

PREDIKSI DAN FORECASTING KUALITAS UDARA MENGGUNAKAN ALGORITMA *EXTREME LEARNING MACHINE*

Agung Sulaksono Ramdhani¹, Meta Kallista², Ig. Prasetya Dwi Wibawa³
^{1,2,3} Universitas Telkom

agungsulaksono@student.telkomuniversity.ac.id¹, metakallista@telkomuniversity.ac.id², prasdwibawa@telkomuniversity.ac.id³

Abstrak

Polusi udara menjadi salah satu faktor terpenting yang mempengaruhi kesehatan manusia. Jakarta adalah ibukota Indonesia, menduduki peringkat ke-9 dalam hal kualitas udara dan polusi perkotaan. Indonesia berada di peringkat ke-9 di antara 106 negara sebagai negara yang paling tercemar di dunia. DKI Jakarta adalah kota yang sangat padat. Tujuan dari penelitian ini adalah untuk memprediksi dan meramalkan data kualitas udara di DKI Jakarta dengan menggunakan algoritma Extreme Learning Machine (ELM). Metode ini memungkinkan penggunaan yang memberikan kecepatan dan performa yang tinggi. Berdasarkan hasil pengujian, diperoleh nilai root mean square error (RMSE) sebesar 0,06%, mean square error (MSE) sebesar 0,004%, dan mean absolute error (MAE) sebesar 0,041%. Nilai-nilai pengukuran evaluasi ini diperoleh dengan fungsi aktivasi ELU dengan 100 neuron tersembunyi untuk prediksi dan 500 untuk forecasting.

Kata kunci : kualitas udara, prediksi, peramalan extreme learning machine, evaluasi metrik

I. PENDAHULUAN

Salah satu faktor yang paling berpengaruh terhadap kesehatan manusia adalah polusi udara, salah satunya konsentrasi PM10 dan PM2.5 yang dapat membahayakan manusia. Oleh karena itu, informasi tentang kualitas udara sangat sangat penting untuk melindungi kesehatan manusia dan mengendalikan polusi udara [1]. Menurut data dari IQAir, pada bulan Oktober 2021, Ibu kota Indonesia, Jakarta, menduduki peringkat ke-9 untuk kualitas udara dan polusi kota.

DKI Jakarta Salah satu faktor yang paling berpengaruh terhadap kesehatan manusia adalah polusi udara merupakan kota yang memiliki kepadatan kendaraan bermotor yang tinggi. 70% merupakan polutan yang disebabkan oleh emisi dari kendaraan bermotor.

Kendaraan bermotor merupakan penghasil polusi terbesar karena mengeluarkan banyak sekali zat yang sangat berbahaya dan merusak kesehatan manusia termasuk merusak lingkungan juga [2].

Machine Learning merupakan salah satu bagian dari Artificial Intelligence atau kecerdasan buatan. Tujuan machine learning adalah untuk mempelajari data – data yang ada sehingga mesin akan mampu untuk membuat keputusan sendiri tanpa bantuan manusia lagi. Machine Learning dapat melakukan analisis regresi dimana proses ini dapat digunakan untuk melihat hubungan sebab akibat antar variabel penelitian. Manfaat dari analisis regresi adalah untuk mengetahui variabel – variabel yang memiliki pengaruh terhadap variabel dependen, serta untuk estimasi atau pendugaan dan forecasting. Dalam makalah ini, kami mengusulkan salah satu metode Machine Learning untuk melakukan prediksi dan peramalan yaitu, Extreme Learning Machine (ELM).

Metode Extreme Learning Machine (ELM) digunakan karena metode ini memiliki kelebihan pembelajaran lebih cepat, mudah untuk diaplikasikan pada masalah kompleks dan diterapkan pada kehidupan nyata[3]. Algoritma ELM

dapat menghasilkan kinerja generalisasi yang baik dalam banyak kasus dan dapat belajar ribuan kali lebih cepat daripada algoritma pembelajaran populer konvensional[4].

