

Penerapan metode *radial basis function neural network* dalam memprediksi curah hujan

Abriadi Rangkuti¹, Rima Aprilia²

^{1,2}Program Studi Matematika, Universitas Islam Negeri Sumatera Utara, Sumatera Utara, Indonesia

Correspondence: abriadi0703201020@uinsu.ac.id

Received: August 12, 2025 | **Revised:** September 3, 2025 | **Accepted:** September 18, 2025 | **Published Online:** September 30, 2025

Abstract

North Tapanuli Regency is highly vulnerable to natural disasters such as floods and landslides due to high rainfall intensity and complex geographical conditions. To anticipate these risks, this study aims to predict rainfall using the Radial Basis Function Neural Network (RBFNN) method. The number of nodes in the input layer was determined based on significant lags identified in the Partial Autocorrelation Function (PACF) plot. The hidden layer was constructed using the K-Means clustering method to define cluster centers and standard deviations. Model performance was evaluated using the Root Mean Square Error (RMSE) metric. The results indicate that the optimal network structure is found in the 4-7-1 architecture, yielding an RMSE of 11.006. This model was then used to predict rainfall for the period from September 1 to December 31, 2024. The prediction results show that rainfall intensity tends to remain stable, ranging from 5 to 9 mm, with the highest value of 9.35 mm on September 1 and the lowest value of 5.40 mm on September 22. Based on these findings, the potential for natural disasters due to high rainfall during the forecast period is relatively low. The RBFNN model has proven effective for handling nonlinear meteorological data patterns, making it a valuable tool for a reference for further academic research in rainfall prediction and data clustering.

Keywords: RBFNN; Rainfall; Forecasting; RMSE

How to Cite: Rangkuti, A., & Aprilia, R. (2025). Penerapan metode radial basis function neural network dalam memprediksi curah hujan. *Aksioma: Jurnal Matematika dan Pendidikan Matematika*, 16(2), 335-348. <https://doi.org/10.26877/w2rkdg62>

PENDAHULUAN

Fenomena perubahan iklim global telah memberikan dampak signifikan terhadap keseimbangan pola cuaca diberbagai wilayah termasuk indonesia, Curah hujan merupakan parameter penting dalam prediksi cuaca dan pengendalian banjir yang saat ini bencana meteorologis seperti banjir sering terjadi dan menyebabkan kerugian yang serius oleh karena itu sangat penting untuk menerapkan model prediksi curah hujan (Yan et al., 2021).

Curah hujan di Indonesia umumnya dipengaruhi oleh fenomena *El-Nino dan Dipole Mode*, pengaruh fenomena ini berinteraksi dengan monsun dan pola lokal yang memengaruhi variabilitas curah hujan tahunan, bulanan dan intensitas hujan ekstrem (Aditya et al., 2021). Salah satu wilayah dengan curah hujan tinggi adalah Kabupaten

Tapanuli Utara, Kabupaten Tapanuli Utara terletak di dataran tinggi Sumatera Utara dengan ketinggian antara 150-1.700 m di atas permukaan laut dengan letak geografis yang berbukit dan kompleks yang berada $1^{\circ}20'-2^{\circ}41'$ lintang utara dan posisi $98^{\circ}05'-99^{\circ}16'$ bujur timur (Pemerintah Daerah Kabupaten Tapanuli Utara, 2020). Berdasarkan data Badan Pusat Statistik (BPS) Kabupaten Tapanuli Utara memiliki curah hujan dengan rata-rata 100-200 mm/pertahun (Pemerintah Daerah Kabupaten Tapanuli Utara, 2020). Kondisi wilayah yang demikian membuat daerah ini rentan terhadap bencana alam seperti banjir dan longsor, menurut Peraturan Dirjen RLPS No. 04 Tahun 2009 sebagaimana dikutip dalam (Nurwulan & Agustina, 2022) banjir terjadi akibat hujan turun di hulu secara terus menerus yang mengakibatkan meluapnya air dan menggenangi daerah sekitarnya. Longsor merupakan pergerakan dimana batuan dan tanah terpisah dari acuannya dan melengser ke arah bawah (Xu et al., 2023), penyebab terjadinya longsor dipicu oleh faktor alam yaitu curah hujan tinggi dan geologi atau itologi (Ahmed, 2021).

Bencana alam seperti banjir dan longsor dapat merugikan warga seperti merusak infrastruktur, pencemaran air, kerugian ekonomi bahkan dapat membahayakan keselamatan warga (Idrus & Umar, 2024), berdasarkan data dari BPS (2011-2024) tentang banyaknya desa/kelurahan yang mengalami kejadian bencana alam menurut kabupaten/kota di Sumatera Utara untuk kabupaten tapanuli utara pada tahun 2011 terjadi sebanyak 113, tahun 2014 sebanyak 113, tahun 2018 sebanyak 148, tahun 2021 sebanyak 48 dan tahun 2024 sebanyak 147. Dampak yang ditimbulkan dari kejadian bencana alam tersebut dibutuhkan upaya untuk meminimalkan resiko dari kejadian tersebut yaitu prediksi curah hujan, yang mana berdasarkan penelitian (Aldardasawi & Eren, 2021) faktor terbesar penyebab terjadinya banjir adalah curah hujan tinggi maka dari itu penelitian ini bertujuan untuk memprediksi curah hujan dengan data *time series* yang menjadi salah satu upaya yang dapat dilakukan, data *time series* dapat digunakan untuk prediksi curah hujan lebih akurat dengan menggunakan data sebelumnya. Dalam hal ini, metode *Radial Basis Function Neural Network* (RBFNN) dapat menjadi solusi permasalahan tersebut karena metode RBFNN dapat memberikan prediksi akurat dengan data seperti curah hujan yaitu data nonlinear.

