



Penerapan Algoritma Backpropagation Untuk Prakiraan Cuaca Harian Dibandingkan Dengan Support Vector Machine dan Logistic Regression

Ayu Zulfiani^{1,2*}, Chairani Fauzi¹

¹Magister Teknik Informatika, IIB Darmajaya, Lampung, Indonesia

²Stasiun Meteorologi Radin Inten II Kelas I Lampung, Lampung, Indonesia

Email: ^{1,*}azulfiani.2121211009@mail.darmajaya.ac.id, ²chairani@darmajaya.ac.id

Email Penulis Korespondensi: azulfiani.2121211009@mail.darmajaya.ac.id

Abstrak—Untuk mengantisipasi dampak yang ditimbulkan oleh cuaca ekstrem, BMKG mengeluarkan prakiraan cuaca, agar masyarakat siap, ketika cuaca ekstrem itu datang. Aplikasi penggunaan teknik Artificial Neural Network (ANN) pada prakiraan cuaca yang sangat berdampak, meningkatkan kemampuan untuk menyelami luasnya big data dalam mendapatkan informasi yang diperlukan, sebagai pembantu yang tepat bagi prakiraan dan pembuatan kebijakan. Data yang digunakan pada penelitian ini adalah data unsur-unsur cuaca, seperti tekanan, suhu udara, kelembaban, arah dan kecepatan angin, serta curah hujan, yang didapatkan dari Stasiun Meteorologi Radin Inten II Lampung. Data observasi memiliki kerapatan data per 1 jam, dengan rentang waktu selama 5 tahun yaitu dari 01 Januari 2018 – 31 Desember 2022. Metode yang dipakai dalam penelitian ini adalah Backpropagation Neural Network (BPNN). Hasil penelitian menunjukkan BPNN dapat memprakirakan hujan terklasifikasi dengan baik dibandingkan metode lainnya, dimana nilai recall saat hujan ringan 0.68, hujan sedang, 0.17, dan hujan lebat 0.03, sedangkan pada metode Support Vector Machine (SVM) dan Logistic Regression (LR) hanya mampu memprakirakan hujan ringan dengan nilai recall saat terjadi hujan ringan 0.51 dan 0.47.

Kata Kunci: Cuaca Ekstrem; Prakiraan Cuaca; ANN; BPNN

Abstract—To anticipate the impacts caused by extreme weather, the Meteorology, Climatology, and Geophysics Agency (BMKG) issues weather forecasts so that the community can be prepared when such extreme weather occurs. The application of Artificial Neural Network (ANN) techniques in weather forecasting significantly enhances the ability to explore vast amounts of big data in obtaining the necessary information, serving as a reliable assistant for forecasting and policymaking. The data used in this study consists of weather elements such as pressure, air temperature, humidity, wind direction and speed, as well as rainfall, obtained from the Radin Inten II Lampung Meteorological Station. The observational data has a data density per hour, spanning a period of 5 years from January 1, 2018, to December 31, 2022. The method employed in this research is Backpropagation Neural Network (BPNN). The research results indicate that BPNN can effectively predict classified rainfall compared to other methods, within recall value when slight rain 0.68, moderate rain 0.17, and heavy rain 0.03, meanwhile Support Vector Machine (SVM) and Logistic Regression (LR) method can predict only slight rain with recall value when slight rain is 0.51 and 0.47.

Keywords: Extreme Weather; Weather Forecast; ANN; BPNN

1. PENDAHULUAN

Cuaca Ekstrem adalah kejadian cuaca yang tidak normal, tidak lazim yang dapat mengakibatkan kerugian terutama keselamatan jiwa dan harta (Peraturan Kepala BMKG Kep.009 Tahun 2010). Berdasarkan data dari Badan Nasional Penanggulangan Bencana (BNPB), selama tahun 2022 saja, telah terjadi 3.054 bencana dengan korban meninggal sampai 392 orang, dengan jumlah kejadian cuaca ekstrem dapat mencapai 931 kejadian (Geoportal Data Bencana Indonesia (bnpb.go.id)). Untuk mengantisipasi dampak yang ditimbulkan oleh cuaca ekstrem, BMKG mengeluarkan peringatan dini, agar masyarakat siap, ketika cuaca ekstrem itu datang.

Atmosfer selalu bergerak dalam skala waktu yang bervariasi berdasarkan fenomena seperti hembusan angin lokal hingga sirkulasi angin global yang mengelilingi bumi [1]. Prakiraan sendiri didefinisikan sebagai perkiraan kejadian yang akan datang dengan berdasarkan pada data sekarang dan yang telah berlalu. Sedangkan prakiraan cuaca prakiraan kondisi atmosfer pada lokasi tertentu dengan menggunakan aplikasi sains dan teknologi (weather forecasting). Prakiraan ini termasuk suhu, hujan, tutupan awan, kecepatan angin, dan kelembaban udara. Prakiraan cuaca dapat dilakukan untuk seminggu ke depan, tetapi akurasi prakiraan akan menurun bersamaan dengan panjangnya waktu prakiraan. Berdasarkan jangka waktunya, prakiraan cuaca diklasifikasikan menjadi now-casting untuk 0-3 jam ke depan, shortcasting untuk 3-6 jam ke depan, dan long casting untuk prakiraan hingga 6 hari ke depan [2].

