



Penerapan Metode *Extreme Learning Machine* (ELM) untuk Memprediksi Hasil Sensor EWS Trafo

Rolisa Apalem^{1*}

^{1*} Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Kota Salatiga, Jawa Tengah, Indonesia.

article info

Article history:

Received 3 June 2023

Received in revised form

13 September 2023

Accepted 20 November 2023

Available online January 2024

DOI:

<https://doi.org/10.35870/jti.k.v8i1.1243>

Keywords:

Early Warning System Trafo (EWS Trafo); Extreme Learning Machine (ELM); Distribution Transformer; Machine Learning; Prediction.

Kata Kunci:

Early Warning System Trafo (EWS Trafo); Extreme Learning Machine (ELM); Transformator Distribusi; Pembelajaran Mesin; Prediksi.

abstract

The Early Warning System (EWS) Trafo is a continuous monitoring tool for transformers that provides warnings when anomalies are detected, aiming to prevent explosions. This device applies artificial intelligence and machine learning technologies to monitor and predict the real-time condition of transformers using sensor data collected by the tool. This research aims to predict the condition of transformers based on the EWS Trafo sensor results using the Extreme Learning Machine (ELM) method. The study investigates the effectiveness of the ELM method in predicting transformer conditions. Based on the research results obtained from several combinations of data training: testing with different numbers of hidden layers, the lowest Mean Absolute Percentage Error (MAPE) value was found in the combination of 40% training data and 60% testing data, out of a total of 470 data points, with 20 hidden layers, at 23.1125%. Thus, it can be concluded that the Extreme Learning Machine (ELM) method is effective in predicting the condition of transformers.

abstract

Early Warning System (EWS) Trafo merupakan alat monitoring secara konitinu untuk trafo yang memberikan peringatan saat terdeteksi anomaly, dengan tujuan mencegah ledakan. Alat ini menerapkan teknologi artificial intelligence dan machine learning untuk memantau dan memprediksi kondisi trafo secara real-time dengan menggunakan data sensor yang dikumpulkan oleh alat tersebut. Pada penelitian ini akan dilakukan prediksi kondisi trafo berdasarkan hasil sensor EWS Trafo dengan menggunakan metode Extreme Learning Machine (ELM). Diamana akan dilihat seberapa baik metode ELM dalam melakukan prediksi kondisi trafo. Berdasarkan hasil penelitian yang dilakukan terhadap beberapa kombinasi jumlah pembagian data training : testing dengan jumlah hidden layer, didapat nilai MAPE terendah ada pada kombinasi pembagian data 40%:60% dari total 470 data dengan hidden layer 20 buah yaitu sebesar 23,1125%. Sehingga dapat dikatakan bahwa metode Extreme Learning Machine (ELM) ini cukup baik dalam memprediksi kondisi trafo.

Corresponding Author. Email: rlsaapalem@gmail.com ^{1}.

© E-ISSN: 2580-1643.

Copyright © 2024 by the authors of this article. Published by Lembaga Otonom Lembaga Informasi dan Riset Indonesia (KITA INFO dan Riset). This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.



ACM Computing Classification System (CCS)

EBSCOhost

Communication and Mass Media Complete (CMMC)

1. Latar Belakang

Saat ini, Perusahaan Listrik Negara (PLN) menjadi pemasok utama listrik yang menyediakan tenaga listrik kepada konsumen melalui trafo distribusi [1]. Trafo atau transformator distribusi merupakan komponen krusial dalam sistem penyaluran tenaga listrik karena berperan dalam mengkonversi daya dari jaringan tegangan menengah menjadi jaringan tegangan rendah [2]. Namun, masalah kerusakan dan gangguan pada trafo distribusi sering terjadi karena jaringan distribusi yang memiliki beberapa trafo yang tersebar jauh dari pusat kendali [3][4]. Gangguan dan kerusakan pada trafo distribusi dapat disebabkan oleh beberapa faktor, antara lain beban pelanggan yang melebihi kapasitas, kebocoran minyak trafo, tegangan phasa yang berlebihan, ketidakseimbangan beban pada setiap phasa, serta peningkatan suhu trafo [5][6].

Dalam mengatasi masalah tersebut, salah satu upaya efektif untuk menghindari atau mencegah gangguan dan kerusakan pada trafo yaitu dengan melakukan monitoring kondisi Trafo. Berbagai perusahaan, instansi, dan organisasi telah berupaya mengembangkan alat-alat untuk memantau kondisi trafo dengan memanfaatkan teknologi terkini. Tujuan dari pengembangan ini adalah memberikan informasi secara *real-time* tentang kondisi trafo kepada pengguna yang membutuhkannya [2][7][8].

