

Prediksi Inflasi di Kota Bandung Menggunakan Metode *Extreme Learning Machine* (ELM)

Hasan Al-Askary Kabalmay *, Marizsa Herlina

Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam,
Universitas Islam Bandung, Indonesia.

ytalaskary05@gmail.com, marizsaherlina@unisba.co.id

Abstract. This study aims to predict monthly inflation in Bandung City using the Extreme Learning Machine (ELM) method. Inflation, which is an indicator of economic stability, is important for predicting effective policy making. Data in the form of a time series of monthly inflation from January 2001 to March 2025 is used with a sliding window technique of 12 months of input and 1 month of output. The data is normalized and divided into 80% training data and 20% testing data. The best ELM model uses 23 Hidden Layer neurons with a coefficient of determination R^2 of 0.9415 in training and 0.7054 in testing. The prediction for the next three months shows inflation results of 6.62% in April 2025, 6.55% in May 2025 and 6.25% in June 2025. These results show that ELM is effective and efficient in modeling non-linear inflation patterns in Bandung City, providing an important reference for policymakers and economic actors.

Keywords: *Inflation, Prediction, Extreme Learning Machine.*

Abstrak. Penelitian ini bertujuan memprediksi inflasi bulanan di Kota Bandung menggunakan metode *Extreme Learning Machine* (ELM). Inflasi yang merupakan indikator kestabilan ekonomi menjadi penting untuk diprediksi demi pengambilan kebijakan yang efektif. Data berupa deret waktu inflasi bulanan Januari 2001 sampai Maret 2025 digunakan dengan teknik sliding window 12 bulan *input* dan 1 bulan *output*. Data dinormalisasi dan dibagi menjadi 80% data *training* dan 20% data *testing*. Model ELM terbaik menggunakan 23 neuron hidden layer dengan nilai koefisien determinasi R^2 sebesar 0,9415 pada *training* dan 0,7054 pada *testing*. Prediksi tiga bulan ke depan menunjukkan hasil inflasi 6.62% pada April 2025, 6.55% pada Mei 2025 dan 6.25% pada Juni 2025. Hasil ini menunjukkan ELM efektif dan efisien dalam memodelkan pola non-linear inflasi Kota Bandung, memberikan referensi penting bagi pembuat kebijakan dan pelaku ekonomi.

Kata Kunci: *Inflasi, Prediksi, Extreme Learning Machine.*

A. Pendahuluan

Inflasi merupakan indikator penting dalam menilai kestabilan ekonomi karena berpengaruh terhadap daya beli, biaya hidup, serta perencanaan usaha dan investasi (Gujarati & Porter, 2009). Kota Bandung sebagai pusat kegiatan ekonomi, pendidikan, dan pariwisata memiliki dinamika inflasi yang dipengaruhi oleh faktor internal dan eksternal, sehingga memerlukan model prediksi yang akurat (BPS Kota Bandung, 2025). Tingginya aktivitas perdagangan, konsumsi, pendidikan, serta pariwisata menjadikan Kota Bandung sebagai salah satu kota strategis yang memerlukan pengendalian inflasi yang tepat dan cepat (Swawikanti & Team, 2025). Beberapa faktor yang memengaruhi inflasi di kota ini antara lain fluktuasi harga pangan, distribusi logistik, kebijakan pemerintah daerah dan nasional, hingga momen musiman seperti Ramadan dan tahun ajaran baru.

Metode tradisional seperti ARIMA memiliki keterbatasan dalam menangani data non-linear, sehingga pendekatan Artificial Intelligence menjadi alternatif yang lebih adaptif (Beaumont et al., 1984). Artificial Neural Network (ANN) efektif memodelkan hubungan non-linear (Zhang et al., 1998), namun proses pelatihannya lambat karena bergantung pada backpropagation.

Machine learning sendiri didefinisikan sebagai kemampuan sistem untuk belajar dari data tanpa diprogram secara eksplisit (Mitchell, 1997). Extreme Learning Machine (ELM) hadir sebagai solusi dengan pelatihan lebih cepat tanpa iterasi dan lebih tahan terhadap overfitting, namun tetap kompetitif dalam akurasi (Huang et al., 2006). Dalam penelitian terdahulu, ELM juga terbukti efektif digunakan untuk peramalan inflasi di Indonesia dengan nilai error yang rendah sebesar 0.0202008 (Nur Alfiyatin et al., 2019). Selain itu, struktur data time series yang digunakan dalam ELM sangat cocok untuk menangkap pola-pola historis yang bersifat musiman atau tren jangka pendek (García et al., n.d.).