Salah satu masalah tersulit dalam prakiraan cuaca, adalah mekanisme dasar dari meteorologi [3]. Pada banyak kasus, peneliti harus membangun hubungan linear antara data input cuaca dan data hasil keluaran, tetapi pada kenyataannya data cuaca bukanlah data yang linear, sehingga fokus berubah menjadi prakiraan non-linear terhadap data cuaca. Keuntungan dari Artificial Neural Network (ANN) dibandingkan dengan metode prakiraan yang lain, ANN mampu meminimalisir kesalahan dengan berbagai algoritma dan memberikan nilai prakiraan yang mendekati keadaan sebenarnya [4].

Secara sederhana, ANN adalah sebuah alat pemodelan data statistik non-linier. ANN dapat digunakan untuk memodelkan hubungan yang kompleks antara input dan output untuk menemukan pola-pola pada data. Pada bentuk sederhananya, ANN adalah tiruan dari otak manusia, yang mempunyai kemampuan untuk belajar hal baru,



beradaptasi pada lingkungan baru yang berubah-ubah. ANN mampu mengola data yang banyak (big data) dan menemukan pola tertentu dari banyak data tersebut [5].

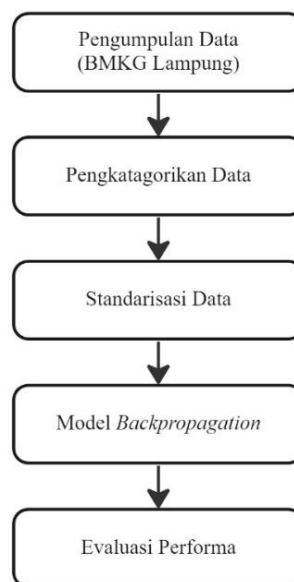
Prakiraan cuaca dengan menggunakan Artificial Neural Network (Jaringan Saraf Tiruan / JST) dan teknik Backpropagation Neural Network (BPNN) telah dilakukan oleh peneliti-peneliti sebelumnya [6]. BPNN bekerja dengan memprakirakan hubungan tidak langsung antara data dan hasil dengan mengubah bobot di dalamnya [7]. Aplikasi penggunaan teknik JST modern pada prakiraan cuaca yang sangat berdampak, meningkatkan kemampuan untuk menyelami luasnya big data dalam mendapatkan informasi yang diperlukan, sebagai pembantu yang tepat bagi prakiraan dan pembuatan kebijakan.

Prakiraan cuaca dengan metode BPNN telah dilakukan dan mendapatkan hasil yang baik, tetapi menggunakan data model, bukan data observasi [8], [9]. Penggunaan data observasi baru digunakan, tetapi untuk memprediksi unsur-unsur cuaca seperti suhu, angin, tekanan, dan kelembaban, tidak memprediksi hujan [10]. Penggunaan BPNN pada data curah hujan mulai digunakan untuk menghitung curah hujan bulanan [11]–[13]. Penelitian menggunakan banyak unsur cuaca untuk meprediksi hujan esok hari telah dilakukan oleh Panggabean [14] dan Lesnussa [15], tetapi tidak membagi klasifikasi curah hujan berdasarkan intensitasnya. Pada penelitian dewi dkk [16], algoritma BPNN dapat mampu meprakirakan dengan baik curah hujan harian.

Untuk itu, pada penelitian ini akan menggunakan JST dengan teknik backpropagation dalam memprakirakan cuaca berdasarkan klasifikasi intensitas hujan. Berbeda dengan penelitian sebelumnya yang digunakan untuk memprakirakan curah hujan untuk bulanan, penelitian ini akan dilakukan untuk memprakiraan potensi terjadinya hujan harian. Penelitian ini akan menggunakan 6 variabel input, yaitu tekanan, suhu, kelembaban, kecepatan angin, tutupan awan, dan jarak pandang, untuk memprakiraan potensi terjadinya hujan pada rentang waktu sehari kemudian.

2. METODOLOGI PENELITIAN

Alur penelitian adalah ringkasan konsep atau gambaran dari penelitian yang akan dilakukan pada penelitian. Penjabaran alur penelitian akan dijelaskan pada subbab ini yang digambarkan pada gambar 1. Penelitian akan dimulai dari pengumpulan data observasi cuaca, lalu sebelum pre-processing data akan dikategorikan terlebih dahulu, pada pre-processing data akan dilakukan standarisasi, setelah itu akan dilakukan uji performa atau evaluasi performa dari algoritma BPNN dibandingkan dengan algoritma lainnya.



Gambar 1. Diagram Alur Penelitian

Proses pertama yang dilakukan pada penelitian ini sesuai dengan diagram alur di atas adalah proses pengumpulan data. Data yang digunakan pada penelitian ini adalah data unsur-unsur cuaca, seperti tekanan, suhu udara, kelembaban, arah dan kecepatan angin, serta curah hujan, yang didapatkan dari Stasiun Meteorologi Radin Inten II Lampung. Data observasi memiliki kerapatan data per hari, dengan rentang waktu selama 5 tahun yaitu dari 01 Januari 2018 – 31 Desember 2022 dengan jumlah data 1826 hari.

Data hujan yang digunakan nantinya akan dikategorikan menjadi tak hujan dengan intensitas hujan 0, hujan ringan sekitar 0-5 mm, hujan sedang sekitar 5-20 mm, dan hujan lebat lebih besar dari 20 mm, pengkatagorian ini



dilakukan untuk prakiraan hujan dengan klasifikasi. Pada prakiraan hujan tanpa klasifikasi hujan hanya dikategorikan sebagai tak hujan dengan intensitas 0 mm dan hujan dengan intensitas lebih besar dari 0 mm.