Sejumlah penelitian telah menggunakan metode RBFNN untuk melakukan prediksi sebelumnya seperti peramalan jumlah titik panas (Aisyah dkk., 2021), peramalan jumlah penumpang kereta api (Aliyyah & Achmad, 2021), peramalan jumlah kunjungan

wisatawan (Ambarwati & Mariani, 2022), prediksi perilaku daya dukung atau *load-bearing behavior* (Moradi et al., 2020) dan prediksi stabilitas terowongan berbentuk persegi panjang (Jitchaijaroen et al., 2024). Dari penelitian-penelitian sebelumnya baru sedikit yang melakukan prediksi tentang curah hujan oleh karena itu penelitian ini berupaya untuk menunjukkan kenggunaan metode RBFNN dalam prediksi curah hujan berbasis data lokal di Tapanuli Utara, dengan demikian hasil penelitian dapat digunakan sebagai referensi pengambilan keputusan bagi pemerintah daerah dalam perencanaan mitigasi resiko bencana alam untuk data kedepannya.

METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan menggunakan metode RBFNN untuk melakukan prediksi curah hujan, penelitian kuantitatif merupakan penelitian yang menggunakan metode statistik dengan berfokus pada penggunaan statistik, matematika dan pengolahan data numerik (Younus & Zaidan, 2022). Metode RBFNN merupakan jenis jaringan syaraf tiruan yang memiliki 3 lapisan yaitu lapisan masuk (*input layer*) yang terdiri dari sejumlah besar unit perseptual yang berfungsi sebagai penghubung antara jaringan saraf dan lingkungan eksternal, lapisan tersembunyi (*hidden layer*) berada di antara lapisan *input* dan *output* yang berisi sekumpulan fungsi RBF yang memungkinkan konversi nonlinear dan lapisan keluar (*output layer*) dengan tugas memproses sinyal keluaran dari lapisan tersembunyi secara matematis untuk menghasilkan output akhir (Chen, 2022) sehingga cocok digunakan untuk prediksi curah hujan yang memiliki data nonlinear.

Penelitian ini menggunakan data sekunder *time series*, data sekunder adalah data yang dikumpulkan oleh pihak lain yang digunakan untuk tujuan yang sedang diteliti (Ajayi, Oluwatosin, 2023), sedangkan data *time series* adalah data yang dikumpulkan secara berurutan dalam waktu tertentu dan sering digunakan untuk pengamatan, prediksi dan deteksi anomali (Almeida et al., 2023). Penelitian dilaksanakan di stasiun Meteorologi kelas 2 Bandara Silangit, Tapanuli Utara dengan menggunakan 3 variabel penelitian yaitu curah hujan, suhu dan tekanan udara. Data yang digunakan dalam penelitian ini adalah data yang didapatkan dari Badan Meteorologi Klimatologi Geografi (BMKG) Bandara Silangit dari 1 Januari 2022 hingga 31 Agustus 2024 dan akan

dilakukan prediksi curah hujan dari 1 September 2024 hingga 31 Desember 2024 berikut data penelitiannya disajikan pada Tabel 1.

Tabel 1. Data penelitian

Tanggal	Curah Hujan	Suhu	Tekanan Udara
01-Jan-2022	13.9	18.6	1019.6
02-Jan-2022	45.8	17.7	1019.9
...			
31-Aug-2024	0.0	19.0	1019

Ada beberapa tahap-tahap penelitian untuk prediksi curah hujan menggunakan metode RBFNN berdasarkan penelitian sebelumnya, berikut tahapannya (Aisha, 2023), (1) Melakukan pengamatan data pada data yang dibutuhkan; (2) Melakukan pengolahan data jika terdapat data yang salah maka dilakukan perbaikan pada data; (3) Melakukan analisis data dengan menentukan model RBFNN terbaik untuk prediksi dengan tahapan sebagai berikut, (a) Melihat lag-lag *Partial Autocorrelation Function* (PACF) yang signifikan untuk menentukan jumlah *node* pada *input layer*; (b) Menentukan jumlah *node hidden layer* dengan cara melakukan uji coba dari 2 hingga 9 *node*; (c) Membagi data menjadi data training dan data testing dengan skala 70% : 30%; (d) Menghitung nilai standar deviasi menggunakan rumus (Sutijo et al., 2006).

$$k(x) = \arg \min_k \|x(n) - \mu_k(n)\|, k = 1, 2, \dots, m \quad (1)$$

(e) Menghitung nilai tengah menggunakan rumus (Sutijo et al., 2006).

$$\mu_k(n+1) = \begin{cases} \mu_k(n) + \eta(x(n) - \mu_k(n)) & , k = k(x) \\ \mu_k(n), & , \text{yang lain} \end{cases} \quad (2)$$

(f) Menghitung nilai fungsi aktivasi *Gaussian* menggunakan rumus (Aisha, 2023).

$$\phi_{kt}(x) = e^{-\frac{(x_{1t}-c_{1k})^2+(x_{2t}-c_{2k})^2+\dots+(x_{jt}-c_{jk})^2}{2\sigma_k^2}} \quad (3)$$

(g) Menghitung nilai bobot dengan nilai fungsi aktivasi *Gaussian* untuk data training menggunakan rumus (Aisha, 2023).

$$W_k = (\Phi'. \Phi)^{-1} x (\Phi'. Y) \quad (4)$$

(h) Menghitung nilai prediksi Y menggunakan rumus (Aisha, 2023).

$$\hat{Y} = \Phi. W_k \quad (5)$$

(i) Menghitung nilai *Root mean square error* (RMSE) dengan nilai prediksi Y untuk data testing menggunakan rumus (Hodson, 2022).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

Menggunakan jumlah *node hidden layer* dengan nilai RMSE terkecil; (4) Menghitung nilai prediksi untuk kedepannya menggunakan model RBFNN terbaik.