II. KAJIAN TEORI

A. Kualitas Udara

Dapat disimpulkan bahwa data dari IQAir, pada bulan Oktober 2021, Ibu kota Indonesia, Jakarta, menduduki peringkat ke-9 untuk kualitas udara dan polusi kota. Indonesia menempati peringkat ke-9 dari 106 negara untuk negara paling berpolusi di dunia pada tahun 2020 dari konsentrasi PM2.5[5]. DKI Jakarta merupakan kota yang memiliki kepadatan kendaraan bermotor yang tinggi. 70% merupakan polutan yang disebabkan oleh emisi dari kendaraan bermotor. Kendaraan bermotor merupakan penghasil polusi terbesar karena mengeluarkan banyak sekali zat yang sangat berbahaya dan merusak kesehatan manusia termasuk merusak lingkungan juga[6].

B. Regresi

Dalam *machine learning*, proses regresi adalah cara untuk memodelkan hubungan antara variabel dependen, atau output, dan salah satu atau lebih variabel independen. Tujuan utama dari proses ini adalah untuk membuat suatu model yang dapat menghitung nilai input dan memprediksi nilai output. Regresi digunakan untuk melakukan proses prediksi atau ramalan, tetapi juga berfokus pada data kontinu seperti memprediksi harga saham berdasarkan fitur tertentu atau memprediksi penjualan berdasarkan hal-hal seperti iklan, cuaca, dan harga produk. Dalam jurnal ini, algoritma pembelajaran mesin *Extreme Learning Machine* (ELM) akan digunakan untuk melakukan proses regresi untuk mendapatkan hasil prediksi dan prediksi.

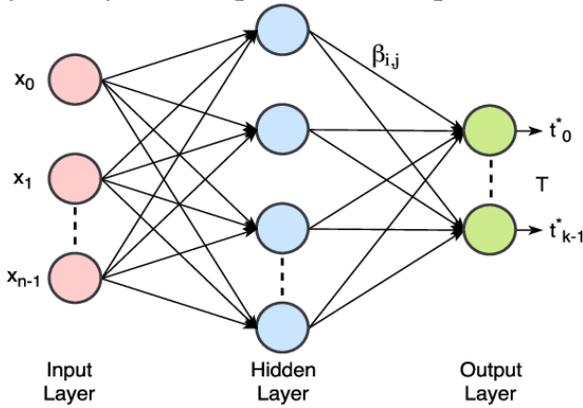
C. Extreme Learning Machine

ELM adalah metode yang bekerja dengan konsep single hidden layer feed forward networks (SLFNs), yang

diberikan N sampel pelatihan $\{(x_i, t_i)\}_{i=1}^N$ dimana x_i adalah vektor input dan t_i merupakan vektor target, hasil keluaran dari jaringan SLFN dengan node L tersembunyi dapat diekspresikan sebagai berikut:

$$o_j = \sum_{i=1}^N \beta_i f_i(x_j) = \sum_{i=1}^N \beta_i f(x_j; a_i, b_i), j = 1, \dots, N \quad (1)$$

Hal ini dapat dituliskan sebagai $f(x) = h(x)\beta$. Dimana, weight dan bias ditentukan secara acak dari batas -1 sampai 1 dan dikerjakan secara bersamaan, β_i merupakan bobot keluaran yang menghubungkan node tersembunyi ke-i lapisan output [7]. Dengan arsitektur sebagai berikut.



GAMBAR 1
ARSITEKTUR EXTREME LEARNING MACHINE

III. METODE

Berikut adalah gambaran rancangan penelitian yang meliputi prosedur atau langkah-langkah penelitian, waktu penelitian, sumber data, cara perolehan data dan menjelaskan metode yang akan digunakan dalam penelitian ini.

Extreme Learning Machine (ELM) yang digunakan untuk menyelesaikan masalah prediksi serta *forecasting*, diterapkan pada dataset sebanyak 2191 data. Dengan memanfaatkan berbagai fungsi aktivasi, serta mengatur hidden neuron yang akan menghasilkan hasil output bermacam macam sesuai kecocokan nya. Tahapan proses prediksi & forecasting menggunakan metode ELM dijelaskan pada sub bab dibawah.