Setelah itu data juga akan dikategorikan menjadi data training (latih) dan data test (uji). Data latih akan digunakan untuk melatih model dengan menggunakan algoritma BPNN pada epoch yang berbeda-beda, sedangkan data uji digunakan untuk menguji performa dari model. Pembagian data ini dibagi ke dalam porsi 70% untuk data latih dan 30% untuk data uji, yang berarti 1278 adalah data uji dan 548 adalah data latih. Penggunaan data latih yang besar dapat meningkatkan akurasi dan performa model dalam memprakirakan cuaca [17].

Sebelum diolah menggunakan algoritma terlebih dahulu dilakukan standarisasi data terhadap variabel input. Standarisasi data adalah elemen dasar dari data mining untuk memastikan data tetap konsisten. Tujuan dilakukannya standarisasi data adalah untuk menghilangkan adanya redundansi dan menstandarisasi informasi, sehingga algoritma yang dilakukan menjadi lebih mudah, efektif, dan efisien, khususnya pada data yang berukuran besar. Persamaan dari standarisasi:

$$s = \frac{x-\mu}{\sigma} \quad (1)$$

Dimana x adalah nilai input, s adalah hasil standarisasi, μ adalah rata-ratanya, dan σ adalah standar deviasi. BPNN terdiri atas setidaknya tiga layer, yaitu input layer, paling sedikit satu hidden layer, dan terakhir output layer. Proses data prakiraan cuaca secara real-time menunjukkan bahwa prakiraan cuaca yang berdasarkan pada teknik BPNN meningkatkan bukan hanya akurasi dari prakiraan dengan model, tetapi juga prakiraan cuaca lokal dalam lokasi yang lebih sempit .

Algoritma pembelajaran BPN dapat dibagi ke dalam dua fase, yaitu propagasi dan pembaruan nilai bobot[18]. Pada setiap fase propagasi mengikuti langkah-langkah berikut:

1. Propagasi maju dari input pola pelatihan diberikan melalui jaringan saraf untuk menghasilkan output
2. Back Propagation dari output aktivasi propagasi melalui JST menggunakan target pola pelatihan untuk menghasilkan delta atau selisih untuk semua output dan neuron.

Ada beberapa fungsi aktivasi yang sering digunakan untuk mengaktifasi algoritma BPNN untuk memprakirakan cuaca [19], [20]:

1. Fungsi ReLU (Rectified Linear Unit), adalah fungsi aktivasi non-linear yang digunakan pada jaringan neuron multi-layer atau jaringan neural dalam (deep neural network). Fungsi ini dituliskan sebagai berikut:

$$f(x) = \max(0, x) \quad (2)$$

dimana x adalah nilai input. Berdasarkan persamaan (2), output dari ReLU adalah nilai maksimum antara 0 dan nilai input. Sehingga,

$$f(x) = \begin{cases} 0, & \text{jika } x < 0 \\ x, & \text{jika } x \geq 0 \end{cases} \quad (3)$$

2. Fungsi Log Sigmoid, adalah fungsi matematika yang memiliki karakteristik kurva berbentuk “S”, yang mengubah nilai antara rentang 0 dan 1. Fungsi sigmoid disebut juga dengan kurva sigmoidal atau fungsi logistik. Ini adalah salah satu fungsi aktivasi non-linier yang paling banyak digunakan.

$$z = f(a) = \frac{1}{1+e^{-a}} \quad (4)$$

dimana:

$f(a)$ adalah fungsi dari a atau fungsi dari nilai net input

e^{-a} adalah eksponen dari $-a$


Struktur layer dari JST dapat dilihat pada gambar 2. Berdasarkan gambar 2, model penelitian terdiri dari 1 input layer yang terdiri dari 6 variabel yaitu P adalah tekanan, T adalah suhu udara, RH adalah kelembaban, W adalah kecepatan angin, C adalah tinggi dasar awan, dan V adalah jarak pandang; 2 hidden layer untuk hidden layer 1 terdiri dari 32 variabel y_1 - y_{32} dan untuk hidden layer 2 terdiri dari 16 variabel z_1 - z_{16} ; dan 1 output layer yang terdiri berupa prakiraan cuaca. Setiap unsur cuaca dari input layer, saling terhubung pada hidden layer, lalu akan mengeluarkan output layer, berupa prakiraan cuaca.

Untuk prakiraan cuaca dengan klasifikasi, output akhir akan menggunakan fungsi aktivasi ReLU dengan nilai maksimum 3, sehingga rentang nilai output berkisar antara 0 – 3. Prakiraan cuaca akan menggunakan nilai akhir output yang akan dibagi ke dalam 4 katagori, yaitu kondisi berawan, dengan nilai output lebih kecil dari 0.5, hujan ringan nilai output antara 0.5 – 1.5, hujan sedang memiliki nilai output antara 1.5 – 2.5, dan hujan lebat memiliki nilai output lebih besar dari 2.5. Untuk prakiraan cuaca tanpa klasifikasi output akhir akan menggunakan fungsi aktivasi Sigmoid sehingga nilai output berkisar antara 0 – 1. Prakiraan cuaca akan menggunakan nilai akhir output yang akan dibagi ke dalam dua katagori, yaitu tidak hujan dengan nilai output lebih kecil dari 0.5 dan hujan dengan nilai output lebih besar dari 0.5.

Evaluasi performa dilakukan dengan menggunakan matriks konfusi untuk mengetahui berapa banyak prakiraan yang benar terjadi, atau meleset dibandingkan keadaan sebenarnya. Pada penelitian ini akan dibuat



matriks konfusi untuk memprakirakan terjadi hujan atau tidaknya. Selain itu akan digunakan laporan klasifikasi (classification report) untuk mengetahui nilai akurasi, recall, dan presisi dari model yang digunakan. Selain itu juga dilakukan perbandingan dengan metode lain seperti Logistic Regression (LR) dan Support Vector Machine (SVM).