HASIL DAN PEMBAHASAN

Hasil penelitian berisi tentang prediksi curah hujan untuk 4 bulan dari 1 September 2024 hingga 31 Desember 2024, dari data pada Tabel.1 dilakukan uji statistik deskriptif untuk lebih mempermudah analisis data, statistik deskriptif merupakan hal dasar dalam statistika yang digunakan untuk pemodelan statistik dan merangkum serta merapikan data (Dong, 2023). Hasil uji statistik deskriptifnya disajikan pada Tabel 2.

Tabel 2. Statistik deskriptif

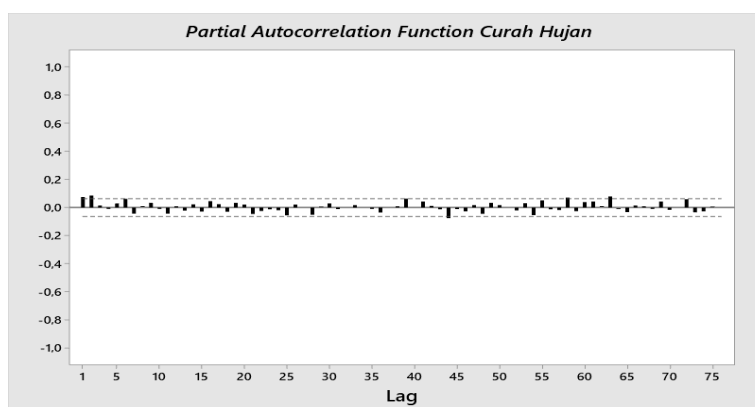
Variabel	N	Minimum	Maximum	Rata-Rata	Std. Deviasi
curah hujan	970	0	90	6.125	11.4406
suhu	970	17	23.9	19.621	0.9486
tekanan udara	970	1014.9	1023	1018.718	1.4491

Dari Tabel statistik deskriptif di atas dapat dilihat bahwa tercantum beberapa isi penting yaitu variabel yang digunakan, jumlah data, nilai terkecil, nilai terbesar, rata-rata dan standar deviasi untuk masing-masing variabel. Selanjutnya akan dilakukan prediksi curah hujan sesuai langkah-langkah yang sudah dijelaskan di metode penelitian yaitu dengan menentukan model RBFNN terbaik dengan beberapa poin penting.

Input layer

Input layer merupakan lapisan pertama untuk menentukan model RBFNN dengan fungsi sebagai penerus data masukan ke lapisan tersembunyi (Fath et al., 2020), pada tahap ini banyaknya *node input layer* akan ditentukan dengan variabel yang berpengaruh dan melihat lag-lag yang signifikan pada plot PACF menggunakan data yang sudah diambil,

lag berfungsi untuk mengukur korelasi nilai saat ini dan nilai masa lalu dari suatu variabel (Stübinger & Adler, 2020). Gambar plot PACF disajikan pada Gambar 1.



Gambar 1. Plot PACF

Dari Gambar 1 didapatkan 2 lag yang signifikan yaitu lag yang pertama (lag 1) dan kedua (lag 2) karena melebihi garis tengah atas, maka didapatkan banyaknya *node* pada *input layer* adalah 4 *node* yaitu variabel suhu, variabel tekanan udara, lag 1 dan lag 2 yang akan dimisalkan dengan $(X_{1(t-1)})$, $(X_{2(t-1)})$, (Y_{t-1}) dan (Y_{t-2}) .

Hidden layer

Hidden layer merupakan lapisan kedua di mana di tahap ini akan dilakukan perhitungan yang berisi *Radial Basis Function (RBF)* (Hashemi Fath et al., 2020). Ada beberapa tahap untuk menentukan banyaknya *node* pada *hidden layer* sebagai berikut, (1) Menghitung nilai fungsi aktivasi *Gaussian*, untuk menghitung nilai fungsi aktivasi *Gaussian* terlebih dahulu menghitung nilai tengah dan standar deviasinya maka akan dimisalkan 4 *node input layer* dan 2 *node hidden layer*, berikut nilai tengah dan standar deviasinya:

$$\text{Nilai tengah } , c_1 = \begin{bmatrix} 0,241 \\ 0,397 \\ 19,978 \\ 1018,634 \end{bmatrix}, c_2 = \begin{bmatrix} 9,167 \\ 9,121 \\ 19,700 \\ 1018,580 \end{bmatrix}$$