A. Preprocessing Data

Normalisasi dan pra-pemrosesan data dilakukan sebelum algoritma *Extreme Learning Machine* (ELM) diterapkan. Normalisasi data. Metode KNN *imputer* dari pustaka *scikit-learn* digunakan untuk memperhitungkan nilai yang hilang sebagai bagian dari sebelum proses. *Imputer* ini digunakan sebagai tambahan dari *Imputer* lain karena merupakan alternatif yang paling handal dan akurat. [8]. Data harus diskalakan setelah proses imputasi agar algoritma *machine learning* dapat memprosesnya dengan benar. Penskalaan proses ini dikenal sebagai normalisasi. Teknik normalisasi yang digunakan dalam penelitian ini dinamakan

min-max scaling untuk nilai min paling kecil disetiap input dan nilai max nilai terbesar dari setiap input..

B. Pembagian Dataset

Melakukan pembagian dataset pada penelitian ini dataset dibagi menjadi *data train* dan *data test* dengan presentase untuk *data train* 70% dan *data test* 30 %.

C. Proses Training

Sebelum proses prediksi, proses pelatihan harus dilakukan untuk mendapatkan nilai output berat. Dalam proses pelatihan, langkah-langkah yang dilakukan adalah [9]:

1. Menginput nilai *weight* dan bias dari rentang -1 hingga 1.
2. Menghitung keluaran *hidden neuron*. Dengan persamaan sebagai berikut,

$$H_{init\ train} = X_{train} \cdot W^T + b \quad (2)$$

Keterangan:

$H_{init\ train}$ = Matriks yang dihasilkan dari *hidden neuron*

X_{train} = Input dari data training

W^T = Transpose Input *weight*

b = Nilai *bias*

Pada penelitian ini proses prediksi dan *forecasting* mengimplementasikan fungsi aktivasi seperti ReLu, Sigmoid, TanH, dan ELU.

1. Menghasilkan keluaran *weight* dengan mentranspose matriks H, yang merupakan fungsi aktivasi biner, menghasilkan output matriks pada neuron tersembunyi..
2. Menggunakan fungsi aktivasi untuk menghitung matriks Moore-Penrose Generalized Invers dari hasil keluaran lapisan tersembunyi. Untuk menemukan matriks Moore-Penrose Generalized Invers, gunakan persamaan (3) berikut ini.

$$H^+ = (H^T H)^{-1} H^T \quad (3)$$

Keterangan:

H = Matriks H keluaran *hidden neuron*

H^+ = Moore-Penrose Generalized Invers

H^T = Matriks H *transpose*

Persamaan 4 berikut bertujuan untuk menghitung nilai *output weight*.

$$\beta = H^+ \cdot Y \quad (4)$$

Keterangan:

β = *Output weight* matriks

H^+ = Moore-Penrose Generalized Invers dari matriks H

Y = Target matriks

D. Proses Testing

Tujuan dari proses ini adalah untuk mengevaluasi penerapan metode ELM berdasarkan proses pelatihan pada langkah sebelumnya. Langkah-langkah proses penilaian metode ELM berikut.

1. Mengambil nilai output berat dari proses pelatihan. Menghitung keluaran neuron tersembunyi dengan menggunakan persamaan (5).

$$H_{init\ test} = X_{test} \cdot W^T + b(5)$$

Keterangan:

$H_{init\ test}$ = Matriks hasil keluaran *hidden layer*

X_{test} = Input data menggunakan data test

W^T = Transpose Input weight

b = Nilai bias

2. Proses menghitung keluaran *hidden neuron*. Dengan menggunakan fungsi aktivasi.

$$H = \frac{1}{1 + \exp(-H_{init\ test})}(6)$$

Keterangan:

H = Fungsi Aktivasi

\exp = Eksponensial

$H_{init\ test}$ = Matriks *output hidden neuron* dalam proses testing

E. Denormalisasi

Bertujuan untuk mengubah nilai asli hasil normalisasi kembali menjadi nilai yang didenormalisasi dengan skala min dan max sesuai dengan nilai paling rendah dan tinggi pada data. Perhitungan denormalisasi data ada di persamaan (7) berikut.