Gambar 2. Struktur dari JST

3. HASIL DAN PEMBAHASAN

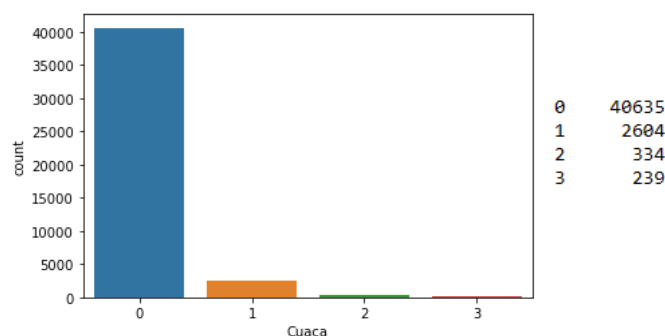
3.1 Analisis Data

Statistik deskriptif digunakan untuk melihat sebaran, rata-rata, nilai min, max, dan quartil dari setiap unsur pada data. Dapat dilihat pada gambar 3, unsur dengan nilai deviasi terkecil adalah tekanan dan yang terbesar adalah jarak pandang. Unsur suhu udara, tekanan, kelembaban, dan angin, memiliki nilai deviasi yang sangat rendah yaitu 2.9, 1.8, 13.4, dan 3.8, sehingga antara nilai min, quartil, dan maksimumnya tidak memiliki perbedaan yang besar. Sedangkan unsur awan dan jarak pandang, memiliki nilai deviasi yang cukup besar yaitu 2011.6 dan 2400.2, sehingga terdapat perbedaan yang sangat besar antara nilai minimum, quartil, dan maksimumnya.


	Suhu	Tekanan	Kelembaban	Angin	Awan	Visibility	Cuaca
count	43812.000000	43812.000000	43812.000000	43812.000000	43812.000000	43812.000000	43812.000000
mean	27.149712	1010.161599	79.060645	3.084527	2117.746280	8299.221674	0.091048
std	2.940024	1.825698	13.410545	3.185257	2011.611158	2400.229305	0.361579
min	19.900000	999.100000	20.000000	0.000000	0.000000	100.000000	0.000000
25%	24.800000	1008.900000	69.000000	0.000000	1400.000000	7000.000000	0.000000
50%	26.400000	1010.300000	82.000000	3.000000	1500.000000	10000.000000	0.000000
75%	29.400000	1011.400000	90.000000	5.000000	1500.000000	10000.000000	0.000000
max	36.600000	1016.200000	100.000000	30.000000	8200.000000	10000.000000	3.000000

Gambar 3. Statistik Deskriptif

Pembagian katagori hujan berdasarkan intensitasnya dapat dilihat pada gambar 4. Berdasarkan gambar 4, kejadian hujan ringan (0), memiliki kejadian paling banyak, dengan jumlah 2.604 jam pengamatan atau 5.9%. Kejadian hujan sedang (2) terjadi dengan 334 jam pengamatan atau 0.8%, sedangkan kejadian paling sedikit yaitu hujan lebat (3) dengan 239 jam pengamatan atau 0.6%.



Gambar 4. Grafik Kejadian Tidak Hujan, Hujan Ringan, Hujan Sedang, dan Berawan



Gambar 5. Grafik Heatmap Korelasi dari Setiap Unsur

Untuk mengetahui hubungan setiap unsur dengan unsur lainnya, maka digunakan grafik heatmap korelasi yang dapat dilihat pada gambar 5. Berdasarkan gambar 5, dapat dilihat bahwa suhu memiliki korelasi negatif dengan kelembaban dan korelasi positif dengan angin dan jarak pandang. Sehingga ketika suhu udara tinggi, maka kelembaban rendah, kecepatan angin tinggi, dan jarak pandang tinggi, begitu pula sebaliknya. Sementara itu, kelembaban memiliki korelasi negatif dengan angin dan jarak pandang, yang berarti pada kelembaban yang tinggi, maka kecepatan angin rendah dan jarak pandang juga rendah. Cuaca sendiri tidak memiliki korelasi yang cukup kuat pada setiap unsur, ini bisa berarti cuaca bukan hanya dipengaruhi oleh salah satu unsur, melainkan semua unsur.

3.2 Pengaturan Model Algoritma Backpropagation Neural Network (BPNN)

Pada tahap ini akan dijelaskan pengaturan model artificial neural network yang digunakan dalam penelitian ini, yang merupakan penggunaan dari library keras. Pengaturan model ini dapat dilihat pada gambar 4.8.a untuk pengaturan model pada hujan dengan klasifikasi yang berbeda-beda dan gambar 4.8.b untuk pengaturan model pada satu klasifikasi hujan.

Pada gambar 6, baik untuk hujan tanpa klasifikasi dan dengan klasifikasi memiliki pengaturan model yang hampir sama. Keduanya memiliki 4 layer yang terdiri dari 1 layer input, 2 hidden layer dengan hidden layer 1 memiliki 32 unit dan hidden layer 2 memiliki 16 unit, serta 1 output layer. Keduanya menggunakan optimizer adam dan metrik yang digunakan adalah akurasi. Epoch yang digunakan pada kedua model akan dimulai dari epoch 10 – 100 dan dibandingkan akurasi, untuk mencegah terjadinya overfitting.

