

PREDIKSI CURAH HUJAN DI WILAYAH MAKASSAR-MAROS MENGUNAKAN JARINGAN SARAF TIRUAN DENGAN METODE *BACKPROPAGATION*

Shane Feehily Weng (Universitas Atma Jaya Makassar, Makassar, shaneweng256@gmail.com)

Richard Frans (Universitas Atma Jaya Makassar, Makassar, richardfrans.rf@gmail.com)

Vinsensia Paola Prattyni (Universitas Atma Jaya Makassar, Makassar, vinsensia.sensi@gmail.com)

Received: 23 November 2025, Revised: 12 Desember 2025, Accepted: 12 Desember 2025

ABSTRAK

Curah hujan merupakan salah satu faktor penting dalam berbagai sektor seperti pertanian, pengelolaan air, dan mitigasi bencana hidrometeorologi. Pola curah hujan yang tidak menentu dan bersifat nonlinier menjadikan metode statistik konvensional kurang efektif dalam melakukan prediksi yang akurat. Penelitian ini bertujuan untuk mengembangkan model prediksi curah hujan menggunakan Jaringan Saraf Tiruan (*Artificial Neural Network*) dengan metode *Backpropagation* berbasis MATLAB, dan menganalisis akurasi serta performa model dalam memprediksi curah hujan berdasarkan data historis. Model jaringan yang dibangun memiliki arsitektur 4–12–1, dengan empat neuron pada lapisan input, dua belas neuron pada lapisan tersembunyi, dan satu *neuron* pada lapisan *output*. Hasil pelatihan menunjukkan bahwa model dengan data curah hujan bulanan memiliki performa yang baik dengan nilai Koefisien Korelasi (R) sebesar 0,84729 dan nilai MSE sebesar $1,22330 \times 10^{-2}$. Hasil penelitian ini menunjukkan bahwa metode *Backpropagation* mampu memberikan hasil prediksi curah hujan bulanan yang akurat dan dapat digunakan sebagai alat bantu dalam perencanaan serta pengelolaan sumber daya air di wilayah Makassar dan Maros.

Kata kunci: Curah hujan, Jaringan Saraf Tiruan, *Backpropagation*, MATLAB.

ABSTRACT

Rainfall is one of the most important factors in various sectors such as agriculture, water resource management, and hydrometeorological disaster mitigation. The irregular and nonlinear characteristics of rainfall patterns render conventional statistical methods less effective in producing accurate predictions. This study aims to develop a rainfall prediction model using an Artificial Neural Network (ANN) with the Backpropagation method implemented in MATLAB, and to analyze the accuracy and performance of the model in predicting rainfall based on historical data. The constructed network model employs a 4–12–1 architecture, consisting of four neurons in the input layer, twelve neurons in the hidden layer, and one neuron in the output layer. The training results indicate that the model trained with monthly rainfall data demonstrates good performance, achieving a Correlation Coefficient (R) of 0.84729 and a Mean Squared Error (MSE) value of 1.22330×10^{-2} . These findings suggest that the Backpropagation method is capable of providing accurate monthly rainfall predictions and can be utilized as a decision-support tool in planning and managing water resources in the Makassar and Maros regions.

Keywords: Rainfall, Artificial Neural Network, Backpropagation, MATLAB.

PENDAHULUAN

Curah hujan merupakan indikator cuaca yang sangat penting dalam bidang pertanian, pengelolaan sumber daya air, perencanaan kota, serta mitigasi bencana seperti banjir dan tanah longsor. Di Sulawesi Selatan, khususnya wilayah Makassar dan Maros, pola curah hujan cenderung fluktuatif dan dipengaruhi oleh berbagai faktor iklim seperti musim, suhu, kelembaban, penyinaran matahari, kecepatan angin, serta kondisi geografis (BMKG, 2024). Ketidakpastian pola hujan tersebut menyulitkan perencanaan, sehingga diperlukan model prediksi yang akurat untuk mendukung pengambilan keputusan.

Metode statistik konvensional seperti regresi linear dan deret waktu telah banyak digunakan, namun memiliki keterbatasan dalam menangkap hubungan nonlinier dan dinamika kompleks antar variabel iklim. Selain itu, beberapa penelitian terdahulu masih terbatas pada penggunaan variabel tunggal, periode data yang relatif singkat, serta evaluasi model yang belum komprehensif, khususnya untuk wilayah Makassar dan Maros.

