Terbit online pada laman web jurnal: **https://ejurnalunsam.id/index.php/jicom/**

Jurnal Informatika dan Teknologi Komputer

Vol. 04 No. 01 (2023) 63 - 70 E-ISSN :2774-7115 P-ISSN: 2775-2089

Penerapan *Backpropagation Neural Network* pada Prediksi Curah Hujan di Sumatera Utara

Ulya Nabilla[1*], Indah Ramadhani[2], Fazrina Saumi[3]
[1,2,3]Program Studi Matematika, Fakultas Teknik, Universitas Samudra
[1*]ulya.nabilla@unsam.ac.id, [2]indahramadani914@gmail.com, [3]fazrinasaumi@unsam.ac.id

Abstract

Indonesia is located on the equator with a latitude of 6°N to 11°S. This latitude causes a high intensity of solar radiation so that the air temperature becomes high. This causes the evaporation of water from the surface of the sea and land to form clouds and rain. One of the provinces in Indonesia that has high rainfall is North Sumatera. Due to the high rainfall, the province often experiences floods and landslides. In order to minimize the impact of floods and landslides, the first thing that can be done is to predict the rainfall in North Sumatera. The method used is Backpropagation Neural Network. This method is a kind of artificial intelligence designed to process information by imitating the nervous system of the human brain. This research aimed to predict rainfall in North Sumatera using Backpropagation Neural Network and determine the accuracy of this method. The data came from the Badan Pusat Statistik (BPS) of North Sumatera, namely rainfall data from January 2020 to December 2022. The results implied that rainfall in 2023 for each month is 190; 266; 197; 178; 290; 182; 299; 350; 213; 485; 357; and 389 (mm/month) and has an accuracy of Mean Absolute Percentage Error (MAPE) of 35.55%, so this method is categorized as suitable for predicting rainfall.

Keywords: Neural Network, Backpropagation, Prediction, Rainfall, MAPE.

Abstrak

Indonesia terletak pada garis khatulistiwa dengan garis lintang 6°LU hingga 11°LS. Garis lintang ini mengakibatkan intensitas radiasi matahari yang tinggi sehingga suhu udara menjadi cukup tinggi dan memicu penguapan air dari permukaan laut dan daratan hingga membentuk awan dan hujan. Salah satu provinsi di Indonesia yang memiliki curah hujan tinggi adalah Sumatera Utara. Curah hujan yang relatif tinggi mengakibatkan provinsi tersebut sering mengalami banjir dan tanah longsor. Untuk meminimalisir dampak terjadinya banjir dan tanah longsor, hal pertama yang dapat dilakukan adalah memprediksi curah hujan di Sumatera Utara. Metode yang digunakan adalah *Backpropagation Neural Network*. Metode ini merupakan *Artificial Intelligence* yang didesain untuk memproses informasi dengan cara menirukan sistem kerja syaraf otak manusia. Penelitian ini bertujuan untuk memprediksi curah hujan di Sumatera Utara menggunakan *Backpropagation Neural Network* dan mengetahui keakuratan metode tersebut. Data yang digunakan bersumber dari Badan Pusat Statistik (BPS) Sumatera Utara, yaitu data curah hujan pada Januari 2020 hingga Desember 2022. Hasil penelitian menunjukkan bahwa curah hujan pada tahun 2023 setiap bulannya adalah 190; 266; 197; 178; 290; 182; 299; 350; 213; 485; 357; dan 389 (dalam satuan mm/bulan) dan memiliki keakuratan yaitu nilai *Mean Absolute Percentage Error* (MAPE) sebesar 35,55%, sehingga metode tersebut dikategorikan layak untuk memprediksi curah hujan.

Kata kunci: Neural Network, *Backpropagation*, Prediksi, Curah Hujan, MAPE.

1. Pendahuluan

Curah hujan diinterpretasikan sebagai banyaknya jumlah air hujan yang turun pada daerah tertentu dalam satuan waktu tertentu [1]. Curah hujan dapat juga diartikan sebagai ketinggian air hujan yang terkumpul, tidak menguap, meresap, dan mengalir pada tempat datar. Menurut [2] curah hujan yang turun ke permukaan bumi setiap harinya tidak selalu sama. Indonesia terletak pada garis khatulistiwa sehingga memiliki intensitas radiasi matahari yang tinggi. Selain itu negara ini juga memiliki garis lintang 6°LU hingga 11°LS. Garis lintang ini mengakibatkan intensitas radiasi matahari yang tinggi sehingga suhu udara menjadi cukup tinggi dan memicu penguapan air dari permukaan laut dan daratan hingga membentuk awan dan hujan. [3] menambahkan Indonesia memiliki lautan yang luas, sehingga proses penguapan dan

Diterima Redaksi : 16-03-2023 | Selesai Revisi : 25-03-2023 | Diterbitkan Online : 01-04-2023

pengumpulan awan-awan semakin cepat dan proses hujan pun dapat terjadi hampir setiap hari. Salah satu provinsi di Indonesia yang memiliki kelembaban dan curah hujan relatif tinggi adalah Sumatera Utara. [4] menyatakan, curah hujan Sumatera Utara dengan kategori tinggi yaitu lebih dari 300 mm/bulan terjadi pada bulan Juni, Oktober dan Desember, dan mengalami peningkatan menjadi sangat tinggi yaitu lebih dari 500 mm/bulan pada bulan Agustus dan November.