Pada gambar 6 (atas) atau hujan dengan klasifikasi, tahap pertama yang dilakukan adalah penetapan nilai max_value dari fungsi aktivasi relu dengan nilai 3, karena pada proses perjalanan model di setiap layernya akan digunakan fungsi aktivasi relu. Penentuan nilai maksimum 3, karena pada output layer, nilai yang diharapkan berkisar antara 0 hingga 3, sehingga nilai maksimum yang diharapkan tidak lebih dari 3.

```

1 def relu_advanced(x):
2     return K.relu(x, max_value=3)
3
4 ann = tf.keras.models.Sequential()
5 ann.add(tf.keras.layers.Dense(units=32, activation=relu_advanced))
6 ann.add(tf.keras.layers.Dense(units=16, activation=relu_advanced))
7 ann.add(tf.keras.layers.Dense(units=1, activation=relu_advanced))
8 ann.compile(optimizer = 'adam', loss = 'binary_crossentropy', metrics = ['accuracy'])
9 ann.fit(X_train, y_train, batch_size = 32, epochs = 100)

```

```


1 ann = tf.keras.models.Sequential()
2 ann.add(tf.keras.layers.Dense(units=32, activation='relu'))
3 ann.add(tf.keras.layers.Dense(units=16, activation='relu'))
4 ann.add(tf.keras.layers.Dense(units=1, activation='sigmoid'))
5 ann.compile(optimizer = 'adam', loss = 'binary_crossentropy', metrics = ['accuracy'])
6 ann.fit(X_train, z_train, batch_size = 32, epochs = 100)

```

Gambar 6. Pengaturan model pada prakiraan hujan dengan klasifikasi (atas) dan pengaturan model pada prakiraan hujan tanpa klasifikasi (bawah)

Berbeda dengan model dengan klasifikasi hujan yang berbeda, pada model dengan satu klasifikasi hujan seperti pada gambar 6 (bawah), tidak ditetapkan nilai maksimum dari relu. Selain itu pada layer output, fungsi aktivasi yang digunakan adalah sigmoid. Ini digunakan, karena output layer pada model ini adalah boolean yaitu 0 atau 1 yang menandakan tidak hujan atau hujan.

3.3 Penggunaan Algoritma Backpropagation Neural Network (BPNN)



Gambar 7. Grafik akurasi pada epoch berbeda-beda untuk hujan tanpa klasifikasi



Grafik akurasi prakiraan metode BPNN dengan epoch yang berbeda-beda untuk memprakirakan hujan 24 jam ke depan tanpa klasifikasi ditunjukkan pada gambar 7. Berdasarkan gambar 7, nilai akurasi di awal cukup tinggi, kemudian menurun hingga ke akurasi minimumnya bernilai 0.44, pada epoch 30. Lalu nilai epoch kembali meningkat cukup besar mencapai nilai maksimum 0.55 pada epoch 50, setelah itu akurasi kembali menurun menjadi 0.51 pada epoch 100.

Matriks konfusi pada gambar 8, akan menunjukkan seberapa banyak hujan 24 jam kemudian yang berhasil diprakirakan. Berdasarkan gambar 8, jumlah prakiraan hujan yang berhasil atau tidak diprakirakan berubah-ubah pada epoch yang berbeda-beda. Pada gambar 8.b, prakiraan hujan paling sedikit dengan 96 kejadian terjadi pada epoch 10. Jumlah prakiraan terbanyak dengan 149 kejadian terjadi pada epoch 50 (gambar 8.d).

a	$\begin{bmatrix} 265 & 212 \\ 137 & 116 \end{bmatrix}$	b	$\begin{bmatrix} 265 & 212 \\ 157 & 96 \end{bmatrix}$	c	$\begin{bmatrix} 198 & 279 \\ 128 & 125 \end{bmatrix}$
d	$\begin{bmatrix} 255 & 222 \\ 104 & 149 \end{bmatrix}$	e	$\begin{bmatrix} 250 & 227 \\ 131 & 122 \end{bmatrix}$		

Gambar 8. Matriks konfusi hujan tanpa klasifikasi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Hasil uji performa model prakiraan hujan 24 jam ke depan akan menampilkan presisi, recall, dan f1-score dapat dilihat pada gambar 9. Berdasarkan gambar 9, pada epoch 50 (gambar 9.a), bukan hanya nilai akurasinya yang lebih tinggi, tetapi juga presisi, recall, dan f1-score dibandingkan epoch 50 (gambar 9.b), baik untuk prakiraan hujan ataupun tidak hujan. Presisi dan recall untuk memprakirakan hujan juga cukup tinggi pada epoch 50, dengan presisi bernilai 0.4 dan recall 0.59.

a		precision	recall	f1-score	support
	0	0.71	0.53	0.61	477
	1	0.40	0.59	0.48	253
	accuracy			0.55	730
	macro avg	0.56	0.56	0.54	730
	weighted avg	0.60	0.55	0.56	730
b		precision	recall	f1-score	support
	0	0.66	0.52	0.58	477
	1	0.35	0.48	0.41	253
	accuracy			0.51	730
	macro avg	0.50	0.50	0.49	730
	weighted avg	0.55	0.51	0.52	730

Gambar 9. Hasil performa model untuk hujan tanpa klasifikasi pada a) epoch 30 dan b) epoch 100

Sementara itu, prakiraan untuk hujan dengan klasifikasi yaitu hujan ringan, hujan sedang, dan hujan lebat, menunjukkan hasil yang berbeda. Grafik tingkat akurasi berbanding dengan epoch untuk prakiraan cuaca 1 hari ke depan ditampilkan pada gambar 10. Berdasarkan gambar 10, akurasi awalnya cukup tinggi dengan nilai 0.44 pada epoch 5, dan terus naik turun hingga mencapai akurasi 0.44 di epoch 100. Akurasi maksimum memiliki nilai hampir sama di tiga epoch yang berbeda-beda yaitu pada epoch 5, 30, dan 100 dengan nilai akurasi 0.44, sedangkan epoch minimumnya 0.42 terjadi pada epoch 10.