$$d = d' (max - min) + min(7)$$

Keterangan:

d' = Nilai hasil normalisasi prediksi

d = Nilai setelah di denormalisasi

min = Nilai terkecil pada fitur X

max = Nilai terbesar pada fitur X

F. Evaluasi

Untuk mengetahui seberapa cocok model kita dengan data yang diuji dan hasil prediksi yang dibuat, evaluasi sangat membantu. Untuk melakukan evaluasi, penelitian ini menggunakan model matriks evaluasi RMSE, MSE, MAE, dan R-Squared. Nilai MSE, MAE, dan RMSE yang diharapkan mendekati 0 dan nilai R-Squared mendekati 1. Untuk menghitung matriks evaluasi, persamaan (8) hingga (11) digunakan:

1. *Root Mean Square Error (RMSE)*

$$RMSE = \sqrt{\frac{1}{n} \sum (y_{pred} - y_{true}) \times 2} \quad (8)$$

Keterangan:

RMSE adalah nilai Root Mean Square Error yang ingin dihitung.

n adalah jumlah total sampel data.

Σ adalah simbol sigma yang menunjukkan operasi penjumlahan.

y_{pred} adalah nilai prediksi.

y_{true} adalah nilai observasi atau sebenarnya.

2. *Mean Square Error (MSE)*

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{pred} - y_{true})^2 \quad (9)$$

Keterangan:

MSE adalah nilai Mean Square Error yang ingin dihitung.

n adalah jumlah total sampel data.

Σ adalah simbol sigma yang menunjukkan operasi penjumlahan.

y_{pred} adalah nilai prediksi.

y_{true} adalah nilai observasi atau sebenarnya.

3. *Mean Absolute Error (MAE)*

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_{pred} - y_{true})| \quad (10)$$

Keterangan:

MAE adalah nilai Mean Absolute Error yang ingin dihitung.

n adalah jumlah total sampel data.

Σ adalah simbol sigma yang menunjukkan operasi penjumlahan.

y_{pred} adalah nilai prediksi.

y_{true} adalah nilai observasi atau sebenarnya.

4. *R-Squared (R2)*

$$R^2 = \frac{SSR}{SST} = \frac{\sum (y_{pred} - y_{true})^2}{\sum (y_{pred} - y_{true})^2} \quad (11)$$

Keterangan:

R2 adalah nilai R-Squared yang ingin dihitung.

SSR merupakan singkatan dari Sum of Squares of Residuals atau Jumlah Kuadrat Residu.

SST merupakan singkatan dari Total Sum of Squares atau Jumlah Kuadrat Total.

n adalah jumlah total sampel data.

Σ adalah simbol sigma yang menunjukkan operasi penjumlahan.

y_{pred} adalah nilai prediksi.

y_{true} adalah nilai observasi atau sebenarnya.

Dalam pengujian prediksi dan *forecasting* menggunakan metode ELM ini menggunakan berbagai fungsi aktivasi diantaranya sebagai berikut.

a. *Retrifier Linear Unit (ReLU)*

Fungsi aktivasi relu ini bekerja sebagai salah satu jenis fungsi aktivasi yang digunakan dalam jaringan saraf tiruan. Rumus atau formula fungsi aktivasi Relu sebagai berikut.

$$f(x) = \max(0, x) \quad (12)$$

di mana:

f(x): fungsi aktivasi ReLU

x: input ke neuron dalam jaringan saraf

Simbol yang digunakan dalam rumus ini adalah:

f(x): simbol untuk fungsi aktivasi ReLU

x: simbol untuk input ke neuron dalam jaringan saraf

b. *Sigmoid*

Fungsi aktivasi sigmoid adalah fungsi matematika yang mengubah nilai input menjadi nilai output yang berada dalam rentang 0 hingga 1. Formulasnya adalah sebagai berikut.

$$f(x) = 1 / (1 + e^{-x}) \quad (13)$$

Simbol yang digunakan:

f(x) = hasil output dari Sigmoid Function

x = input ke Sigmoid Function

e = bilangan konstan Euler (2.71828...)

c. *Tan Hyperbolic*

Fungsi aktivasi TanH adalah fungsi matematis yang menghasilkan output dalam rentang -1 hingga 1. Rumus dari Tanh Function adalah:

$$f(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (14)$$

Simbol yang digunakan:

f(x) = output dari Tanh Function

x = input ke Tanh Function

e = bilangan konstan Euler (2.71828...)

