

Prediksi Curah Hujan Menggunakan Jaringan Syaraf Tiruan *Backpropagation* pada *Software* Matlab

Muhammad Erlangga Prasetya^{1*}, Eddy Ryansyah¹, Muhammad Rusfauzi Surya¹, Yuyun Umaidah¹

¹ Fakultas Ilmu Komputer, Program Studi Informatika, Universitas Singaperbangsa Karawang, Karawang, Indonesia

Email: ^{1*}gaaerlang03@gmail.com, ¹eddyryansyah1612@gmail.com, ¹2110631170084@student.unsika.ac.id,

¹yuyun.umaidah@staff.unsika.ac.id

Email Penulis Korespondensi: gaaerlang03@gmail.com

Artikel Info :

Artikel History :

Submitted : 13-06-2025

Accepted : 22-07-2025

Published : 30-09-2025

Kata Kunci:

Prediksi_Curah_Hujan;
Jaringan_Syaraf_Tiruan;
Backpropagation;
Matlab;
Pengembangan_Model_
Prediksi

Keyword:

Rainfall_Prediction;
Artificial_Neural_Netwo
rk; Backpropagation;
Matlab;
Prediction_Model_Deve
lopment

Abstrak—Penelitian ini bertujuan untuk merancang dan mengimplementasikan model prediksi curah hujan menggunakan pendekatan Jaringan Syaraf Tiruan (JST) dengan algoritma pembelajaran *backpropagation* pada platform Matlab. Prediksi curah hujan merupakan aspek penting dalam bidang pertanian, hidrologi, dan pengelolaan sumber daya air, yang membutuhkan metode akurat dan adaptif terhadap pola data musiman. Dalam penelitian ini, data curah hujan bulanan Kota Bogor periode 2020-2022 digunakan sebagai *dataset* pelatihan dan pengujian. Data tersebut dinormalisasi menggunakan fungsi aktivasi *sigmoid* untuk meningkatkan performa pelatihan jaringan. Arsitektur jaringan terdiri dari 12 neuron input, 10 neuron tersembunyi, dan 1 neuron *output*. Hasil pelatihan menunjukkan tingkat kesalahan (*Mean Squared Error*) sebesar 0.00090677 dengan nilai regresi 0.99022, sedangkan hasil pengujian menghasilkan regresi sebesar 0.98837. Temuan ini menunjukkan bahwa metode *backpropagation* pada JST mampu memprediksi curah hujan secara efektif dan akurat. Model ini dapat dikembangkan lebih lanjut untuk memprediksi fenomena cuaca lainnya.

Abstract—This study aims to design and implement a rainfall prediction model using the Artificial Neural Network (ANN) approach with the backpropagation learning algorithm on the Matlab platform. Rainfall prediction is an important aspect in agriculture, hydrology, and water resources management, which requires accurate and adaptive methods to seasonal data patterns. In this study, monthly rainfall data for Bogor City for the period 2020-2022 was used as the training and testing dataset. The data was normalized using the sigmoid activation function to improve the network training performance. The network architecture consists of 12 input neurons, 10 hidden neurons, and 1 output neuron. The training results showed an error rate (Mean Squared Error) of 0.00090677 with a regression value of 0.99022, while the test results produced a regression of 0.98837. These findings indicate that the backpropagation method in ANN is able to predict rainfall effectively and accurately. This model can be further developed to predict other weather phenomena.

1. PENDAHULUAN

Indonesia merupakan negara yang memiliki dua musim utama, yaitu musim hujan dan musim kemarau, yang secara umum terjadi secara bergantian sepanjang tahun [1]. Puncak musim kemarau umumnya terjadi pada bulan Juni hingga Agustus, sedangkan musim hujan mencapai puncaknya pada bulan Desember hingga Februari [2]. Perubahan pola cuaca, khususnya intensitas curah hujan, berpengaruh besar terhadap berbagai sektor, seperti pertanian, transportasi, industri, dan pengelolaan sumber daya air [3]. Dalam sektor pertanian, ketersediaan air yang dipengaruhi oleh curah hujan menjadi faktor penting dalam mendukung masa tanam, khususnya komoditas seperti padi yang sangat tergantung pada irigasi dan distribusi air yang tepat [4].

Prediksi curah hujan menjadi salah satu upaya penting untuk mengantisipasi dan merencanakan kegiatan yang bergantung pada kondisi iklim [5]. Meskipun curah hujan bersifat fluktuatif dan tidak dapat ditentukan secara pasti, perkembangan teknologi memungkinkan analisis pola historis curah hujan untuk menghasilkan prediksi yang mendekati kenyataan [6].

Beberapa penelitian sudah dilakukan untuk mengatasi permasalahan tersebut dengan menggunakan berbagai pendekatan. Misalnya penelitian yang dilakukan oleh Nanlohy & Haumahu [7] yang menggunakan *Autoregressive Integrated Moving Average* (ARIMA) untuk memprediksi curah hujan di Kota Surabaya. Meskipun ARIMA memberikan hasil yang cukup baik di beberapa kondisi, metode ini memiliki keterbatasan, terutama dalam menangani fluktuasi curah hujan yang tidak stabil dan musiman. ARIMA juga memerlukan data yang lebih panjang dan sering kali tidak efektif ketika data curah hujan tidak stasioner atau memiliki pola musiman yang beragam setiap tahunnya. Oleh karena keterbatasan tersebut, diperlukan metode yang lebih adaptif untuk menangani data yang kompleks. Dalam hal ini, salah satu metode yang terbukti efektif dalam melakukan prediksi berbasis data historis adalah dengan menggunakan Jaringan Syaraf Tiruan (JST) [8].

Jaringan Syaraf Tiruan merupakan model pemrosesan informasi yang meniru cara kerja otak manusia, terdiri atas neuron-neuron buatan yang saling terhubung dan mampu mempelajari pola dari data melalui proses pelatihan [9]. JST memiliki kemampuan generalisasi dan adaptasi yang tinggi, sehingga sering digunakan dalam berbagai tugas prediktif, termasuk peramalan cuaca [10]. Berbagai arsitektur JST telah dikembangkan, seperti *perceptron*, *feedforward*, *Adaline*, *Madaline*, dan *backpropagation*. Di antara berbagai algoritma pelatihan, *backpropagation* merupakan salah satu yang paling umum digunakan karena kemampuannya dalam memperbarui bobot secara iteratif berdasarkan *error* yang dihasilkan [11].

