



Penerapan Jaringan Saraf Tiruan dengan Metode Backpropagation untuk Memprediksi Curah Hujan di Kota Medan

Tiara Bela Harahap^{1*}, Lailan Sofinah Harahap², Naina Nazwa Hasibuan³

¹⁻³Program Studi Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Indonesia

*Penulis Korespondensi: tiarabelahrp@gmail.com

Abstract. Rainfall is a crucial factor in the stability of the Earth's ecosystem and has a significant impact on agriculture, forestry, energy, and water management. However, increasingly unstable climate change makes rainfall patterns difficult to predict accurately using traditional methods. The city of Medan, the capital of North Sumatra Province, has a tropical rainforest climate with an average annual rainfall of approximately ± 2200 mm and an average temperature of 27°C . Significant weather fluctuations in this area can trigger flooding when rainfall increases and cause water shortages when rainfall decreases (BMKG, 2021). Therefore, a prediction approach that can manage non-linear and dynamic data is needed. Artificial Neural Networks (ANN) are one of the reliable machine learning methods for detecting data patterns. By using the backpropagation algorithm, the model can gradually reduce prediction errors, making it widely used in weather forecasting applications. In this regard, this study uses ANN with the backpropagation method to forecast monthly rainfall in Medan City by utilizing data from 2022–2024 as training and testing data.

Keywords: Artificial Neural Networks; Backpropagation; Medan City; Rainfall; Weather Forecast.

Abstrak. Hujan adalah faktor krusial dalam kestabilan ekosistem bumi dan memiliki dampak signifikan pada sektor pertanian, kehutanan, energi, serta pengelolaan air. Akan tetapi, perubahan iklim yang semakin tidak stabil menjadikan pola hujan sulit diperkirakan dengan tepat menggunakan cara-cara tradisional. Kota Medan, yang merupakan ibu kota Provinsi Sumatera Utara, memiliki iklim hutan hujan tropis dengan rata-rata curah hujan tahunan sekitar ± 2200 mm dan suhu rata-rata 27°C . Fluktuasi cuaca yang signifikan di daerah ini dapat memicu banjir ketika curah hujan meningkat dan menyebabkan kekurangan air saat curah hujan menurun (BMKG, 2021). Karena itu, diperlukan pendekatan prediksi yang dapat mengelola data yang bersifat non-linear dan dinamis. Jaringan Saraf Tiruan (JST) merupakan salah satu metode machine learning yang handal dalam mendeteksi pola data. Dengan menggunakan algoritma backpropagation, model dapat secara bertahap mengurangi kesalahan prediksi, sehingga banyak digunakan dalam aplikasi ramalan cuaca. Sehubungan dengan hal itu, studi ini menggunakan JST dengan metode backpropagation untuk meramalkan curah hujan bulanan di Kota Medan dengan memanfaatkan data tahun 2022–2024 sebagai data pelatihan dan pengujian

Kata Kunci: Backpropagation; Curah Hujan; Jaringan Saraf Tiruan; Kota Medan; Prediksi Cuaca.

1. LATAR BELAKANG

Hujan merupakan fenomena atmosfer yang berperan penting dalam menjaga keseimbangan ekosistem serta menunjang kehidupan manusia, khususnya sebagai sumber utama ketersediaan air. Curah hujan yang bersifat fluktuatif memiliki dampak signifikan terhadap berbagai sektor, seperti pertanian, energi, dan pengelolaan sumber daya air, sehingga ketidakpastian pola hujan sering menjadi tantangan dalam perencanaan dan pengambilan keputusan. Di Indonesia, curah hujan dibedakan menjadi tiga tipe, yaitu ekuatorial, monsun, dan lokal, yang masing-masing dipengaruhi oleh pergerakan zona konvergensi, angin musim, serta kondisi fisik wilayah setempat. Oleh karena itu, pemahaman dan prediksi curah hujan menjadi aspek penting dalam penelitian klimatologi dan hidrologi untuk mendukung mitigasi bencana serta perencanaan yang adaptif terhadap perubahan iklim.

Kota Medan sebagai ibu kota Provinsi Sumatera Utara memiliki luas wilayah 265,10 km² atau sekitar 3,6% dari total wilayah provinsi, dengan kepadatan penduduk yang relatif tinggi. Secara geografis, Medan terletak pada 3°27'–3°47' Lintang Utara dan 98°35'–98°44' Bujur Timur dengan topografi yang cenderung miring ke utara dan ketinggian antara 2,5–37,5 meter di atas permukaan laut (BMKG, 2021). Berdasarkan klasifikasi iklim Köppen, Medan termasuk dalam iklim hutan hujan tropis dengan musim kemarau yang tidak jelas, suhu rata-rata sekitar 27°C, serta curah hujan tahunan sekitar 2200 mm. Kondisi tersebut menjadikan Medan wilayah yang tepat untuk penerapan model prediksi curah hujan berbasis Jaringan Saraf Tiruan (JST) dengan algoritma backpropagation (BMKG, 2021)