d. *Exponential Linear Unit (ELU)*

Fungsi aktivasi ELU adalah fungsi aktivasi berdasarkan ReLU yang memiliki konstanta alfa ekstra (α) yang menentukan kehalusan fungsi saat input negatif. Rumus dari fungsi aktivasi Elu adalah :

$$ELU(x) = \begin{cases} x & \text{if } x \geq 0 \\ \alpha(e^x - 1) & \text{if } x < 0 \end{cases} \quad (15)$$

IV. HASIL DAN PEMBAHASAN

Pada penelitian ini memiliki hasil akhir berupa nilai evaluasi matriks proses prediksi dan forecasting. Pada algoritma prediksi menggunakan metode ELM digunakan beberapa parameter, yaitu jumlah *hidden neuron* dan fungsi aktivasi. Dari hasil pengujian yang dilakukan, kedua

parameter tersebut mempengaruhi hasil dari model machine learning prediksi menggunakan ELM. Hal tersebut dapat ditinjau dari nilai metrik evaluasi pada hasil prediksi ELM. Dari hasil pengujian prediksi ELM, kernel paling baik yang bisa digunakan untuk dataset ISPU adalah fungsi aktivasi ELU. Berikut adalah hasil terbaik untuk setiap partikel.

A. Hasil terbaik dari Prediksi

Berikut ini hasil terbaik dari pengujian prediksi menggunakan algoritma *Extreme Learning Machine*, tabel *Matriks Evaluasi berupa RMSE, MSE, MAE, dan R2* yang dihasilkan dari data train dan data test (1) sampai (10). Dengan hasil Plot grafik Actual, prediksi, train, dan test dari gambar (1) sampai (6).

1. DKI 1 NO2

Hasil matriks evaluasi menggunakan fungsi aktivasi *ReLU* dari train dihasilkan dengan nilai RMSE sebesar 0.034 MSE sebesar 0.001, MAE sebesar 0.024, dan R2 0.898. \

TABEL 1 EVALUASI MATRIKS DKI 1 NO2

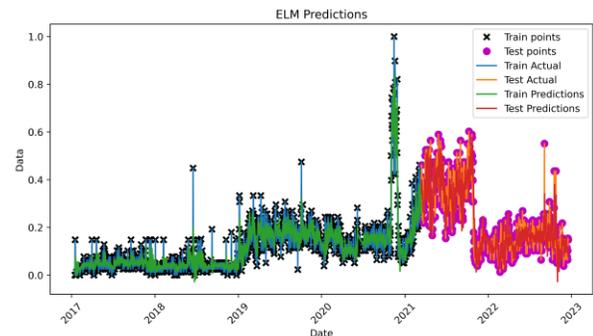
Data Train Evaluation			
RMSE	MSE	MAE	R2
0.034	0.001	0.024	0.898

Hasil matriks evaluasi menggunakan fungsi aktivasi *ReLU* dari test dihasilkan dengan nilai RMSE sebesar 0.093 MSE sebesar 0.009, MAE sebesar 0.068, dan R2 0.521.

TABEL 2 EVALUASI MATRIKS DKI 1 NO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.093	0.009	0.068	0.521

Berikut adalah plot data dari NO2 DKI1 dengan fungsi aktivasi *ReLU*.



GAMBAR 2 DKI 1 NO2

2. DKI 2 SO2

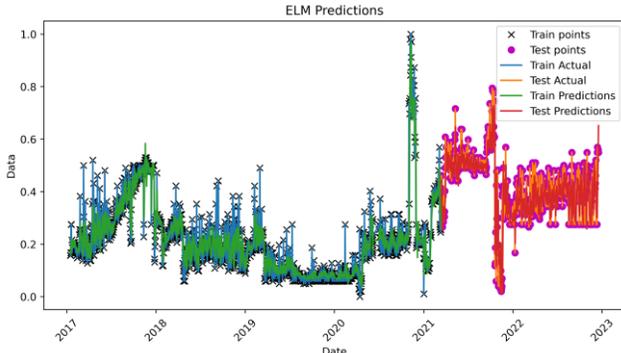
TABEL 3 EVALUASI MATRIKS DKI 2 SO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.055	0.003	0.036	0.843