Perkembangan *Artificial Intelligence* (AI), khususnya *Artificial Neural Network* (ANN), menawarkan pendekatan yang lebih adaptif dalam memodelkan pola nonlinier. Dengan dukungan MATLAB dan *toolbox Neural Network*, pengembangan model dapat dilakukan secara sistematis dan efisien. Penelitian ini bertujuan mengembangkan model prediksi curah hujan di Makassar dan Maros menggunakan ANN berbasis multivariat di MATLAB. Kontribusi penelitian ini terletak pada penggunaan beberapa variabel iklim sebagai input, proses pelatihan dan pengujian yang terstruktur, serta evaluasi kinerja model yang komprehensif untuk meningkatkan akurasi prediksi.

METODOLOGI PENELITIAN

Bagian ini berisikan subjek penelitian, teknik pengumpulan data, lokasi penelitian, teknik pengumpulan data dan teknik analisis data. Secara sederhana, bagian ini menjelaskan bagaimana data-data diperoleh dan dihasilkan pada suatu penelitian yang dilakukan.

Jenis Penelitian

Jenis penelitian ini adalah penelitian kuantitatif yaitu dilakukan pengumpulan data dan dianalisis untuk mengukur variabel dan hubungannya menggunakan aplikasi perangkat lunak MATLAB untuk membangun model dan mengevaluasi performa model prediksi curah hujan

Data dan Sumber Data Penelitian

Data yang digunakan adalah data historis curah hujan bulanan dari tahun 2014 hingga 2024 yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) wilayah Makassar dan Maros.

Hipotesis Penelitian

Secara umum, diasumsikan bahwa model Jaringan Saraf Tiruan (*Artificial Neural Network*) dengan metode *Backpropagation* mampu memprediksi curah hujan bulanan di wilayah Makassar–Maros dengan tingkat akurasi yang baik. Hal ini didasarkan pada kemampuan ANN dalam mempelajari hubungan nonlinier antara variabel-variabel meteorologis yang kompleks. Adapun fungsi aktivasi yang digunakan yaitu fungsi aktivasi sigmoid dengan rumus sebagai berikut.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (1)$$

Di mana:

- x = nilai input
- e = bilangan eksponensial (≈ 2.718)
- $\sigma(x)$ = output antara 0 dan 1

Secara khusus, diasumsikan bahwa terdapat hubungan yang signifikan antara suhu udara, kelembaban udara, penyinaran matahari, dan kecepatan angin terhadap nilai curah hujan bulanan. Model ANN *Backpropagation* diharapkan dapat mengenali pola dan keterkaitan antara keempat parameter tersebut dengan curah hujan, sehingga mampu menghasilkan prediksi yang mendekati data aktual. Data curah hujan yang memiliki nilai nol akan dikeluarkan dan tidak dipakai karena data yang akan dihitung hanya data yang memiliki curah hujan (terjadi hujan pada bulan itu). Dikeluarkannya nilai nol juga karena dapat mengganggu proses pembelajaran jaringan.

Selain itu, hasil pelatihan jaringan diharapkan menghasilkan nilai *Mean Square Error* (MSE) yang rendah serta koefisien korelasi (R) yang tinggi, yang menunjukkan bahwa model memiliki performa prediksi yang baik dan dapat digunakan sebagai pendekatan dalam memprediksi curah hujan.

Langkah Penelitian

Langkah-langkah untuk melakukan prediksi pada penelitian ini adalah sebagai berikut.

a. Pengumpulan Data

Data yang diperlukan pada penelitian ini berupa data historis curah hujan harian selama 10 tahun mulai dari 2014 sampai dengan 2024 yang disediakan oleh tiga Stasiun BMKG yaitu Stasiun Meteorologi (BMKG) Paotere, Stasiun Klimatologi Sulawesi Selatan dan Stasiun Meteorologi Klas I Hasanuddin Makassar.

b. Pra-Pemrosesan Data

Setelah dilakukan pengumpulan, data dikategorikan berdasarkan masing-masing data. Variabel curah hujan akan menjadi variabel Y (*output*) dan suhu, kelembaban, penyinaran matahari serta kecepatan angin akan menjadi variabel X (*input*).

Kemudian data curah hujan yang memiliki nilai 0 akan dikeluarkan dan tidak dipakai. Dikeluarkannya nilai nol ini karena nilai nol dapat mengganggu proses pembelajaran jaringan.