Dari penjelasan diatas, diketahui bahwa tim Universitas Kristen Satya berupaya menciptakan inovasi baru dalam mendukung monitoring kondisi trafo dengan membuat alat *early warning system trafo* atau alat peringatan dini ledakan trafo yang kemudian disingkat menjadi EWS Trafo. Alat ini dirancang untuk memonitoring trafo secara kontinu dan memberikan peringatan jika terdapat anomaly pada trafo. Alat *Early Warning System* (EWS) Trafo yang dikembangkan menerapkan teknologi kecerdasan buatan (*artificial intelligence*) dan pembelajaran mesin (*machine learning*) guna melakukan pemantauan dan prediksi kondisi trafo berdasarkan data sensor yang terdapat pada alat tersebut.

Hasil prediksi yang baik dari alat EWS Trafo dapat memberikan informasi penting dalam pemeliharaan kondisi trafo. Dengan adanya peringatan dini, Tindakan yang tepat dapat segera dilakukan untuk

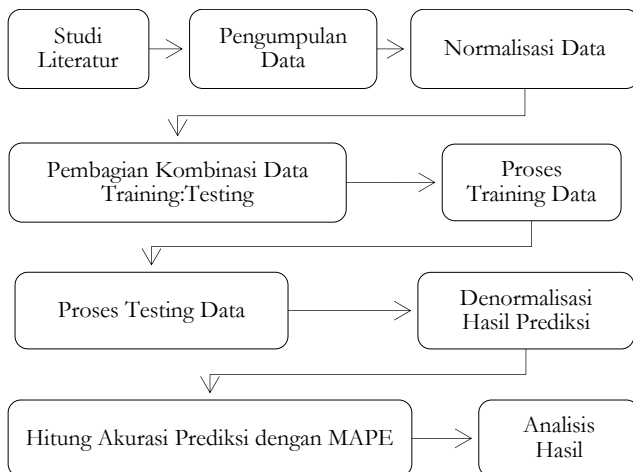
mencegah terjadinya gangguan serius, seperti ledakan trafo. Sehingga, pemilihan metode *machine learning* yang tepat sangat perlu, agar mendapat hasil prediksi yang akurat. *Machine learning* adalah “bagian dari *artificial intelligence* yang berfungsi membuat komputer memiliki kemampuan untuk belajar tentang data baru tanpa harus di program secara eksplisit”, metode ini diperkenalkan pertama kali oleh Arthur Samuel pada tahun 1950 [9]. Salah satu metode *machine learning* yang sering digunakan untuk melakukan prediksi adalah metode Jaringan Syaraf Tiruan (JST), metode ini merupakan model komputasi yang diadaptasi dari sistem saraf manusia, dimana metode ini memiliki beberapa *neuron* yang saling terkait satu sama lain [10]. Salah satu metode yang terdapat dalam JST yaitu *Extreme Learning Machine* (ELM). Metode ELM merupakan metode pembelajaran baru dari JST, dan pertama kali dikenalkan oleh Huang pada tahun 2004 [11]. Metode ELM ini memiliki keunggulan dalam *learning speed* (waktu) [12], karena untuk bobot awal diperoleh secara *random* tanpa perlu iterasi seperti metode JST yang lain, juga memiliki tingkat ketidaksesuaian atau tingkat kesalahan rendah [13]. Penelitian mengenai peramalan harga cabai merah besar di wilayah Jawa Timur menggunakan metode ELM, dan diperoleh nilai kesalahan terkecil menggunakan *Mean Absolute Percentage Error* (MAPE) sebesar 3%, dimana jumlah fitur yang digunakan 2, jumlah *neuron* sebanyak 3 dan rentang nilai bobot sebesar [-1,8, 1,8] [14].

Penelitian yang dilakukan oleh Izati *dkk* (2019) yang mengkaji Prediksi Harga Emas Menggunakan *Feed Forward Neural Network* dengan Metode *Extreme Learning Machine*. Hasil penelitian ini menunjukkan bahwa model *Feedforward Neural Network* (FFNN) dengan X_{t-1} sebagai variabel *input* dan jumlah *hidden nodes* sebanyak 7, mampu memberikan hasil pemodelan yang sangat baik pada proses *training* yaitu dengan nilai MAPE sebesar 0,6752% dan mampu memberikan model dengan kemampuan prediksi yang sangat baik dengan nilai MAPE sebesar 0,5499%. Hasil prediksi yang didapat juga sangat baik karena mendekati nilai aktualnya [15]. Penelitian lainnya dilakukan prediksi nilai ekspor impor migas dan non-migas di Indonesia dengan menggunakan metode ELM. Hasil dari penelitian ini menunjukkan bahwa metode ELM mampu memprediksi nilai ekspor impor migas dan non-migas di Indonesia dengan baik, dilihat dari nilai rata-rata MAPE untuk data ekspor sebesar