Dalam konteks perubahan iklim global, pola curah hujan semakin sulit diprediksi menggunakan metode statistik linier seperti regresi sederhana, exponential smoothing, atau ARIMA (Yuniarti, 2022). Oleh karena itu, pendekatan berbasis machine learning, khususnya Jaringan Saraf Tiruan, semakin banyak digunakan karena kemampuannya dalam memodelkan hubungan non-linear dan data yang kompleks. Berbagai penelitian menunjukkan bahwa JST mampu memberikan hasil prediksi yang lebih baik dibandingkan metode regresi tradisional, terutama pada data cuaca yang saling bergantung dan dinamis (Jordan et al., 2006)

Jaringan Saraf Tiruan merupakan sistem komputasi yang meniru cara kerja otak manusia dalam mengenali pola dan mempelajari hubungan input-output melalui neuron buatan yang tersusun dalam lapisan input, hidden, dan output. JST bersifat adaptif karena bobot antar neuron dapat diperbarui selama proses pelatihan tanpa memerlukan model matematis eksplisit (Khairina, 2022). Prinsip kerja ini sejalan dengan konsep bahwa neuron mentransformasikan informasi dan meneruskannya ke neuron lain untuk membentuk proses pembelajaran, sehingga JST banyak dimanfaatkan dalam peramalan cuaca dan mitigasi bencana seperti banjir dan kekeringan (Aisuwarya et al., 2022). Jst tidak hanya dapat digunakan untuk peramalan cuaca jangka pendek tetapi juga mendukung kebijakan mitigasi bencana seperti banjir dan kekeringan (Article, 2021). Artificial Neural Networks (ANN) sendiri merupakan bagian dari kecerdasan buatan yang terinspirasi oleh jaringan saraf biologis manusia, di mana setiap node dirancang untuk berperilaku menyerupai neuron asli (Kurniawan, 2023). Node yang dibuat di ANN seharusnya di program untuk berperilaku seperti neuron yang sebenarnya, karena mereka adalah neuron buatan (Raharjo, 2022).

Algoritma backpropagation merupakan pengembangan jaringan multilayer yang terdiri dari lapisan input, hidden, dan output, sehingga mampu meningkatkan akurasi model dibandingkan jaringan satu lapis (Imaduddin, 2023). Metode ini menggunakan pembelajaran terawasi dan efektif dalam menyelesaikan permasalahan kompleks dengan tingkat akurasi

tinggi. Proses pelatihannya mencakup tiga fase utama, yaitu fase maju, fase mundur, dan fase modifikasi bobot (Priyo et al., 2021). Pada fase maju, data diproses dari lapisan input hingga output untuk menghasilkan prediksi awal. Fase mundur digunakan untuk menghitung error dan mendistribusikannya kembali ke lapisan sebelumnya melalui turunan fungsi aktivasi, sedangkan fase modifikasi bobot bertujuan memperbarui bobot dan bias berdasarkan nilai error agar prediksi pada iterasi selanjutnya semakin mendekati nilai target.

2. KAJIAN TEORITIS

Curah hujan adalah salah satu variabel iklim penting yang secara langsung memengaruhi dinamika alam dan kehidupan manusia, terutama dalam sektor pertanian, pengelolaan air, dan mitigasi bencana. Distribusi dan intensitas curah hujan bersifat non-linear dan dinamis, dipengaruhi oleh banyak faktor seperti tekanan atmosfer, suhu, serta kondisi geografis yang beragam dari satu lokasi ke lokasi lain. Kondisi ini menyebabkan metode statistik linier konvensional sering kali kurang efektif dalam memprediksi pola hujan secara akurat karena tidak mampu menangkap hubungan kompleks antar variabel iklim yang saling bergantung. Hal ini memerlukan pendekatan yang lebih canggih yang mampu memodelkan pola-pola non-linear tersebut secara efektif (Barrera et al., 2022).

Jaringan Saraf Tiruan (ANN atau JST) adalah teknik komputasi yang meniru cara kerja otak manusia, terdiri dari neuron-neuron buatan yang saling terhubung dalam beberapa lapisan (input, hidden, output). Metode ini terkenal karena kemampuannya untuk melakukan learning from data tanpa memerlukan model matematis eksplisit dari fenomena yang dipelajari. Penggunaan ANN memberi keuntungan karena kemampuan mengenali pola kompleks dalam data non-linear, termasuk dalam masalah prediksi curah hujan (Huntington et al., 2024).

Salah satu algoritma pembelajaran paling umum pada JST adalah backpropagation, yaitu metode pembelajaran dengan pengawasan (supervised learning) yang bertujuan meminimalkan kesalahan prediksi melalui penyesuaian bobot jaringan. Proses ini mencakup tiga tahap utama: fase maju (feedforward) untuk mengestimasi keluaran, fase mundur (backward propagation) untuk menghitung error dan mendistribusikannya kembali, serta fase pembaruan bobot (weight update) untuk memodifikasi bobot dan bias jaringan agar error pada iterasi berikutnya semakin kecil. Backpropagation terbukti efektif dalam menangani pola non-linear data seperti curah hujan.

Berbagai penelitian menunjukkan bahwa ANN, khususnya yang menggunakan backpropagation, lebih unggul daripada model statistik tradisional seperti regresi linier atau ARIMA dalam prediksi curah hujan karena ANN dapat secara implisit menangkap hubungan

kompleks dan non-linear dalam data runtun waktu (time series). Model konvensional sering kali gagal memberikan prediksi yang akurat ketika karakter data sangat dinamis dan tidak linear, sedangkan JST mampu belajar dari pola historis curah hujan dengan tingkat akurasi lebih tinggi (Arief et al., 2025).