Tabel 1. Format data curah hujan bulanan tahun 2014 hingga 2024

Tahun	Bulan	Curah Hujan (mm)	Suhu (°C)	Kelembaban (%)	Penyinaran Matahari (Jam)	Kecepatan Angin (m/s)
2014	Januari	16.8	26.7	89.0	2.5	3.2
	Februari	11.0	27.2	86.1	4.6	2.5
	Maret	10.0	27.6	85.6	5.4	2.1
	April	4.7	28.1	84.1	6.2	2.0
	Mei	3.3	28.5	80.8	6.7	1.9
	Juni	1.9	27.2	79.2	5.7	1.8
	Juli	1.0	27.5	78.5	7.6	1.9
	Agustus	0.2	27.4	75.8	7.5	2.1
	Nopember	3.0	28.7	78.1	7.5	2.2
	Desember	12.1	27.4	85.0	5.2	2.4

c. Mengeluarkan Data *Outlier*

Siombing (2022) menjelaskan data *outlier* merupakan data-data yang bobotnya bisa didefinisikan sebagai bobot menyimpang terlalu jauh dari data-data yang lain. Hal ini nantinya dapat menyebabkan data yang ada tidak terdistribusi secara normal. Digunakan salah satu metode untuk mengeluarkan data *outlier* ini yaitu metode *Z-score* yang merupakan ukuran statistik yang digunakan untuk menentukan seberapa jauh suatu nilai data menyimpang dari rata-ratanya dalam satuan simpangan baku. Secara matematis, rumus *Z-score* cukup sederhana:

$$Z_i = \frac{X_i - \bar{X}}{s} \quad (2)$$

Dengan keterangan:

Z_i : nilai *Z-score* dari data ke- i ,

X_i : nilai data ke- i ,

\bar{X} : rata-rata (*mean*) dari keseluruhan data,

s : simpangan baku (*standard deviation*) dari data.

Rentang *Z-score* yang digunakan adalah -3 sampai dengan 3 yang didasarkan pada prinsip distribusi normal (*Gaussian Distribution*), dimana sekitar 99,7% dari seluruh data akan berada dalam rentang tersebut. Ghazali (2018) mengatakan untuk sampel yang lebih besar (lebih dari 80), standar skor dinyatakan *outlier* apabila nilainya berada pada kisaran 3 ke atas.

d. Normalisasi Data

Normalisasi data ini dilakukan untuk menyamakan ukuran nilai dari tiap data agar bobot datanya menjadi lebih seimbang. Dalam penelitian ini digunakan teknik normalisasi *min-max* berjarak antara 0 sampai 1. Digunakan *range* 0 sampai 1 karena menurut Chamidah (2012), fungsi sigmoid yang biasanya digunakan dalam *backpropagation* akan membawa nilai *input* dengan range yang tak terbatas ke nilai *output* yang terbatas, yaitu dalam range 0 sampai 1. Menurut Han, et al. (2011), normalisasi data teknik *min-max* merupakan transformasi linier dari data asli.

Persamaan normalisasi data *min-max* dapat dilihat pada persamaan 3.

$$v'_i = \frac{v_i - \min_A}{\max_A - \min_A} (\text{new_max}_A - \text{new_min}_A) + \text{new_min}_A \quad (3)$$

Di mana :

v : nilai normal


- A : variabel
- min_A : nilai minimum pada variabel
- max_A : nilai maksimum pada variabel
- new_min_A : nilai minimum baru pada nilai normal
- new_max_A : nilai maksimum baru pada nilai normal

Lalu untuk melakukan denormalisasi nantinya, dapat dilihat pada persamaan 4 berikut.

$$v_i = \frac{v_i - new_min_A}{(new_max_A - new_min_A)} (max_A - min_A) + min_A \tag{4}$$

e. Desain, *Network training* dan Pengujian model ANN

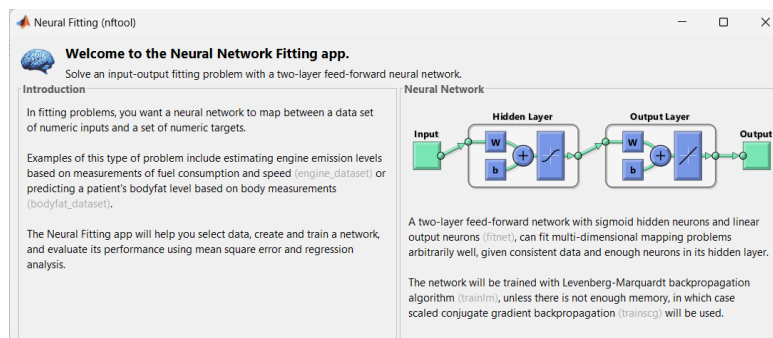
Pada langkah ini, dilakukan pemodelan arsitektur ANN dengan menggunakan MATLAB. Buka aplikasi MATLAB, kemudian pilih *apps* dan pilih *neural net fitting*.



Sumber: MATLAB R2021a

Gambar 1. Tampilan menu *apps* pada MATLAB

Setelah itu, akan muncul tampilan dari program *neural net fitting* seperti pada gambar 2.



Sumber: MATLAB R2021a

Gambar 2. App *Neural Net Fitting*

f. Validasi Kinerja

Perlu dilakukan validasi kinerja pada jaringan yang telah dijalankan karena dalam pengukuran prediksi, tidak ada yang dapat menyentuh hingga 100%. Oleh karena itu, diperlukan suatu metode perhitungan untuk mengetahui tingkat kesalahan yang terjadi.