Curah hujan yang memiliki intensitas tinggi dapat mengakibatkan banjir dan tanah longsor [5]. Lebih lanjut, [6] menyatakan pada tahun 2021, Provinsi Sumatera Utara berada pada urutan ke-8 untuk bencana banjir dan urutan ke-5 untuk bencana tanah longsor. [7] menambahkan pada tahun 2022 terdapat 17 kabupaten/ kota yang terdampak bencana banjir dan tanah longsor di Provinsi Sumatera Utara.

Untuk meminimalisir dampak terjadinya banjir dan tanah longsor, hal pertama yang dapat dilakukan adalah memprediksi curah hujan di Sumatera Utara. Menurut [8] curah hujan tidak dapat ditentukan secara pasti, namun dapat diprediksi menggunakan data curah hujan pada masa lampau. Salah satu metode yang dapat digunakan untuk memprediksi curah hujan tersebut adalah *Backpropagation Neural Network*.

Backpropagation Neural Network merupakan salah satu metode dapat digunakan untuk memprediksi suatu kejadian berdasarkan pola kejadian yang di masa lampau [9]. Menurut [10] metode tersebut merupakan *Artificial Intelligence* yang didesain untuk memproses informasi dengan cara menirukan sistem kerja syaraf otak manusia.

Untuk menerapkan *Backpropagation Neural Network* pada prediksi curah hujan, diperlukan tiga layer yaitu *input layer*, *hidden layer*, dan *output layer*. Hasil penelitian [11] menunjukkan bahwa tidak ada perubahan signifikan dalam nilai akurasi pada *Backpropagation* dengan satu, dua, atau tiga *hidden layer*. Semakin banyak *hidden layer*, maka semakin banyak pula *epoch* yang diperlukan dan nilai akurasi semakin kecil. [12] menambahkan banyaknya *hidden layer* pada *Backpropagation Neural Network* dapat mempengaruhi tingkat akurasi. Semakin banyak *layer*, maka hasil yang diperoleh semakin baik tetapi waktu yang dibutuhkan cukup lama. Namun secara umum, [10] menyatakan bahwa performa *Backpropagation Neural Network* dinilai cukup baik dalam memprediksi data *time series*.

Oleh karena itu, penelitian ini bertujuan untuk memprediksi curah hujan di Sumatera Utara menggunakan *Backpropagation Neural Network* dan mengetahui keakuratan metode tersebut menggunakan *Mean Absolute Percentage Error* (MAPE).

2. Metode Penelitian

Menurut [9], desain *Backpropagation Neural Network* ditentukan didasarkan pada: 1) pola antar *neuron* yang disebut arsitektur jaringan; 2) metode penentuan bobot penghubung yang disebut *training* atau algoritma; serta 3) fungsi aktivasi yang di-*running* oleh masing-masing *neuron* pada *input* jaringan untuk menentukan *output*.

Proses pada *Backpropagation Neural Network* terjadi pada *hidden layer* yang sudah ditentukan sebelumnya. Setiap penghubung antar *layer* diberi bobot untuk menuju ke *layer* berikutnya.

Adapun parameter yang digunakan dalam *Backpropagation Neural Network* adalah sebagai berikut[9].

a. *Learning Rate*

Learning Rate menginterpretasikan kestabilan metode *Backpropagation Neural Network.* Jika nilai *learning rate* besar maka *training step* juga besar sehingga metode tersebut akan mengalami ketidakstabilan. Sebaliknya, apabila nilainya sangat kecil maka *output* akan konvergen, tetapi membutuhkan waktu yang lama. Nilai learning rate berada pada [0,1].

b. Momentum

Momentum digunakan untuk menghitung perubahan bobot agar *training* berjalan lancar dan bobot tidak berhenti pada kondisi yang belum optimal. Pemberian momentum mengakibatkan perubahan yang cukup besar pada waktu yang dibutuhkan dalam proses *traning*. Semakin besar nilai momentum maka semakin cepat pula waktu *training* yang dibutuhkan. peningkatan nilai momentum cenderung membuat jumlah iterasi (*epoch*) semakin kecil, namun tingkat keakurasiannya tetap bervariasi. Nilai momentum berada pada [0,1].

c. Nilai Iterasi (*Epoch*)

Siklus pola *training* disebut sebagai atau *epoch* atau iterasi yang merupakan perulangan proses *training* hingga memperoleh *output* yang diinginkan atau sampai kondisi berhenti yang telah ditentukan.