Gambar 10. Grafik akurasi pada epoch berbeda-beda untuk hujan dengan klasifikasi

Untuk melihat seberapa banyak prakiraan yang benar dan salah untuk prakiraan 1 hari ke depan, maka digunakan matriks konfusi pada gambar 11. Berdasarkan gambar 11, model BPNN menghasilkan prakiraan yang berbeda-beda pada epoch yang berbeda. Pada epoch 5 (gambar 11.a), BPNN tidak dapat memprakirakan hujan sedang dan hujan lebat. Pada epoch 10 (gambar 9.b) dan epoch 50 (gambar 11.d), BPNN tidak dapat



memprakirakan hujan lebat, meskipun masih bisa memprakirakan hujan sedang. Pada epoch 30 (gambar 9.c) dan epoch 100 (gambar 11.e), BPNN mampu memprakirakan baik hujan ringan, hujan sedang, maupun hujan lebat. Epoch 30 mampu memprakirakan hujan ringan dan hujan sedang lebih banyak dibandingkan epoch 100.

a	[[136 190 0 0] [76 186 0 0] [16 53 0 0] [20 53 0 0]]	b	[[91 230 5 0] [45 213 4 0] [14 52 3 0] [10 61 2 0]]
c	[[127 164 22 13] [47 178 27 10] [11 44 12 2] [9 47 15 2]]	d	[[98 217 11 0] [41 212 9 0] [13 51 5 0] [12 60 1 0]]
	e		[[165 135 22 4] [77 144 35 6] [17 41 9 2] [15 49 7 2]]

Gambar 11. Matriks konfusi hujan dengan klasifikasi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Untuk melihat lebih detail kemampuan dari model BPNN, maka akan ditampilkan presisi, recall, dan f-1 score pada gambar 12. Berdasarkan gambar 12, epoch 30 memiliki nilai presisi dan recall yang lebih besar saat terjadi hujan ringan dan hujan sedang, tetapi saat tidak hujan nilai recall lebih rendah, meskipun presisinya lebih besar. Pada saat hujan lebat nilai recall antara epoch 30 dan 100 sama, tetapi presisi saat epoch 100 lebih besar. Epoch 30 menjadi epoch terbaik dalam memprakirakan hujan 1 hari ke depan, karena memiliki nilai recall yang lebih besar, yang menandakan bahwa epoch 30 memiliki peluang memprakirakan hujan lebih banyak dibandingkan dengan epoch 100.

a		precision	recall	f1-score	support
	0	0.65	0.39	0.49	326
	1	0.41	0.68	0.51	262
	2	0.16	0.17	0.17	69
	3	0.07	0.03	0.04	73
	accuracy			0.44	730
	macro avg	0.32	0.32	0.30	730
	weighted avg	0.46	0.44	0.42	730
b		precision	recall	f1-score	support
	0	0.60	0.51	0.55	326
	1	0.39	0.55	0.46	262
	2	0.12	0.13	0.13	69
	3	0.14	0.03	0.05	73
	accuracy			0.44	730
	macro avg	0.31	0.30	0.29	730
	weighted avg	0.43	0.44	0.43	730

Gambar 12. Hasil performa model untuk hujan dengan klasifikasi pada a) epoch 30 dan b) epoch 100

3.4 Perbandingan Dengan Metode Logistic Regression dan Support Vector Machine

Hasil uji performa dan matriks konfusi untuk metode SVM ditampilkan pada gambar 13. Berdasarkan gambar 13, akurasi prakiraan cuaca dengan metode SVM lebih besar dengan nilai 0.52 dimana dengan metode BPNN hanya 0.44 (gambar 13.a). Jika dilihat lebih detail, nilai recall untuk prakiraan hujan ringan dengan metode SVM lebih kecil dimana hanya 0.65, sedangkan BPNN dapat mencapai 0.68. Ini menunjukkan bahwa metode BPNN dapat lebih banyak memprakirakan terjadinya hujan. Matriks konfusi pada gambar 13 juga menunjukkan bahwa hujan ringan yang gagal diprakirakan dengan metode SVM lebih banyak yaitu 90, sedangkan pada metode BPNN hanya 47 kejadian. Salah satu kekurangan dari metode SVM yang menjadi alasan utama penggunaan metode BPNN adalah metode SVM tidak dapat memprakirakan terjadinya hujan sedang dan hujan ringan, sedangkan metode BPNN bisa.



	precision	recall	f1-score	support	
0	0.63	0.61	0.62	353	
1	0.42	0.64	0.51	251	[[217 136 0 0]
2	0.00	0.00	0.00	60	[90 161 0 0]
3	0.00	0.00	0.00	66	[21 39 0 0]
					[17 49 0 0]]
accuracy			0.52	730	
macro avg	0.26	0.31	0.28	730	
weighted avg	0.45	0.52	0.47	730	

Gambar 13. Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode SVM pada hujan dengan klasifikasi