(i) Rata-rata Kuadrat Kesalahan (*Mean Square Error = MSE*)

Voni (2016), menyebutkan bahwa *mean square error* dihitung dari penjumlahan kuadrat semua kesalahan prediksi pada setiap periode dan membaginya dengan jumlah periode peramalan. Rumus dari MSE ini dapat dilihat pada persamaan 5.

$$MSE = \frac{(A_t - F_t)^2}{n} \tag{5}$$

Di mana :

A_t : Nilai curah hujan aktual
 F_t : Nilai hasil prediksi curah hujan
 n : jumlah data

(ii) **Rata-rata presentase kesalahan absolut (*Mean Absolute Presentage Error = MAPE*)**

Voni (2016) juga menyebutkan MAPE merupakan perhitungan yang membandingkan presentase perbedaan nilai rata-rata absolut antara nilai yang diprediksi dengan nilai aktual yang persamaannya dapat dilihat pada persamaan 6 berikut.

$$MAPE = \left(\frac{1}{n} \right) \left| \frac{F_t - A_t}{A_t} \right| \tag{6}$$

Di mana :

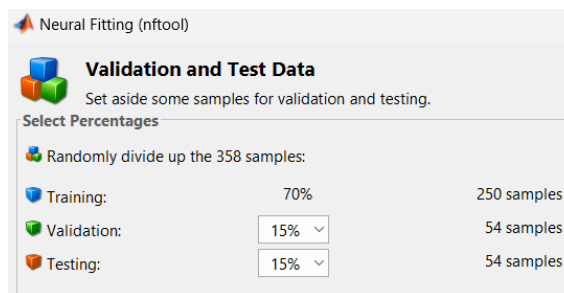
A_t : Nilai curah hujan aktual
 F_t : Nilai hasil prediksi curah hujan
 n : jumlah data

HASIL DAN PEMBAHASAN

Bagian ini berisikan hasil penelitian yang diperoleh berdasarkan analisa data yang dilakukan beserta dengan pembahasannya secara ilmiah. Hasil penelitian yang diperoleh harus dijelaskan secara detail terkait dengan mengapa hal tersebut bisa terjadi secara saintifik atau mengapa hubungan antara variabel-variabel yang terdapat pada hasil penelitian bisa sedemikian.

Deskripsi Data

Data yang diambil untuk dijadikan variabel yaitu curah hujan (mm), suhu (°C), kelembaban (%), penyinaran matahari (jam) dan kecepatan angin (m/s) dari tahun 2014 sampai dengan 2024. Total data yang digunakan dalam penelitian ini sebanyak 358 untuk masing-masing variabel, yang dibagi menjadi tiga yaitu data *network training* sebanyak 70%, data validasi 15% dan data tes sebanyak 15%.




Sumber: MATLAB R2021a

Gambar 3. Rasio pembagian data *training*, *validation* dan *testing*

A. Arsitektur Jaringan Saraf Tiruan

Model dari jaringan saraf tiruan yang digunakan adalah *multilayer perceptron (MLP)* dengan metode *backpropagation* yang terdiri dari *Input layer* sebanyak 4 *neuron*, *hidden layer* dengan jumlah 12 *neuron* dan *output layer* sebanyak 1 *neuron* yang akan menjadi prediksi curah hujan.



Sumber: MATLAB R2021a

Gambar 4. Arsitektur jaringan saraf tiruan


B. Hasil *Network training*, Pengujian dan Validasi Model

Setelah konfigurasi dari jaringan telah selesai, selanjutnya dilakukan *network training*, validasi dan pengujian pada model jaringan yang sudah dibentuk. Pada *network training* jaringan, digunakan algoritma *network training Levenberg-Marquardt*. *Network training* dilakukan pada dua data curah hujan yaitu curah hujan bulanan yang hasilnya dapat dilihat di halaman selanjutnya.

1. **Prediksi Curah Hujan Bulanan**

Beberapa hasil dari prediksi curah hujan bulanan Output yang diteliti dapat dilihat sebagai berikut.

(i) **Analisis Regresi (*Regression Plot*)**




Sumber: MATLAB R2021a

Gambar 5. Hasil plot regresi bulanan

Seperti yang dapat dilihat pada gambar 5, Koefisien (R) untuk data *training* sebesar $R = 0,85022$, data validasi $R = 0,84283$, data testing $R = 0,83624$ dan data keseluruhan sebesar $R = 0,84729$. Plot regresi ini memperlihatkan bahwa Sebagian besar titik data yang digunakan mendekati garis ideal ($Y = T$), walaupun masih ada juga titik data yang tersebar disekitar garis ideal.