Dengan keunggulan tersebut, ELM menjadi metode yang potensial untuk diterapkan pada data inflasi Kota Bandung. Penelitian ini bertujuan untuk meramalkan inflasi di Kota Bandung dengan menggunakan Metode Extreme Learning Machine (ELM). Penelitian ini diharapkan dapat memberikan referensi akademis terkait penggunaan Metode Extreme Learning Machine (ELM) serta dapat memberikan informasi prediksi inflasi yang bermanfaat bagi pemerintah dan pelaku ekonomi dalam perencanaan kebijakan di Kota Bandung.

B. Metode

Penelitian ini menggunakan pendekatan deskriptif kuantitatif dengan metode analisis yang digunakan yaitu *extreme learning machine*. Tahapan analisis yang digunakan dalam penelitian ini yaitu:

Pengumpulan Data

Data Inflasi Kota Bandung pada Januari 2001 – Maret 2025 yang dikumpulkan dari situs BPS Jawa Barat. Dalam dataset terdapat 2 variabel (inflasi dan tanggal) yang berjumlah 291 baris data. Data diklasifikasikan sebagai data sekunder.

Preprocessing Data

Menurut (García et al., n.d.), proses *preprocessing* data mencakup sejumlah tahapan yang dilakukan sebelum penerapan teknik data mining. Tahapan ini meliputi pembersihan data dari kesalahan, pengubahan format data agar sesuai dengan kebutuhan analisis, serta penyesuaian struktur data untuk meningkatkan kualitas dan kemudahan dalam pengolahan dengan tujuan agar data menjadi lebih terstruktur dan siap digunakan, sehingga mendukung proses analisis yang lebih efektif dan menghasilkan output yang lebih akurat. *Preprocessing* pada analisis ini meliputi:

1. Pengecekan data hilang dan data duplikat, dimana hasilnya tidak terdapat data hilang ataupun data duplikat.
2. Normalisasi data menggunakan *Min-Max Normalization* bertujuan untuk mengubah nilai-nilai pada data menjadi ke dalam rentang 0 hingga 1 (Nur Alfiyatin et al., 2019). Proses ini dilakukan dengan menggunakan Persamaan 1.

$$x_{\text{normalisasi}} = \frac{x_i - \min(x)}{(\max(x) - \min(x))} \quad \dots (1)$$

Keterangan:

$X_{\text{normalisasi}}$	: Hasil normalisasi data x pada indeks ke-i
X_i	: Data indeks ke-i
$\min(x)$	: Data minimum pada data x
$\max(x)$	: Data maksimum pada data x

Menentukan Struktur Data

Pada penelitian ini digunakan 12 *neuron input* dan 1 *neuron output*.

Split Data

Proporsi yang digunakan pada penelitian ini yaitu 80:20, dimana 80% untuk data *training* dan 20% untuk data *testing*.

Menentukan Jumlah Neuron Hidden Layer

Pemilihan jumlah neuron dalam hidden layer mengacu pada prinsip bahwa semakin kompleks data, maka semakin besar kapasitas yang dibutuhkan untuk memetakan relasi non-linear, tanpa menyebabkan overfitting (Heaton, 2005). Proses ini dilakukan dengan cara mengulang proses training dengan jumlah *neuron hidden layer* dari 1-23, jumlah *neuron hidden layer* dipilih berdasarkan nilai *R-Squared* terbesar. Setelah dilakukan, jumlah *neuron hidden layer* terbaik yaitu sebanyak 23.

Proses Training

Proses *training* meliputi:

1. Menentukan matriks W berordo 23x223 dengan nilai acak.
2. Mentranspose W, kemudian menginisialisasi matriks output dari *hidden layer* menggunakan persamaan berikut.

$$\gamma = X * W^T \quad \dots (2)$$

Keterangan:

γ : Matriks inisialisasi

X : Matriks *input neuron*

W^T : Matriks *input weight* yang sudah di-transpose

3. Menghitung nilai keluaran dari *hidden layer* (H) menggunakan fungsi sigmoid.

$$H = \frac{1}{1 + \exp^{-\gamma}} \quad \dots (3)$$

Keterangan:

H : Matriks keluaran *hidden layer*

γ : *Input data matriks neuron* dari matriks inisialisasi

Kemudian matriks in digunakan untuk membentuk matriks H.