6,6742% dengan perbandingan data *training:testing* 70%:30%, jumlah fitur 5, dan *hidden layer* 8, sedangkan nilai rata-rata MAPE untuk data import sebesar 10,0515% dengan perbandingan data *training:testing* 80%:20%, jumlah fitur 4, dan *hidden layer* 10 [16]. Berdasarkan latar belakang yang ada, penelitian ini dilakukan untuk memprediksi kondisi trafo berdasarkan hasil sensor dari alat EWS Trafo dengan menerapkan metode *machine learning* yaitu metode *Extreme Learning Machine*.

2. Metode Penelitian

Penelitian ini bersifat kualitatif dengan menggunakan metode deskriptif. Penelitian kualitatif adalah metode penelitian yang yang spesifikasinya sistematis, terencana, terstruktur dengan jelas dan akurat, metode ini biasanya dinyatakan dalam bentuk angka, grafik, juga menggunakan rumus statistika dalam perhitungannya. Metode Deskriptif adalah metode yang digunakan untuk mendeskripsikan atau memberi gambaran umum mengenai objek yang diteliti maupun hasil penelitian. Dalam penelitian ini ada beberapa langkah yang dilakukan untuk memperoleh hasil prediksi menggunakan metode *Extreme Learning Machine* (ELM). Gambar 1 merupakan alur atau langkah penelitian yang dilakukan.



Gambar 1. Alur Penelitian

Pada Gambar 1 dapat dijelaskan sebagai berikut:

Studi Literatur

Tahap pengumpulan informasi sebagai referensi. Dalam tahap ini dikumpulkan beberapa penelitian

yang diperlukan dari jurnal, buku, maupun artikel yang membahas proses prediksi menggunakan metode ELM, transformator distribusi, kondisi trafo, dan metode pemantauan (monitoring) kondisi trafo.

Pengumpulan Data

Pada penelitian ini data yang digunakan berupa data sekunder dari *website* Kaggle yang berisi *dataset* kondisi Kesehatan trafo (<https://www.kaggle.com/datasets/easonlai/sample-power-transformers-health-condition-dataset?resource=download>). *Dataset* ini mencakup atribut dari sensor EWS Trafo dan nilai *health index*, yang akan digunakan untuk memprediksi kondisi trafo.

Normalisasi (Pre-processing) Data

Proses ini mengubah data menjadi nilai yang lebih spesifik atau lebih kecil dan memiliki range yang tidak terlalu jauh yaitu dalam interval $[0,1]$, namun nilai interval sendiri dapat disesuaikan dengan keluaran fungsi aktivasi yang digunakan. Proses normalisasi dapat dilakukan dengan persamaan 1 [15].

$$x'_i = \frac{0,8 (x_i - (x_{min}))}{((x_{max}) - (x_{min}))} + 0,1 \quad (1)$$

Keterangan :

x'_i : Data ke-i hasil normalisasi.

x_i : Data ke-i sebelum dinormalisasi.

(x_{min}) : Nilai minimum dari data sebelum dinormalisasi.

(x_{max}) : Nilai maksimum dari data sebelum dinormalisasi.

Pembagian Kombinasi Data Training : Testing

Sebelum melakukan proses training maupun *testing*, data yang sudah di normalisasi dibagi menjadi 2 bagian yaitu data *training* dan *testing*. Dalam penelitian ini data *training : testing* dibagi menjadi 6 kombinasi yaitu:

- 1) 40% data *training* (188 data) dan 60% data *testing* (282 data);
- 2) 50% data *training* (235 data) dan 50% data *testing* (235 data);
- 3) 60% data *training* (282 data) dan 40% data *testing* (188 data);
- 4) 70% data *training* (329 data) dan 30% data *testing* (141 data);
- 5) 80% data *training* (376 data) dan 20% data *testing* (94 data); dan

- 6) 90% data *training* (423 data) dan 10% data *testing* (47 data)

Proses Training Data

Persentase jumlah data yang digunakan dalam proses training yaitu 40%, 50%, 60%, 70%, 80%, dan 90% dari data yang digunakan. Proses *training* dilakukan dalam beberapa Langkah:

- 1) Menginisialisasi W (bobot) dan Bias secara *random* (acak) dengan *range* [0,1].
- 2) Menghitung *output hidden layer* (H_{init}) dengan persamaan 2.

$$H_{init\ i\ j} = (\sum_{i=1}^n w_{i\ j} + x_i) + b_j \quad (2)$$

Keterangan :

- $H_{init\ i\ j}$: Matriks hasil *output hidden layer* untuk proses *training*.
 i : Banyak data atau data ke- i (1, 2, 3, ...)
 j : Banyak *hidden nodes*.
 n : Jumlah input *neuron*.
 w : Input *weight* (bobot).
 x : Data yang digunakan.
 b : Nilai bias.