(ii) **Kinerja Jaringan Selama *Network Training***




Sumber: MATLAB R2021a

Gambar 6. Grafik kinerja jaringan bulanan

Berdasarkan gambar 6, terlihat bahwa nilai *error* (MSE) mengalami penurunan pada awal *network training* hingga mencapai kestabilan pada sekitar *epoch* ke-6. Pada titik tersebut, diperoleh nilai *best validation performance* sebesar 0,012629. Hal ini menunjukkan bahwa model mencapai kemampuan generalisasi terbaiknya pada *epoch* ke-6. Setelah itu, nilai *error* pada data validasi mulai meningkat, sehingga *network training* dihentikan secara otomatis untuk mencegah *overfitting*.

(iii) **Status *Network training* (*Training State*)**

Hasil *network training* pada gambar 7 menunjukkan bahwa pada *epoch* ke-12, nilai *gradient* akhir adalah 0.0075337. Nilai ini menandakan bahwa pembaruan bobot jaringan masih terjadi, namun perubahannya sudah relatif kecil. Parameter mu konvergen pada nilai 0.0001, yang menandakan algoritma *Levenberg-Marquardt* mampu menyesuaikan parameter optimasi dengan baik. Selain itu, jumlah *validation checks* mencapai angka 6 pada *epochs* ke 12, sehingga *network training* berhenti karena kinerja pada data validasi tidak lagi mengalami perbaikan.




Sumber: MATLAB R2021a

Gambar 7. Grafik status *network training* bulanan

Dengan kondisi ini, dapat disimpulkan bahwa proses *network training* berhenti pada saat yang tepat untuk mencegah jaringan mengalami *overfitting* sekaligus memastikan model tetap mampu melakukan generalisasi.

(iv) **Distribusi Error (Error Histogram)**

Error histogram adalah grafik batang yang menunjukkan distribusi *error* antara nilai prediksi jaringan (Y) dengan nilai target aktual (T). Pada histogram *error*, sebagian besar kesalahan prediksi terdistribusi di sekitar nilai nol, dengan mayoritas *error* berada dalam rentang -0,1 hingga 0,1.




Sumber: MATLAB R2021a

Gambar 8. Grafik distribusi *error* bulanan

(v) **Evaluasi Jaringan (Evaluate Network)**

Secara keseluruhan, hasil evaluasi jaringan menunjukkan nilai MSE sebesar $1,22330 \times 10^{-2}$ dengan koefisien korelasi (R) sebesar 0,84518.



Sumber: MATLAB R2021a

Gambar 9. Evaluasi jaringan bulanan

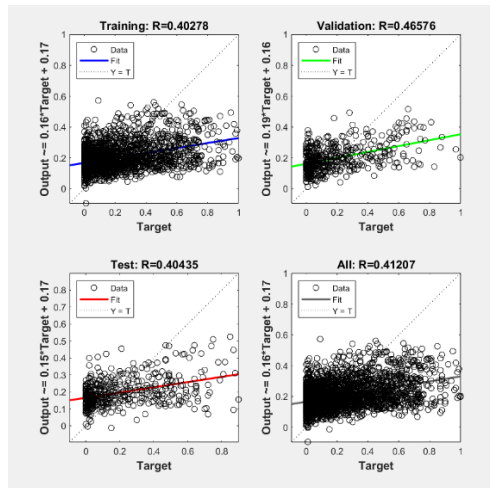
Hasil ini memperkuat bahwa jaringan yang dibangun dapat melakukan prediksi curah hujan bulanan dengan tingkat akurasi yang cukup baik, serta mampu menangkap pola hubungan antara data masukan dan data target dengan cukup efektif.

2. Prediksi Curah Hujan Harian

Sebagai pembandingan, dilakukan juga prediksi curah hujan harian. Data curah hujan harian memiliki tingkat fluktuasi yang tinggi karena sangat dipengaruhi oleh variabel atmosfer jangka pendek seperti perubahan suhu, tekanan udara, arah angin, dan kelembaban. Kondisi tersebut menyebabkan pola data harian menjadi lebih kompleks dan sulit dikenali oleh jaringan.

Diharapkan dari hasil perbandingan ini dapat diketahui bahwa data bulanan cenderung menghasilkan nilai kesalahan yang lebih kecil dan korelasi yang lebih tinggi dibandingkan data harian, karena pola hujan bulanan lebih mudah dipelajari oleh jaringan. Data yang akan digunakan sebanyak 3219 data variabel, yang hasilnya dapat dilihat pada poin berikut.