$$H = \begin{pmatrix} \frac{1}{1 + \exp^{-\gamma_{1,1}}} & \dots & \frac{1}{1 + \exp^{-\gamma_{1,n}}} \\ \vdots & \ddots & \vdots \\ \frac{1}{1 + \exp^{-\gamma_{m,1}}} & \dots & \frac{1}{1 + \exp^{-\gamma_{n,m}}} \end{pmatrix} \quad \dots (4)$$

4. Menghitung Matriks H^+ atau *Moore-Penrose Generalized Invers*.

$$H^+ = (H^T H)^{-1} H^T \quad \dots (5)$$

Keterangan:

H^+ : Matriks Moore-Penrose Generalized Invers.

H : Matriks keluaran hidden layer.

H^T : Matriks keluaran hidden layer setelah di-transpose.

5. Menghitung bobot output atau β .

$$\beta = H^+ y \quad \dots (6)$$

Keterangan:

β : Matriks bobot output (keluaran) weight.

H^+ : Matriks Moore-Penrose Generalized Invers.

y : Vektor target.

Vektor target (y) berukuran n (jumlah *neuron input*) x 1.

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \cdot \\ y_n \end{bmatrix}$$

6. Menghitung hasil prediksi pada *training*.

$$Y = H\beta \quad \dots (7)$$

Keterangan:

Y : Hasil prediksi atau output.

H : Matriks keluaran hidden layer.

β : Matriks bobot *output* (keluaran) weight.

Hasil prediksi (Y) berukuran n (jumlah *neuron input*) $\times$ 1, dan matriks bobot (β) *output* berukuran m (jumlah *neuron hidden layer*) $\times$ 1.

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ Y_n \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \cdot \\ \beta_m \end{bmatrix}$$

7. Denormalisasi data prediksi *training*.

$$\text{denormalisasi} = \text{xnormalisasi} * (\max(x) - \min(x)) + \min(x) \quad \dots (8)$$

Keterangan:

$x_{\text{denormalisasi}}$: Hasil denormalisasi data x pada indeks ke- i

$x_{\text{normalisasi}}$: Hasil normalisasi data x pada indeks ke- i

$\min(x)$: Data minimum pada data x

$\max(x)$: Data maksimum pada data x

8. Menghitung *R-Squared* pada proses *training*.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \dots (9)$$

Keterangan:

y_i : nilai aktual pada data ke- i

$\hat{y}_i$: nilai prediksi pada data ke- i

$\bar{y}$: nilai rata-rata dari seluruh data aktual

n : jumlah total observasi

Proses *Testing*

Proses *testing* meliputi:

1. Menggunakan matriks bobot input (W) yang telah diperoleh dari hasil *training*.
2. Menginisialisasi matriks *output* dari *hidden layer* menggunakan Persamaan 2.
3. Menghitung nilai keluaran dari *hidden layer* (H) menggunakan Persamaan 3.
4. Menghitung hasil prediksi pada *testing* menggunakan Persamaan 7.
5. Denormalisasi data prediksi *testing* menggunakan Persamaan 8.
6. Menghitung *R-Squared* pada proses *testing* menggunakan Persamaan 9.

Peramalan 3 Bulan ke Depan

Setelah diperoleh model ELM terbaik dengan jumlah neuron hidden layer dan performa evaluasi yang baik pada data training maupun testing, model tersebut kemudian digunakan untuk melakukan peramalan inflasi tiga bulan ke depan. Peramalan ini dilakukan secara recursive, artinya hasil prediksi pada bulan ke- $t+1$ akan digunakan sebagai input untuk memprediksi bulan ke- $t+2$, dan seterusnya. Input awal berupa 12 bulan inflasi terakhir dari data historis yang telah digunakan untuk proses training dan testing. Seluruh data input diformulasikan dalam bentuk yang telah dinormalisasi, kemudian hasil prediksi dalam skala normalisasi dikembalikan ke skala asli (persen inflasi) melalui proses denormalisasi.

C. Hasil Penelitian dan Pembahasan

Analisis Deskriptif

Pada deskripsi data ini penulis mendeskripsikan nilai inflasi di Kota Bandung.