Dalam konteks prediksi curah hujan, algoritma *backpropagation* bekerja dengan memasukkan data input berupa nilai curah hujan historis yang telah dinormalisasi, kemudian mempelajari pola hubungan antara input dan target *output* melalui proses pelatihan yang berulang [12]. Proses ini menghasilkan model prediktif yang mampu memberikan estimasi nilai curah hujan di masa depan dengan akurasi yang cukup tinggi [13].

Kota Bogor dipilih sebagai objek penelitian karena memiliki karakteristik cuaca yang representatif untuk daerah tropis Indonesia. Dengan musim hujan yang intens pada periode tertentu dan musim kemarau yang relatif lebih pendek. Letaknya yang berada di daerah dataran tinggi dapat mempengaruhi pola curah hujan yang umumnya lebih tinggi dibandingkan dengan daerah dataran rendah, sehingga data curah hujan Kota Bogor memberikan gambaran yang akurat mengenai pola perubahan curah hujan musiman, yang sangat dipengaruhi oleh faktor geografis dan iklim.

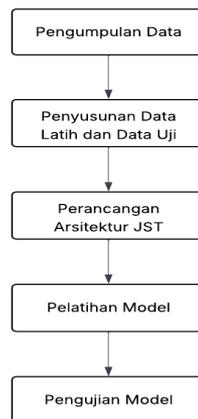
Matlab digunakan dalam penelitian ini sebagai perangkat lunak pendukung karena menyediakan fungsi-fungsi numerik dan antarmuka pemrograman yang memudahkan dalam perancangan serta pelatihan jaringan syaraf tiruan [14]. Dengan memanfaatkan kemampuan Matlab dalam simulasi dan analisis numerik, model prediksi curah hujan dapat diimplementasikan secara efisien dan dievaluasi secara kuantitatif.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun model prediksi curah hujan menggunakan Jaringan Syaraf Tiruan dengan algoritma *backpropagation* berbasis Matlab. Diharapkan model ini dapat menjadi solusi yang mendukung pengambilan keputusan dalam bidang pertanian, mitigasi bencana banjir, dan manajemen sumber daya air secara lebih akurat dan adaptif.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan teknis dengan memanfaatkan algoritma *backpropagation* pada Jaringan Syaraf Tiruan (JST) untuk melakukan prediksi curah hujan berdasarkan data historis. Seluruh proses dilakukan menggunakan *software* Matlab untuk mendukung tahap pemodelan, pelatihan, dan pengujian jaringan.



Gambar 1. Tahapan penelitian

Secara umum, tahapan penelitian ini dimulai dari pengumpulan data, yang kemudian dilanjutkan dengan proses normalisasi data mentah. Setelah data dinormalisasi, dilakukan penyusunan data latih dan data uji menggunakan teknik *sliding window*. Proses ini diulang terus-menerus sepanjang deret waktu data, sehingga menghasilkan serangkaian pasangan input-output yang digunakan untuk melatih JST dalam mengenali pola musiman curah hujan. Pembagian data ini dilakukan dengan rasio 50% untuk data latih (2020-2021) dan 50% untuk data uji (2021-2022), berdasarkan jumlah pola yang dihasilkan setelah *sliding window*. Tahapan selanjutnya adalah perancangan arsitektur JST, diikuti dengan pelatihan model menggunakan data latih. Terakhir, model yang telah terlatih diuji menggunakan data uji untuk mengevaluasi kinerjanya.

2.1.1 Pengumpulan Data

Data curah hujan bulanan Kota Bogor selama periode 2020-2022 digunakan sebagai dasar dalam proses pelatihan dan pengujian. Data ini diperoleh dari Badan Pusat Statistik Provinsi Jawa Barat dan mencakup nilai curah hujan dalam satuan milimeter (mm) per bulan.

Tabel 1. Data curah hujan Kota Bogor (mm)

Bulan/Tahun	2020	2021	2022
Januari	207.6	304.3	106.6
Februari	336.6	486.8	150.3
Maret	292.5	233.0	113.2
April	271.4	505.1	316.6
Mei	292.3	510.3	228.5
Juni	30.3	311.1	463.7
Juli	63.7	115.6	358.1
Agustus	41.6	399.5	384.9
September	87.7	317.3	353.7
Oktober	327.3	566.5	492.3
November	207.3	183.6	321.0
Desember	262.1	279.1	224.1

Sebelum digunakan dalam pelatihan, data dinormalisasi ke dalam rentang 0.1 hingga 0.9 agar sesuai dengan fungsi aktivasi *sigmoid* yang digunakan dalam JST [15]. Proses normalisasi dilakukan menggunakan rumus berikut:

$$x' = \frac{0.8 \times (x - b)}{a - b} + 0.1 \quad (1)$$

Keterangan:

x' = Data hasil normalisasi

x = Data asli

a = Nilai maksimum

b = Nilai minimum

Tabel 2. Data curah hujan Kota Bogor setelah dinormalisasi (mm)

Bulan/Tahun	2020	2021	2022
Januari	0.3642373	0.50892979	0.2135004
Februari	0.55676264	0.78067906	0.27909334
Maret	0.49107021	0.40289161	0.22384802
April	0.459704	0.80886139	0.52691375
Mei	0.49102046	0.81637336	0.39555376
Juni	0.1	0.51932716	0.74632796
Juli	0.14935016	0.2269324	0.58947205
Agustus	0.11649151	0.65076177	0.6284746
September	0.18516883	0.52833157	0.58215907
Oktober	0.54325602	0.9	0.78950936
November	0.36416268	0.32841863	0.53422673
Desember	0.44619738	0.47156893	0.38948448

2.1.2 Penyusunan Data Latih dan Data Uji

Data yang telah dinormalisasi kemudian dibagi menjadi dua bagian, yaitu data latih dan data uji. Data latih terdiri atas data curah hujan tahun 2020 hingga 2021, sedangkan data uji menggunakan data dari tahun 2021 hingga 2022. Teknik *sliding window* digunakan untuk menyusun pola data, yaitu dengan menggunakan 12 bulan berturut-turut sebagai input dan bulan ke-13 sebagai target prediksi.

