

Penerapan *Extreme Learning Machine* (ELM) untuk Meramalkan Laju Inflasi di Indonesia

Muhammad Fahmuddin S¹, Suwardi Annas², Nur Ismi³

Program Studi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Makassar, Indonesia

Keywords: ANN, ELM, Forecasting, Inflation, SLFNs, Time Series.

Abstract:

Inflation is a tendency to increase prices of goods and services in general which takes place continuously. Artificial neural network (ANN) is an information processing model that is almost the same as the workings of a living thing's memory system, such as the process of transferring information in the brain. Forecasting is an activity to determine future events based on past data. Time series is a series of observational data that occurs based on the time index sequentially with the right time span. The data used in this research is monthly inflation data in Indonesia. Extreme Learning Machine (ELM) is a method on artificial neural networks that uses a single hidden layer feedforward neural networks (SLFNs) architecture. The advantages of ELM compared to conventional learning algorithms are learning speed, better generalization performance, and much simpler implementation. Based on the analysis that has been carried out using the Extreme Learning Machine (ELM) method, obtaining an error value RMSE of 0,1992215.

1. Pendahuluan

Extreme Learning Machine (ELM) diperkenalkan oleh Huang Guang Bin, Zhu, dan Siew pada tahun 2006 dalam penelitiannya yang berjudul *Extreme Learning Machine :Theory and applications*. Secara teori, proses pembelajaran jaringan menggunakan ELM membutuhkan waktu relatif singkat (Dewi, 2018). Metode *Extreme Learning Machine* (ELM) adalah metode pada jaringan saraf tiruan yang menggunakan arsitektur *single hidden layer feedforward neural networks* (SLFNs). Metode ELM memiliki keunggulan pada *learning speed* sehingga mampu digunakan untuk mengatasi permasalahan dalam peramalan (Huang dkk.,2006).

Inflasi adalah kecenderungan naiknya harga barang dan jasa pada umumnya yang berlangsung secara terus menerus. Jika harga barang dan jasa di dalam negeri meningkat maka inflasi mengalami kenaikan, sedangkan jika harga barang dan jasa turun, maka inflasi mengalami penurunan. Naiknya harga barang dan jasa tersebut menyebabkan turunnya nilai uang. Inflasi dapat juga diartikan sebagai penurunan nilai uang terhadap nilai barang dan jasa secara umum (Badan Pusat Statistik, 2022).

* Corresponding author.

E-mail address: suwardi_annas@unm.ac.id



This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License.

Laju inflasi yang tinggi menggambarkan besarnya kemungkinan nilai mata uang, tingkat produksi, distribusi dan arah perkembangan ekonomi sehingga dapat menimbulkan ekspektasi keliru dan manipulasi yang dapat mempengaruhi perekonomian secara keseluruhan. Sebaliknya inflasi yang rendah juga tidak menguntungkan perekonomian karena menggambarkan rendahnya daya beli dan permintaan akan barang dan jasa yang pada dasarnya memperlambat pertumbuhan ekonomi (Grahadian Saukat, 2020).

2. Tinjauan Pustaka

2.1 Peramalan

Peramalan merupakan suatu teknik yang memperkirakan suatu nilai pada masa yang akan datang dengan memperhatikan data masa lalu maupun data saat ini. Peramalan merupakan bagian integral dalam pengambilan keputusan sebab efektif atau tidaknya suatu keputusan umumnya bergantung pada beberapa faktor yang tidak dapat dilihat pada waktu keputusan itu diambil (Aswi & Sukarna, 2006). Berdasarkan metode pendekatannya, peramalan dibagi menjadi 2 yaitu metode kualitatif dan metode kuantitatif. Metode peramalan kualitatif menggunakan penggabungan beberapa faktor pada variabel seperti intuisi, emosi, pengalaman, dan sistem penilaian pengambilan keputusan untuk mendapatkan hasil peramalan. Metode peramalan kuantitatif menggunakan model matematis yang beragam dengan bergantung pada data historis dan variabel sebab akibat untuk meramalkan suatu kejadian atau permintaan.