Standar deviasi $, \sigma_1 = 1,112, \sigma_2 = 11,785$

Untuk nilai fungsi aktivasi *Gaussian* dari 4 *node input layer* dan 2 *hidden layer* dengan nilai tengah dan fungsi aktivasi diatas untuk data 1,2 sampai 968 berikut perhitungannya:

$$\begin{aligned} \phi_{11} &= \exp \left[-\frac{(45,8 - 0,241)^2 + (13,9 - 0,397)^2 + (17,7 - 19,978)^2 + (1019,9 - 1018,634)^2}{2(1,112)^2} \right] = 0 \\ \phi_{21} &= \exp \left[-\frac{(45,8 - 9,167)^2 + (13,9 - 9,121)^2 + (17,7 - 19,700)^2 + (1019,9 - 1018,580)^2}{2(11,785)^2} \right] = 0,007 \\ \phi_{12} &= \exp \left[-\frac{(1,5 - 0,241)^2 + (45,8 - 0,397)^2 + (18,8 - 19,978)^2 + (1018,2 - 1018,634)^2}{2(1,112)^2} \right] = 0 \\ \phi_{22} &= \exp \left[-\frac{(1,5 - 9,167)^2 + (45,8 - 9,121)^2 + (18,8 - 19,700)^2 + (1018,2 - 1018,580)^2}{2(11,785)^2} \right] = 0,006 \\ \phi_{1968} &= \exp \left[-\frac{(5,8 - 0,241)^2 + (0 - 0,397)^2 + (18,5 - 19,978)^2 + (1019 - 1018,634)^2}{2(1,112)^2} \right] = 0 \end{aligned}$$

$$\phi_{2968} = \exp \left[-\frac{(5,8 - 9,167)^2 + (0 - 9,121)^2 + (18,5 - 19,700)^2 + (1019 - 1018,580)^2}{2(11,785)^2} \right] = 0,707$$

(2) Menghitung nilai bobot, dari nilai fungsi aktivasi *Gaussian* dengan tambahan nilai bobot bias akan dibentuk menjadi matriks berukuran 677×3 sebagai berikut:

$$\Phi = \begin{bmatrix} 1 & 0 & 0,0072 \\ 1 & 0 & 0,0064 \\ 1 & 0 & 0,0004 \\ \vdots & \ddots & \vdots \\ 1 & 0 & 0,7971 \end{bmatrix}$$

Dari matriks yang diatas akan digunakan untuk mencari nilai bobot dengan menggunakan persamaan 4 sebagai berikut:

$$W_k = (\Phi' \cdot \Phi)^{-1} x (\Phi' \cdot Y)$$

$$W_k = \left(\begin{bmatrix} 1 & 0 & 0,0072 \\ 1 & 0 & 0,0064 \\ 1 & 0 & 0,0004 \\ \vdots & \ddots & \vdots \\ 1 & 0 & 0,7971 \end{bmatrix} \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 0 & 0 & 0 & \ddots & 0 \\ 0,0072 & 0,0064 & 0,0004 & \dots & 0,7971 \end{bmatrix} \right)^{-1} x$$

$$\left(\begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 0 & 0 & 0 & \ddots & 0 \\ 0,0072 & 0,0064 & 0,0004 & \dots & 0,7971 \end{bmatrix} x \begin{bmatrix} 1,5 \\ 55,4 \\ 0 \\ \vdots \\ 0,01 \end{bmatrix} \right)$$

$$W_k = \begin{bmatrix} 0,011 & -0,003 & -0,016 \\ -0,003 & 0,023 & -0,000 \\ -0,016 & -0,000 & 0,028 \end{bmatrix} x \begin{bmatrix} 4350 \\ 499,3 \\ 2431 \end{bmatrix}$$

$$W_k = \begin{bmatrix} 6,703 \\ -4,397 \\ 0,645 \end{bmatrix}$$

(3) Menghitung nilai prediksi Y, nilai prediksi Y akan dihitung untuk semua data dengan menggunakan persamaan 5 sebagai berikut:

$$\hat{Y} = \Phi \cdot W_k$$

$$\hat{Y} = \begin{bmatrix} 1 & 0 & 0,0072 \\ 1 & 0 & 0,0064 \\ 1 & 0 & 0,0004 \\ \vdots & \vdots & \vdots \\ 1 & 0 & 0,7074 \end{bmatrix} x \begin{bmatrix} 6,703 \\ -4,397 \\ 0,645 \end{bmatrix}$$

$$\hat{Y} = \begin{bmatrix} 6,7076 \\ 6,7071 \\ 6,7032 \\ \vdots \\ 7,1593 \end{bmatrix}$$

(4) Menghitung RMSE, nilai RMSE dihitung untuk memilih berapa banyak *node* pada *hidden layer* dengan menggunakan persamaan 6 sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$RMSE = \sqrt{\frac{1}{292} ((8,2 - 7,1) + (2 - 7,147) + \dots + (14,5 - 7,159))}$$

$$RMSE = 11,0409$$

Dengan memisalkan 4 *node input layer* dan 2 *node hidden layer* didapatkan nilai RMSE 11,0409, dengan cara yang sama akan dihitung untuk 3 hingga 9 *node hidden layer* dan didapatkan hasil seperti disajikan pada Tabel 3.