Tabel 1. Deskripsi Data

Jumlah Data	Jumlah Nilai	Rata-rata	Maksimum	Minimum	Standar Deviasi
291	1680,43	5,77467354	20,29	-0,5	4,031191081

Berdasarkan tersebut, didapat jumlah data inflasi di Kota Bandung sebanyak 291, dengan jumlah nilai 1680.43, rata-ratanya sebesar 5.77, nilai tertinggi inflasinya sebesar 20.29, nilai terendah inflasi sebesar -0.5, dan standar deviasinya sebesar 4.03.



Gambar 1. Plot Data Inflasi Kota Bandung

Berdasarkan plot di atas, laju inflasi Kota Bandung mengalami lonjakan tajam pada tahun 2005–2006 dan 2008, kemungkinan akibat kenaikan harga BBM dan krisis global. Inflasi kembali meningkat pada 2022 saat pemulihan pasca pandemi COVID-19, lalu menurun lagi di akhir 2024.

Preprocessing Data

Data terlebih dahulu diperiksa keberadaan nilai hilang (*missing value*) dan data duplikat. Hasil pengecekan menunjukkan bahwa tidak terdapat nilai hilang maupun data duplikat. Selanjutnya, normalisasi diterapkan untuk mengubah skala nilai ke dalam rentang $[0,1]$ dengan menggunakan Persamaan 1. Data yang telah dinormalisasikan kemudian dirubah menjadi data *time series*, pada penelitian ini menggunakan 12 *input* sebagai *input neuron*. Struktur data dapat dilihat pada Tabel 2, dimana $X_1 - X_{12}$ merupakan *input neuron* sedangkan X_{13} sebagai *output/target*.

Tabel 2. Struktur Data ELM dalam Bentuk *Time Series*

Urutan ke-	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	Output/Target (X_{13})
	X_{t-12}	X_{t-11}	X_{t-10}	X_{t-9}	X_{t-8}	X_{t-7}	X_{t-6}	X_{t-5}	X_{t-4}	X_{t-3}	X_{t-2}	X_{t-1}	
1	0,350649	0,42809	0,52381	0,546417	0,531987	0,574796	0,621453	0,599327	0,553151	0,580568	0,610871	0,596922	0,787398
2	0,42809	0,52381	0,546417	0,531987	0,574796	0,621453	0,599327	0,553151	0,580568	0,610871	0,596922	0,787398	0,796056
3	0,52381	0,546417	0,531987	0,574796	0,621453	0,599327	0,553151	0,580568	0,610871	0,596922	0,787398	0,796056	0,713805
...	...	...	...	...	...	...	...	...	...	...	...	...	...
277	0,11544	0,117845	0,148148	0,140452	0,133237	0,12506	0,117364	0,126022	0,107263	0,103896	0,098124	0,101491	0,053391
278	0,117845	0,148148	0,140452	0,133237	0,12506	0,117364	0,126022	0,107263	0,103896	0,098124	0,101491	0,053391	0
279	0,148148	0,140452	0,133237	0,12506	0,117364	0,126022	0,107263	0,103896	0,098124	0,101491	0,053391	0	0,053872

Kemudian data tersebut di-split menjadi data untuk training dan testing. Pembagian ini yaitu 80% untuk data training mulai dari urutan ke-1 hingga ke-233, dan 20% untuk data testing mulai dari ke-234 hingga ke-291.

Menentukan Jumlah Neuron Hidden Layer

Pemilihan jumlah *neuron hidden layer* terbaik dilihat berdasarkan nilai *R-Squared* terbesar pada proses training dan tidak memiliki indikasi *underfitting* maupun *overfitting* yang dapat dilihat berdasarkan nilai *R-Squared* pada proses *training* dan *testing*. Semakin besar nilai *R-Squared* yang

diperoleh, maka nilai taksiran akan semakin mendekati nilai sebenarnya atau metode yang diperoleh merupakan metode terbaik. Hasil perhitungan nilai *R-Squared* pada setiap jumlah *neuron hidden layer*.