2.2 Analisis Deret Waktu

Deret waktu merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan rentang waktu yang tepat, sedangkan analisis Deret waktu adalah salah satu tahapan statistika yang diterapkan untuk meramalkan struktur probabilistik keadaan yang terjadi di masa yang akan datang dalam rangka pengambilan keputusan (Aswi & Sukarna, 2006). Suatu urutan pengamatan dikatakan memiliki model deret waktu jika memenuhi dua syarat berikut:

1. Interval waktu antar indeks waktu t dapat dinyatakan dalam satuan waktu yang sama (identik).
2. Adanya ketergantungan antara pengamatan Z_t dengan Z_{t+k} yang dipisahkan oleh jarak waktu berupa kelipatan Δ_t sebanyak k kali (dinyatakan sebagai *lag k*).

Hal ini sesuai dengan tujuan analisis deret waktu yaitu meramalkan kondisi di masa yang akan datang (*forecasting*), mengetahui hubungan antarpeubah, dan kepentingan kontrol (untuk mengetahui apakah proses terkendali atau tidak).

2.3 Jaringan Saraf Tiruan

Jaringan saraf tiruan (*Artificial Neural Network*) adalah salah satu bagian dari kecerdasan buatan (*Artificial Intelligence*) (Siwi, 2016). Jaringan saraf tiruan (JST) adalah suatu model pemrosesan informasi yang hampir sama dengan cara kerja sistem ingatan makhluk hidup, seperti proses transfer informasi di dalam otak (Ashar dkk., 2018). Menurut Anwar dalam kutipan buku Puspitaningrum, mengatakan bahwa lapisan dalam jaringan saraf tiruan dibagi menjadi tiga bagian, antara lain sebagai berikut (Anwar, 2020).

- a. *Input Layer* (Lapisan *Input*) *node* dalam lapisan *input* disebut sebagai unit *input*. Pada lapisan ini diisikan sebuah gambaran masalah yang dapat berupa parameter, bobot, ataupun arah aliran data dalam sebuah proses.
- b. *Hidden Layer* (Lapisan Tersembunyi) *node* dalam lapisan tersembunyi disebut sebagai unit tersembunyi. Lapisan ini merupakan penghubung antara lapisan *input* dan lapisan *output* yang bertugas untuk mengombinasikan masukan dari lapisan *input* berdasarkan bobot dan memberikan keluaran dari relasi yang terhubung dalam perhitungan untuk memberikan hasil keluaran pada lapisan berikutnya.
- c. *Output Layer* (Lapisan *Output*) *node* dalam lapisan *output* disebut sebagai unit *output*. Lapisan ini adalah hasil pemrosesan dari jaringan saraf tiruan terhadap suatu permasalahan.

2.4 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi yang menggambarkan hubungan antara tingkat aktivasi internal (*summation function*) yang mungkin berbentuk *linier* atau *nonlinier*. Fungsi aktivasi digunakan untuk menentukan *output* suatu *neuron*. Dalam penelitian ini, digunakan fungsi aktivasi *sigmoid biner* karena memiliki nilai pada *range* 0 sampai 1, mudah diturunkan, *kontinue*, dan merupakan fungsi yang tidak turun. Fungsi ini juga dapat digunakan oleh jaringan syaraf yang nilai *ouputnya* 0 atau 1 (Ardilla, 2016) Fungsi *sigmoid biner* dirumuskan sebagai berikut.


$$f(x) = \frac{1}{1+\exp(-x)} \quad (2.1)$$

$$f'(x) = f(x)[1 - f(x)] \quad (2.2)$$

2.5 Extreme Learning Machine (ELM)

Extreme Learning Machine (ELM) diperkenalkan oleh (Huang, Zhu, & Siew, 2006). ELM merupakan metode pengembangan dari jaringan syaraf tiruan *feedforward* sederhana dengan menggunakan satu *hidden layer* atau biasa dikenal dengan *Single Hidden Layer Feedforward Neural Networks* (SLFNs) (Huang dkk., 2006). Jaringan *feedforward* menggunakan parameter yang ditentukan secara manual seperti *input weight* dan bias. *Input weight* dan bias ini dibangkitkan secara acak dalam suatu rentang -1 hingga 1 . Nilai yang diacak tersebut, bisa menghindari hasil peramalan yang tidak stabil (Giusti dkk., 2018).