Tahapan penelitian menggunakan *Backpropagation Neural Network* adalah sebagai berikut.

1. Mengumpulkan data penelitian

Data penelitian yang dikumpulkan adalah data curah pada Provinsi Sumatera Utara. Data ini diperoleh dari Badan Pusat Statistik (BPS) Sumatera Utara.

2. Melakukan normalisasi data

[8] menyatakan data awal memiliki *range* nilai yang beragam sehingga perlu dilakukan normalisasi. Tujuannya adalah untuk menyamakan *range* nilai dari setiap *input.* [13] menambahkan tujuan dari normalisasi data adalah mentransformasikan data

menggunakan fungsi *sigmoid* agar memudahkan perhitungan. Fungsi *sigmoid* yang digunakan seperti pada persamaan 1.

$$x' = \frac{x-b}{a-b} \quad (1)$$

Keterangan:

$x' = data\ hasil\ normalisasi$
$x = data\ asli$
$a = nilai\ maksimum$
$b = nilai\ minimum$

3. Membagi data

Menurut [14] data dibagi menjadi dua bagian yang saling lepas yaitu, data *training* dan data *testing*. [1] menyatakan pembagian data yang sering digunakan adalah 50% data *training* dan 50% data *testing*.

4. Melakukan *Training*

Training menggunakaan algoritma *Backpropagation Neural Network* melewati dua tahapan, yaitu *feedforward* dan *backforward* [15].

a. *Feedforward*

i. Menginisialisasi bobot dan parameter yaitu *learning rate*, momentum, iterasi maksimal, MAPE, dan jumlah *hidden layer*.

ii. Menghitung *output* pada *hidden layer* menggunakan persamaan 2.

$$z_{in\ j} = v_{j0} + \Sigma_{i=1}^{n} x_i v_{ji} \quad (2)$$

Keterangan:

$z_{in\ j} = nilai\ output\ unit\ z_j$
$v_{j0} = bias\ input\ layer\ ke\ hidden\ layer$
$x_i = nilai\ input\ pada\ input\ layer$
$v_{ji} = bobot\ input\ layer\ ke\ hidden\ layer$

Selanjutnya menghitung nilai *output* menggunakan persamaan fungsi aktivasi *sigmoid biner* seperti pada persamaan 3.

$$z_j = f(z_{in\ j}) = \frac{1}{1+e^{-z_{inj}}} \quad (3)$$

Keterangan:

$z_{in\ j} = nilai\ output$

iii. Menghitung nilai *input* pada setiap *output* dari *hidden layer* menggunakan persamaan 4.

$$y_{in\ k} = w_{ok} + \Sigma_{j=1}^{p} z_j w_{jk} \quad (4)$$

Keterangan:

$y_{in\ k} = nilai\ keluaran\ y$
$w_{ok} = bias\ hidden\ layer\ ke\ output\ layer$
$w_{jk} = bobot\ hidden\ layer\ ke\ output\ layer$

Gunakan fungsi aktivasi pada persamaan 5 untuk menghitung sinyal *output.*

$$y = f(y_{in\ k}) = \frac{1}{1+e^{-y_{ink}}} \quad (5)$$

Keterangan:

$y_k = nilai\ keluaran\ di\ unit\ y$

iv. Menghitung nilai MAPE menggunakan persamaan 6.

$$MAPE = \frac{\Sigma_{t=1}^{n} \frac{|x_t - y_t|}{x_t}}{n} \times 100\% \quad (6)$$

Keterangan:

$n = banyaknya\ data$
$x_t = nilai\ asli\ target\ ke-t$
$y_t = nilai\ peramalan\ data\ ke-t$

Menurut [16] kriteria keakuratan menggunakan MAPE ditunjukkan seperti pada tabel 1.

Tabel 1. Kriteria Keakuratan menggunakan MAPE

MAPE	Kategori Kemampuan Prediksi
< 10%	Sangat Baik
10% – 20%	Baik
20% – 50%	Layak
> 50%	Buruk

v. Menentukan nilai MAPE yang diperoleh apakah kurang atau sama dengan nilai MAPE target. Jika nilai MAPE yang diperoleh lebih besar dari nilai MAPE target maka iterasi atau *epoch* akan berhenti.

b. *Feedforward*

i. Setiap *output* y menerima pola target yang berkaitan dengan pola *input training*, kemudian menghitung nilai eror dengan persamaan 7.

$$\delta_k = (t_k - y_k) f'(y_{in\ k})(t_k - y) y(1-y) \quad (7)$$

Keterangan:

$\delta_k = nilai\ kesalahan\ di\ output\ layer$
$t_k = nilai\ target$

Menghitung koreksi bobot untuk memperbarui nilai (w_{jk}) menggunakan persamaan 8.