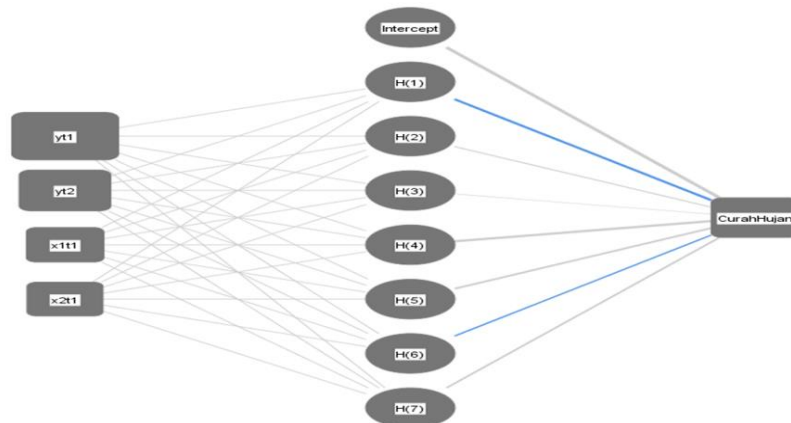
Tabel 3. Hasil RMSE

Hidden layer	RMSE
H2	11,041
H3	11,018
H4	11,125
H5	11,392
H6	11,179
H7	11,006
H8	11,165
H9	11,168
H9	11,168

Dari hasil RMSE pada Tabel 3 dapat dilihat bahwa nilai RMSE terkecil ada di H7 yang berarti bahwa banyaknya *node* yang dipakai untuk *hidden layer* adalah 7.

Output layer

Output layer merupakan lapisan terakhir, lapisan ini akan menghasilkan keluaran jaringan dengan menggabungkan secara linear keluaran *node* atau *neuron* dari lapisan tersembunyi (Hashemi Fath et al., 2020). Dari hasil jumlah *node* yang telah didapatkan dari masing-masing lapisan maka model RBFNN terbaik yang akan dipakai untuk melakukan prediksi curah hujan adalah 4-7-1 yaitu 4 *node input layer*, 7 *node hidden layer* dan 1 *node output layer*. Berikut gambar model RBFNN yang sudah ditentukan untuk lebih memperjelas:



Gambar 2. Model RBFNN

Dari model RBFNN terbaik yang sudah ditentukan maka akan dihitung nilai prediksi kedepannya dengan menggunakan model tersebut yaitu 4-7-1 dengan langkah-langkah yang sama seperti sebelumnya sebagai berikut:

$$\text{Nilai tengah, } c_1 = \begin{bmatrix} 0,241 \\ 0,397 \\ 19,978 \\ 1018,634 \end{bmatrix}, c_2 = \begin{bmatrix} 0,591 \\ 0,297 \\ 19,395 \\ 1018,780 \end{bmatrix}, c_3 = \begin{bmatrix} 3,531 \\ 6,287 \\ 19,329 \\ 1018,588 \end{bmatrix}, c_4 = \begin{bmatrix} 25,223 \\ 0,809 \\ 19,198 \\ 1018,387 \end{bmatrix}$$

$$c_5 = \begin{bmatrix} 21,912 \\ 17,694 \\ 19,066 \\ 1018,592 \end{bmatrix}, c_6 = \begin{bmatrix} 5,397 \\ 3,868 \\ 19,531 \\ 1018,559 \end{bmatrix}, c_7 = \begin{bmatrix} 1,806 \\ 33,384 \\ 22,908 \\ 1018,588 \end{bmatrix}$$

$$\text{Standar deviasi, } \sigma_1 = 1,112, \sigma_2 = 1,254, \sigma_3 = 3,992, \sigma_4 = 9,202, \\ \sigma_5 = 12,692, \sigma_6 = 4,536, \sigma_7 = 16,226$$

Dari nilai Tengah dan standar deviasi yang sudah didapat akan dihitung nilai fungsi aktivasi *Gaussian* sebagai berikut:

$$\phi_{11} = \exp \left[-\frac{(45,8 - 0,241)^2 + (13,9 - 0,397)^2 + (17,7 - 19,978)^2 + (1019,9 - 1018,634)^2}{2(1,112)^2} \right] = 0$$

$$\phi_{21} = \exp \left[-\frac{(45,8 - 0,591)^2 + (13,9 - 0,297)^2 + (17,7 - 19,395)^2 + (1019,9 - 1018,780)^2}{2(1,254)^2} \right] = 0$$

$$\phi_{31} = \exp \left[-\frac{(45,8 - 3,531)^2 + (13,9 - 6,287)^2 + (17,7 - 19,329)^2 + (1019,9 - 1018,588)^2}{2(3,992)^2} \right] = 0$$

$$\phi_{41} = \exp \left[-\frac{(45,8 - 25,223)^2 + (13,9 - 0,809)^2 + (17,7 - 19,198)^2 + (1019,9 - 1018,387)^2}{2(9,202)^2} \right] = 0,029$$

$$\phi_{51} = \exp \left[-\frac{(45,8 - 21,912)^2 + (13,9 - 17,694)^2 + (17,7 - 19,066)^2 + (1019,9 - 1018,592)^2}{2(12,692)^2} \right] = 0,161$$

$$\phi_{61} = \exp \left[-\frac{(45,8 - 5,397)^2 + (13,9 - 3,868)^2 + (17,7 - 19,531)^2 + (1019,9 - 1018,559)^2}{2(4,536)^2} \right] = 0$$

$$\phi_{71} = \exp \left[-\frac{(45,8 - 1,806)^2 + (13,9 - 33,384)^2 + (17,7 - 22,908)^2 + (1019,9 - 1018,588)^2}{2(16,226)^2} \right] = 0,012$$

Selanjutnya akan dihitung nilai fungsi aktivasi *Gaussian* sampai semua data dan menghasilkan matriks dengan ukuran 968 x 3:

$$\Phi = \begin{bmatrix} 1 & 0 & 0 & 0 & 0,029 & 0,161 & 0 & 0,012 \\ 1 & 0 & 0 & 0 & 0,722 & 0,024 & 0 & 0,722 \\ 1 & 0 & 0 & 0 & 0,005 & 0,014 & 0 & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 1 & 0 & 0 & 0,24 & 0,107 & 0,169 & 0,672 & 0,113 \end{bmatrix}$$