Tabel 3. Data latih

Pola	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
1	0.364	0.557	0.491	0.46	0.491	0.1	0.149	0.116	0.185	0.543	0.364	0.446	0.509
2	0.557	0.491	0.46	0.491	0.1	0.149	0.116	0.185	0.543	0.364	0.446	0.509	0.781
3	0.491	0.46	0.491	0.1	0.149	0.116	0.185	0.543	0.364	0.446	0.509	0.781	0.403

Pola	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
4	0.46	0.491	0.1	0.149	0.116	0.185	0.543	0.364	0.446	0.509	0.781	0.403	0.809
5	0.491	0.1	0.149	0.116	0.185	0.543	0.364	0.446	0.509	0.781	0.403	0.809	0.816
6	0.1	0.149	0.116	0.185	0.543	0.364	0.446	0.509	0.781	0.403	0.809	0.816	0.519
7	0.149	0.116	0.185	0.543	0.364	0.446	0.509	0.781	0.403	0.809	0.816	0.519	0.227
8	0.116	0.185	0.543	0.364	0.446	0.509	0.781	0.403	0.809	0.816	0.519	0.227	0.651
9	0.185	0.543	0.364	0.446	0.509	0.781	0.403	0.809	0.816	0.519	0.227	0.651	0.528
10	0.543	0.364	0.446	0.509	0.781	0.403	0.809	0.816	0.519	0.227	0.651	0.528	0.9
11	0.364	0.446	0.509	0.781	0.403	0.809	0.816	0.519	0.227	0.651	0.528	0.9	0.328
12	0.446	0.509	0.781	0.403	0.809	0.816	0.519	0.227	0.651	0.528	0.9	0.328	0.472

Pada Tabel 3 menampilkan data yang digunakan untuk melatih Jaringan Syaraf Tiruan (JST). Data latih ini diambil dari hasil normalisasi curah hujan Kota Bogor pada periode tahun 2020 hingga 2021. Setiap baris dalam tabel ini merepresentasikan satu pola data (*sliding window*). Kolom “x1” hingga “x12” adalah 12 bulan data curah hujan berturut-turut yang menjadi input bagi JST, dan kolom “Target” adalah nilai curah hujan bulan ke-13 yang menjadi target prediksi. Total terdapat 12 pola data latih dalam tabel ini.

Tabel 4. Data uji

Pola	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
1	0.509	0.781	0.403	0.809	0.816	0.519	0.227	0.651	0.528	0.9	0.328	0.472	0.214
2	0.781	0.403	0.809	0.816	0.519	0.227	0.651	0.528	0.9	0.328	0.472	0.214	0.279
3	0.403	0.809	0.816	0.519	0.227	0.651	0.528	0.9	0.328	0.472	0.214	0.279	0.224
4	0.809	0.816	0.519	0.227	0.651	0.528	0.9	0.328	0.472	0.214	0.279	0.224	0.527
5	0.816	0.519	0.227	0.651	0.528	0.9	0.328	0.472	0.214	0.279	0.224	0.527	0.396
6	0.519	0.227	0.651	0.528	0.9	0.328	0.472	0.214	0.279	0.224	0.527	0.396	0.746
7	0.227	0.651	0.528	0.9	0.328	0.472	0.214	0.279	0.224	0.527	0.396	0.746	0.589
8	0.651	0.528	0.9	0.328	0.472	0.214	0.279	0.224	0.527	0.396	0.746	0.589	0.628
9	0.528	0.9	0.328	0.472	0.214	0.279	0.224	0.527	0.396	0.746	0.589	0.628	0.582
10	0.9	0.328	0.472	0.214	0.279	0.224	0.527	0.396	0.746	0.589	0.628	0.582	0.79
11	0.328	0.472	0.214	0.279	0.224	0.527	0.396	0.746	0.589	0.628	0.582	0.79	0.534
12	0.472	0.214	0.279	0.224	0.527	0.396	0.746	0.589	0.628	0.582	0.79	0.534	0.389

Kemudian pada Tabel 4 berisi data yang digunakan untuk menguji kinerja JST setelah proses pelatihan. Data uji ini berasal dari hasil normalisasi curah hujan Kota Bogor pada periode tahun 2021 hingga 2022. Sama seperti data latih, setiap baris menunjukkan satu pola data (*sliding window*) dengan “x1” hingga “x12” sebagai input dan “Target” sebagai nilai curah hujan bulan ke-13 yang akan dibandingkan dengan hasil prediksi JST. Total terdapat 12 pola data uji dalam tabel ini.

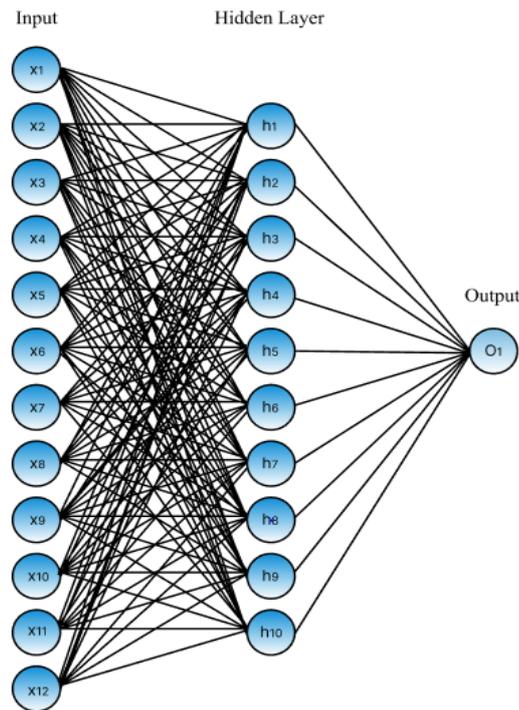
Tabel 5. Mekanisme penyusunan data latih dan uji

Pola	x1 sampai x12	Target
1	Data hasil normalisasi bulan ke-1 sampai bulan ke-12	Data target hasil normalisasi bulan ke-13
2	Data hasil normalisasi bulan ke-1 sampai bulan ke-13	Data target hasil normalisasi bulan ke-14
3	Data hasil normalisasi bulan ke-1 sampai bulan ke-14	Data target hasil normalisasi bulan ke-15
4	Data hasil normalisasi bulan ke-1 sampai bulan ke-15	Data target hasil normalisasi bulan ke-16
...
12	Data hasil normalisasi bulan ke-1 sampai bulan ke-n	Data target hasil normalisasi bulan ke-n

Dapat dilihat pada Tabel 5 merupakan mekanisme dalam penyusunan data latih dan uji dari data hasil normalisasi data asli curah hujan Kota Bogor pada tahun 2020 sampai tahun 2021 dan pada tahun 2021 sampai tahun 2022.