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (8)$$

Keterangan:

$\Delta w_{kj} = nilai\ koreksi\ bobot\ hidden\ layer$

Menghitung koreksi bias untuk memperbarui nilai (w_{k0}) menggunakan persamaan 9.

$$\Delta w_{ko} = \alpha \delta_k \quad (9)$$

Keterangan:

$\Delta w_{ko} = nilai\ koreksi\ bias\ hidden\ layer$

ii. Menghitung momentum yang dari *neuron* pada *layer* pada setiap *hidden layer* $(zj, untuk\ j = 1,2,3, \dots, q)$ persamaan 10.

$$\delta_{in\ j} = \Sigma_{k=1}^{m} \delta_k w_{jk} \quad (10)$$

Keterangan:

$\delta_{in\ j} = nilai\ untuk\ menghitung\ \delta_j$

Kemudian menghitung eror menggunakan pada persamaan 11.

$$\delta_j = \delta_{in\ j} f'(z_{in\ j}) = \delta_{in\ j} z_j (1 - z_j) \quad (11)$$

Keterangan:

$\delta_j = nilai\ eror\ pada\ hidden\ layer$

Menghitung koreksi nilai bobot menggunakan persamaan 12.

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (12)$$

Keterangan:

$\Delta v_{ji} = nilai\ koreksi\ bobot\ input\ layer$

Menghitung koreksi bias untuk memperbarui nilai v_{0j} menggunakan persamaan 13

$$\Delta v_{j0} = \alpha \delta_j \quad (13)$$

Keterangan:

$\Delta v_{j0} = nilai\ koreksi\ bias\ input\ layer$

iii. Menghitung bobot dan bias baru di antara *hidden layer* dan *output* seperti pada persamaan 14.

$$w_{jk}(baru) = w_{jk}(lama) + \Delta w_{jk} \quad (14)$$

Keterangan:

$w_{jk}(baru) = nilai$ bobot dan bias baru

Menghitung bobot dan bias baru di antara *input* dan *hidden layer* seperti pada persamaan 15.

$$v_{ij}(baru) = v_{ij}(lama) + \Delta v_{ij} \quad (15)$$

Keterangan:

$v_{ij}(baru) = nilai$ bobot dan bias baru

5. Melakukan *Testing*
   Melakukan *testing* menggunakan algoritma *feedforward*.
6. Melakukan validasi silang
   Mengukur nilai akurasi menggunakan MAPE seperti pada persamaan 6.
7. Melakukan denormalisasi
   [17] menyatakan denormalisasi merupakan suatu proses pengembalian nilai yang telah dinormalisasi sebelumnya oleh *output layer* ke nilai aslinya agar memperoleh nilai *output* pada *range* yang sebenarnya. Denormalisasi dilakukan menggunakan persamaan 16.

$$x = x'(a - b) + b \quad (16)$$

Keterangan:

$x = denormalisasi$

$x' = data\ hasil\ normalisasi$

$a = nilai\ maksimum$

$b = nilai\ minimum$

8. Memrediksi Curah Hujan

3. Hasil dan Pembahasan

Penelitian ini menggunakan data curah hujan per bulan pada Provinsi Sumatera Utara mulai tahun 2020 hingga tahun 2022 yang ditampilkan pada tabel 2.

Tabel 2. Data Curah Hujan

Bulan	Curah Hujan (mm/bulan)		
	2020	2021	2022
Januari	87	519	213
Februari	79	88	296
Maret	104	201	232
April	326	300	169
Mei	486	146	134
Juni	615	231	319
Juli	300	127	150
Agustus	196	378	514
September	336	287	243
Oktober	466	260	376
November	337	494	526
Desember	0,5933	0,1772	0,4515

Sumber: Badan Pusat Statistik (BPS) Sumatera Utara

Data pada tabel 2 dibagi menjadi 50% data *training* dan 50% data *testing.* Data *training* adalah data curah hujan pada Januari 2020-Desember 2021. Data tersebut dapat dilihat pada tabel 3.

Tabel 3. Pembagian Data *Training*

Input	Target
Januari 2020 - Desember 2020	Januari 2021
Februari 2020 - Januari 2021	Februari 2021
Maret 2020 - Februari 2021	Maret 2021
April 2020 - Maret 2021	April 2021
Mei 2020 - April 2021	Mei 2021
Juni 2020 - Mei 2021	Juni 2021
Juli 2020 - Juni 2021	Juli 2021
Agustus 2020 - Juli 2021	Agustus 2021
September 2020 - Agustus 2021	September 2021
Oktober 2020 - September 2021	Oktober 2021
November 2020 - Oktober 2021	November 2021
Desember 2020 - November 2021	Desember 2021

Sedangkan data *testing* adalah data curah hujan pada Januari 2021-Desember 2022. Data tersebut dapat dilihat pada tabel 4.