Berikutnya akan dihitung nilai bobot menggunakan matriks yang didapat:

$$W_k = (\Phi' \cdot \Phi)^{-1} x (\Phi' \cdot Y)$$

$$W_k = \left(\begin{bmatrix} 1 & 0 & 0 & 0 & 0,029 & 0,161 & 0 & 0,012 \\ 1 & 0 & 0 & 0 & 0,722 & 0,024 & 0 & 0,722 \\ 1 & 0 & 0 & 0 & 0,005 & 0,014 & 0 & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 1 & 0 & 0 & 0,672 & 0,047 & 0,201 & 0,639 & 0,209 \end{bmatrix} \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ 0 & 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \ddots & 0,672 \\ 0,029 & 0,722 & 0,005 & \ddots & 0,047 \\ 0,161 & 0,024 & 0,014 & \ddots & 0,201 \\ 0 & 0 & 0 & \ddots & 0,639 \\ 0,012 & 0,722 & 0 & \dots & 0,209 \end{bmatrix} \right)^{-1}$$

$$x \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ 0 & 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \ddots & 0 \\ 0 & 0 & 0 & \ddots & 0,672 \\ 0,029 & 0,722 & 0,005 & \ddots & 0,047 \\ 0,161 & 0,024 & 0,014 & \ddots & 0,201 \\ 0 & 0 & 0 & \ddots & 0,639 \\ 0,012 & 0,722 & 0 & \dots & 0,209 \end{pmatrix} x \begin{pmatrix} 1,5 \\ 55,4 \\ 0 \\ 9,5 \\ 3,5 \\ 18,4 \\ \vdots \\ 0,01 \end{pmatrix}$$

$$W_k = \begin{pmatrix} 5,731 \\ -3,284 \\ 1,479 \\ 0,011 \\ 4,348 \\ 2,988 \\ -2,144 \\ 2,247 \end{pmatrix}$$

Dari nilai bobot yang sudah didapat akan dibentuk menjadi suatu model persamaan untuk menghitung nilai prediksi curah hujan kedepannya dengan model sebagai berikut:

$$\hat{y}_t = 5,731 + (-3,284x\phi_1) + (1,479x\phi_2) + (0,011x\phi_3) + (4,348x\phi_4) \\ + (2,988x\phi_5) + (-2,144x\phi_6) + (2,247x\phi_7)$$

Dari model persamaan di atas diperlukan nilai fungsi aktivasi *Gaussian* untuk data ke-n (data yang mau diprediksi) yang dalam hal ini diperlukan nilai fungsi aktivasi *Gaussian* ke 971 karena jumlah data keseluruhan adalah 970, berikut perhitungannya:

$$\phi_{11} = \exp \left[-\frac{(14,5 - 0,241)^2 + (5,8 - 0,397)^2 + (17 - 19,978)^2 + (1019,7 - 1018,634)^2}{2(1,112)^2} \right] = 0$$

$$\phi_{21} = \exp \left[-\frac{(14,5 - 0,591)^2 + (5,8 - 0,297)^2 + (17 - 19,395)^2 + (1019,7 - 1018,780)^2}{2(1,254)^2} \right] = 0$$

$$\phi_{31} = \exp \left[-\frac{(14,5 - 3,531)^2 + (5,8 - 6,287)^2 + (17 - 19,329)^2 + (1019,7 - 1018,588)^2}{2(3,992)^2} \right] = 0,018$$

$$\phi_{41} = \exp \left[-\frac{(14,5 - 25,223)^2 + (5,8 - 0,809)^2 + (17 - 19,198)^2 + (1019,7 - 1018,387)^2}{2(9,202)^2} \right] = 0,421$$

$$\phi_{51} = \exp \left[-\frac{(14,5 - 21,912)^2 + (5,8 - 17,694)^2 + (17 - 19,066)^2 + (1019,7 - 1018,592)^2}{2(12,692)^2} \right] = 0,534$$

$$\phi_{61} = \exp \left[-\frac{(14,5 - 5,397)^2 + (5,8 - 3,868)^2 + (17 - 19,531)^2 + (1019,7 - 1018,559)^2}{2(4,536)^2} \right] = 0,101$$

$$\phi_{71} = \exp \left[-\frac{(14,5 - 1,806)^2 + (5,8 - 33,384)^2 + (17 - 22,908)^2 + (1019,7 - 1018,588)^2}{2(16,226)^2} \right] = 0,162$$

Dari nilai fungsi aktivasi *Gaussian* yang telah didapat maka nilai prediksi curah hujan untuk data ke 971 adalah:

$$\hat{y}_{971} = 5,731 + (-3,284x0) + (1,479x0) + (0,011x0,018) + (4,348x0,421) \\ + (2,988x0,534) + (-2,144x0,101) + (2,247x0,162)$$

$$\hat{y}_{971} = 9,3069$$

Dengan cara yang sama maka dilakukan perhitungan untuk nilai prediksi curah hujan periode 01 September 2024 hingga 31 Desember 2024 hasilnya dapat disajikan pada Tabel 4.