Algoritma ELM tidak melatih bobot masukan dan bias, namun ELM melatih untuk memperoleh bobot keluarannya dengan menerapkan metode *least square* dan *moore-penrose inverse* pada sistemnya. Parameter seperti bobot masukan dan bias dipilih secara *random*, sehingga ELM memiliki kecepatan pembelajaran yang baik dan mampu menghasilkan performa yang baik (Jannah dkk., 2020). Berikut adalah struktur *Extreme Learning Machine* (ELM).



Gambar 1 Struktur metode *Extreme Learning Machine* (ELM)

Sumber: (Giusti dkk., 2018)

2.5.1 Normalisasi Data

Normalisasi data bertujuan untuk merubah nilai data agar memiliki *range* yang sama yaitu 0-1 (Giusti dkk., 2018). Normalisasi dapat dihitung menggunakan Persamaan berikut ini (Phiadelvira dkk., 2022).

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (2.3)$$

Keterangan;

X_n = nilai dari hasil normalisasi data

- X_i = nilai data asli
 X_{min} = nilai minimum data
 X_{max} = nilai maksimum data

2.5.2 Proses Training

Proses *training* harus dilalui sebelum melakukan proses prediksi. Proses *training* bertujuan untuk mendapatkan nilai *output weight* dengan laju kesalahan yang rendah (Hendriansa, 2019). Langkah-langkah proses *training* adalah sebagai berikut (Sulton, 2019).

1. Menentukan nilai *input weight* dan bias diinisialisasi secara acak dengan *range* antara -1 hingga 1, sedangkan nilai bias dengan *range* 0 hingga 1.
2. Menghitung matriks keluaran *hidden layer* (H_{init}) menggunakan persamaan berikut ini:

$$H_{init} = X_{Training} \times W^T + b \quad (2.4)$$

Keterangan :

H_{init} = Matriks keluaran *hidden layer*

$X_{Training}$ = *Input* data yang digunakan

W^T = *Input weight transpose*

b = Nilai bias

3. Menghitung hasil matriks H_{init} dengan menggunakan fungsi aktivasi *sigmoid biner*. Berikut adalah persamaannya :

$$H_{exp} = \frac{1}{1 + \exp(H_{init})} \quad (2.5)$$

Keterangan :

H_{exp} = Matriks keluaran *hidden layer* dengan fungsi aktivasi *sigmoid biner*

H_{init} = Matriks keluaran *hidden layer*

Exp = Nilai *exponential* 2.71828183

4. Menghitung matriks H^+ *pseudo-inverse* dengan *moore-penrose* menggunakan persamaan di bawah ini :

$$H^+ = (H^T \times H_{exp})^{-1} \times H^T \quad (2.6)$$

Keterangan :

H^+ = Matriks keluaran *pseudo-inverse* dengan *moore-penrose*

H^T = Hasil transpose dari matriks H_{exp}

H_{exp} = Matriks keluaran *hidden layer* dengan fungsi aktivasi *sigmoid biner*

$(H^T \times H_{exp})^{-1}$ = Matriks *invers* hasil perkalian H^T dengan H_{exp}

5. Menghitung bobot keluaran dari *hidden layer* dengan persamaan berikut:

$$\hat{\beta} = H^+ \times Y \quad (2.7)$$

Keterangan :

$\hat{\beta}$ = Matriks *output weight*

H^+ = Matriks *moore-penrose*

Y = Hasil prediksi

2.5.3 Proses Testing

Proses *testing* dilakukan berdasarkan *input weight*, bias dan *output weight* yang sesuai dari perhitungan *training*. Proses *testing* bertujuan untuk mengevaluasi kemampuan ELM sebagai metode untuk memprediksi. Langkah-langkah yang dilakukan untuk proses *testing* menggunakan metode ELM adalah sebagai berikut. (Hendriansa, 2019)