Tabel 3. Hasil Perhitungan Nilai *R-Squared*

Jumlah <i>Neuron</i>	Nilai R^2 Proses <i>Training</i>	Nilai R^2 Proses <i>Testing</i>	Jumlah <i>Neuron</i>	Nilai R^2 Proses <i>Training</i>	Nilai R^2 Proses <i>Testing</i>	Jumlah <i>Neuron</i>	Nilai R^2 Proses <i>Training</i>	Nilai R^2 Proses <i>Testing</i>
1	-0,491111	-	9	0,879651	0,45786	17	0,928277	0,704486
2	0,550522	0,088183	10	0,828337	0,453692	18	0,926954	0,726759
3	0,772703	0,644106	11	0,893803	0,649788	19	0,928505	0,60059
4	0,592674	-	12	0,906949	0,59464	20	0,924842	0,691162
5	0,832802	0,238565	13	0,921113	0,619794	21	0,940841	0,711119
6	0,697755	0,138611	14	0,912851	0,672118	22	0,926049	0,667516
7	0,837067	0,223109	15	0,926338	0,533411	23	0,941531	0,705441
8	0,894004	0,665121	16	0,915062	0,710114			

Karena pada jumlah *neuron hidden layer* 23 mendapatkan hasil *R-Squared* tertinggi di proses *training* dimana bernilai 0,941531 dan 0,705441 di proses *testing*. Maka 23 adalah jumlah *neuron hidden layer* terbaik.

Proses *Extreme Learning Machine* (ELM)

Pada tahap proses *training* langkah awal yang dilakukan yaitu merandom nilai untuk membentuk matriks bobot input (W) yang berukuran m (jumlah *neuron hidden layer*) $\times$ n (jumlah *neuron input*). Dimana jumlah *neuron hidden layer* yang digunakan yaitu 1-23, sedangkan *neuron input* yaitu 12. Karena jumlah *neuron hidden layer* yang terbaik yaitu sebanyak 23, maka matriks W berordo 23×12 .

$$W = \begin{bmatrix} -1,3903 & -0,3688 & -0,3783 & 1,7209 & \dots & -0,6524 \\ -0,7582 & -0,4478 & -1,5597 & -0,9480 & \dots & -0,6035 \\ 0,1520 & 2,4881 & -1,9858 & -1,6556 & \dots & -3,1343 \\ 0,8517 & -0,0280 & 0,2014 & 0,6417 & \dots & -0,4636 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0,8542 & 1,1348 & -0,5291 & -0,0643 & \dots & 0,8937 \end{bmatrix}$$

Dari matriks bobot input (W) dengan ordo 23×12 dilakukan pengujian menggunakan *Extreme Learning Machine* (ELM) melalui tahap proses *training* dan proses *testing* didapat nilai *R-Squared* sebesar 0,941531 pada proses *training* dan 0,705441 pada proses *testing*. Secara keseluruhan model terbaik yaitu mode yang menggunakan jumlah *neuron hidden layer* sebanyak 23.

Dengan nilai *R-Squared* yang tinggi pada proses *training* dan proses *testing*, selanjutnya melakukan peramalan 3 bulan ke depan secara *recursive* dengan menggunakan model dari proses *training*. Dimana untuk ramalan bulan pertama menggunakan 12 data terakhir yang sudah dinormalisasi sebagai *input*, ramalan bulan kedua menggunakan 11 data terakhir + hasil peramalan bulan pertama yang sudah dinormalisasi, ramalan bulan ketiga menggunakan 10 data terakhir + hasil peramalan bulan pertama dan kedua sebagai *input*.


Nilai hasil dari ELM dikembalikan atau mengubah data yang dinormalisasi ke dalam skala aslinya atau bentuk awalnya agar perbandingan data aktual dan hasil peramalan pada jaringan saraf ELM dapat dilihat dengan mudah. Hasil peramalan didapatkan 6,6201% pada bulan April 2025, 6,5531% pada bulan Mei 2025, dan 6,2476% pada bulan Juni 2025.

Tabel 4 merupakan hasil perbandingan data aktual dan data prediksi yang sudah didenormalisasi menggunakan Persamaan 8.

Tabel 4. Hasil Perbandingan Data Aktual dan Data Prediksi

Tanggal	Aktual	Prediksi
01/01/2002	15,87	12,57
01/02/2002	16,05	16,41
01/03/2002	14,34	15,42
01/04/2002	13,72	13,75
01/05/2002	13,58	13,58
⋮	⋮	⋮
01/02/2025	-0,5	0,32
01/03/2025	0,62	-0,36
01/04/2025		6,62
01/05/2025		6,55
01/06/2025		6,25

Plot perbandingan antara hasil peramalan dan data aktual dapat dilihat pada Gambar 2.