Dalam aplikasi prediksi curah hujan, ANN biasanya dilatih menggunakan data historis runtun waktu yang telah dinormalisasi untuk menstabilkan proses pelatihan. Evaluasi model umumnya dilakukan menggunakan metrik seperti Mean Squared Error (MSE) untuk mengukur rata-rata kesalahan kuadrat antara nilai prediksi dan aktual, serta koefisien korelasi (R) untuk menilai sejauh mana model mengikuti pola data. Nilai MSE yang rendah dan nilai R yang mendekati 1 menandakan model mampu menghasilkan prediksi yang akurat dan sesuai pola data historis (Nordin et al., 2023).

Beragam studi kasus dari tahun 2021 hingga awal 2025 telah menunjukkan penerapan JST berbasis backpropagation dalam prediksi curah hujan bulanan pada berbagai wilayah. Contoh penelitian membangun model prediksi curah hujan dengan arsitektur MLP/BPNN dan menghasilkan akurasi tinggi dengan berbagai konfigurasi neuron, learning rate, dan epoch. Hasil-hasil ini menunjukkan bahwa pendekatan ANN non-linear sering kali memberikan performa prediksi yang lebih baik dibandingkan metode konvensional, khususnya pada data runtun waktu iklim yang berfluktuasi. Model JST terbukti relevan dan efektif dalam penelitian praktek klimatologi modern (Wijonarko, 2025).

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan *quantitative experiment* dengan memanfaatkan model Jaringan Saraf Tiruan *backpropagation* untuk memprediksi curah hujan bulanan di Kota Medan.

Data Penelitian

Data yang digunakan dalam penelitian ini berupa data curah hujan bulanan yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kota Medan dengan periode pengamatan tahun 2022 hingga 2024. Data dinyatakan dalam satuan milimeter (mm) dan merepresentasikan rata-rata curah hujan bulanan, sehingga dapat menggambarkan variasi musiman serta pola curah hujan di wilayah Kota Medan. Data tersebut selanjutnya digunakan sebagai masukan utama dalam proses pelatihan dan pengujian model Jaringan Saraf Tiruan (JST). Seluruh proses pengolahan data dan pemodelan dilakukan menggunakan platform Google Colab berbasis Python yang mendukung komputasi berbasis GPU, sehingga mempercepat proses pelatihan model backpropagation. Sebelum tahap pemodelan, data dibagi

menjadi dua bagian, yaitu 70% sebagai data pelatihan dan 30% sebagai data pengujian. Pembagian ini bertujuan untuk melatih model dalam mengenali pola data historis sekaligus menguji kemampuan generalisasi model terhadap data yang belum pernah dipelajari. Melalui tahapan metode ini, diharapkan model yang dikembangkan mampu menghasilkan prediksi curah hujan yang akurat dan dapat dimanfaatkan sebagai bahan pertimbangan dalam pengelolaan sumber daya air serta perencanaan kegiatan terkait kondisi cuaca di Kota Medan.

Pemrosesan Data

Sebelum proses pemodelan Jaringan Saraf Tiruan (JST) dilakukan, data terlebih dahulu melalui tahap praproses untuk memastikan kualitas dan kesesuaian data dengan kebutuhan model. Pada penelitian ini digunakan teknik normalisasi Min-Max Scaling, yaitu metode yang mengubah nilai data ke dalam rentang 0 hingga 1. Normalisasi ini bertujuan untuk menyamakan skala data, mempercepat proses konvergensi selama pelatihan, serta menghindari dominasi nilai dengan skala besar yang dapat mengganggu proses pembelajaran jaringan. Dengan skala data yang seragam, model dapat mempelajari pola curah hujan secara lebih efektif.


Seluruh proses pengolahan data dan pemodelan dilakukan menggunakan bahasa pemrograman Python dengan dukungan beberapa pustaka pendukung. NumPy dan Pandas digunakan untuk pengolahan data numerik dan tabular, Matplotlib dimanfaatkan untuk visualisasi data dan hasil model, serta Scikit-learn digunakan pada tahap praproses dan evaluasi, termasuk normalisasi, pembagian data, serta perhitungan metrik evaluasi seperti Mean Squared Error (MSE) dan Mean Absolute Error (MAE). Pembangunan dan pelatihan model JST dilakukan menggunakan TensorFlow/Keras yang mendukung pendefinisian arsitektur jaringan, fungsi aktivasi, serta algoritma optimasi. Seluruh tahapan ini dijalankan pada platform Google Colab untuk memanfaatkan lingkungan komputasi berbasis cloud dan dukungan GPU.

Setelah tahap praproses, model JST dirancang dengan arsitektur 12–10–1. Lapisan input terdiri dari 12 neuron yang merepresentasikan data curah hujan dari 12 bulan sebelumnya sebagai masukan untuk memprediksi nilai bulan berikutnya, sehingga model dapat mengenali pola musiman tahunan. Lapisan tersembunyi terdiri dari 10 neuron yang berfungsi menangkap hubungan non-linear dan pola tersembunyi dalam data, sedangkan lapisan output terdiri dari 1 neuron yang menghasilkan nilai prediksi curah hujan bulan selanjutnya dalam satuan milimeter (mm). Perancangan arsitektur ini diharapkan mampu menghasilkan proses pelatihan yang optimal serta prediksi curah hujan dengan tingkat akurasi yang baik..