2.1.3 Perancangan Arsitektur Jaringan

Jaringan syaraf tiruan yang dirancang memiliki 12 neuron input yang merepresentasikan 12 bulan data curah hujan, 1 *hidden layer* dengan 10 neuron, dan 1 neuron *output* yang mewakili hasil prediksi curah hujan untuk bulan berikutnya.



Gambar 2. Arsitektur jaringan syaraf tiruan

2.1.4 Pelatihan

Pada tahap pelatihan, digunakan metode *backpropagation* pada jaringan syaraf tiruan dengan arsitektur yang telah dirancang sebelumnya. Ada beberapa parameter yang mempengaruhi proses pelatihan, yaitu:

- Goal* dengan nilai 0.001. *Goal* merupakan nilai yang menentukan target *error* yang menjadi nilai ukur untuk pemberhentian di mana proses pelatihan akan berhenti jika telah menemui target *error* [16].
- Epoch* sebesar 1000, *epoch* menandakan satu siklus algoritma yang belajar dari seluruh set data latih [17].
- LR atau *learning rate*, menggunakan 0.1 untuk mengontrol perubahan bobot selama pelatihan [18].

Selanjutnya data hasil pelatihan akan disimpan di dalam jaringan *net_keluaran*. Lalu, hasil akan dibandingkan dengan data latih.

```
filename = 'Data.xlsx';
sheet = 2;
xlRange = 'D6:P17';
data = xlsread(filename, sheet, xlRange);
data_latih = Data(:,1:12);
target_latih = Data(:,13);
[m,n] = size(data_latih);

% Pembuatan JST
net = newff(minmax(data_latih), [10 1], {'logsig','purelin'},'traingdx');

% Memberikan nilai untuk mempengaruhi proses pelatihan
net.performFcn = 'mse';
net.trainParam.goal = 0.001;
net.trainParam.show = 20;
net.trainParam.epochs = 1000;
net.trainParam.mc = 0.95;
net.trainParam.lr = 0.1;

% Proses training
[net_keluaran,tr,Y,E] = train(net,data_latih,target_latih);

% Hasil setelah pelatihan
bobot_hidden = net_keluaran.IW(1,1);
bobot_keluaran = net_keluaran.LW(2,1);
bias_hidden = net_keluaran.b(1,1);
bias_keluaran = net_keluaran.b(2,1);
jumlah_iterasi = tr.num_epochs;
nilai_keluaran = Y;
nilai_error = E;
error_MSE = (1/n)*sum(nilai_error.^2);

save net.mat net_keluaran;

% Hasil prediksi
hasil_latih = sim(net_keluaran,data_latih);
max_data = 566.5;
min_data = 30.3;
hasil_latih = ((hasil_latih-0.1)*(max_data-min_data)/0.8)+min_data;

% Performansi hasil prediksi
filename = 'Data.xlsx';
sheet = 1;
xlRange = 'E7:P7';
target_latih Asli = xlsread(filename, sheet, xlRange);
```

Gambar 3. Kode program pelatihan

2.1.5 Pengujian

Model yang telah dilatih kemudian diuji menggunakan data uji untuk mengevaluasi kemampuan generalisasi jaringan terhadap data baru. Evaluasi dilakukan dengan menghitung kesalahan dan nilai regresi terhadap *output* target.

```
% Load jaringan yang sudah dibuat pada proses pelatihan
load net_net

% Proses membaca data uji normalisasi dari excel
filename = 'Data.xlsx';
sheet = 2;
xlRange = 'D24:P35';
Data = xlsread(filename, sheet, xlRange);
data_uji = Data(:, 1:12);
target_uji = Data(:, 13);
[m, n] = size(data_uji);

% Hasil prediksi
hasil_uji = sim(net_keluaran, data_uji);
nilai_error = hasil_uji - target_uji;

max_data = 566.5;
min_data = 30.3;
hasil_uji_esli = ((hasil_uji - 0.1) * (max_data - min_data) / 0.8) + min_data;

% Performasi hasil prediksi
error_MSE = (1 / n) * sum(nilai_error.^2);

% Baca target uji asli dari excel
filename = 'Data.xlsx';
sheet = 1;
xlRange = 'E8:P8';
target_uji_asli = xlsread(filename, sheet, xlRange);
```

Gambar 4. Kode program pengujian

```
% Menyiapkan data prediksi
data_prediksi = hasil_uji(end-11:end);
data_prediksi = data_prediksi';

% Melakukan prediksi
hasil_prediksi = sim(net_keluaran, data_prediksi);
for n = 1:11
    data_prediksi = [data_prediksi(end-10:end); hasil_prediksi(end)];
    hasil_prediksi = [hasil_prediksi; sim(net_keluaran, data_prediksi)];
end

hasil_prediksi_esli = ((hasil_prediksi - 0.1) * (max_data - min_data) / 0.8) + min_data;

% Melakukan denormalisasi terhadap hasil prediksi
hasil_prediksi_esli1 = round(hasil_prediksi_esli * (max_data - min_data) + min_data);

% Grafik hasil prediksi
figure
plot(hasil_prediksi_esli1, 'mo-')
grid on
title('Grafik Keluaran JST Prediksi Tahun 2023')
xlabel('Pola ke-')
ylabel('Curah Hujan (mm/hari)')
legend('Keluaran JST')
```

Gambar 5. Kode program pengujian dan prediksi

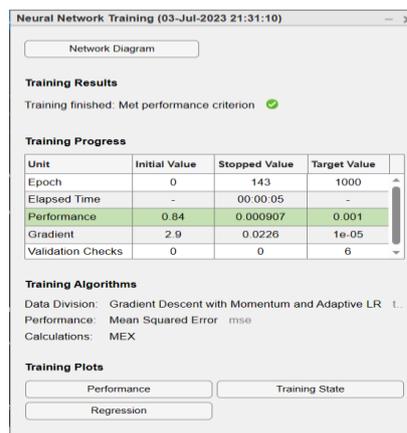
3. HASIL DAN PEMBAHASAN

Bagian ini membahas hasil pelatihan, pengujian, dan prediksi curah hujan yang dilakukan dengan menggunakan jaringan syaraf tiruan berbasis *backpropagation* pada platform Matlab. Setiap hasil yang diperoleh dianalisis secara deskriptif melalui grafik dan data numerik, untuk menilai sejauh mana akurasi dan efisiensi model dalam melakukan prediksi.