Tabel 4. Hasil prediksi curah hujan

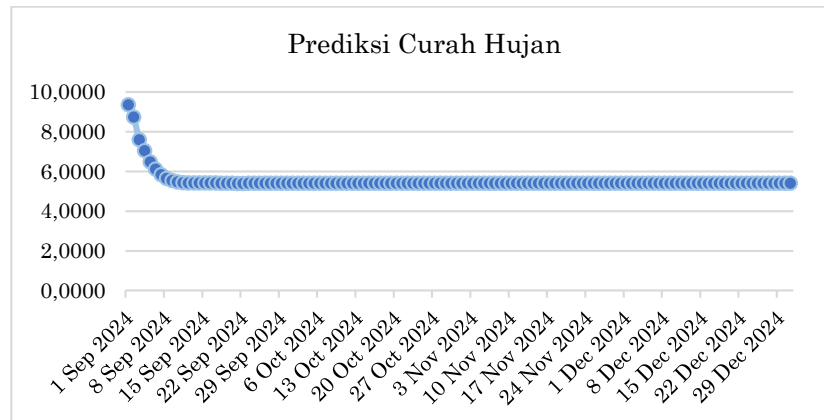
Tanggal	Prediksi curah hujan			
	September	October	November	Desember
1	9,3537	5,4068	5,4070	5,4066
2	8,7345	5,4051	5,4074	5,4065
3	7,5980	5,4038	5,4076	5,4064
4	7,0408	5,4033	5,4076	5,4064
5	6,4782	5,4036	5,4073	5,4065
6	6,1138	5,4047	5,4069	5,4066
7	5,8323	5,4062	5,4064	5,4067
8	5,6551	5,4077	5,4061	5,4068
9	5,5383	5,4089	5,4060	5,4069
10	5,4708	5,4094	5,4060	5,4069
11	5,4380	5,4090	5,4062	5,4069
12	5,4229	5,4081	5,4065	5,4068
13	5,4180	5,4069	5,4069	5,4067
14	5,4179	5,4058	5,4071	5,4066
15	5,4198	5,4050	5,4073	5,4065
16	5,4190	5,4047	5,4072	5,4065
17	5,4151	5,4048	5,4071	5,4066
18	5,4105	5,4054	5,4068	5,4066
19	5,4062	5,4063	5,4066	5,4067
20	5,4029	5,4073	5,4064	5,4068
21	5,4012	5,4080	5,4063	5,4068
22	5,4010	5,4083	5,4063	5,4068
23	5,4019	5,4081	5,4064	5,4068
24	5,4037	5,4076	5,4066	5,4067
25	5,4062	5,4069	5,4068	5,4067
26	5,4087	5,4062	5,4069	5,4066
27	5,4106	5,4057	5,4070	5,4066
28	5,4112	5,4055	5,4070	5,4066
29	5,4104	5,4056	5,4069	5,4066
30	5,4088	5,4059	5,4068	5,4067
31	-	5,4064	-	5,4067

Hasil dari prediksi curah hujan pada Tabel 4 menunjukkan bahwa intensitas curah hujan relatif rendah sesuai dengan penelitian (Wahyudi et al., 2021). Adapun kategori hujan disajikan pada Tabel 5.

Tabel 5. Kategori hujan

Kategori hujan	Intensitas curah hujan per-hari (mm)
tidak ada	-
hujan ringan	0.1 – 20
hujan sedang	21 – 50
hujan lebat	51 – 100
hujan sangat lebat	>100

Berikut grafik dari hasil prediksi curah hujan pada Tabel 4 disajikan pada gambar 3.



Gambar 3. Grafik hasil prediksi curah hujan

SIMPULAN

Dari hasil penelitian dan pembahasan dapat disimpulkan bahwa model struktur jaringan RBFNN terbaik adalah 4-7-1 yaitu 4 *node input layer*, 7 *node hidden layer* dan 1 *node output layer* dengan nilai RMSE 11,006. Berdasarkan Tabel 4 hasil prediksi curah hujan dapat dilihat nilai terkecil prediksi curah hujan yaitu 22 September 2024 (5,4010 mm) dan nilai terbesar yaitu 1 September (9,3557), dari hasil tersebut dapat disimpulkan nilai prediksi curah hujan terbilang kategori curah hujan rendah yang berarti kemungkinan terjadi bencana alam seperti banjir dan longsor karena curah hujan tidak ada. Berdasarkan Kesimpulan tersebut metode RBFNN mampu memberikan prediksi curah hujan dengan data *time series* dan dapat dijadikan referensi terkait prediksi curah hujan untuk data kedepannya. penelitian ini diharapkan dapat dikembangkan lagi dengan menambahkan variabel-variabel lain yang mempengaruhi curah hujan serta metode evaluasi kinerja model dapat menggunakan metode yang lain untuk menambah keakuratan hasil prediksi.

DEKLARASI

- Kontribusi Penulis : AR: konseptualisasi, visualisasi, penulisan draf awal, dan penyuntingan; RA: penulisan tinjauan, penyuntingan dan supervisi.
- Pernyataan Pendanaan : Penelitian ini tidak menerima pendanaan eksternal.
- Konflik Kepentingan : Tidak ada konflik kepentingan dalam penelitian.
- Informasi Tambahan : Informasi tambahan tersedia atas permintaan.