Perancangan Model Jaringan saraf tiruan

Perancangan arsitektur jaringan saraf tiruan dilakukan dengan menyusun struktur jaringan secara sistematis sesuai dengan algoritma pembelajaran yang digunakan. Pada penelitian ini, model jaringan dibangun menggunakan algoritma pembelajaran *Backpropagation*, yaitu salah satu metode paling populer dalam pelatihan jaringan saraf tiruan karena kemampuannya dalam meminimalkan kesalahan melalui proses propagasi maju dan mundur. Jaringan ini terdiri atas tiga komponen utama, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*). Setiap lapisan memiliki peran penting dalam membentuk model prediksi yang optimal.

Arsitektur jaringan yang dirancang tampak pada Gambar 1, yang memperlihatkan struktur dasar jaringan saraf tiruan dengan satu lapisan *input*, satu lapisan tersembunyi, dan satu lapisan *output*. Model ini diimplementasikan menggunakan TensorFlow/Keras, yang merupakan *framework deep learning modern* dan fleksibel, memudahkan pengguna dalam merancang, melatih, serta mengevaluasi model jaringan saraf tiruan.



Gambar 1. Desain Jaringan Saraf Tiruan Backpropagation.

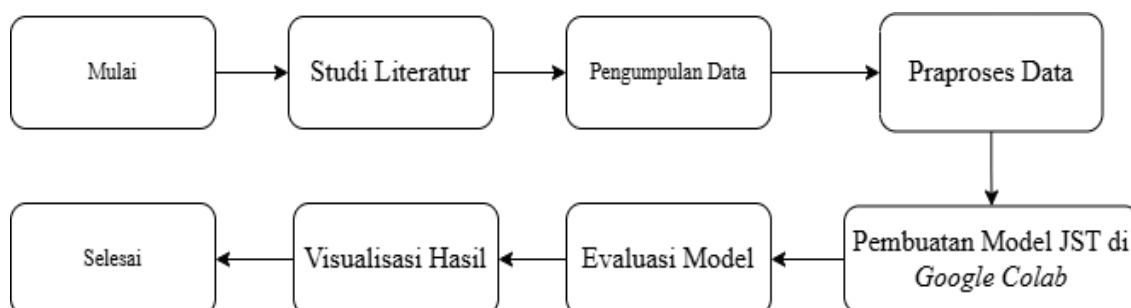
Rancangan penelitian ini terdiri dari beberapa tahapan utama yang saling berkesinambungan. Tahap awal adalah studi literatur untuk mengkaji teori dasar Jaringan Saraf Tiruan (JST), algoritma backpropagation, serta penelitian terdahulu terkait prediksi curah hujan sebagai landasan penentuan metode dan parameter penelitian. Tahap berikutnya adalah pengumpulan data berupa data curah hujan bulanan yang diperoleh dari BMKG Kota Medan atau sumber terbuka lainnya dalam bentuk deret waktu. Data yang telah terkumpul kemudian melalui tahap praproses dengan menerapkan normalisasi Min-Max Scaling ke dalam rentang 0–1 guna meningkatkan stabilitas dan efisiensi proses pelatihan model. Selanjutnya, model Jaringan Saraf Tiruan dibangun menggunakan bahasa pemrograman Python dengan dukungan library TensorFlow/Keras dan dijalankan pada platform Google Colab berbasis cloud yang menyediakan fasilitas GPU, sehingga proses pelatihan dapat dilakukan secara lebih cepat dan optimal.

```

import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
model = Sequential([
    Dense(10, input_dim=12, activation='relu'),
    Dense(1, activation='linear')
])
model.compile(optimizer='adam', loss='mse', metrics=['mae'])
model.fit(X_train, y_train, epochs=200, validation_data=(X_test, y_test))

```

Model yang digunakan memiliki arsitektur 12–10–1, di mana lapisan input terdiri dari 12 neuron yang merepresentasikan data curah hujan 12 bulan terakhir, lapisan tersembunyi terdiri dari 10 neuron dengan fungsi aktivasi ReLU untuk menangkap hubungan non-linear dalam data, serta lapisan output terdiri dari satu neuron dengan fungsi aktivasi linear untuk menghasilkan prediksi curah hujan bulan berikutnya. Setelah proses pelatihan selesai, kinerja model dievaluasi menggunakan dua metrik utama, yaitu Mean Squared Error (MSE) dan Koefisien Korelasi (R). MSE digunakan untuk mengukur rata-rata kesalahan kuadrat antara nilai prediksi dan nilai aktual, sedangkan koefisien korelasi R digunakan untuk menilai kekuatan hubungan antara hasil prediksi dan data sebenarnya, di mana nilai R yang mendekati 1 menunjukkan kemampuan model dalam mengikuti pola curah hujan dengan baik. Penggunaan kedua metrik ini memberikan penilaian kinerja model yang lebih objektif dan menyeluruh. Selain evaluasi numerik, dilakukan visualisasi hasil menggunakan library Matplotlib, meliputi grafik perbandingan data aktual dan hasil prediksi serta grafik nilai loss selama proses pelatihan. Keseluruhan tahapan ini memastikan proses penelitian berjalan secara sistematis, mulai dari pengolahan data hingga evaluasi dan penyajian hasil, sebagaimana digambarkan dalam diagram alur penelitian pada Gambar 2.