Tabel 4. Pembagian Data *Testing*

Input	Target
Januari 2021 - Desember 2021	Januari 2022
Februari 2021 - Januari 2022	Februari 2022
Maret 2021 - Februari 2022	Maret 2022
April 2021 - Maret 2022	April 2022
Mei 2021 - April 2022	Mei 2022
Juni 2021 - Mei 2022	Juni 2022
Juli 2021 - Juni 2022	Juli 2022
Agustus 2021 - Juli 2022	Agustus 2022
September 2021 - Agustus 2022	September 2022
Oktober 2021 - September 2022	Oktober 2022
November 2021 - Oktober 2022	November 2022
Desember 2021 - November 2022	Desember 2022

Selanjutnya dilakukan normalisasi pada tabel 3 dan 4 menggunakan persamaan 1. Normalisasi data dilakukan menggunakan *software matlab* dan dapat dilihat pada tabel 5.

Tabel 5. Normalisasi Data Curah Hujan Tahun 2020-2022

Bulan	Curah Hujan (mm/bulan)		
	2020	2021	2022
Januari	0,0149	0,8209	0,2500
Februari	0	0,0168	0,4049
Maret	0,0466	0,2276	0,2854
April	0,4608	0,4123	0,1679

Bulan	Curah Hujan (mm/bulan)		
	2020	2021	2022
Mei	0,7593	0,1250	0,1026
Juni	1	0,2836	0,4478
Juli	0,4123	0,0896	0,1325
Agustus	0,2183	0,5578	0,8116
September	0,4795	0,3881	0,3060
Oktober	0,7220	0,3377	0,5541
November	0,4813	0,7743	0,8340

Selanjutnya akan dijelaskan proses perhitungan manual untuk iterasi *(epoch)* pertama. Perhitungan ini sebagai gambaran proses perhitungan prediksi menggunakan *Backpropagation Neural Network*.

Setelah diperoleh tabel 5, selanjutnya dilakukan proses *training* dengan *feedforward*. Pada tahap ini dilakukan inisialisasi bobot dan parameter dengan *learning rate* 0,1; momentum 0,8; target eror 0,01; maksimal iterasi 500; serta 10 *hidden layer*. Nilai *input* dihitung menggunakan bobot tersebut dan persamaan 2 hingga memperoleh hasil seperti pada tabel 6.

Tabel 6. Hasil Perhitungan $z_{in\,j}$

Hasil Perhitungan $z_{in\,j}$	
$z_{in\,1}$	-1,7302
$z_{in\,2}$	-5,8124
z_{in3}	-6,7120
$z_{in\,4}$	1,5540
$z_{in\,5}$	-2,4015
$z_{in\,6}$	1,6712
$z_{in\,7}$	-0,2001
z_{in8}	-0,2847
$z_{in\,9}$	2,3670
$z_{in\,10}$	1,2479

Sedangkan nilai nilai *output* dihitung menggunakan persamaan 3 dan diperoleh hasil yaitu tabel 7.

Tabel 7. Hasil Perhitungan z_j

Hasil Perhitungan z_j	
z_1	0,1506
z_2	0,0030
z_3	0,0012
z_4	0,8255
z_5	0,0830
z_6	0,8417
z_7	0,4501
z_8	0,4293
z_9	0,9143
z_{10}	0,7769

Nilai *input* tersebut diproses kembali untuk setiap *output* pada *hidden layer* menggunakan persamaan 4 sehingga diperoleh yaitu $y_{in1} = -1{,}1341$. Selanjutnya dihitung nilai *output* menggunakan persamaan 5 sehingga diperoleh $y = \frac{1}{1+e^{-(-1{,}1341)}} = 0{,}2434$. Kemudian dihitung nilai eror menggunakan persamaan 6 dan masuk ke proses *backforward.*

Pada tahap *backforward*, setiap *output y* menerima target pola yang berkaitan dengan pola *input training*. Masing-masing *output* tersebut dihitung nilai eror menggunakan persamaan 7 sehingga diperoleh $\delta_1 = 0{,}1064$. Selanjutnya dihitung koreksi bobot dan bias menggunakan persamaan 8 sehingga diperoleh hasil yaitu tabel 8.