Hasil uji performa menggunakan metode SVM untuk memprakirakan hujan satu hari ke depan tanpa klasifikasi ditunjukkan pada gambar 14. Berdasarkan gambar 14, akurasi metode SVM mencapai 0.64 sedangkan akurasi metode BPNN hanya sekitar 0.56. Untuk nilai recall prakiraan hujan metode SVM memiliki nilai 0.66, sedangkan BPNN hanya 0.46. Matriks konfusi juga menunjukkan bahwa prakiraan hujan tanpa klasifikasi lebih tepat diprakirakan dengan metode SVM dibandingkan dengan BPNN.

	precision	recall	f1-score	support	
0	0.63	0.61	0.62	353	
1	0.65	0.66	0.65	377	[[217 136]
					[128 249]]
accuracy			0.64	730	
macro avg	0.64	0.64	0.64	730	
weighted avg	0.64	0.64	0.64	730	

Gambar 14. Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode SVM pada hujan tanpa klasifikasi

Hasil pengujian metode logistic regression (LR) untuk prakiraan hujan dengan klasifikasi ditunjukkan pada gambar 15. Jika dibandingkan dengan metode BPNN, akurasi dari metode LR lebih besar dengan nilai 0.51 dimana dengan metode BPNN hanya 0.44. Jika dilihat lebih detil, metode LR memiliki nilai recall yang lebih rendah yaitu 0.57, sedangkan BPNN mencapai 0.68 pada saat memprakirakan hujan ringan. Ini menunjukkan bahwa metode BPNN dapat memprakirakan hujan ringan lebih banyak dibandingkan dengan metode LR.

	precision	recall	f1-score	support	
0	0.60	0.65	0.62	353	[[231 122 0 0]
1	0.41	0.56	0.47	251	[110 140 0 1]
2	0.00	0.00	0.00	60	[27 33 0 0]
3	0.00	0.00	0.00	66	[19 47 0 0]]
accuracy			0.51	730	
macro avg	0.25	0.30	0.27	730	
weighted avg	0.43	0.51	0.46	730	

Gambar 15. Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode LR pada hujan dengan klasifikasi

Selain itu, dari matriks konfusi dapat dilihat bahwa hujan ringan yang gagal diprakirakan dengan metode LR lebih banyak yaitu 140, sedangkan pada metode BPNN hanya 47 kejadian. Salah satu kekurangan dari metode SVM yang menjadi alasan utama penggunaan metode BPNN adalah metode SVM tidak dapat memprakirakan terjadinya hujan sedang dan hujan ringan, sedangkan metode BPNN bisa.

Hasil uji performa menggunakan metode LR untuk memprakirakan hujan satu hari ke depan tanpa klasifikasi ditunjukkan pada gambar 16. Berdasarkan gambar 16, akurasi metode LR mencapai 0.64 sedangkan akurasi metode BPNN hanya sekitar 0.56 (gambar 38). Untuk nilai recall prakiraan hujan metode SVM memiliki nilai 0.79, sedangkan BPNN hanya 0.46. Matriks konfusi juga menunjukkan bahwa prakiraan hujan tanpa klasifikasi lebih tepat diprakirakan dengan metode LR dibandingkan dengan BPNN.

	precision	recall	f1-score	support	
0	0.68	0.49	0.57	353	
1	0.62	0.79	0.69	377	[[172 181]
					[80 297]]
accuracy			0.64	730	
macro avg	0.65	0.64	0.63	730	
weighted avg	0.65	0.64	0.63	730	

Gambar 16. Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode LR pada hujan tanpa klasifikasi



4. KESIMPULAN

Pada prakiraan hujan dengan klasifikasi epoch 30 menjadi epoch yang menghasilkan performa terbaik, sedangkan untuk hujan tanpa klasifikasi epoch 100 menjadi epoch yang menghasilkan performa terbaik. Algoritma JST dengan menggunakan metode BPNN dalam memprakirakan hujan dengan baik pada prakiraan cuaca harian. BPNN dapat melakukan prakiraan hujan terklasifikasi dengan baik, mulai dari hujan ringan, hujan sedang, hingga hujan lebat. Hasil penelitian menunjukkan BPNN dapat memprakirakan hujan terklasifikasi dengan baik dibandingkan metode lainnya, dimana nilai recall saat hujan ringan 0.68, hujan sedang, 0.17, dan hujan lebat 0.03, sedangkan pada metode Support Vector Machine (SVM) dan Logistic Regression (LR) hanya mampu memprakirakan hujan ringan dengan nilai recall saat terjadi hujan ringan 0.51 dan 0.47. Pada prakiraan hujan tanpa klasifikasi nilai recall BPNN untuk memprakiraan hujan hanya 0.59, sedangkan SVM dan LR menghasilkan nilai recall yang lebih besar dengan nilai berturut-turut 0.66 dan 0.79. Pada penelitian ini memakai fungsi aktivasi ReLU yang telah dimodifikasi untuk memprakirakan hujan dengan klasifikasi, penelitian selanjutnya dapat menggunakan fungsi aktivasi lain untuk mendapatkan performa model yang lebih baik. Selain itu, pada penelitian ini dilakukan prakiraan hujan harian, sehingga penelitian selanjutnya dapat melakukan prakiraan cuaca terkini (nowcasting) dengan rentang waktu antara 0-6 jam ke depan.