1. Diketahui *input weight* dan bias dari proses *training*.

2. Menghitung matriks H_{init} Testing. Berikut persamaan untuk Menghitung matriks H_{init} :

$$H_{init} = X_{Testing} \times W^T + b \quad (2.8)$$

Keterangan :

H_{init} = Matriks keluaran *hidden layer*

$X_{Training}$ = Input data yang digunakan

W^T = input weight transpose

b = Nilai bias

3. Menghitung matriks keluaran *hidden layer* H_{exp} dengan menggunakan fungsi aktivasi *sigmoid biner*.

Berikut adalah persamaannya :

$$H_{exp} = \frac{1}{1 + \exp(H_{init})} \quad (2.9)$$

Keterangan :

H_{exp} = Matriks keluaran *hidden layer* dengan fungsi aktivasi *sigmoid biner*

H_{init} = Matriks keluaran *hidden layer*

Exp = Nilai *exponential* 2.71828183

4. Menghitung *output layer* hasil prediksi *testing*, dengan persamaan berikut:

$$\hat{Y} = H_{exp} \times \hat{\beta} \quad (2.10)$$

Keterangan :

$\hat{Y}$ = Output layer hasil prediksi *testing*

H_{exp} = Output *hidden layer* dengan fungsi aktivasi *sigmoid biner*

$\hat{\beta}$ = Nilai output weight training

2.5.4 Denormalisas

Denormalisasi berfungsi untuk mengembalikan nilai yang telah dinormalisasikan menjadi nilai asli (Phiadelvira dkk., 2022). Berikut adalah persamaan proses denormalisasi (Sulton, 2019).

$$X = (X'(X_{max} - X_{min})) + X_{min} \quad (2.11)$$

Keterangan :

X = Nilai prediksi sebelum didenormalisasi

X' = Nilai asli setelah didenormalisasi

X_{min} = Nilai minimum pada dataset

X_{max} = Nilai maksimal pada dataset

2.6 Root Mean Square Error (RMSE)

Root Mean Squared Error (RMSE) merupakan salah satu cara untuk mengevaluasi dengan mengukur tingkat akurasi hasil peramalan suatu model. Model yang menghasilkan nilai RMSE lebih rendah menunjukkan model yang lebih baik. Berikut adalah persamaan Root Mean Squared Error (RMSE) (Alfiyatin dkk., 2019).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_i) - (\hat{y}_i)^2}{n}} \quad (2.12)$$

Keterangan:

y_i = data aktual

$\hat{y}_i$ = hasil peramalan

i = urutan data pada database

n = jumlah data

3. Metode Penelitian

3.1 Jenis dan Sumber Data

Penelitian ini menggunakan data sekunder. Data sekunder merupakan data yang diperoleh dari sumber yang sudah ada. Data ini diperoleh dari publikasi pada *website* Bank Indonesia (BI) dari Januari 2012 – September 2022.

3.2 Definisi Operasional Variabel

Variabel yang digunakan pada penelitian ini adalah laju inflasi setiap bulannya di Indonesia periode Januari 2012 – Oktober 2022. Laju inflasi adalah persentase kenaikan harga barang dan jasa dari suatu periode ke periode selanjutnya secara terus menerus.

3.3 Teknik Analisis Data

Teknik analisis data yang akan dilakukan dalam penelitian ini adalah sebagai berikut:

1. Melakukan pengambilan data di situs *website* Bank Indonesia (BI).
2. Melakukan tahap normalisasi data yang bertujuan untuk menyesuaikan data masukan terhadap data keluaran.
3. Melakukan pembagian data *training* dan data *testing* sebagai masukan, *training:testing* sebesar 80:20, 70:30, 60:40.
4. Melakukan proses *Extreme Learning Machine* (ELM).
5. Melakukan peramalan dengan metode *Extreme Learning Machine* (ELM).
6. Melakukan proses denormalisasi untuk mengembalikan nilai yang telah dinormalisasi menjadi nilai asli.
7. Membuat interpretasi dan kesimpulan berdasarkan hasil pengolahan data.
8. Menyusun laporan hasil penelitian.