- 3) Menghitung fungsi aktivasi hasil *output hidden layer* dengan menggunakan fungsi aktivasi sigmoid biner. Fungsi aktivasi sigmoid biner dapat dilihat pada persamaan 3.

$$H = \frac{1}{(1+e^{-(H_{init})})} \quad (3)$$

Keterangan :

- H : Nilai Perhitungan Aktivasi
 e : Bilangan euler dengan nilai pembulatan 2,718
 H_{init} : Nilai Matriks hasil *output hidden layer*

- 4) Menghitung matriks *Moore-Penrose Generalized Invers* dengan persamaan 4.

$$H^+ = (H^T \times H)^{-1} \times H^T \quad (4)$$

Keterangan :

- H^+ : Matriks *Moore-Penrose Generalized Inverse* dengan fungsi aktivasi.
 H : Matriks H *output hidden layer*.

H^T : Matriks H Transpose.

- 5) Menghitung *output weight* (bobot) antara *hidden layer* dengan *output layer*. *Output weight* diperoleh dengan menggunakan persamaan 5.

$$\beta = H^+ \times Y \quad (5)$$

Keterangan :

- β : Matriks *output weight* (bobot) .
 H^+ : Matriks *Moore-Penrose Generalized Inverse* dari matriks H .
 Y : Matriks Target (prediksi).

Proses Testing Data

Proses *testing* sendiri hampir mirip dengan proses *training*, namun pada proses testing tidak menghitung nilai matriks *Moore-Penrose Generalized Inverse* dan *output weight*. Persentase jumlah data *testing* yang digunakan dalam proses *testing* yaitu 60%, 50%, 40%, 30%, 20%, dan 10% dari data yang ada. Proses *testing* dilakukan dalam beberapa langkah :

- 1) Menginisialisasi *output weight* dan bias hasil dari proses *training*.
- 2) Menghitung *output hidden layer* dan fungsi aktivasi dengan menggunakan persamaan 2 dan 3.
- 3) Menghitung hasil prediksi (*output layer*) menggunakan persamaan 6.

$$y = H \times \beta \quad (6)$$

Keterangan :

- y : *output layer* yang merupakan hasil prediksi
 H : *output hidden layer* dihitung dengan fungsi aktivasi
 β : nilai *output weight* dari proses *training*

Denormalisasi Hasil Prediksi

Data hasil prediksi kemudian didenormalisasikan. Denormalisasi berfungsi mengembalikan nilai yang dinormalisasi (dalam interval [0,1]) ke nilai semula (aktual) untuk mendapatkan prediksi dari data *testing*. Denormalisasi dapat dilakukan dengan persamaan 7.

$$d = d' \times (max - min) + min \quad (7)$$

Keterangan :

- d : Nilai hasil prediksi setelah dinormalisasi.

- d' : Nilai hasil prediksi sebelum denormalisasi.
 max : Nilai maksimum dari dataset.
 min : Nilai minimum dari dataset.

Hitung Akurasi Prediksi dengan MAPE

Hasil prediksi yang sudah didenormalisasi, selanjutnya dilakukan pengukuran tingkat kesalahan untuk mengetahui tingkat keakuratan dari metode ELM dalam memprediksi kondisi trafo berdasarkan hasil sensor EWS trafo. Tingkat keakuratan suatu metode dilihat dari nilai kesalahan prediksinya, semakin kecil nilai kesalahan, maka semakin baik metode tersebut dalam melakukan prediksi. Pengukuran tingkat kesalahan prediksi dapat dihitung dengan MAPE. MAPE (*Mean Absolute Percentage Error*) adalah kesalahan persentase absolut rata-rata, oleh karena itu, nilai kesalahan positif atau negatif diabaikan dalam MAPE. Semakin kecil nilai kesalahan yang diperoleh dengan MAPE, maka semakin baik hasil prediksinya. Kriteria nilai MAPE dapat dilihat pada Tabel 1.