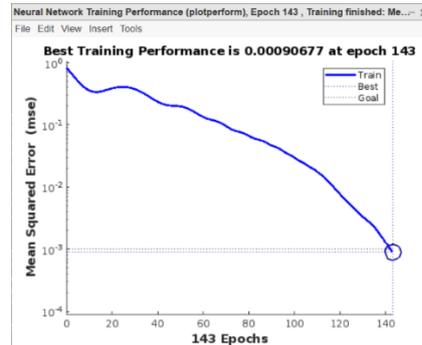
3.1 Hasil

3.1.1 Hasil Pelatihan

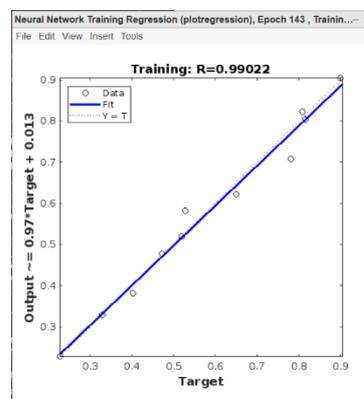
Proses pelatihan dilakukan menggunakan parameter yang telah ditentukan sebelumnya, yaitu jumlah *epoch* sebanyak 1000, *learning rate* sebesar 0.1, dan target *error* (*goal*) sebesar 0.001. Hasil pelatihan ditunjukkan pada Gambar 6, 7, dan 8.



Gambar 6. Hasil pelatihan jaringan syaraf tiruan



Gambar 7. Grafik Mean Squared Error (MSE)

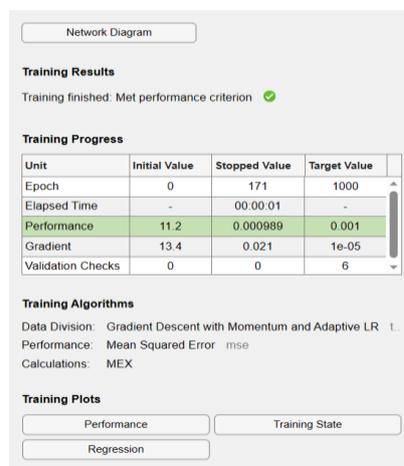


Gambar 8. Grafik regresi pelatihan

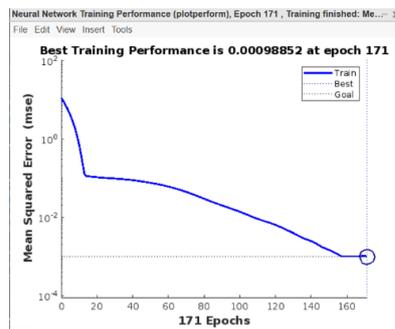
Berdasarkan hasil pelatihan, didapatkan bahwa performa terbaik jaringan tercapai pada *epoch* ke-143 dengan nilai MSE sebesar 0.00090677 dan nilai regresi sebesar 0.99022. Hal ini menunjukkan bahwa model mampu mengenali pola data secara efektif dan konsisten terhadap target.

3.1.2 Hasil Pengujian

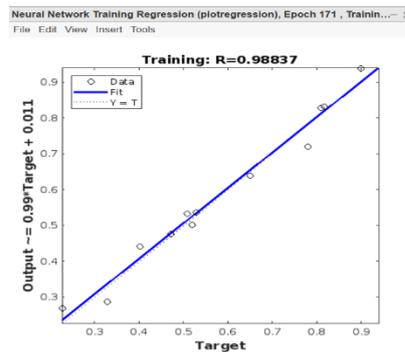
Setelah proses pelatihan, model diuji menggunakan data yang belum pernah dilihat sebelumnya untuk mengevaluasi kemampuan generalisasi jaringan.



Gambar 9. Hasil pengujian jaringan syaraf tiruan



Gambar 10. Grafik *mean squared error* pengujian



Gambar 11. Grafik regresi pengujian

3.1.3 Evaluasi Metrik Tambahan

Untuk memperkuat validitas hasil, dilakukan perhitungan metrik evaluasi tambahan yaitu *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE). Perhitungan dilakukan baik untuk data latih maupun data uji.

Tabel 6. Perbandingan metrik evaluasi antara data latih dan data uji

Metrik	Data Latih	Data Uji	Selisih
MSE	0.00090677	0.00098552	0.00007875
RMSE	0.03011	0.03143	0.00132
MAE	0.02345	0.02891	0.00546
MAPE (%)	8.42	10.76	2.34
R ²	0.99022	0.98837	0.00185

3.1.4 Analisis Prediksi per Bulan

Untuk mengevaluasi performa model secara lebih detail dan mengidentifikasi pola temporal dalam akurasi prediksi, dilakukan analisis prediksi curah hujan berdasarkan periode bulanan selama satu tahun penuh. Analisis ini bertujuan untuk mengamati konsistensi model dalam memprediksi curah hujan pada setiap bulan, mengidentifikasi periode dengan tingkat akurasi tertinggi dan terendah, serta memahami variasi kesalahan prediksi yang terjadi sepanjang tahun, sehingga dapat memberikan gambaran komprehensif mengenai kemampuan model dalam menangani fluktuasi musiman curah hujan di Kota Bogor.

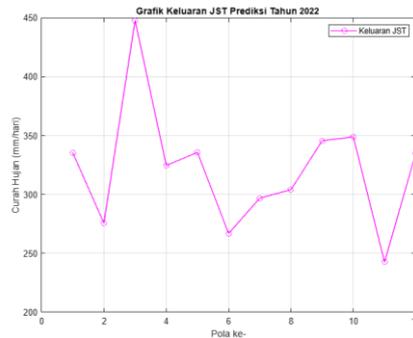
Tabel 7. Analisis prediksi per bulan (data uji)

Bulan	Target Aktual (mm)	Prediksi (mm)	Absolute Error (mm)	Percentage Error (%)
Januari	106.6	211.1	104.5	98.02
Februari	150.3	258.3	108.0	71.83
Maret	113.2	325.8	212.6	187.87
April	316.6	312.8	3.8	1.20
Mei	228.5	294.2	65.7	28.78
Juni	463.7	310.7	153.0	33.03
Juli	358.1	134.4	223.7	62.44
Agustus	384.9	144.7	240.2	62.46
September	353.7	62.2	291.5	82.43

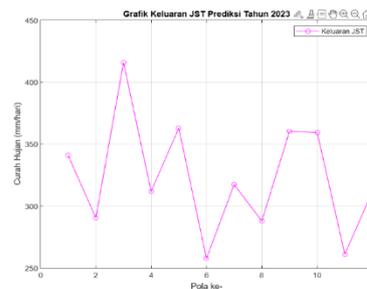
Bulan	Target Aktual (mm)	Prediksi (mm)	Absolute Error (mm)	Percentage Error (%)
Oktober	492.3	102.1	390.2	79.23
November	321.0	1068.0	253.8	79.09
Desember	224.1	563.6	339.5	151.58

3.1.5 Hasil Prediksi

Model kemudian digunakan untuk memprediksi curah hujan bulanan di Kota Bogor pada tahun 2023. Hasil prediksi disajikan dalam bentuk grafik pada Gambar 12 dan 13 serta dalam Tabel 8.