Gambar 2. Diagram Alir Penelitian.

4. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan data historis curah hujan bulanan Kota Medan sebagai dasar dalam proses pelatihan dan pengujian model Jaringan Saraf Tiruan (JST). Data yang digunakan mencakup periode tahun 2022 hingga 2024, yang dinilai cukup representatif untuk menggambarkan variasi musiman dan tren curah hujan di wilayah tersebut. Seluruh data diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kota Medan sebagai lembaga resmi penyedia data klimatologi, sehingga kualitas dan keandalan data dapat dipertanggungjawabkan secara ilmiah. Data curah hujan disajikan dalam bentuk rata-rata bulanan dengan satuan milimeter (mm), yang relevan untuk merepresentasikan pola musiman serta mempermudah proses pengolahan dan pemodelan. Keseluruhan data tersebut ditampilkan dalam Tabel 1 dan digunakan sebagai acuan utama dalam analisis serta pembangunan model prediksi curah hujan pada tahap penelitian selanjutnya.

Tahun	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Tahunan	R24(mm)
2022	268	245	292	310	210	150	132	118	160	230	295	305	2715	226
2023	275	255	305	322	218	148	120	112	158	240	310	318	2781	231
2024	260	240	280	300	205	145	125	115	162	235	305	320	2692	224

Gambar 3. Data Curah Hujan Selama 3 Tahun.

Data curah hujan setelah melalui proses normalisasi ditampilkan pada Tabel 2, yang memperlihatkan bagaimana nilai asli curah hujan telah diubah ke dalam rentang skala tertentu agar dapat diproses secara lebih efisien oleh model jaringan saraf tiruan. Normalisasi ini dilakukan menggunakan metode *Min-Max Scaling*, sehingga nilai yang semula bervariasi secara signifikan kini berada dalam kisaran 0 hingga 1. Penyajian hasil normalisasi pada Tabel 2 membantu memberikan gambaran yang lebih jelas mengenai perubahan skala data, sekaligus memperlihatkan kesiapan data tersebut untuk digunakan pada tahap pelatihan dan pengujian model prediksi. Dengan tampilan data yang sudah terstandarisasi, proses pemodelan menjadi lebih stabil, akurat, dan terhindar dari bias akibat perbedaan skala antar nilai curah hujan.

Tahun	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
2022	0.742857	0.633333	0.857143	0.942857	0.466667	0.180952	0.095238	0.028571	0.228571	0.561905	0.871429	0.919048
2023	0.77619	0.680952	0.919048	1	0.504762	0.171429	0.038095	0	0.219048	0.609524	0.942857	0.980952
2024	0.704762	0.609524	0.8	0.895238	0.442857	0.157143	0.061905	0.014286	0.238095	0.585714	0.919048	0.990476

Gambar 4. Data Curah Hujan Setelah Normalisasi.

Pada tahap pelatihan, model jaringan saraf tiruan menggunakan data curah hujan dari bulan ke-1 hingga bulan ke-24 yang merepresentasikan dua tahun pertama dari keseluruhan data. Rentang ini memberikan informasi historis yang memadai bagi model untuk mempelajari

pola musiman, tren tahunan, serta variasi curah hujan yang bersifat siklik. Dengan cakupan data pelatihan yang relatif panjang, model mampu membentuk pemahaman yang lebih stabil terhadap hubungan antar nilai curah hujan dari waktu ke waktu.

Selanjutnya, pengujian model dilakukan menggunakan data dari bulan ke-13 hingga bulan ke-36, sehingga terdapat tumpang tindih periode antara data pelatihan dan pengujian. Pendekatan ini memungkinkan evaluasi kemampuan generalisasi model terhadap pola data yang berada di luar cakupan utama pelatihan, namun tetap mempertahankan kesinambungan temporal. Hasil pengujian menunjukkan bahwa pembagian data dengan cara ini memberikan gambaran kinerja model yang lebih realistis, karena model diuji pada data yang memiliki karakteristik serupa tetapi tidak sepenuhnya identik dengan data pelatihan.

Secara keseluruhan, pembagian data pelatihan dan pengujian tersebut berperan penting dalam menghasilkan model prediksi yang andal. Data pelatihan digunakan untuk membentuk pola pembelajaran, sedangkan data pengujian berfungsi untuk menilai performa model secara objektif. Kombinasi kedua rentang data ini menjadi dasar yang kuat dalam mengevaluasi kemampuan model dalam memprediksi curah hujan secara akurat dan konsisten, sebagaimana dibahas pada hasil penelitian yang diperoleh.

x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
0,742857	0,633333	0,857143	0,942857	0,466667	0,180952	0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619
0,633333	0,857143	0,942857	0,466667	0,180952	0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952
0,857143	0,942857	0,466667	0,180952	0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048
0,942857	0,466667	0,180952	0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1
0,466667	0,180952	0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762
0,180952	0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429
0,095238	0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095
0,028571	0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0
0,228571	0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048
0,561905	0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524
0,871429	0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857
0,919048	0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952
0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762
0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524
0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8
1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238
0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857
0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143
0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905
0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286
0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095
0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095	0,585714
0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095	0,585714	0,919048
0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095	0,585714	0,919048	0,990476