Tabel 8. Hasil Perhitungan Δw_{jk}

Hasil Perhitungan Δw_{jk}	
$\Delta w_{1,1}$	0,0016
$\Delta w_{1,2}$	0,0000
$\Delta w_{1,3}$	0,0000
$\Delta w_{1,4}$	0,0088
$\Delta w_{1,5}$	0,0009
$\Delta w_{1,6}$	0,0090
$\Delta w_{1,7}$	0,0048
$\Delta w_{1,8}$	0,0046
$\Delta w_{1,9}$	0,0097
$\Delta w_{1,10}$	0,0083

Kemudian delta *input* dari setiap *hidden layer* $(z_j, j = 1, 2, 3, \dots, q)$ dijumlahkan untuk mengetahui nilai eror menggunakan persamaan 10. Hasil yang diperoleh ditampilkan pada tabel 9.

Tabel 9. Hasil Perhitungan $\delta_{in\,j}$

Hasil Perhitungan $\delta_{in\,j}$	
$\delta_{in\,1}$	0,3552
$\delta_{in\,2}$	0,0359
$\delta_{in\,3}$	0,0162
$\delta_{in\,4}$	-0,2059
$\delta_{in\,5}$	-0,0085
$\delta_{in\,6}$	0,0952
$\delta_{in\,7}$	0,1374
$\delta_{in\,8}$	-0,0801
$\delta_{in\,9}$	-0,1017
$\delta_{in\,10}$	0,3743

Kemudian nilai eror dihitung menggunakan persamaan 11 dan diperoleh hasil yaitu tabel 10.

Tabel 10. Hasil Perhitungan δ_j

Hasil Perhitungan δ_j	
δ_1	0,0454
δ_2	0,0001
δ_3	0,0000
δ_4	-0,0297
δ_5	-0,0006
δ_6	0,0127
δ_7	0,0340
δ_8	-0,0196
δ_9	-0,0080
δ_{10}	0,0649

Nilai eror tersebut digunakan untuk menghitung koreksi bobot dan bias menggunakan persamaan 12 sehingga diperoleh tabel 11.

Tabel 11. Hasil Perhitungan Δv_{ij}

	Δv_1	Δv_2	Δv_3	...	Δv_{12}
x_1	0,0000678	0	0,0002119		0,0026959
x_2	0,0000002	0	0,0000005		0,0000064
x_3	0,0000000	0	0,0000001		0,0000012
x_4	-0,0000443	0	-0,0001383		-0,0017596
x_5	-0,0000010	0	-0,0000030		-0,0000385
x_6	0,0000189	0	0,0000591	...	0,0007523
x_7	0,0000508	0	0,0001586		0,0020178
x_8	-0,0000293	0	-0,0000916		-0,0011650
x_9	-0,0000119	0	-0,0000372		-0,0004727
x_{10}	0,0000968	0	0,0003026		0,0038492

Selanjutnya dihitung bobot dan bias baru di antara *hidden layer* dan *output layer* menggunakan persamaan 14 sehingga diperoleh tabel 12.

Tabel 12. Bobot dan Bias Baru *Hidden Layer* ke *Output Layer*

Bias	Y
w_1	3,3402
w_2	0,3375
w_3	0,1524
w_4	-1,9263
w_5	-0,0792
w_6	0,9034
w_7	1,2963
w_8	-0,7487
w_9	-0,9460
w_{10}	3,5264
Bias	−2,8935

Sedangkan bobot dan bias baru di antara *input layer* dan *hidden layer* dihitung menggunakan persamaan 15 dan diperoleh tabel 13.

Tabel 13. Bobot dan Bias Baru *Input Layer* ke *Hidden Layer*

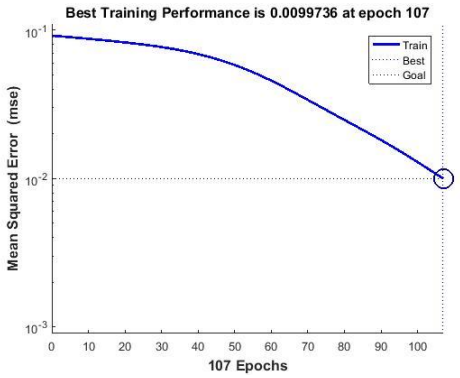
Bobot	v_1	v_2	...	Δv_{12}
z_1	-0,5220	2,6873		-3,9211
z_2	2,9632	0,8807		-2,1315
z_3	-2,5447	-1,1921		2,9941
z_4	-1,5729	0,0882		-3,9005
z_5	-2,2817	-0,6321		3,4331
z_6	-2,0790	-2,4223	...	1,6371
z_7	2,9385	-2,0695		-0,1107
z_8	0,5741	-2,7133		0,7023
z_9	0,4566	-2,8947		-2,9925
z_{10}	-2,6516	-1,9422		-0,3784
Bias	3,2959	-0,7986		3,1689

Selanjutnya dilakukan langkah yang sama mulai dari menghitung nilai input dan menggunakan bobot baru sehingga diperoleh nilai *output* dan nilai target dari proses training. Hasil ini ditampilkan pada tabel 14.