Gambar 12. Grafik pengujian curah hujan tahun 2022



Gambar 13. Grafik prediksi curah hujan tahun 2023

Kedua grafik di atas menunjukkan pola visual yang mirip. Ini mengindikasikan bahwa jaringan syaraf tiruan berhasil mengenali tren musiman yang ada dalam data historis.

Tabel 8. Hasil prediksi curah hujan Kota Bogor tahun 2023

Bulan	Curah Hujan (mm/hari)
Januari	340.9146
Februari	290.5618
Maret	415.7014
April	311.8902
Mei	362.8715
Juni	257.7904
Juli	317.4057
Agustus	287.9731
September	360.3675
Oktober	359.2568
November	261.2172
Desember	311.8516

3.2 Pembahasan

3.2.1 Analisis Performa Model

Pada bagian ini, performa model Jaringan Syaraf Tiruan (JST) yang telah dilatih dengan algoritma *backpropagation* akan dibahas secara mendalam. Model ini menunjukkan kemampuan yang kuat dalam mempelajari dan merepresentasikan pola curah hujan musiman di Kota Bogor. Indikasi utama dari akurasi model yang tinggi terlihat dari nilai koefisien determinasi (R^2) yang konsisten tinggi, yaitu lebih dari 0.98, baik pada

data yang digunakan untuk pelatihan maupun pada data uji yang belum pernah dilihat model sebelumnya. Nilai R^2 yang mendekati 1 ini secara statistik mengonfirmasi bahwa model sangat baik dalam menjelaskan variabilitas data curah hujan aktual dan dapat diandalkan untuk prediksi.

Selain itu, untuk memberikan gambaran yang lebih komprehensif mengenai validitas hasil, telah dilakukan perhitungan metrik evaluasi tambahan, yaitu *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE), seperti yang disajikan pada Tabel 7. Metrik MAE memberikan informasi mengenai rata-rata selisih absolut antara nilai prediksi model dan nilai curah hujan aktual, yang menunjukkan seberapa dekat prediksi model terhadap nilai sebenarnya dalam satuan milimeter. Sementara itu, MAPE menawarkan perspektif kesalahan dalam bentuk persentase, membuatnya lebih mudah diinterpretasikan oleh berbagai pemangku kepentingan. Nilai MAPE keseluruhan yang relatif rendah, di bawah 11% (tepatnya 10.76% untuk data uji), mengindikasikan bahwa rata-rata kesalahan prediksi model dalam bentuk persentase adalah kecil. Ini berarti selisih antara *output* prediksi dengan data aktual tidak terlalu besar, sehingga hasil prediksi yang dihasilkan model dapat dianggap akurat, mudah dipahami, dan relevan untuk aplikasi praktis.

3.2.2 Evaluasi *Overfitting* dan *Underfitting*

Bagian ini membahas evaluasi terhadap potensi terjadinya *overfitting* atau *underfitting* pada model, yang didasarkan pada perbandingan metrik evaluasi antara data latih dan data uji sebagaimana yang disajikan pada Tabel 6. Analisis gap (selisih) antara performa pada data latih dan data uji sangat krusial untuk memahami kemampuan generalisasi model.

Dari hasil analisis, terlihat adanya peningkatan kecil pada nilai *error* (MSE, RMSE, MAE, dan MAPE) serta sedikit penurunan pada nilai R^2 ketika model diterapkan pada data uji dibandingkan dengan data latih. Sebagai contoh, MSE meningkat sebesar 0.00007875, RMSE meningkat sebesar 0.00132, MAE meningkat sebesar 0.00546, dan MAPE meningkat sebesar 2.34%. Sementara itu, R^2 mengalami penurunan sebesar 0.00185. Perubahan-perubahan ini, meskipun tidak terlalu besar, mengindikasikan adanya tanda-tanda *slight overfitting*. Kondisi ini menunjukkan bahwa model mungkin telah sedikit terlalu spesifik dalam mempelajari pola pada data pelatihan, sehingga performanya sedikit menurun ketika dihadapkan pada data baru. Namun, karena perbedaan performa antara data latih dan data uji tidak signifikan, *overfitting* ini masih dianggap dalam batas yang wajar dan tidak terlalu mempengaruhi kemampuan generalisasi model secara drastis.

Beberapa faktor yang dapat berkontribusi pada *slight overfitting* ini meliputi ukuran *dataset* yang relatif kecil (dengan 12 pola untuk pelatihan dan 12 pola untuk pengujian), kompleksitas model yang mungkin sedikit berlebihan untuk *dataset* tersebut (dengan penggunaan 10 *hidden neurons*), serta ketiadaan teknik *regularization* yang diterapkan selama proses pelatihan.

3.2.3 Analisis Pola Musiman dan Kesalahan Prediksi

Berdasarkan analisis numerik yang lebih rinci per bulan, sebagaimana disajikan pada Tabel 7, dapat diidentifikasi adanya pola musiman dalam kesalahan prediksi model. Meskipun metrik evaluasi secara keseluruhan menunjukkan performa model yang baik, namun variasi kesalahan prediksi pada skala bulanan memang terlihat. Hal ini menunjukkan bahwa model mungkin menghadapi tantangan yang berbeda dalam memprediksi curah hujan pada periode-periode tertentu dalam setahun. Bulan-bulan yang menunjukkan *absolute error* dan *percentage error* tertinggi, mengindikasikan kesulitan terbesar model dalam melakukan prediksi, antara lain:

- Maret, dengan *absolute error* sebesar 212.6 mm dan *percentage error* sebesar 187.87%, menjadikannya bulan dengan kesalahan prediksi tertinggi.
- Desember, dengan *absolute error* sebesar 339.5 mm dan *percentage error* sebesar 151.58%.
- Januari, dengan *absolute error* sebesar 104.5 mm dan *percentage error* sebesar 98.02%.