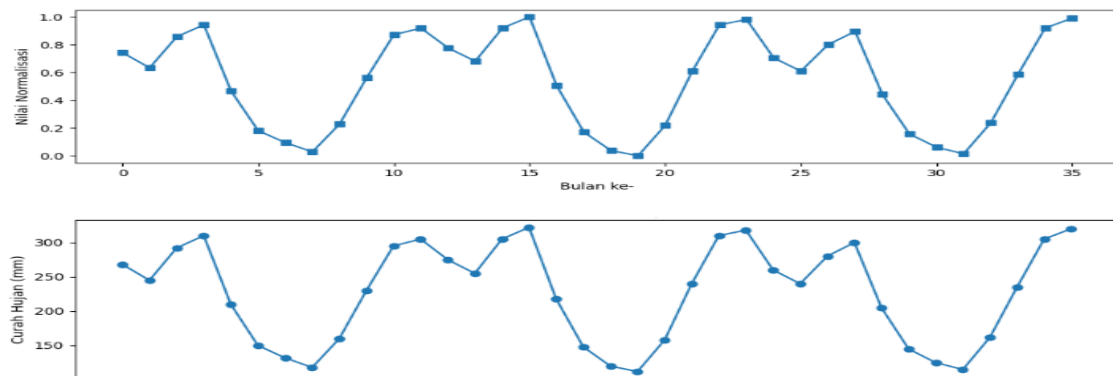
Gambar 5. Data Pelatihan Jaringan.

Data pelatihan dan pengujian jaringan yang telah disiapkan pada Tabel 3 dan 4 untuk pengolahan kedalam *software Google Colab*, dilakukan pemrograman untuk melakukan pelatihan jaringan. Menggunakan arsitektur jaringan saraf 12-10-1, terdiri dari 12 nilai masukan data curah hujan selama satu tahun atau 12 bulan, 10 *neuron* pada *hidden layer*, dan 1 nilai keluaran data curah hujan pada bulan berikutnya.

x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Target
0,77619	0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762
0,680952	0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524
0,919048	1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8
1	0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238
0,504762	0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857
0,171429	0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143
0,038095	0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905
0	0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286
0,219048	0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095
0,609524	0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095	0,585714
0,942857	0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095	0,585714	0,919048
0,980952	0,704762	0,609524	0,8	0,895238	0,442857	0,157143	0,061905	0,014286	0,238095	0,585714	0,919048	0,990476

Gambar 6. Data Pengujian Jaringan.

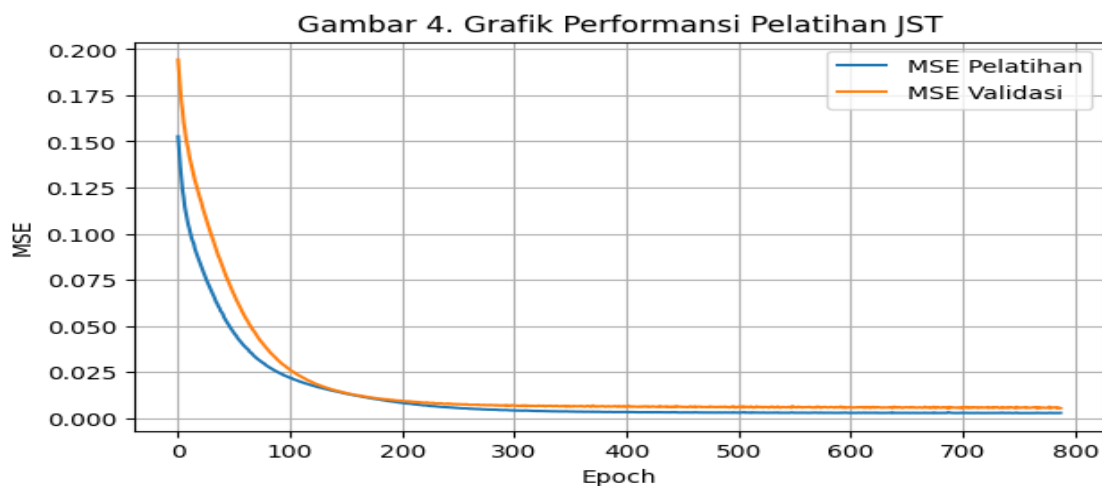
Data pelatihan dan pengujian yang telah disusun dan disajikan pada Tabel 3 dan Tabel 4 selanjutnya diproses menggunakan platform Google Colab untuk melatih model jaringan saraf tiruan. Data hasil praproses dimasukkan ke dalam arsitektur jaringan 12–10–1 yang dirancang khusus untuk prediksi curah hujan. Arsitektur ini terdiri dari 12 neuron pada lapisan input yang merepresentasikan data curah hujan bulanan selama satu tahun, sehingga memungkinkan model mempelajari pola musiman secara lebih menyeluruh. Lapisan tersembunyi dengan 10 neuron berfungsi menangkap hubungan non-linear dan pola kompleks antar data masukan, sedangkan satu neuron pada lapisan output digunakan untuk menghasilkan prediksi curah hujan bulan berikutnya. Proses pelatihan dilakukan secara iteratif menggunakan bahasa pemrograman Python dan library deep learning di Google Colab, sehingga model dapat dioptimalkan hingga mencapai kinerja prediksi yang terbaik.