Tabel 14. Hasil Data *Training*

Bulan	*Output Training*	Target Data *Training*
Januari 2021	0,7753	0,8209
Februari 2021	0,1318	0,0168
Maret 2021	0,3410	0,2276
April 2021	0,4052	0,4123
Mei 2021	0,2687	0,1250
Juni 2021	0,2341	0,2836
Juli 2021	0,2285	0,0896
Agustus 2021	0,3969	0,5578
September 2021	0,3698	0,3881
Oktober 2021	0,1910	0,3377
November 2021	0,7478	0,7743
Desember 2021	0,1530	0,1772

Berdasarkan hasil perhitungan menggunakan *software matlab*, diketahui bahwa *best training performance* terjadi pada *epoch* ke-107. Hal ini dikarenakan iterasi atau *epoch* pada proses training berhenti pada *epoch* ke-107 dengan nilai eror 0,0099736. Nilai ini lebih kecil dari target error yang ditentukan yaitu 0,01 maka proses training berhenti kemudian dilanjutkan dengan proses *testing*. *Best training performance* dapat dilihat pada gambar 1.



Gambar 1. *Best Training Performance*

Proses *testing* dilakukan dengan cara *feedforward*. Pada tahap ini diperoleh nilai *output* dan nilai error dari proses *testing* yang ditampilkan pada tabel 15.

Tabel 15. Hasil Data *Testing*

Bulan	Keluaran Pengujian	Target Data Uji
Januari 2022	0,3711	0,2500
Februari 2022	0,9637	0,4049
Maret 2022	0,4758	0,2854
April 2022	0,9426	0,1679
Mei 2022	0,6398	0,1026
Juni 2022	0,5462	0,4478
Juli 2022	0,7118	0,1325
Agustus 2022	0,2088	0,8116
September 2022	0,6946	0,3060
Oktober 2022	0,2851	0,5541
November 2022	0,4133	0,8340
Desember 2022	0,3886	0,4515

Prediksi untuk tahun 2023 dilakukan secara *feedfoward*. Hasil prediksi ini selanjutnya dinormalisasikan sehingga diperoleh data prediksi curah hujan bulanan tahun 2023. Data tersebut ditampilkan pada tabel 16.

Tabel 16. Prediksi Curah Hujan Tahun 2023

Bulan	Hasil Prediksi (mm/bulan)	Klasifikasi
Januari 2023	190	Sedang
Februari 2023	266	Sedang
Maret 2023	197	Sedang
April 2023	178	Sedang
Mei 2023	290	Sedang
Juni 2023	182	Sedang
Juli 2023	299	Sedang
Agustus 2023	350	Tinggi
September 2023	213	Sedang
Oktober 2023	485	Tinggi
November 2023	357	Tinggi
Desember 2023	389	Tinggi

Hasil prediksi mengunakan *Backpropagation Neural Network* dicek kembali keakuratannya menggunakan MAPE seperti pada persamaan 6. Hasilnya adalah $MAPE = 35{,}55\%$. Hal ini menunjukkan bahwa metode *Backpropagation Neural Network* layak digunakan untuk memprediksi curah hujan di Sumatera Utara.

4. Kesimpulan

Berdasarkan penelitian yang dilakukan, dapat disimpulkan bahwa prediksi curah hujan di Sumatera Utara menggunakan metode *Backpropagation Neural Network* mulai Januari hingga Desember 2023 adalah 190; 266; 197; 178; 290; 182; 299; 350; 213; 485; 357; dan 389 (mm/bulan). Pada Januari hingga Juli serta September termasuk dalam kategori curah hujan sedang, sedangkan pada bulan Agustus serta Oktober hingga Desember termasuk dalam kategori curah hujan tinggi. Metode ini layak digunakan untuk memprediksi curah hujan di Sumatera Utara karena memiliki $MAPE = 35{,}55\%$.

Daftar Rujukan

[1] G. Z. Muflih, Sunardi, and A. Yudhana, 'Jaringan Saraf Tiruan Backpropagation untuk Prediksi Curah Hujan di Wilayah Kabupaten Wonosobo', *MUST J. Math. Educ. Sci. Technol.*, vol. 4, no. 1, pp. 45–56, 2019.

[2] S. K. Nasib, Nurwan, E. D. D. Yanuari, and T. Machmud, 'Karakteristik Rantai Markov Pada Data Curah Hujan Bulanan Stasiun Djalaluddin', *JMPM J. Mat. Dan Pendidik. Mat.*, vol. 7, no. 2, pp. 81–89, 2022.