Tabel 1. Kriteria Nilai MAPE

Persentase Nilai MAPE	Keterangan
< 10%	Prediksi Sangat Baik
10% - 20%	Prediksi Baik
20% - 50%	Prediksi Cukup
>50%	Prediksi Tidak Akurat

Perentasi Nilai MAPE dapat diperoleh dengan persamaan 8.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}}{y_i} \right| \times 100 \quad (8)$$

Keterangan :

- $MAPE$: Nilai error prediksi dalam persen.
 n : Banyak data yang diuji.
 \hat{y} : Nilai data hasil prediksi.
 y_i : Nilai data aktual.

Analisis Hasil

Setelah semua proses prediksi yang dilakukan dengan menggunakan metode ELM, selanjutnya dilakukan Analisa hasil. Analisa dilakukan untuk membandingkan data hasil prediksi dengan data aktual berdasarkan nilai MAPE yang diperoleh, juga menganalisa kombinasi pembagian data *training* dan

testing dengan kombinasi jumlah *hidden layer* yang optimal untuk digunakan dalam prediksi kondisi trafo.

3. Hasil dan Pembahasan

Hasil dan pembahasan dari penelitian ini merupakan penerapan dari metode *Extreme Learning Machine* (ELM) dalam memprediksi kondisi kesehatan trafo yang dilihat dari nilai *health index* berdasarkan hasil sensor EWS Trafo. Pembangunan model prediksi dilakukan menggunakan *tools Google Colaboratory* (<https://colab.research.google.com>) dengan Bahasa pemrograman *python*, dan juga menggunakan beberapa *library* pendukung yang dimiliki *python* antara lain *Pandas*, *NumPY*, *Matplotlib*, *Scikit-Learn* (*sklearn*), dan ELM (*Extreme Learning Machine*). Pada prediksi kondisi trafo menggunakan metode ELM akan dilakukan pengujian terhadap kombinasi jumlah data *training* : *testing* dengan kombinasi jumlah *hidden layer*. Tujuan dari pengujian ini adalah menentukan kombinasi dari jumlah data *training* : *testing* dengan kombinasi jumlah *hidden layer* yang optimal untuk memprediksi kondisi trafo. Dalam pengujian ini, proses evaluasi didasarkan pada nilai MAPE yang diperoleh dari setiap kali menjalankan program. Pada setiap percobaan, nilai MAPE yang didapatkan berbeda-beda, hal ini dikarenakan nilai bobot dan bias yang diinisialisasi secara *random* setiap kali menjalankan program, sehingga pengujian ini dilakukan 10 kali percobaan untuk tiap kombinasi pembagian data *training* : *testing* dengan kombinasi jumlah *hidden layer*, dan kemudian dihitung nilai rata-rata MAPE dari setiap percobaan terhadap kombinasi yang ada. Adapun pembagian data *training* : *testing* yang akan digunakan yaitu 40%:60%, 50%:50%, 60%:40%, 70%:30%, 80%:20%, dan 90%:10%, dan *hidden layer* dengan kelipatan 5 mulai dari 5 sampai 50. Pengujian ini menggunakan jumlah fitur (*input layer*) sebanyak 14, serta nilai bobot dan bias akan diinisialisasi secara *random* pada setiap percobaan.

Hasil Pengujian Kombinasi Jumlah Data Training: Testing dengan Kombinasi Jumlah Hidden Layer


1) Kombinasi Data 40%:60%

Hasil pengujian terhadap kombinasi data 40%:60% dengan beberapa *hidden layer*, menunjukkan bahwa nilai MAPE terbaik terdapat *hidden layer* sejumlah 20 dengan nilai MAPE sebesar 23,1125%. Untuk lebih jelasnya dapat dilihat pada Tabel 2 dan Gambar 2

berikut :

Tabel 2. Nilai Rata-rata MAPE untuk Kombinasi Data 40%:60%

Jumlah Hidden Layer	Rata-rata Nilai MAPE
5	31,2591 %
10	24,6476 %
15	23,7105 %
20	23,1125 %
25	23,8318 %
30	23,2254 %
35	24,5380 %
40	25,0185 %
45	26,0294 %
50	29,0714 %




Gambar 2. Grafik Rata-rata MAPE untuk Kombinasi Data 40%:60%

2) Kombinasi Data 50%:50%

Hasil pengujian terhadap kombinasi data 50%:50% dengan beberapa *hidden layer*, menunjukkan bahwa jumlah *hidden layer* 20 buah memiliki nilai MAPE terendah yaitu 24,0002%. Lebih jelasnya dapat dilihat pada Tabel 3 dan Gambar 3 berikut:

Tabel 3. Nilai Rata-rata MAPE untuk Kombinasi Data 50%:50%

Jumlah Hidden Layer	Rata-rata Nilai MAPE
5	29,4936 %
10	24,4939 %
15	24,0263 %
20	24,0002 %
25	24,1838 %
30	24,2584 %
35	24,2557 %
40	24,9480 %
45	25,5948 %
50	27,2113 %