Gambar 7. Data Curah Hujan 2022-2024.


Pada tahap pelatihan, nilai *error goal* atau *Mean Squared Error* (MSE) menjadi indikator utama untuk menilai sejauh mana model jaringan saraf tiruan mampu menyesuaikan bobot dan biasnya agar menghasilkan prediksi yang semakin mendekati nilai aktual, dan proses perubahan nilai MSE ini dapat diamati secara visual pada Gambar 4. Grafik tersebut menunjukkan bagaimana error menurun secara bertahap seiring bertambahnya jumlah *epoch* pelatihan, yang menandakan bahwa model berhasil belajar dari pola-pola curah hujan yang terdapat dalam data pelatihan. Pengamatan terhadap penurunan MSE sangat penting karena

memberikan gambaran apakah model mengalami konvergensi dengan baik atau justru menghadapi masalah seperti *overfitting* maupun *underfitting*. Dengan demikian, Gambar 4 bukan hanya berfungsi sebagai ilustrasi pelatihan, tetapi juga sebagai alat analisis untuk memastikan bahwa parameter jaringan telah dioptimalkan



Gambar 8. Training Performance.

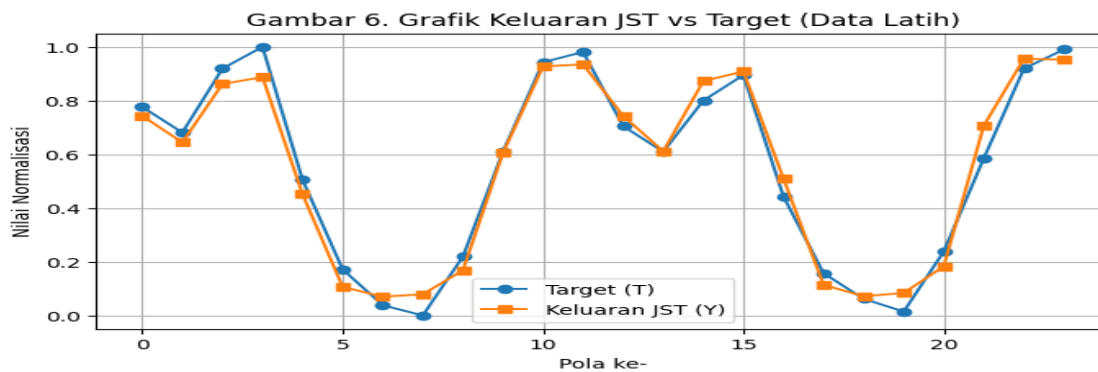
Koefisien korelasi R yang dihasilkan adalah sebesar 0.9868, ditampilkan pada Gambar 5.



Gambar 9. Koefisien relasi.

Hasil perbandingan antara keluaran jaringan saraf tiruan dengan nilai target pada data latih menunjukkan sejauh mana model mampu mempelajari pola historis curah hujan, dan visualisasi dari perbandingan tersebut ditampilkan pada Gambar 6. Grafik ini memperlihatkan hubungan antara prediksi yang dihasilkan oleh model dengan data aktual pada periode pelatihan, sehingga dapat diamati apakah model berhasil mengikuti fluktuasi dan tren curah hujan bulanan secara konsisten. Kesesuaian bentuk kurva antara prediksi dan target menjadi indikator penting untuk menilai kualitas pembelajaran jaringan, di mana semakin mirip kedua garis tersebut, semakin baik kemampuan model dalam menangkap pola musiman, variasi intensitas hujan, serta perubahan nilai dari bulan ke bulan.

Analisis visual seperti pada Gambar 10 juga membantu mengidentifikasi kemungkinan penyimpangan prediksi, seperti nilai yang meleset pada kondisi curah hujan ekstrem atau bulan-bulan tertentu yang memiliki karakteristik khusus. Dengan demikian, Gambar 6 tidak hanya berfungsi sebagai ilustrasi hasil pelatihan, tetapi juga sebagai alat evaluasi yang memberikan pemahaman mendalam mengenai efektivitas jaringan saraf tiruan dalam mempelajari hubungan antara variabel masukan dan keluaran pada data latih.



Gambar 10. Hasil Perbandingan.

Berdasarkan nilai koefisien korelasi dan nilai *Mean Squared Error* (MSE) yang diperoleh pada proses pelatihan, dapat disimpulkan bahwa jaringan saraf tiruan yang digunakan memiliki kemampuan yang baik dalam mempelajari pola curah hujan dari data historis. Nilai koefisien korelasi yang tinggi menunjukkan bahwa hubungan antara prediksi jaringan dan data target sangat kuat, sedangkan nilai MSE yang rendah menandakan bahwa selisih antara nilai prediksi dengan nilai aktual relatif kecil selama proses pelatihan berlangsung. Pada tahap pengujian jaringan, nilai MSE yang dihasilkan memperkuat temuan tersebut, karena model tetap mampu memberikan prediksi yang mendekati data sebenarnya meskipun menggunakan data yang tidak termasuk dalam proses pelatihan. Hal ini menunjukkan bahwa jaringan saraf tiruan berbasis algoritma backpropagation cukup efektif dalam melakukan generalisasi terhadap pola curah hujan yang kompleks dan bersifat musiman.