4. Hasil dan Pembahasan

4.1. Analisis Deskriptif

Penelitian ini dilakukan dengan menggunakan data inflasi setiap bulan di Indonesia yang dimulai dari januari 2012 sampai dengan oktober 2022 yaitu sebanyak 130 data. Data lengkap tentang data inflasi setiap bulannya di Indonesia dapat dilihat pada lampiran 1.

Gambar 2 Grafik Data Aktual Inflasi setiap Bulannya di Indonesia


Tabel 1 Analisis Deskriptif

	Minimum	Maksimum	Rata-rata	Standar Deviasi
Inflasi	1,32	8,79	4,11	1,93

Berdasarkan Tabel 1 data inflasi periode januari 2012 – oktober 2022 memiliki nilai minimum 1,32, nilai maksimum 8,79, nilai rata-rata 4,11, dan standar deviasi 1,93.

4.2 Hasil

Berikut ini
hasil
data inflasi
bulannya di
dengan
Studio




Peramalan

merupakan
peramalan
setiap
indonesia
program *R*

menggunakan metode *Extreme Learning Machine*.


Periode	Peramalan	Periode	Peramalan
November 2022	0,6041334	Desember 2023	0,4821124
Desember 2022	0,6573520	Januari 2024	0,4506218
Januari 2023	0,7222395	Februari 2024	0,4099723

Tabel 2	Februari 2023	0,8207524	Maret 2024	0,4421653	<i>Hasil</i>
	Maret 2023	0,8980326	April 2024	0,4605996	
	April 2023	0,9180077	Mei 2024	0,4900609	
	Mei 2023	0,9220914	Juni 2024	0,3393868	
	Juni 2023	0,8417363	Juli 2024	0,2831992	
	Juli 2023	0,8042815	Agustus 2024	0,4333825	
	Agustus 2023	0,7193064	September 2024	0,3719941	
	September 2023	0,6622465	Oktober 2024	0,5863857	
	Oktober 2023	0,6095947	November 2024	0,5153319	
	November 2023	0,5607732	Desember 2024	0,5178104	
<i>Peramalan</i>					



Gambar 3 Plot Hasil Peramalan Metode ELM

Terlihat pada sumbu x menunjukkan tahun pada data yang di tampilkan yaitu dari tahun 2012 sampai dengan tahun 2024, sedangkan pada sumbu y diketahui menunjukkan nilai hasil peramalan data inflasi setiap bulannya di Indonesia. Kurva berwarna hitam menggambarkan data aktual dan kurva berwarna biru menggambarkan hasil peramalan data inflasi.



Gambar 4 Plot Perbandingan Data Aktual, Fitted dan Peramalan

Pada Gambar 4 yang merupakan hasil plot dari perbandingan data aktual, data *fitted* dan data peramalan data inflasi setiap bulannya di Indonesia dengan metode *Extreme Learning Machine*. Terdapat sumbu x yang menjelaskan tentang tahun sedangkan pada sumbu y menjelaskan tentang nilai data. Pada plot di atas warna biru menunjukkan data aktual, warna merah menunjukkan data *fitted* dan warna hijau menunjukkan data hasil peramalan.

4.3 Denormalisasi

Analisis prediksi dengan menggunakan metode *Extreme Learning Machnie* setelah hasil peramalan telah di dapatkan maka selanjutnya adalah tahap denormalisasi. Denormalisasi berfungsi untuk mengembalikan nilai yang telah dinormalisasikan menjadi nilai asli. Berikut Tabel merupakan hasil dari denormalisasi hasil peramalan laju inflasi.

Tabel 4 Hasil Denormalisasi

Periode	Hasil	Periode	Hasil
November 2022	5,83	Desember 2023	4,92
Desember 2022	6,23	Januari 2024	4,68
Januari 2023	6,71	Februari 2024	4,38
Februari 2023	7,45	Maret 2024	4,62
Maret 2023	8,02	April 2024	4,76
April 2023	8,17	Mei 2024	4,98
Mei 2023	8,20	Juni 2024	3,85
Juni 2023	7,60	Juli 2024	3,43
Juli 2023	7,32	Agustus 2024	4,55
Agustus 2023	6,69	September 2024	4,09
September 2023	6,26	Oktober 2024	5,70
Oktober 2023	5,87	November 2024	5,16
November 2023	5,50	Desember 2024	5,18

4.4 Nilai Akurasi

nilai akurasi hasil peramalan dari analisis *Extreme Learning Machine* yang sudah dilakukan untuk mengetahui apakah analisis yang sudah dilakukan layak digunakan, dengan menggunakan program *R Studio* maka di dapatkan nilai *Road Mean Square Error* (RMSE) sebagai berikut.