[3] S. Peronika, *Prediksi Curah Hujan di Daerah Bandara Sultan Mahmud Badaruddin II Menggunakan Jaringan Syaraf Tiruan dengan Metode Backpropagation dan Radial Basis Function Network*. Palembang: Universitas Sriwijaya, 2017.

[4] Badan Pusat Statistik (BPS) Provinsi Sumatera Utara, 'Curah Hujan dan Banyaknya Hari Hujan di BMKG Wil I 2021-2023'. Accessed: Jan. 05, 2023. [Online]. Available: https://sumut.bps.go.id/indicator/151/341/1/curah-hujan-dan-banyaknya-hari-hujan-di-bmkg-wil-i.html

[5] R. Abelia, Ruslan, L. Laome, Baharuddin, Makkulau, and Agusrawati, 'Penerapan Jaringan Syaraf Tiruan Backpropagation pada Peramalan Curah Hujan di Kota Kendari', *JMKS J. Mat. Komputasi Dan Stat.*, vol. 2, no. 2, pp. 1–7, 2022.

[6] Badan Pusat Statistik (BPS), 'Banyaknya Desa/Kelurahan Menurut Jenis Bencana Alam dalam Tiga Tahun Terakhir (Desa), 2014-2021'. Accessed: Jan. 03, 2023. [Online]. Available: https://www.bps.go.id/id/statistics-table/2/OTU0IzI=/banyaknya-desa-kelurahan-menurut-jenis-bencana-alam-dalam-tiga-tahun-terakhir.html

[7] Dinas Komunikasi dan informatika Provinsi Sumatera Utara, 'Curah Hujan Tinggi, 17 Kabupaten/Kota di Sumut Dilanda Banjir dan Longsor'. [Online]. Available: https://sumutprov.go.id/artikel/artikel/curah-hujan-tinggi--17-kabupatenkota-di-sumut--dilanda-banjir-dan-longsor

[8] K. N. A. Dewi, S. Bhari, and Irwansyah, 'Model Prediksi Curah Hujan Harian Menggunakan Jaringan Syaraf Tiruan Backpropagation', *Indones. Phys. Rev.*, vol. 2, no. 1, pp. 9–17, 2019.

[9] U. Cahyati, *Prediksi Curah Hujan dengan Menggunakan Metode Jaringan Syaraf Tiruan (JST) Backpropagation Sebagai Pendukung Kalender Tanam di Kabupaten Lamongan*. Surabaya: Universitas Islam Negeri Sunan Ampel, 2019.

[10] Fitriyanti, 'Aplikasi Jaringan Syaraf Tiruan Backpropagation dalam Prediksi Curah Hujan Bulanan di Kabupaten Wajo Sulawesi Selatan', *JPF J. Pendididkan Fis.*, vol. 11, no. 1, pp. 44–55, 2022.

[11] E. V. Ang and N. S. Kiswanto, 'The Effect of The Number of Hidden Layers in The Backpropagation in Case Study Weather Classification', *Proxies J. Inform.*, vol. 2, no. 2, pp. 58–67, 2019.

[12] U. Khasanah and N. Ulinnuha, 'Prediksi Biaya Konsumsi Bahan Bakar Gas Menggunakan Metode Backpropagation Neural Network (Studi Kasus: PLTU PT. Pembangkit Jawa Bali Unit Pembangkitan Gresik)', *J. Sains Mat. Dan Stat.*, vol. 5, no. 2, pp. 9–17, 2019.

[13] H. Putra and N. U. Walmi, 'Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation', *J. Nas. Teknol. Dan Sist. Inf.*, vol. 6, no. 2, pp. 100–107, 2020.

[14] D. E. Rufiyanti, *Implementasi Jaringan Syaraf Tiruan Backpropagation dengan Input Model Arima untuk Peramalan Harga Saham*. Semarang: Universitas Negeri Semarang, 2015.

[15] N. F. Mufinnun, H. Rahman, and M. N. Jauhari, 'Implementasi Backpropagation Neural Network pada Prediksi Jumlah Penjualan Toyota Avanza di Indonesia', *JRMM J. Ris. Mhs. Mat.*, vol. 6, no. 1, pp. 288–297, 2022.

[16] M. Y. Habibi and E. Riksakomara, 'Peramalan Harga Garam Konsumsi Menggunakan Artificial Neural Network Feedforward - Backpropagation (Studi Kasus : PT. Garam Mas, Rembang, Jawa Tengah)', *J. Tek. ITS*, vol. 6, no. 2, pp. 306–310, 2017.

[17] N. Lestari and L. L. V. FC, 'Implementasi Jaringan Syaraf Tiruan untuk Menilai Kelayakan Tugas Akhir Mahasiswa (Studi Kasus di Amik Bukittinggi)', *J. Teknol. Inf. Komun. Digit. Zone*, vol. 8, no. 1, pp. 10–24, 2017.