TABEL 4 EVALUASI MATRIKS DKI 2 SO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.076	0.006	0.051	0.586

Berikut adalah plot data dari NO2 DKI1 dengan fungsi aktivasi ELU



GAMBAR 3
DKI 2 SO2

3. DKI 5 SO2

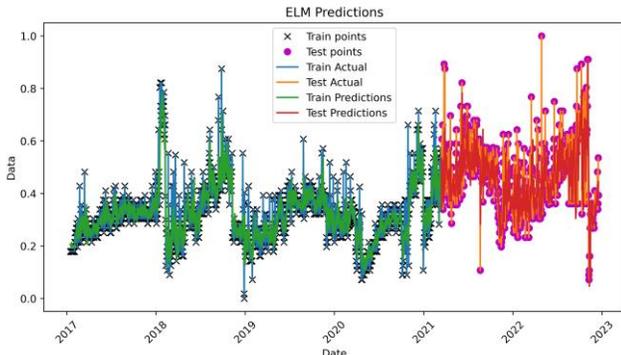
TABEL 5 EVALUASI MATRIKS DKI 5 SO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.061	0.004	0.042	0.713

TABEL 6 EVALUASI MATRIKS DKI 5 SO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.114	0.013	0.081	0.254

Berikut adalah plot data dari SO2 DKI5 dengan fungsi aktivasi ELU



GAMBAR 4
DKI 5 SO2

4. DKI 3 NO2

**TABEL 7
EVALUASI MATRIKS DKI 3 NO2**

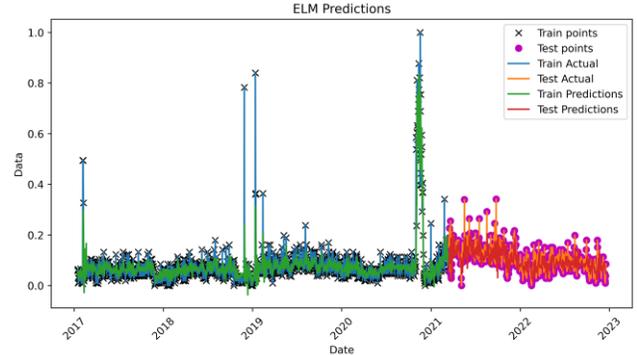
Data Train Evaluation			
-----------------------	--	--	--

RMSE	MSE	MAE	R2
0.048	0.002	0.025	0.711

TABEL 8 EVALUASI MATRIKS DKI 3 NO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.040	0.002	0.029	0.227

Berikut adalah plot data dari NO2 DKI1 dengan fungsi aktivasi ELU



GAMBAR 5
DKI 3 NO2

5. DKI 1 SO2

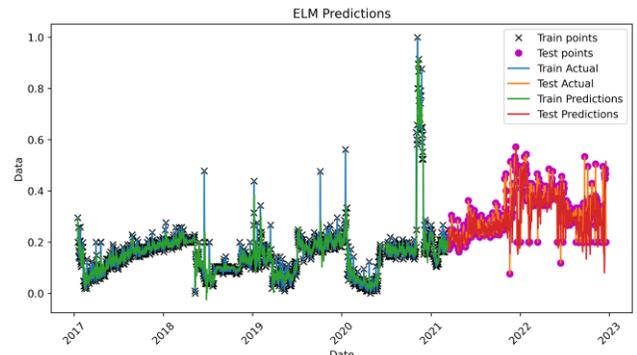
TABEL 9 EVALUASI MATRIKS DKI 1 SO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.037	0.001	0.022	0.866