Tabel 5 Nilai Akurasi

Parameter	Nilai
RMSE (80% : 20%)	0,1992215
RMSE (70% : 30%)	0,249786
RMSE (60% : 40%)	0,3851066

Berdasarkan pada Tabel 4.6 nilai RMSE dari perbandingan pembagian nilai training dan testing, dapat dilihat bahwa nilai terkecil berada pada pembagian training testing 80:20 yaitu sebesar 0,1992215.

5. Kesimpulan

Berdasarkan hasil yang diperoleh, maka dapat di tarik kesimpulan dari pengujian dan pembahasan peramalan laju inflasi setiap bulannya di Indonesia menggunakan metode *Extreme Learning Machine* (ELM) adalah sebagai berikut:

1. Data inflasi periode januari 2012 – oktober 2022 memiliki nilai minimum 1,32, nilai maksimal 8,79, nilai rata-rata (*mean*) 4,11 dan standar deviasi 1,93.
2. Hasil peramalan data inflasi setiap bulannya di Indonesia dengan menggunakan metode *Extreme Learning Machine* (ELM). Tahun 2023 mengalami kenaikan yang sangat signifikan pada bulan mei hingga menyentuh angka 8,20%, sedangkan pada tahun 2024 mengalami penurunan pada bulan juli yaitu 3,43%.

References

- Aditiya, B. A., Widiyanto, D., Falih, N., Komputer, F. I., Pembangunan, U., Veteran, N., & Tiruan, J. S. (2020). *Implementasi Metode Exrtreme Learning Machine (ELM) untuk Memprediksi Indeks Pembangunan Manusia*. 493–503.
- Alfiyatin, A. N., Mahmudy, W. F., Ananda, C. F., & Anggodo, Y. P. (2019). Penerapan Extreme Learning Machine (ELM) untuk Peramalan Laju Inflasi di Indonesia. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 6(2), 179.
- Anicic, O., Jović, S., Skrijelj, H., & Nedić, B. (2017). Prediction of laser cutting heat affected zone by extreme learning machine. *Optics and Lasers in Engineering*, 88, 1–4.
- Anwar, R. N. (2020). *Visualisasi Dashboard dan Peramalan Jumlah Kasus. X*.
- Ardilla, Y. (2016). *Metode Hibrida ARIMA dan Multilayer Perceptron untuk Peramalan Jangka Pendek Konsumsi Listrik di Jawa Timur*.
- Arifianty, A., Mulyono, M., & Irzal, M. (2017). Peramalan Indeks Harga Saham Gabungan (IHSG) dengan Metode Extreme Learning Machine (ELM). *JMT : Jurnal Matematika Dan Terapan*, 1(1), 22–32.
- Ashar, N. M., Cholissodin, I., & Dewi, C. (2018). *Penerapan Metode Extreme Learning Machine (ELM) Untuk Memprediksi Jumlah Produksi Pipa Yang Layak (Studi Kasus Pada PT . KHI Pipe Industries)*. 2(11), 4621–4628.
- Aswi & Sukarna. (2006). *Analisis Deret Waktu : Teori dan Aplikasi*.
- Atmadja, Adwin S., S. P. (1999). *INFLASI DI INDONESIA : 1*(1), 54–67.
- Badan pusBadan pusat statistik. (2022). pengertian Inflasi.
- Cholisa, F. nur. (2021). *prediksi penjualan minuman kopi menggunakan metode extreme learning machine (ELM)*.
- Dewi, E. A. (2018). *Perbandingan Metode Holt Winter's Exponentian Smoothing dan Extreme Learning Machine (ELM) pada Peramalan Penjualan Semen*. 3, 1–13.
- Fauziah, F., Ningsih, Y. I., & Setiarini, E. (2019). Analisis Peramalan (Forecasting) Penjualan Jasa Pada Warnet Bulian City di Muara Bulian. *Eksis: Jurnal Ilmiah Ekonomi Dan Bisnis*, 10(1), 61.

