vol. 1 No. 1.

**Andry Winata**, mahasiswa teknik informatika semester 8 dari Universitas Tarumanagara, Indonesia.