Gambar 3. Grafik Rata-rata MAPE untuk Kombinasi Data 50%:50%

3) Kombinasi Data 60%:40%

Hasil pengujian terhadap kombinasi data 60%:40% dengan beberapa *hidden layer*, menunjukkan bahwa nilai MAPE terkecil yaitu 24,3684% berada pada *hidden layer* sejumlah 20 buah. Untuk lebih jelasnya dapat dilihat pada Tabel 4 dan Gambar 4:

Tabel 4. Nilai Rata-rata MAPE untuk Kombinasi Data 60%:40%

Jumlah Hidden Layer	Rata-rata Nilai MAPE
5	29,6995 %
10	25,7511 %
15	24,4857 %
20	24,3684 %
25	24,6530 %
30	24,5136 %
35	24,8247 %
40	25,7448 %
45	26,0571 %
50	27,5318 %




Gambar 4. Grafik Rata-rata MAPE untuk Kombinasi Data 60%:40%

4) Kombinasi Data 70%:30%

Hasil pengujian terhadap kombinasi data 70%:30% dengan beberapa *hidden layer*, menunjukkan bahwa *hidden layer* sebanyak 20 buah memiliki nilai MAPE terbaik yaitu 23,8912%. Lebih jelasnya dapat dilihat pada Tabel 5 dan Gambar 5 berikut:

Tabel 5. Nilai Rata-rata MAPE untuk Kombinasi Data 70%:30%

Jumlah Hidden Layer	Rata-rata Nilai MAPE
5	28,1607 %
10	26,2234 %
15	24,6492 %
20	23,8912 %
25	24,1466 %
30	23,9189 %
35	25,1043 %
40	24,4053 %
45	25,2582 %
50	25,4947 %



Gambar 5. Grafik Rata-rata MAPE untuk Kombinasi Data 70%:30%


5) Kombinasi Data 80%:20%

Hasil pengujian terhadap kombinasi data 80%:20% dengan beberapa *hidden layer*, memiliki hasil yang berbeda dari kombinasi sebelumnya, dimana nilai MAPE terendah berada pada *hidden layer* sebanyak 50 buah yaitu 24,4673%. Untuk jelasnya dapat dilihat pada Tabel 6 dan Gambar 6 berikut:

Tabel 6. Nilai Rata-rata MAPE untuk Kombinasi Data 80%:20%

Jumlah Hidden Layer	Rata-rata Nilai MAPE
5	30,2995 %
10	26,5703 %
15	25,3312 %

20	24,9201 %
25	24,7970 %
30	24,7624 %
35	24,8025 %
40	24,8078 %
45	24,9995 %
50	24,4673 %




Gambar 6. Grafik Rata-rata MAPE untuk Kombinasi Data 80%:20%

6) Kombinasi Data 90%:10%

Hasil pengujian terhadap kombinasi data 90%:10% dengan beberapa *hidden layer*, menunjukkan bahwa nilai MAPE terendah berada pada jumlah hidden layer sebanyak 25 buah dengan nilai MAPE yaitu 23,8335%. Lebih jelasnya dapat dilihat pada Tabel 7 dan Gambar 7 berikut:

Tabel 7. Nilai Rata-rata MAPE untuk Kombinasi Data 90%:10%

Jumlah Hidden Layer	Rata-rata Nilai MAPE
5	29,7102 %
10	26,0273 %
15	24,4492 %
20	24,2236 %
25	23,8335 %
30	24,2014 %
35	24,1182 %
40	23,8927 %
45	25,0018 %
50	25,1534 %



Gambar 7. Grafik Rata-rata MAPE untuk Kombinasi Data 90%:10%

Analisis Perbandingan Kombinasi Jumlah Data Training: Testing dengan Kombinasi Jumlah Hidden Layer

Hasil pengujian yang dilakukan terhadap kombinasi data *training* : *testing* dengan kombinasi jumlah *hidden layer* didapat beberapa nilai rata-rata MAPE terkecil dari setiap kombinasi data *training* : *testing* dengan kombinasi jumlah *hidden layer*. Rata-rata pengujian yang dilakukan dengan beberapa kombinasi data *training* : *testing* menunjukkan bahwa jumlah *hidden layer* 20 buah memiliki nilai rata-rata MAPE yang kecil. Agar lebih jelas, hasil dapat dilihat pada Tabel 8 berikut :


Tabel 8. Nilai MAPE terkecil dari Kombinasi Pembagian Data dan Jumlah Hidden Layer

Kombinasi Training : Testing	Jumlah Hidden Layer	Nilai MAPE
40% : 60 %	20	23,1125 %
50% : 50%	20	24,0002 %
60% : 40%	20	24,3684 %
70% : 30%	20	23,8912 %
80% : 20%	50	24,4673 %
90% : 10%	25	23,8335 %

Tabel 8 menunjukkan bahwa nilai MAPE terkecil berada pada kombinasi Data 40% : 60% dengan *hidden layer* sejumlah 20 buah yaitu sebesar 23,1125 %. Sehingga kombinasi data 40% : 60% dengan 20 buah *hidden layer* merupakan kombinasi yang optimal untuk digunakan dalam prediksi kondisi trafo.