(i) Analisis Regresi (*Regression Plot*)




Sumber: MATLAB R2021a

Gambar 10. Grafik analisis regresi harian

Analisis regresi yang ditunjukkan pada gambar 10, menghasilkan nilai koefisien korelasi (R), di mana data *network training*, R = 0,40278, Data validasi, R = 0,46576, data pengujian, R = 0,40435 dan nilai keseluruhan, R = 0,41207.

Nilai R yang relatif rendah (sekitar 0,37– 0,43) menunjukkan bahwa hubungan antara data aktual dan hasil prediksi belum terlalu kuat. Hal ini terlihat pula pada grafik regresi, di mana banyak titik data masih menyebar cukup jauh dari garis ideal ($Y = T$). Dengan kata lain, model belum mampu menangkap pola data secara optimal.

(ii) Kinerja Jaringan Selama *Network training* (*Performance Plot*)



Sumber: MATLAB R2021a


Gambar 11. Grafik Kinerja Jaringan Harian

Grafik *performance plot* pada gambar 15 menunjukkan bahwa nilai *Mean Squared Error* (MSE) turun dengan cepat pada *epoch* awal, kemudian menjadi relatif stabil pada *epoch* berikutnya. Nilai *best validation performance* diperoleh sebesar 0,033938 pada *epoch* ke-20.

Penurunan *MSE* yang signifikan pada awal pelatihan menandakan bahwa bobot-bobot jaringan berhasil menyesuaikan diri dengan pola data masukan. Stabilitasnya nilai *MSE* setelah *epoch* ke-20 menunjukkan bahwa jaringan telah mencapai titik konvergensi, sehingga peningkatan jumlah *epoch* selanjutnya tidak memberikan peningkatan akurasi yang berarti.

(iii) **Status Network Training (Training State)**

Hasil *training state* pada gambar 16 di mana *gradient* terakhir bernilai 0,0031604 pada *epoch* ke-26, menandakan bahwa pembaruan bobot jaringan sudah sangat kecil dan proses pembelajaran hampir mencapai kestabilan. μ (μ) bernilai konstan pada $1e-05$, menunjukkan bahwa algoritma *Levenberg-Marquardt* sudah menyesuaikan parameter optimasi dengan baik dan stabil. *Validation checks* mencapai angka 6 pada *epoch* ke-26, yang berarti *network training* dihentikan karena kinerja validasi tidak lagi menunjukkan peningkatan setelah beberapa iterasi.




Sumber: MATLAB R2021a

Gambar 12. Grafik Status Network Training Harian

Dengan kondisi ini, dapat disimpulkan bahwa proses *network training* berhenti pada saat yang tepat untuk mencegah jaringan mengalami *overfitting* sekaligus memastikan model tetap mampu melakukan generalisasi.

(iv) **Distribusi Error (Error Histogram)**

Histogram *error* memperlihatkan bahwa sebagian besar kesalahan prediksi terdistribusi di sekitar nilai nol, dengan mayoritas *error* berada pada rentang -0,2 hingga 0,2. Dari rentang nilai tersebut, dapat dilihat bahwa terjadi penyimpangan prediksi cukup jauh dari nilai aktual jika dibandingkan dengan distribusi *error* bulanan.



Sumber: MATLAB R2021a

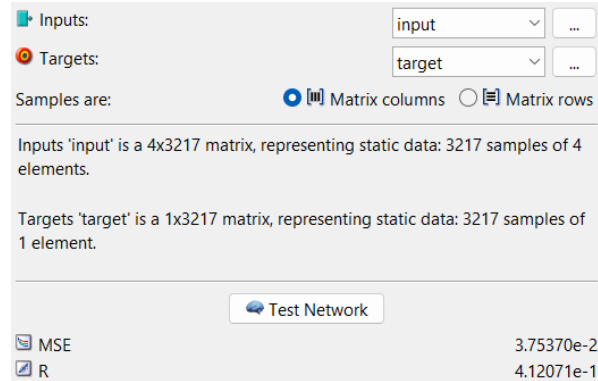
Gambar 13. Grafik Distribusi Error Harian

Distribusi *error* yang tidak sepenuhnya simetris ini mengindikasikan bahwa proses pelatihan jaringan saraf tiruan belum sepenuhnya optimal dalam mengenali pola data secara menyeluruh. Kondisi tersebut dapat disebabkan oleh karakteristik data yang sangat bervariasi

atau parameter pelatihan yang belum tepat, seperti jumlah neuron tersembunyi, *learning rate*, maupun rasio pembagian data pelatihan dan validasi.

(v) **Evaluasi Jaringan (*Evaluate Network*)**

Hasil evaluasi jaringan menunjukkan bahwa model menghasilkan nilai MSE sebesar 0,0375 dengan koefisien korelasi keseluruhan (R) sebesar 0,41207. Nilai ini memperlihatkan bahwa tingkat akurasi prediksi masih tergolong rendah.