Sebaliknya, bulan-bulan dengan *absolute error* dan *percentage error* terendah, yang menunjukkan performa prediksi model yang sangat baik, antara lain:

- April, dengan *absolute error* hanya 3.8 mm dan *percentage error* 1.20%, menunjukkan kesalahan terendah.
- Mei, dengan *absolute error* 65.7 mm dan *percentage error* 28.78%.
- Juni, dengan *absolute error* 153.0 mm dan *percentage error* 33.03%.

Variasi yang signifikan dalam tingkat kesalahan prediksi antar bulan ini mengindikasikan bahwa model mungkin mengalami kesulitan dalam memprediksi pola curah hujan pada bulan-bulan tertentu. Kesulitan ini kemungkinan disebabkan oleh fluktuasi ekstrem atau pola curah hujan yang kurang representatif dalam data pelatihan untuk bulan-bulan tersebut.

3.2.4 Validitas dan Reliabilitas Model

Penggunaan berbagai metrik evaluasi (MSE, RMSE, MAE, MAPE, dan R^2) secara bersamaan memberikan validasi yang komprehensif dan mendalam terhadap performa model. Setiap metrik menawarkan perspektif unik yang berkontribusi pada penilaian keseluruhan validitas dan reliabilitas model:

MSE (Mean Squared Error) dan RMSE (Root Mean Squared Error): Kedua metrik ini cenderung memberikan penalti yang lebih besar untuk *error* yang signifikan atau *outliers*, yang berarti model cukup *robust* terhadap nilai-nilai ekstrem. Nilai RMSE juga memberikan gambaran *error* dalam satuan asli data (milimeter), sehingga lebih mudah diinterpretasikan.

MAE (Mean Absolute Error): Metrik ini memberikan ukuran *error* rata-rata yang lebih *interpretable* karena berada dalam skala asli data (milimeter), tanpa memberikan penalti yang lebih besar pada *error* yang ekstrem.

MAPE (Mean Absolute Percentage Error): MAPE sangat berguna karena memberikan perspektif *error* dalam bentuk persentase, yang membuatnya mudah dipahami oleh berbagai pemangku kepentingan, termasuk individual yang mungkin tidak familiar dengan terminologi statistik. Nilai MAPE yang relatif rendah (10.76% untuk data uji) secara kuat menegaskan bahwa model memiliki akurasi persentase yang baik secara rata-rata.

R^2 (Koefisien Determinasi): Nilai R^2 yang tinggi (0.98837 pada data uji) menunjukkan proporsi variansi data aktual yang dapat dijelaskan oleh model. Nilai yang mendekati 1 ini mengindikasikan bahwa model memiliki kemampuan yang sangat baik dalam menangkap dan mereplikasi variasi yang ada dalam data curah hujan.

Secara keseluruhan, selisih antara *output* prediksi model dan data curah hujan aktual sangatlah kecil, yang secara konsisten ditunjukkan oleh nilai MAPE keseluruhan di bawah 11% (10.76% untuk data uji). Konsistensi ini memperkuat keyakinan terhadap validitas dan reliabilitas model dalam melakukan prediksi curah hujan.

3.3 Keterbatasan Penelitian

Penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan. Pertama, ukuran dataset yang digunakan relatif kecil, yakni hanya mencakup data curah hujan bulanan Kota Bogor selama tiga tahun (2020-2022), yang dapat membatasi kemampuan generalisasi model pada skala waktu yang lebih panjang atau pada wilayah geografis lain. Kedua, input variabel yang digunakan dalam model hanya terbatas pada data curah hujan historis tanpa mempertimbangkan faktor-faktor meteorologis lain seperti suhu, kelembaban, tekanan udara, dan kecepatan angin, yang berpotensi meningkatkan akurasi prediksi. Ketiga, model JST yang digunakan masih terbatas pada arsitektur *feedforward* dengan algoritma *backpropagation* tanpa regularisasi lanjutan, sehingga terdapat potensi *overfitting* pada data pelatihan.

4. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah diuraikan, dapat disimpulkan bahwa model prediksi curah hujan menggunakan Jaringan Syaraf Tiruan (JST) dengan algoritma *backpropagation* pada *software* Matlab mampu memberikan hasil prediksi yang akurat dan stabil. Proses pelatihan menghasilkan nilai *Mean Squared Error* (MSE) sebesar 0.00090677 dan nilai regresi sebesar 0.99022, sedangkan pengujian menghasilkan nilai regresi sebesar 0.98837. Hal ini menunjukkan bahwa model memiliki tingkat akurasi dan korelasi yang tinggi antara *output* dan target, baik dalam data pelatihan maupun data pengujian.

Model JST yang dirancang dengan 12 neuron input, 10 neuron pada *hidden layer*, dan 1 neuron *output* terbukti mampu mengenali pola musiman pada data historis curah hujan di Kota Bogor. Hasil prediksi tahun 2023 menunjukkan pola yang konsisten dengan tren curah hujan tahunan, yang menandakan efektivitas model dalam memetakan data waktu ke masa depan.

Penelitian ini memberikan kontribusi dalam pengembangan sistem prediksi cuaca berbasis kecerdasan buatan, khususnya untuk kebutuhan perencanaan di sektor pertanian, pengelolaan air, dan mitigasi bencana. Namun demikian, untuk meningkatkan akurasi dan daya adaptif model ke depannya, disarankan untuk melakukan validasi silang (*cross-validation*) serta eksperimen komparatif dengan metode pembelajaran mesin lainnya seperti *Random Forest*, *Support Vector Regression*, *Long Short-Term Memory* (LSTM), atau *hybrid models* yang menggabungkan fitur meteorologis multiparameter. Pendekatan ini diharapkan mampu menghasilkan model prediktif yang lebih *robust*, generalis, dan relevan terhadap dinamika iklim tropis di Indonesia.