Analisis Perbandingan Hasil Prediksi dengan Data Aktual
Berdasarkan pengujian yang dilakukan, maka pembagian data *training* : *testing* yang digunakan adalah 40%:60%, jumlah *hidden layer* 20 buah, jumlah fitur (*input layer*) 14 buah, dan 1 *output layer* (hasil prediksi).

Berdasarkan kombinasi tersebut, data hasil prediksi yang diperoleh serta data aktual ditunjukkan pada Gambar 8.



Gambar 8. Grafik Perbandingan Data Aktual dan Hasil Prediksi

Gambar 8 merupakan perbandingan data aktual dan hasil prediksi dengan nilai MAPE sebesar 22,6047%. Hasil prediksi kondisi trafo pada data *testing* ke-40 sebanyak 21,40 memiliki selisih terendah yaitu 0.175 dengan data aktual sebanyak 21,58. Sedangkan data *testing* ke-125 dengan hasil prediksi 29,81 dan data aktual 69,42 memiliki selisih tertinggi yaitu 39,610. Grafik diatas juga menunjukkan pola hasil prediksi cenderung mengikuti pola data aktual. Sehingga penerapan metode ELM dapat dikatakan cukup baik dalam memprediksi kondisi trafo yang dilihat dari *Health Index*.

4. Kesimpulan dan Saran

Berdasarkan hasil penerapan metode *Extreme Learning Machine* (ELM) dalam memprediksi kondisi trafo dan perhitungan akurasi hasil prediksi dengan nilai MAPE pada dataset Kondisi Kesehatan trafo dari Kaggle, maka dapat disimpulkan sebagai berikut : 1) Metode *Extreme Learning Machine* (ELM) mampu menyelesaikan permasalahan prediksi kondisi trafo dengan nilai kesalahan terendah. Proses penerapan metode ELM dimulai dengan normalisasi data, kemudian pembagian data *training* : *testing*, inialisasi bobot dan bias secara acak, selanjutnya melakukan proses *training* dan *testing*, setelah itu hasil prediksi di denormalisasi ke dalam bentuk nilai aktual, dan

kemudian dilakukan perhitungan nilai kesalahan dengan MAPE. 2) Penelitian menunjukkan bahwa nilai MAPE pada prediksi kondisi trafo dipengaruhi oleh jumlah kombinasi data training: testing dan jumlah hidden layer. Hasil penelitian menunjukkan bahwa kombinasi data 40%:60% dengan 20 hidden layer menghasilkan rata-rata MAPE terendah, yaitu 23,1125%. 3) Perbandingan data aktual dan hasil prediksi dari kombinasi data 40%:60% dengan *hidden layer* 20, menghasilkan nilai MAPE sebesar 22,6047%, dengan selisih terendah 0,175 dari hasil prediksi 21,40 dan data aktual 21,58, serta selisih tertinggi yaitu 39,610 dari hasil prediksi 29,81 dan data aktual 69,42. Sehingga Penerapan metode ELM cukup baik dalam memprediksi kondisi trafo.

Saran yang dapat diberikan untuk penelitian selanjutnya yaitu: 1) Diharapkan adanya penggabungan metode lain dengan metode ELM seperti metode optimasi atau metode kecerdasan buatan lainnya, agar hasil prediksi yang diperoleh lebih optimal dan mendapat selisih yang minimal juga. Atau juga bisa menggunakan metode lain untuk membandingkan hasil prediksinya. 2) menambah skenario pengujian berupa pengujian bobot dan fungsi aktivasi, sehingga dapat mengetahui pengaruh parameter selain parameter yang digunakan dalam penelitian ini. 3) Penelitian selanjutnya untuk memprediksi trafo yang dilihat dari nilai *Health Index* (HI), diharapkan dapat menyesuaikan data sensor sebagai fitur atau *input layer*, dan juga cara perhitungan HI dari tiap-tiap penyedia layanan monitoring kondisi trafo.