Sumber: MATLAB R2021a


Gambar 14. Evaluasi Jaringan Harian

Dengan demikian, jaringan saraf tiruan pada konfigurasi ini belum mampu memodelkan pola curah hujan bulanan secara akurat, dan diperlukan penyesuaian lebih lanjut seperti memperbesar jumlah *neuron*, menambah data latih, atau mencoba algoritma optimasi lain.

3. Hasil Prediksi Curah Hujan Bulanan (Bulanan)

Setelah melalui proses *network training* jaringan saraf tiruan dan evaluasi model, diperoleh *output* berupa curah hujan prediksi yang dapat langsung dibandingkan hasilnya dengan curah hujan aktual bulanan. Hasil yang masih dalam bentuk data normalisasi diubah Kembali dengan melakukan denormalisasi data menggunakan persamaan (3). Untuk perbandingan antara curah hujan aktual bulanan dan curah hujan prediksi bulanan dapat dilihat pada gambar

Secara visual, batang berwarna oranye (hasil prediksi) sering kali berada di bawah batang biru (data aktual), yang menunjukkan bahwa model cenderung melakukan *underestimation*, yaitu memprediksi nilai curah hujan lebih rendah daripada nilai sebenarnya.



Gambar 15. Grafik Perbandingan Curah Hujan Aktual dengan Prediksi

Meskipun demikian, secara keseluruhan pola pergerakan antara keduanya masih searah, menandakan bahwa model telah berhasil menangkap sebagian besar tren umum curah hujan meskipun dengan akurasi yang belum tinggi.

Tabel 2. Perbandingan curah hujan actual dan prediksi

Tahun	Bulan	Curah Hujan (mm)	Prediksi Curah Hujan (mm)	RMSE
2014	Januari	16.8	17.87	0.06
	Februari	11.0	14.81	0.20
	Maret	10.0	9.92	0.01
	April	4.7	7.41	0.14
	Mei	3.3	5.28	0.11
	Juni	1.9	4.09	0.12
	Juli	1.0	3.12	0.11
	Agustus	0.2	2.85	0.14
	Nopember	3.0	4.67	0.09
	Desember	12.1	13.22	0.06

KESIMPULAN

Berdasarkan penelitian mengenai prediksi curah hujan menggunakan jaringan saraf tiruan (ANN) dengan algoritma backpropagation, disimpulkan bahwa:

1. Model ANN dengan arsitektur 4-12-1 berhasil memprediksi curah hujan dengan akurasi yang cukup tinggi ($R = 0,84729$), mampu mengenali hubungan nonlinier antara variabel input (suhu, kelembaban, penyinaran matahari, dan kecepatan angin) terhadap curah hujan. Proses pelatihan menunjukkan MSE terbaik 0,01223 dan korelasi kuat ($R = 0,845$), dengan konvergensi yang efisien tanpa overfitting.
2. Untuk pengembangan lebih lanjut, disarankan untuk menambah data historis curah hujan, menggabungkan model hibrida dengan teknik lain, dan menerapkan deep learning seperti CNN atau RNN untuk meningkatkan ketepatan dan kompleksitas prediksi curah hujan.

DAFTAR PUSTAKA

- Ali, Z. I., Nur, I. M., & Fauzi, F. (2020). Artificial Neural Network Untuk Memprediksi Curah Hujan Di Kota Padang Dengan Metode Backpropagation dan Adaline.
- Aprianto, R., & Puspitasari, P. (2020). Prediksi Curah Hujan Bulanan Tahun 2020 Kabupaten Sumbawa Menggunakan Artificial Neural Network (ANN) Back Propagation. *Prosiding Seminar Nasional IPPeMas 2020 Inovasi Hasil Penelitian dan Pengabdian kepada Masyarakat dalam Menunjang Era Industri 4.0*, 622–628.
- Apriyanto, A., Fitriyanto, S., & Nufus, H. (2024). Analisis Pola Musim Hujan dan Kemarau Berdasarkan Prediksi Curah Hujan Tahun 2024 Menggunakan *Artificial Neural Network (ANN)* di Kabupaten Sumbawa. *Jurnal Ilmiah Multi Sciences*, 16(1), 25–32.
- Astutik, V. T. (2017). *Peramalan Runut Waktu Curah Hujan Menggunakan Metode" SVR-ANT CO"*
- Basha, C. Z., Bhavana, N., & Bhavya, P. (2020, July). Rainfall prediction using machine learning & deep learning techniques. In *2020 international conference on electronics and sustainable communication systems (ICESC)* (pp. 92-97). IEEE.
- Chamidah, N., & Salamah, U. (2012). Pengaruh normalisasi data pada jaringan syaraf tiruan *backpropagasi gradient descent adaptive gain (BPGDAG)* untuk klasifikasi. *ITSMART: Jurnal Teknologi dan Informasi*, 1(1), 28-33.
- Darma, S., & Firzada, F. (2024). Pemanfaatan Algoritma Levenberg-Marquardt untuk Analisis Prediksi Presentase Penduduk yang Melakukan Pengobatan Sendiri. *Journal of computer system and informatics* 6(1), 386-395.
- Dzulkarnain, A., & Ma'ady, M. N. P. (2024). Teori dan Penerapan Backpropagation Neural Networks untuk Internet of Things: Online dan Batch Mode. *Jurnal SISFO Inspirasi Profesional Sistem Informasi* 11(1), 25-38