Meskipun demikian, performa jaringan masih dapat ditingkatkan untuk mencapai akurasi prediksi yang lebih optimal. Peningkatan ini dapat dilakukan dengan memperluas jumlah data latih sehingga jaringan dapat mempelajari variasi pola cuaca yang lebih beragam, serta melakukan penyesuaian terhadap berbagai parameter pelatihan seperti *error goal*, jumlah *epoch*, arsitektur jaringan (misalnya jumlah *neuron* atau lapisan tersembunyi), dan pemilihan jenis fungsi aktivasi yang digunakan. Parameter-parameter tersebut sangat mempengaruhi kualitas pembelajaran jaringan, sehingga pengaturannya secara tepat dapat menghasilkan performa prediksi yang lebih akurat dan stabil. Adapun nilai MSE pada tahap pengujian yang

diperoleh, yaitu sebesar 0.003232, menggambarkan bahwa model telah mencapai tingkat kesalahan yang sangat kecil. Nilai ini divisualisasikan secara lebih jelas pada Gambar 7, yang menunjukkan grafik perubahan *error* selama proses pengujian dan menjadi indikator keberhasilan model dalam memprediksi curah hujan secara efektif.

5. KESIMPULAN DAN SARAN

Studi ini menunjukkan bahwa Jaringan Saraf Tiruan (JST) dengan algoritma backpropagation mampu memprediksi curah hujan di Kota Medan dengan tingkat akurasi yang cukup tinggi. Model JST dengan struktur 12-10-1 dapat mempelajari pola hujan dari data 2022–2024 dan memberikan kinerja prediksi yang baik, terbukti dari nilai koefisien korelasi (R) 0.9868 yang menunjukkan hubungan sangat kuat antara data aktual dan hasil prediksi, serta nilai MSE pengujian 0.003232 yang menunjukkan tingkat kesalahan prediksi yang rendah. Dengan demikian, penerapan metode *backpropagation* sangat tepat untuk analisis prediksi curah hujan guna mendukung perencanaan mitigasi bencana dan pengelolaan sumber daya air. Kinerja model masih bisa diperbaiki dengan menambah data pelatihan dan melakukan penyesuaian terhadap parameter seperti jumlah *epoch*, struktur jaringan, dan fungsi aktivasi agar hasil prediksi lebih optimal di kemudian hari.

DAFTAR REFERENSI

- Aisuwarya, R., Hidayat, A., Yolanda, D., Utami, E., & Adela, V. (2022). *Jaringan saraf tiruan*. CV Eureka Media Aksara.
- Arief, M., Istiyanto, F., & Palloan, P. (2025). Monthly rainfall prediction using the backpropagation neural network (BPNN) algorithm in Maros Regency. *Scientific Journal of Informatics*, 10(1). <https://doi.org/10.15294/sji.v10i1.37982>
- Article, M. R. (2021). Literature review on rainfall prediction.
- Badan Meteorologi, Klimatologi, dan Geofisika. (2021). *Geografi Kota Medan*.
- Barrera-Animas, A. Y., Oyedele, L. O., Bilal, M., Akinosho, T. D., Delgado, J. M., & Akanbi, L. A. (2022). Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting. *Machine Learning with Applications*, 7, 100204. <https://doi.org/10.1016/j.mlwa.2021.100204>
- Huntington, I., Zemnazi, O., Filali, S. E. L., & Ouahabi, S. (2024). Weather forecasting using artificial neural network (ANN): A review. *Procedia Computer Science*, 241, 618–623. <https://doi.org/10.1016/j.procs.2024.08.090>
- Imaduddin, M. A. (2023). Prediksi cuaca pada data time series menggunakan backpropagation neural network (BPNN). *Jurnal Ilmiah*, 10*(5), 4873–4879.
- Jordan, M., Kleinberg, J., & Schölkopf, B. (2006). *Pattern recognition and machine learning*. Springer.

- Khairina, N. (2022). *Konsep dasar jaringan syaraf tiruan*. Universitas Medan Area.
- Kurniawan, M. (2023). *Artificial neural network*. Informatika ITATS.
- Nordin, N. Z. A., Yunus, M. M., & Dahalan, A. N. (2023). Implementation of rainfall forecasting using ANN. In *Proceedings of the 5th International Conference on Applied Engineering and Natural Sciences* (pp. 641–645).
- Priyo, S. S., Helmie, A. W., Indra, W., Nurdin, B., & Widodo, T. K. (2021). Backpropagation dan aplikasinya. In *Chapter 7* (pp. 135–146).
- Raharjo, D. B. (2022). *Deep learning dengan Python* (M. M. T. Dr. Mars Caroline Wibowo, S.T., Ed.). Yayasan Prima Agus Teknik.
- Wijonarko, P. (2025). Neural network backpropagation untuk memprediksi tingkat curah hujan Kota Padang (Studi kasus: BMKG). *Jurnal Informatika*, 13(3), 2333–2339.
- Yuniarti, T. (2022). Regresi linier, exponential smoothing, dan ARIMA. *Jurnal Statistika*, 3(1), 1–15.