5. Daftar Pustaka

- [1] Statistik PLN 2021. 2021. PT PLN (Persero), Jakarta. Available at: <https://web.pln.co.id/statics/uploads/2022/03/Statistik-PLN-2021-Unaudited-21.2.22.pdf>.
- [2] Soedjarwanto, N. and Nama, G.F., 2019. Monitoring Arus, Tegangan dan Daya pada Transformator Distribusi 20 KV Menggunakan Teknologi Internet of Things. *Jurnal EECCIS*, 13(3). pp. 128–133. Available: <https://jurnaleeccis.ub.ac.id/>.
- [3] Nugraha, I.M.A. and Desnanjaya, I.G.M.N., 2021. Penempatan dan Pemilihan Kapasitas Transformator Distribusi Secara Optimal Pada Penyulang Perumnas. *Jurnal RESISTOR (Rekayasa Sistem Komputer)*, 4(1), pp.33-44. DOI: <https://doi.org/10.31598/jurnalresistor.v4i1.722>.
- [4] Ir Denny Richard Pattiapon, M.T., 2017. TINJAUAN PENGAMAN GARDU DISTRIBUSI 37A TERHADAP LEDAKAN TRAF0 DI SKIP DALAM PALDAM. *JURNAL SIMETRIK*, 7(2), pp. 31–37. DOI: <https://doi.org/10.31959/js.v7i2.47>.
- [5] de Fretes, R., 2022. Analisis Penyebab Kerusakan Transformator menggunakan Metode RCA (Fishbone diagram and 5-Why Analysis) di PT. PLN (Persero) Kantor Pelayanan Kiandarat. *ARIKA*, 16(2), pp.117-124. DOI: <https://doi.org/10.30598/arika.2022.16.2.117>.
- [6] Zebua, O., Endah, K., Syaiful, A. and Aldiansyah, A., 2021. Rancang Bangun Alat Monitoring Ketidakseimbangan Beban Transformator Distribusi Berbasis Internet of Things. *Electrician–Jurnal Rekayasa dan Teknologi Elektro*, 15(2), pp.146-152. .
- [7] Madjid, A.R. and Suprianto, B., 2019. Prototype Monitoring Arus, dan Suhu pada Transformator Distribusi Berbasis Internet Of Things (IoT). *Jurnal Teknik Elektro*, 8(1), pp. 111–119.
- [8] Prasetyo, B.E., Putra, W.H.N., Syauqy, D., Bhawiyuga, A., Wibowo, S.S., Ronilaya, F., Siradjuddin, I. and Adhisuwignjo, S., 2020. Sistem Monitoring Trafo Distribusi PT. PLN (Persero) berbasis IoT. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 7(1), pp.205-210. DOI: <https://doi.org/10.25126/jtiik.202071951>.
- [9] Id, I.D., 2021. *Machine Learning: Teori, Studi Kasus dan Implementasi Menggunakan Python* (Vol. 1). Unri Press.

- [10] Faizal, R., Setiawan, B.D. and Cholisoddin, I., 2019. Prediksi Nilai Cryptocurrency Bitcoin menggunakan Algoritme Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(5), pp.4226-4233.
- [11] Huang, G.B., Zhu, Q.Y. and Siew, C.K., 2004, July. Extreme learning machine: a new learning scheme of feedforward neural networks. In *2004 IEEE international joint conference on neural networks (IEEE Cat. No. 04CH37541)* (Vol. 2, pp. 985-990). IEEE. DOI: <https://doi.org/10.1109/IJCNN.2004.1380068>.
- [12] Huang, G.B., Zhu, Q.Y. and Siew, C.K., 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3), pp.489-501. DOI: <https://doi.org/10.1016/j.neucom.2005.12.126>.
- [13] Huang, G.B., Zhou, H., Ding, X. and Zhang, R., 2011. Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), pp.513-529. DOI: <https://doi.org/10.1109/TSMCB.2011.2168604>.
- [14] Adiatmaja, P.B., Setiawan, B.D. and Wihandika, R.C., 2019. Peramalan Harga Cabai Merah Besar Wilayah Jawa Timur Menggunakan Metode Extreme Learning Machine. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(6), pp.5444-5449.
- [15] Izati, N.A., Warsito, B. and Widiharhi, T., 2019. Prediksi Harga Emas Menggunakan Feed Forward Neural Network Dengan Metode Extreme Learning Machine. *Jurnal Gaussian*, 8(2), pp.171-183. DOI: <https://doi.org/10.14710/j.gauss.8.2.171-183>.
- [16] Kertayuga, D., Santoso, E. and Hidayat, N., 2021. Prediksi Nilai Ekspor Impor Migas Dan Non-Migas Indonesia Menggunakan Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 5(6), pp.2792-2800.