DAFTAR PUSTAKA

- Aditya, F., Gusmayanti, E., & Sudrajat, J. (2021). Pengaruh perubahan curah hujan terhadap produktivitas padi sawah di Kalimantan Barat. *Jurnal Ilmu Lingkungan*, 19(2), 237–246. <https://doi.org/10.14710/jil.19.2.237-246>
- Ahmed, B. (2021). The root causes of landslide vulnerability in Bangladesh. *Landslides*, 18(5), 1707–1720. <https://doi.org/10.1007/s10346-020-01606-0>
- Aisha, N. (2023). Penerapan radial basis function neural network pada prediksi curah hujan di Kabupaten Cirebon. (pp. 1–72).
- Aisyah, S., Wahyuningsih, S., & Tisna Amijaya, F. D. (2021). Peramalan jumlah titik panas provinsi Kalimantan Timur menggunakan metode radial basis function neural network. *Jambura Journal of Probability and Statistics*, 2(2), 64–74. <https://doi.org/10.34312/jjps.v2i2.10292>
- Ajayi, Oluwatosin, V. (2023). A review on primary sources of data and secondary sources of data. *European Journal of Education and Pedagogy*, 2(3), 1–7. <https://doi.org/10.5281/zenodo.16739602>
- Aldardasawi, A. F. M., & Eren, B. (2021). Floods and their impact on the environment. *Academic Perspective Procedia*, 4(2), 42–49. <https://doi.org/10.33793/acperpro.04.02.24>
- Almeida, A., Brás, S., Sargento, S., & Pinto, F. C. (2023). Time series big data: a survey on data stream frameworks, analysis and algorithms. *Journal of Big Data*, 10(1), 1–32. <https://doi.org/10.1186/s40537-023-00760-1>
- Ambarwati, I., & Mariani, S. (2022). Perbandingan metode elman recurrent dan radial basis. *UNNES Journal of Mathematics*, 11(2), 171–178. <http://journal.unnes.ac.id/sju/index.php/ujm>
- Chen, Z. (2022). Research on internet security situation awareness prediction technology based on improved RBF neural network algorithm. *Journal of Computational and Cognitive Engineering*, 1(3), 103–108. <https://doi.org/10.47852/bonviewJCCE149145205514>
- Dong, Y. (2023). Descriptive statistics and its applications. *Highlights in Science, Engineering and Technology*, 47, 16–23. <https://doi.org/10.54097/hset.v47i.8159>
- Hashemi Fath, A., Madanifar, F., & Abbasi, M. (2020). Implementation of multilayer

- perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems. *Petroleum*, 6(1), 80–91. <https://doi.org/10.1016/j.petlm.2018.12.002>
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Idrus, I., & Umar, B. (2024). Mitigasi bencana banjir akibat longsor pada daerah aliran sungai terhadap ketersediaan air bersih di Kecamatan Dondo. *Jurnal Bangunan Konstruksi (BARAKKA)*, 2(1), 46–52. <https://doi.org/10.63877/jbk.v2i1.47>
- Jitchaijaroen, W., Keawsawasvong, S., Wipulanusat, W., Kumar, D. R., Jamsawang, P., & Sunkpho, J. (2024). Machine learning approaches for stability prediction of rectangular tunnels in natural clays based on MLP and RBF neural networks. *Intelligent Systems with Applications*, 21(December 2023), 200329. <https://doi.org/10.1016/j.iswa.2024.200329>
- Laila Nurwulan, R. R., & Agustina, U. F. (2022). Analisis penanggulangan bencana banjir di desa tarajusari kecamatan Banjaran Kabupaten Bandung. 5(2), 58–69.
- Moradi, M. J., Roshani, M. M., Shabani, A., & Kioumars, M. (2020). Prediction of the load-bearing behavior of spsw with rectangular opening by RBF network. *Applied Sciences (Switzerland)*, 10(3). <https://doi.org/10.3390/app10031185>
- Pemerintah Daerah Kabupaten Tapanuli Utara. (2020). *Profil dan Potensi Kabupaten Tapanuli Utara*. 1–28. <https://www.taputkab.go.id>
- Stübinger, J., & Adler, K. (2020). How to identify varying lead-lag effects in time series data: Implementation, validation, and application of the generalized causality algorithm. *Algorithms*, 13(4), 1–19. <https://doi.org/10.3390/A13040095>
- Sutijo, B., Subanar, & Guritno, S. (2006). Pemilihan hubungan input-node pada jaringan saraf (Input-Nodes Link Selection on Radial Basis Funtion Neural Network). *Journal of Mathematics and Natural Sciences*, 16(1), 55–61. <https://journal.ugm.ac.id/bimipa/article/view/13902/9973>
- Wahyudi, S. R., Sari, R. F., & Widayarsi, R. (2021). Penentuan pola penyebaran curah hujan harian Kabupaten Karo dengan menggunakan rantai Markov Orde-N. *Jurnal Riset dan Aplikasi Matematika*, 05(02), 144–157. journal.unesa.ac.id/index.php/jram
- Xu, Q., Zhao, B., Dai, K., Dong, X., Li, W., Zhu, X., Yang, Y., Xiao, X., Wang, X., Huang, J., Lu, H., Deng, B., & Ge, D. (2023). Remote sensing for landslide investigations: A progress report from China. *Engineering Geology*, 321(August 2022). <https://doi.org/10.1016/j.enggeo.2023.107156>
- Yan, J., Xu, T., Yu, Y., & Xu, H. (2021). Rainfall forecast model based on the tabnet model. *Water (Switzerland)*, 13(9). <https://doi.org/10.3390/w13091272>
- Younus, A. M., & Zaidan, M. N. (2022). The influence of quantitative research in business & information technology: An appropriate research methodology philosophical reflection. *American Journal of Interdisciplinary Research and Development*, 04(May), 61–79. www.ajird.journalspark.org