REFERENCES

- [1] E. Aldrian, *Meteorologi Laut Indonesia*. 2008. [Online]. Available: <https://www.researchgate.net/publication/305809658>
- [2] M. R. Kurniawan, "Perancangan Mobile Predictor Cuaca Maritim Menggunakan Metode Hybrid Logika Fuzzy Tipe 2-Jaringan Syaraf Tiruan dengan Optimasi Algoritma Differential Evolution Designing The Cluster of Indonesian Preacher Based On The Speech Using K-Nearest Neighbor View project," 2018, doi: 10.13140/RG.2.2.27518.84803.
- [3] P. Mohan and K. K. Patil, "Deep learning based weighted SOM to forecast weather and crop prediction for agriculture application," *International Journal of Intelligent Engineering and Systems*, vol. 11, no. 4, pp. 167–176, Aug. 2018, doi: 10.22266/ijies2018.0831.17.
- [4] S. A. Kakar et al., "Artificial Neural Network based Weather Prediction using Back Propagation Technique," *International Journal of Advanced Computer Science and Applications*, vol. 9, no. 8, 2018, doi: 10.14569/IJACSA.2018.090859.
- [5] Z. Al Sadeque and F. M. Bui, "A Deep Learning Approach to Predict Weather Data Using Cascaded LSTM Network," in 2020 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE), IEEE, Aug. 2020, pp. 1–5. doi: 10.1109/CCECE47787.2020.9255716.
- [6] E. G. Wahyuni, L. M. F. Fauzan, F. Abriyani, N. F. Muchlis, and M. Ulfa, "Rainfall prediction with backpropagation method," *J Phys Conf Ser*, vol. 983, p. 012059, Mar. 2018, doi: 10.1088/1742-6596/983/1/012059.
- [7] C. Sekhar and P. S. Meghana, "A Study on Backpropagation in Artificial Neural Networks," *Asia-Pacific Journal of Neural Networks and Its Applications*, vol. 4, no. 1, pp. 21–28, Aug. 2020, doi: 10.21742/AJNNIA.2020.4.1.03.
- [8] S. Singh, M. Kaushik, A. Gupta, and A. K. Malviya, "Weather Forecasting using Machine Learning Techniques," *SSRN Electronic Journal*, 2019, doi: 10.2139/ssrn.3350281.
- [9] M. Wica, M. Witkowski, A. Szumiec, and T. Ziebura, "Weather Forecasting System with the use of Neural Network and Backpropagation Algorithm," 2019.
- [10] S. M. Seeta G K M and B. M. Lakshmi, "WEATHER PREDICTION USING NEURAL NETWORK BACKPROPAGATION," vol. 14, no. 24, 2019, [Online]. Available: www.arpnjournals.com
- [11] S. Sholahudin et al., "Backpropagation and Radial Basis Function Methods for Predicting Rainfall in Sukabumi City Using Artificial Neural Networks: A Comparative Analysis," *FIDELITY : Jurnal Teknik Elektro*, vol. 4, no. 2, pp. 25–28, May 2022, doi: 10.52005/fidelity.v4i2.69.
- [12] G. Z. Muflih, S. Sunardi, and A. Yudhana, "Jaringan Saraf Tiruan Backpropagation untuk Prediksi Curah Hujan di Wilayah Kabupaten Wonosobo," *MUST: Journal of Mathematics Education, Science and Technology*, vol. 4, no. 1, p. 45, Jul. 2019, doi: 10.30651/must.v4i1.2670.
- [13] G. K. Rahul, S. Singh, and S. Dubey, "Weather Forecasting Using Artificial Neural Networks," in 2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO), IEEE, Jun. 2020, pp. 21–26. doi: 10.1109/ICRITO48877.2020.9197993.
- [14] D. A. H. Panggabean, F. M. Sihombing, and N. M. Aruan, "PREDIKSI TINGGI CURAH HUJAN DAN KECEPATAN ANGIN BERDASARKAN DATA CUACA DENGAN PENERAPAN ALGORITMA ARTIFICIAL NEURAL NETWORK (ANN)," *SEMINASTIKA*, vol. 3, no. 1, pp. 1–7, Nov. 2021, doi: 10.47002/seminastika.v3i1.237.
- [15] Y. A. Lesnussa, C. G. Mustamu, F. Kondo Lembang, and M. W. Talakua, "APPLICATION OF BACKPROPAGATION NEURAL NETWORKS IN PREDICTING RAINFALL DATA IN AMBON CITY," *International Journal of Artificial Intelligence Research*, vol. 2, no. 2, Aug. 2018, doi: 10.29099/ijair.v2i2.59.
- [16] K. nonik Afsari dewi, S. Bahri, and I. Irwansyah, "MODEL PREDIKSI CURAH HUJAN HARIAN MENGGUNAKAN JARINGAN SYARAF TIRUAN BACKPROPAGATION," *Indonesian Physical Review*, p. 9, Jan. 2019, doi: 10.29303/ipr.v2i1.17.
- [17] I. Intan, R. Rismayani, St. A. D. Ghani, N. Nurdin, and A. T. C. Koswara, "Performance Analysis of Weather Forecasting using Machine Learning Algorithms (Analisis Performansi Prakiraan Cuaca Menggunakan Algoritma Machine Learning)," *Jurnal Pekommas*, vol. 6, no. 2, pp. 1–8, Oct. 2021, doi: 10.30818/jpkm.2021.2060221.
- [18] Dios Kurniawan, *Pengenalan machine learning dengan python*. Jakarta: Elex Media Komputindo, 2021.
- [19] Suyanto, *Soft Computing Membangun Mesin Ber-IQ Tinggi*. Bandung: Penerbit Informatika, 2008.
- [20] S. Sharma, S. Sharma, and A. Athaiya, "ACTIVATION FUNCTIONS IN NEURAL NETWORKS," *International Journal of Engineering Applied Sciences and Technology*, vol. 04, no. 12, pp. 310–316, May 2020, doi: 10.33564/IJEAST.2020.v04i12.054.