- Fitriyanti. (2022). Aplikasi Jaringan Syaraf Tiruan Backpropagation dalam Prediksi Curah Hujan Bulanan di Kabupaten Wajo Sulawesi Selatan. *JPF (Jurnal Pendidikan Fisika) Universitas Islam Negeri Alauddin Makassar*, 11(1), 44–55.
- Frans, R., & Arfiadi, Y. (2024). PREDIKSI KUAT TEKAN BETON BERDASARKAN JARINGAN SARAF TIRUAN DAN MODEL REGRESI LINEAR BERGANDA. *Jurnal Konstruksi Teknik Sipil*, 1(3), 278-284.
- Gavin, H. P. (2019). The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems. *Department of Civil and Environmental Engineering Duke University August*, 3, 1-23.
- Ghozali, I. (2001). Aplikasi Analisis Multivariate Dengan Program SPSS, Badan Penerbit Universitas Diponegoro, Semarang.
- Han, J., Pei, J., & Tong, H. (2022). *Data mining: concepts and techniques*. Morgan kaufmann.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. Prentice hall PTR.
- Herdhyanti, A., Muflikhah, L., & Cholissodin, I. (2022). Prediksi Curah Hujan dengan Empat Parameter menggunakan Backpropagation (Studi Kasus: Stasiun Meteorologi Ahmad Yani). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 6(12), 5862-5870
- Kusumadewi, S. (2004). *Artificial Intelligence (Teknik dan Aplikasinya)*. Graha Ilmu.
- Li, M. (2024). Comprehensive review of backpropagation neural networks. *Academic Journal of Science and Technology*, 9(1), 150-154.
- Parmar, A., Mistree, K., & Sompura, M. (2017, March). Machine learning techniques for rainfall prediction: A review. In *International conference on innovations in information embedded and communication systems* (Vol. 3, p. 6).
- Program Studi Teknik Sipil Fakultas Teknik Universitas Atma Jaya Makassar. 2022. *Pedoman Penulisan Tugas Akhir (Skripsi)*. Universitas Atma Jaya, Makassar.
- Rácz, A., Bajusz, D., & Héberger, K. (2021). Effect of dataset size and train/test split ratios in QSAR/QSPR multiclass classification. *Molecules*, 26(4), 1111.
- Rojas, R. (1996). The backpropagation algorithm. In *Neural networks: a systematic introduction* (pp. 149-182). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Sihombing, P. R., Suryadiningrat, S., Sunarjo, D. A., & Yuda, Y. P. A. C. (2023). Identifikasi Data Outlier (Pencilan) dan Kenormalan Data Pada Data Univariat serta Alternatif Penyelesaiannya. *Jurnal Ekonomi Dan Statistik Indonesia*, 2(3), 307-31.
- Sinaga, D. (2020). Jaringan Saraf Tiruan Infeksi Mata Dengan Menggunakan Metode Berarsitektur Multi Layer Perceptron. *Jdan teknologi ilmiah (INTI) Jurnal Majalah Ilmiah Informasi*, 7(2), 189-192.
- Sutikno, I., Sukmawati, N. E., Priyo, S. S., Helmie, A. W., Indra, W., Nurdin, B., & Diah, P. D. (2016). Backpropagation dan Aplikasinya. *Ilmu Komput. Stud. Kasus dan Apl*, 135-146.
- Tjolleng, A. (2017). *Pengantar Pemrograman Matlab*. Elex Media Komputindo.
- Wijaya, A. H. (2019). Artificial Neural Network Untuk Memprediksi Beban Listrik dengan Menggunakan metode Backpropagation (Studi Kasus PT. PLN Regional Sumatera Barat). *Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer dan Teknologi Informasi*, 5(2), 61-70.
- Yoranda, D. H., Furqon, M. T., & Data, M. (2018). Prediksi Intensitas Curah Hujan Menggunakan Metode Jaringan Saraf Tiruan Backpropagation. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(10), 3793-3801.