- Giusti, A., Widodo, A. W., & Adinugroho, S. (2018). Prediksi Penjualan Mi Menggunakan Metode Extreme Learning Machine (ELM) di Kober Mie Setan Cabang Soekarno Hatta. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 2(8), 2972–2978.
- Grahadian Saukat, S. (2020). Provinsi Kepulauan Riau. *Kompas Pedia*, 1–23.
- Hendriansa, B. (2019). *perancangan sistem informasi peramalan produksi apel di kota batu dengan metode extreme learning machine(ELM) (studi kasus di dinas pertanian kota batu)*.
- Huang, G. Bin, Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501.
- Irwin Dwi Agustina, Wiwik Anggraeni, S.Si, M.Kom, Ahmad Mukhlason, S.Kom, M, S. (2010). *Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan. Undergraduate Thesis, Information system, RSSI 519*.
- Jannah, R. (2020). *Implementasi metode extreme learning machine (elm) dalam klasifikasi tipe gangguan skizofrenia*.
- Nadio, K., Putra, D., Furqon, M. T., & Yudistira, N. (2020). Prediksi Penjualan Hijab menggunakan Metode Extreme Learning Machine (ELM) (Studi Kasus : Vie Hijab Store). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 4(6), 1750–1757.
- Pamungkas, M. B., & Wibowo, A. (2018). Aplikasi Metode Arima Box-. *The Indonesian Journal of Public Health*, 13, 181–194.
- Phiadelvira, B. Y., Haq, D. Z., Novitasari, D. C. R., & Setiawan, F. (2022). Prediksi Besar Daya Listrik Tenaga Gelombang Laut Metode Oscillating Water Coloumn (PLTGL-OWC) di Banyuwangi Menggunakan Extreme Learning Machine (ELM). *Unnes Journal of Mathematics*, 11(1), 1–7.
- Prayoga, Y., Tambunan, H. S., & Parlina, I. (2019). Penerapan Clustering Pada Laju Inflasi Kota Di Indonesia Dengan Algoritma K-Means. *BRAHMANA: Jurnal Penerapan Kecerdasan Buatan*, 1(1), 24–30.
- Ridha, M. (2019). *Inflasi dalam pandangan umur chapra tesis*.
- Siwi, I. P. (2016). *Peramalan Produksi Gula Pasir Menggunakan Extreme Learning Machine (Elm) Pada Pg Candi Baru Sidoarjo*.
- Sulton, A. I. (2019). Peramalan Produksi Padi di Kabupaten Lumajang Menggunakan Metode Extreme Learning Machine. *Seminar Informatika Aplikatif Polinema*, 1–6.
- Suriyani, N. K., & Sudiarta, G. M. (2018). Pengaruh Tingkat Suku Bunga, Inflasi Dan Nilai Tukar Terhadap Return Saham Di Bursa Efek Indonesia. *E-Jurnal*, 7(6), 3172–3200.
- Sutawijaya, A., & Zulfahmi, S. P. (1999). *Inflasi Di Indonesia : 1*(1), 54–67.
- Tiwari, M., Adamowski, J., & Adamowski, K. (2016). Water demand forecasting using extreme learning machines. *Journal of Water and Land Development*, 28(1), 37–52.
- Toto Syatori Nasehudin, N. G. (2012). *Metode Penelitian Kuantitatif*.
- Wanto, A., & Windarto, A. P. (2017). Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation. *Jurnal & Penelitian Teknik Informatika Sinkron*, 2(2), 37–43.
- Wuryandari, M. D., & Afrianto, I. (2012). Perbandingan Metode Jaringan Syaraf Tiruan Backpropagation Dan Learning Vector Quantization Pada Pengenalan Wajah. *Jurnal Komputer Dan Informatika*, 1(1), 45–51.