TABEL 10 EVALUASI MATRIKS DKI 1 SO2

Data Train Evaluation			
RMSE	MSE	MAE	R2
0.070	0.005	0.046	0.302

Berikut adalah plot data dari NO2 DKI1 dengan fungsi aktivasi ELU



GAMBAR 6
DKI 1 SO2

B. Hasil terbaik dari Forecasting

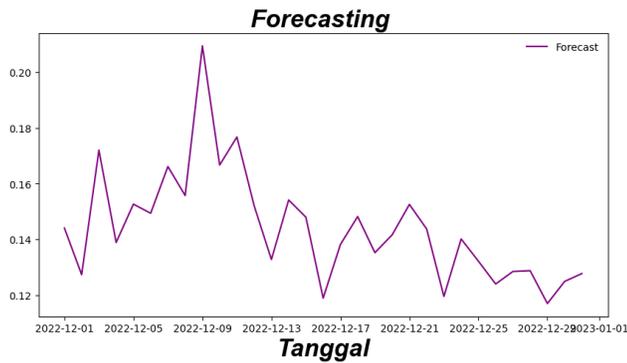
Berikut ini hasil terbaik dari pengujian forecasting menggunakan algoritma *Extreme Learning Machine*, dari hasil semua menggunakan fungsi aktivasi ELU dengan hidden neuron 500. Tabel *Matriks Evaluasi* berupa *RMSE*, *MSE*, dan *MAE* yang dihasilkan ditampilkan dari tabel(11) sampai (15). Dengan hasil Plot *forecasting* ditampilkan dari gambar (7) sampai (11).