REFERENCES

- [1] A. Ravelliani and S. Salman, "Penyakit Influenza Berdasarkan Iklim di Indonesia: Literature Review," *J. Farmasetis*, vol. 11, no. 3, pp. 209–214, 2022, [Online]. Available: <https://journal2.stikeskendal.ac.id/index.php/far/article/view/499>
- [2] M. Imron, M. S. Baskoro, D. R. Prima, and A. Suherman, "KOMPOSISI HASIL TANGKAPAN DAN POLA

- MUSIM PENANGKAPAN CANTRANG YANG DI DARATKAN DI PELABUHAN PERIKANAN PANTAI TEGALSARI, JAWA TENGAH,” *Saintek Perikan. Indones. J. Fish. Sci. Technol.*, vol. 17, no. 2, pp. 138–145, Aug. 2021, doi: 10.14710/ijfst.17.2.138-145.
- [3] A. Angel, D. Dasrizal, and E. Juita, “Analisis Pengaruh Curah Hujan terhadap Hasil Pertanian Padi di Nagari Balimbing Kecamatan Rambatan Kabupaten Tanah Datar,” *Indones. Res. J. Educ.*, vol. 5, no. 1, pp. 273–281, 2025.
- [4] R. Alamsyah, E. Ryansyah, A. Y. Permana, and R. Mufidah, “SISTEM PENYIRAMAN TANAMAN OTOMATIS MENGGUNAKAN LOGIKA FUZZY DENGAN TEKNOLOGI INTERNET OF THINGS BERBASIS ESP8266 DAN APLIKASI BLYNK,” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 2, pp. 862–868, Apr. 2024, doi: 10.23960/jitet.v12i2.4007.
- [5] D. Sangaji and T. Sutabri, “Analisis XGBoost dan Random Forest untuk Prediksi Curah Hujan dalam Mendukung Mitigasi Karhutla,” *J. Pustaka AI (Pusat Akses Kaji. Teknol. Artif. Intell.*, vol. 5, no. 1, pp. 13–18, Apr. 2025, doi: 10.55382/jurnalpustakaai.v5i1.905.
- [6] S. Hithama Hutabarat and F. Al-Islama Achyunda Putra, “PERBANDINGAN METODE EXPONENTIAL SMOOTHING DAN ARIMA PADA PERAMALAN CURAH HUJAN DI KOTA MALANG,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 4, pp. 7294–7300, May 2025, doi: 10.36040/jati.v9i4.14427.
- [7] Y. W. A. Nanlohy and G. Haumahu, “Model Autoregressive Integrated Moving Average (ARIMA) untuk Peramalan Curah Hujan di Kota Surabaya,” *Tensor Pure Appl. Math. J.*, vol. 2, no. 1, pp. 25–32, May 2021, doi: 10.30598/tensorvol2iss1pp25-32.
- [8] J. Prasetya, B. Santoso, and S. Kacung, “PREDIKSI HARGA EMAS MENGGUNAKAN JARINGAN SYARAF TIRUAN BACKPROPAGATION HYPERPARAMETER TUNING,” *J. Inform. Teknol. dan Sains*, vol. 7, no. 2, pp. 768–776, May 2025, doi: 10.51401/jinteks.v7i2.5739.
- [9] R. Gusriwa and Y. M. Putra, “Model Prediksi Kerusakan Sepeda Motor Matic Menggunakan Jaringan Saraf Tiruan dan Metode Hebb’s Rule,” *Kesatria J. Penerapan Sist. Inf. (Komputer dan Manajemen)*, vol. 6, no. 2, pp. 585–592, 2025, [Online]. Available: <https://pkm.tunasbangsa.ac.id/index.php/kesatria/article/view/601>
- [10] S. Arti and E. Suherlan, “Evaluasi Kinerja Machine Learning dalam Memprediksi Kemampuan Adaptasi Mahasiswa pada Lingkungan Pembelajaran Daring,” *J. Pustaka AI (Pusat Akses Kaji. Teknol. Artif. Intell.*, vol. 5, no. 1, pp. 50–57, Apr. 2025, doi: 10.55382/jurnalpustakaai.v5i1.901.
- [11] Budi Mulyono and Nursalim, “Prediksi Rentet Waktu Penjualan Barang Menggunakan Algoritma Backpropagation,” *J. Kolaboratif Sains*, vol. 6, no. 2, pp. 131–139, Feb. 2023, doi: 10.56338/jks.v6i2.3300.
- [12] S. F. Prasetyo, T. F. Efendi, and M. Muqorobin, “Implementasi Sistem Prediksi Curah Hujan Dengan Penerapan Jaringan Syaraf Tiruan Berbasis Website,” *J. Ris. Tek. Komput.*, vol. 1, no. 2, pp. 80–96, 2024, [Online]. Available: <https://journal.smartpublisher.id/index.php/jurikom/article/view/110>
- [13] L. H. Aguswandi, D. Syafitri, and T. T. Sujaka, “PEMODELAN PREDIKTIF MENGGUNAKAN ALGORITMA BACKPROPAGATION,” *Pros. Semin. Nas. Teknol. Inovasi, dan Ekon.*, pp. 149–157, 2025, [Online]. Available: <https://journal.universitاسbumigora.ac.id/index.php/SETIE/article/view/5010>
- [14] H. Hendy and A. A. Fajrin, “Framework Jaringan Syaraf Tiruan Dengan Algoritma Genetika Pada Pengenalan Iris Mata,” *Comput. Sci. Ind. Eng.*, vol. 7, no. 2, pp. 70–81, 2022, [Online]. Available: <https://forum.upbatam.ac.id/index.php/comasiejournal/article/view/5846>
- [15] T. B. Sianturi, I. Cholissodin, and N. Yulistira, “Penerapan Algoritma Long Short-Term Memory (LSTM) berbasis Multi Fungsi Aktivasi Terbobot dalam Prediksi Harga Ethereum,” *J. Pengemb. Teknol. Inf. Dan Ilmu Komput.*, vol. 7, no. 3, pp. 1101–1107, 2023, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/12384>
- [16] M. R. Siregar, A. P. Azhari, D. Hartama, and A. P. Windarto, “Peramalan Nilai Penjualan Gas Elpiji 3 Kg di Sumatera Utara dengan bantuan Analisis Metode Jaringan Saraf Tiruan,” *Bull. Artif. Intell.*, vol. 1, no. 2, pp. 52–58, Oct. 2022, doi: 10.62866/buai.v1i2.51.
- [17] R. Alfalaq, I. Safitri, and S. Rizal, “Perancangan Dan Implementasi Image Enhancement Plat Nomor Kendaraan Dengan Membandingkan Metode Srcnn Dan Vdsr,” vol. 11, no. 4, pp. 2727–2734, 2024, [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/24122>
- [18] A. G. Visitama and H. Sabita, “Penjadwalan Matakuliah Dengan Menggunakan Metode Jaringan Neural Network (Studi Kasus IIB Darmajaya),” *Tek. J. Ilm. Bid. Ilmu Rekayasa*, vol. 18, no. 1, pp. 161–172, 2024, doi: 10.5281/zenodo.10879808.