**Gambar 2.** Hasil Perbandingan Data Aktual dan Prediksi serta *Forecasting*

Pada Gambar 2 terlihat bahwa selisih antara prediksi dan aktual tidak terlalu mencolok, ini menunjukkan bahwa model berhasil mempelajari pola data historis dengan baik. Hasil forecast terlihat sedikit lebih tinggi dibandingkan dengan data aktual terakhir, yang berarti proyeksi inflasi akan meningkat..

D. Kesimpulan

Berdasarkan hasil penelitian mengenai prediksi inflasi di Kota Bandung menggunakan metode Extreme Learning Machine (ELM), diperoleh model terbaik dengan 23 neuron pada hidden layer. Model ini menghasilkan nilai koefisien determinasi (R^2) sebesar 0,941531 pada data training dan 0,705441 pada data testing, yang menunjukkan bahwa model memiliki kemampuan yang baik dalam mempelajari pola historis inflasi serta mampu melakukan generalisasi dengan cukup baik terhadap data baru.

Proses peramalan dilakukan secara recursive untuk memprediksi inflasi tiga bulan ke depan. Hasil peramalan menunjukkan tren kenaikan inflasi dari April hingga Juni 2025, dengan nilai inflasi masing-masing sebesar 6,62%, 6,55%, dan 6,25%.

Dengan hasil ini, dapat disimpulkan bahwa metode Extreme Learning Machine mampu digunakan sebagai alternatif dalam melakukan peramalan data ekonomi, khususnya inflasi, secara efisien dan akurat.

Ucapan Terimakasih

Berisi ucapan terima kasih kepada pihak-pihak terkait yang membantu penelitian, atau dari pihak yang memberikan hibah atau dana untuk kegiatan riset.

Daftar Pustaka

- Beaumont, C., Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1984). Forecasting: Methods and Applications. *The Journal of the Operational Research Society*, 35(1), 79. <https://doi.org/10.2307/2581936>
- BPS Kota Bandung. (2025). *Januari 2025 inflasi Year on Year (y-on-y) Kota Bandung sebesar 0,61 persen.* - Badan Pusat Statistik Kota Bandung. <https://bandungkota.bps.go.id/id/pressrelease/2025/02/03/1609/januari-2025-inflasi-year-on-year--y-on-y--kota-bandung-sebesar-0-61-persen-.html>
- Fazrilillah, U. N., & Rohaeni, O. (2024). Penerapan Metode Holt's Exponential Smoothing Dalam Memprediksi Jumlah Nasabah Kredit. *DataMath: Journal of Statistics and Mathematics*, 2(1), 11–16.
- García, S., Luengo, J., & Herrera, F. (n.d.). *Intelligent Systems Reference Library 72 Data Preprocessing in Data Mining*. <http://www.springer.com/series/8578>
- Gujarati, & Porter. (2009). *The McGraw-Hill Series Economics*.
- Heaton, Jeff. (2005). *Introduction to neural networks with Java*. Heaton Research.
- Huang, G. Bin, Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70, 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Mitchell, T. M. . (1997). *Machine Learning*. McGraw-Hill.
- Muhammad Rizq Nafisyah Alam, & Aceng Komarudin Mutaqin. (2023). Pemodelan Distribusi Poisson-Sujatha pada Data Frekuensi Klaim Asuransi Kendaraan Bermotor di Indonesia. *Jurnal Riset Statistika*, 71–78. <https://doi.org/10.29313/jrs.v3i1.1944>
- Nur Alfiyatin, A., Firdaus Mahmudy, W., Fajri Ananda, C., Priyo Anggodo, Y., Ilmu Komputer, F., Brawijaya Malang, U., & Ekonomi dan Bisnis, F. (2019). *PENERAPAN EXTREME LEARNING MACHINE (ELM) UNTUK PERAMALAN LAJU INFLASI DI INDONESIA IMPLEMENTATION EXTREME LEARNING MACHINE FOR INFLATION FORECASTING IN INDONESIA*. 6(2), 179–186. <https://doi.org/10.25126/jtiik.20186900>
- Swawikanti, K., & Team, R. T. (2025). *Pengertian Inflasi, Jenis, hingga Dampaknya Bagi Negara.* <https://www.ruangguru.com/blog/apa-itu-inflasi-dan-apa-saja-penyebabnya>
- Trianto Syahbannu Prayoga, & Suliadi. (2024). Korelasi Rank-Spearman pada Hubungan Beberapa Variabel Produk Domestik Regional Bruto. *Jurnal Riset Statistika*, 137–144. <https://doi.org/10.29313/jrs.v4i2.5162>
- Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35–62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)