1. DKI 1 NO2

TABEL 11
EVALUASI MATRIKS DKI 1 NO2

RMSE	MSE	MAE
0.092	0.008	0.066

Berikut adalah plot data dari DKI1 NO2 dengan fungsi aktivasi ELU



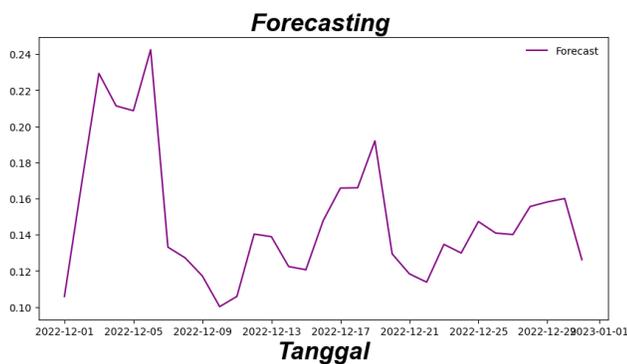
GAMBAR 7
DKI 1 NO2

2. DKI 2 NO2

TABEL 12 EVALUASI MATRIKS DKI 2 NO2

RMSE	MSE	MAE
0.081	0.007	0.065

Berikut adalah plot data dari DKI2 NO2 dengan fungsi aktivasi ELU

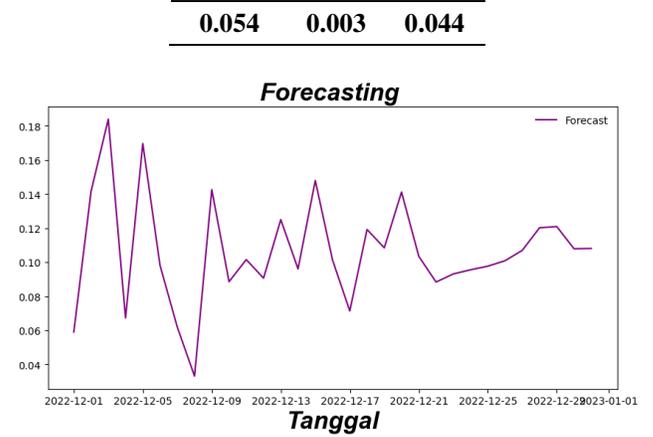


GAMBAR 8
DKI 2 NO2

3. DKI 3 NO2

TABEL 13 BERIKUT ADALAH PLOT DATA DARI DKI3 NO2 DENGAN FUNGSI AKTIVASI ELU

RMSE	MSE	MAE
0.054	0.003	0.044



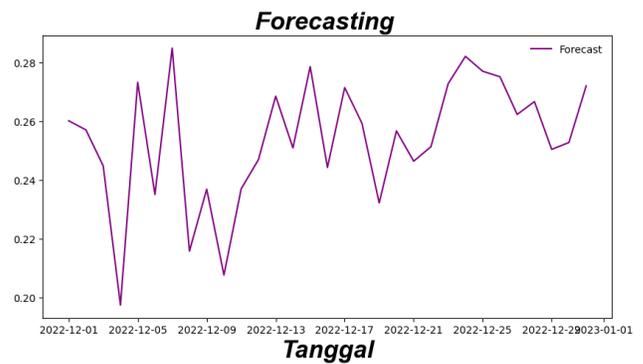
GAMBAR 9
DKI 3 NO2

4. DKI 4 PM10

TABEL 14 EVALUASI MATRIKS DKI 1 NO2

RMSE	MSE	MAE
0.06	0.004	0.041

Berikut adalah plot data dari DKI4 PM10 dengan fungsi aktivasi ELU



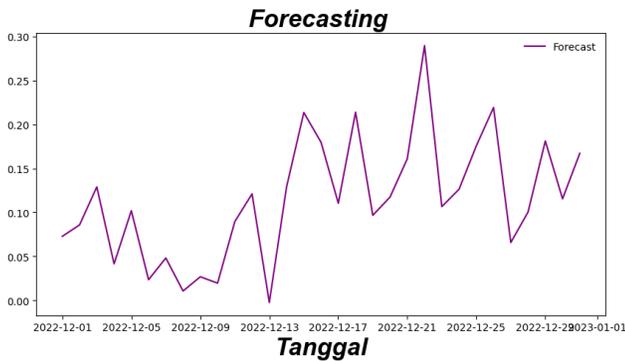
GAMBAR 10
DKI 4 NO2

5. DKI 5 NO2

TABEL 15 EVALUASI MATRIKS DKI 5 NO2

RMSE	MSE	MAE
0.118	0.014	0.096

Berikut adalah plot data dari DKI5 NO2 dengan fungsi aktivasi ELU



GAMBAR 11
DKI 5 NO2

V. KESIMPULAN

Pengujian dan analisis yang dilakukan untuk prediksi dan prediksi dataset ISPU DKI Jakarta menggunakan Algoritma Extreme Learning Machine menunjukkan hasil terbaik untuk proses prediksi partikel NO₂ di daerah DKI1. Nilai evaluasi matriks terkecil, yaitu RMSE sebesar 0.034, MSE sebesar 0.001, MAE sebesar 0.024, dan R-squared sebesar 0.898, ditemukan untuk data pelatit. Untuk data DKI1 NO₂, fungsi aktivasi digunakan dengan ReLu dengan neuron tersembunyi 100. Untuk proses prediksi, partikel PM₁₀ di daerah DKI4 memberikan hasil terbaik dengan nilai matriks evaluasi RMSE sebesar 0,06, MSE sebesar 0.004, dan MAE sebesar 0.041. Fungsi aktivasi yang digunakan ELU dengan *hidden neuron 500*.

REFERENSI

- [1] T. Xayasouk and H. Lee, "Air pollution prediction system using deep learning," *WIT Transactions on Ecology and the Environment*, vol. 230, pp. 71–79, 2018, doi: 10.2495/AIR180071.
- [2] Ismatullah Hadi, "Prediksi Kualitas Udara Menggunakan Metode Gaussian Process Regression (GPR)," Bandung, 2022
- [3] A. Nur Alfiyatin et al., "Penerapan Extreme Learning Machine (Elm) Untuk Peramalan Laju Inflasi Di Indonesia Implementation Extreme Learning Machine For Inflation Forecasting In Indonesia," vol. 6, no. 2, pp. 179–186, 2018, doi: 10.25126/jtiik.20186900.
- [4] G. Bin Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, no. 1–3, pp. 489–501, Dec. 2006, doi: 10.1016/j.neucom.2005.12.126.

- [5] PT. Gramedia Asri Media, "Dampak Negatif dari Pencemaran Udara & Solusinya," Gramedia, Oct. 24, 2022. <https://www.gramedia.com/literasi/dampak-negatif-dari-pencemaran-udara> (accessed Jul. 31, 2023).
- [6] Nirzha Maulidya Ashar, Imam Cholissodin, Candra Dewi 2018. "Penerapan Metode Extreme Learning Machine (ELM) Untuk Memprediksi Jumlah Produksi Pipa Yang Layak(Studi Kasus Pada PT. KHI Pipe Industries)", *jurnal pengembangan teknologi informasi dan ilmu komputer* Vol. 2, no. 11 , November 2018, hlm.4621-44628
- [7] O. Altukhova, "Choice of method imputation missing values for obstetrics clinical data," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 976–984. doi: 10.1016/j.procs.2020.09.093.