

BAB IV

HASIL DAN PEMBAHASAN

4.1. Statistik Deskriptif

Statistik Deskriptif dilakukan untuk melihat analisis statistik dan analisis deskriptif dari data yang didapatkan. Analisis ini dilakukan untuk mengkaji data dan mengambil langkah selanjutnya dalam penelitian ini.

4.1.1. Analisis Statistik

```
<class 'pandas.core.frame.DataFrame'>
Index: 43812 entries, 1/1/2018 0:00 to 31/12/2022 23:00
Data columns (total 8 columns):
#   Column          Non-Null Count  Dtype
---  -
0   Suhu             43812 non-null  float64
1   Tekanan         43812 non-null  float64
2   Kelembaban     43812 non-null  int64
3   Angin           43812 non-null  float64
4   Awan            43812 non-null  float64
5   Visibility      43812 non-null  int64
6   Cuaca          43812 non-null  int64
```

Gambar 4.1 Tipe Data

Tipe data yang digunakan pada penelitian ini dapat dilihat dari gambar 4.1. Berdasarkan gambar 1, data yang digunakan pada penelitian ini terdiri dari 8 kolom, dengan setiap kolomnya terdiri dari 43.812 entri. Data yang digunakan selama 5 tahun dari tgl 1 Januari 2018 jam 00.00 UTC hingga 31 Desember 2022 jam 23.00 UTC. Tipe data float dilihat pada unsur suhu udara, tekanan, angin, dan awan. Sedangkan tipe data integer dapat dilihat pada unsur kelembaban, *visibilty* (jarak pandang), dan cuaca. Data dari setiap unsur tersebut tidak ada yang bernilai null.

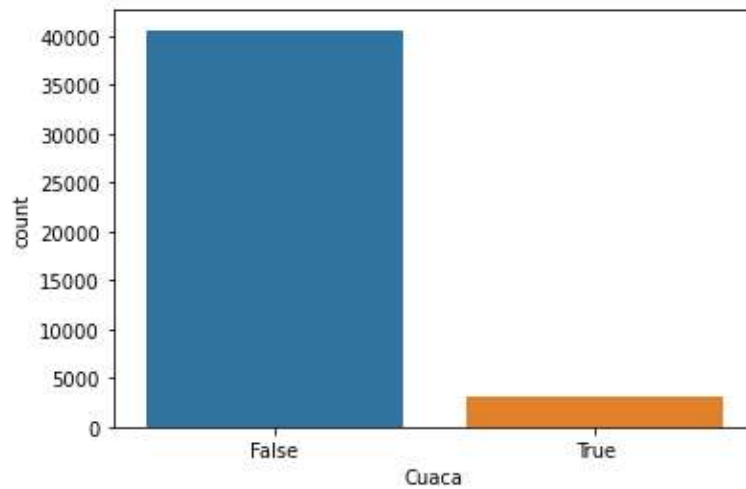
	Suhu	Tekanan	Kelembaban	Angin	Awan	Visibility	Cuaca
count	43812.000000	43812.000000	43812.000000	43812.000000	43812.000000	43812.000000	43812.000000
mean	27.149712	1010.161599	79.060645	3.084527	2117.746280	8299.221674	0.091048
std	2.940024	1.825698	13.410545	3.185257	2011.611158	2400.229305	0.361579
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 4.2 Statistik Deskriptif

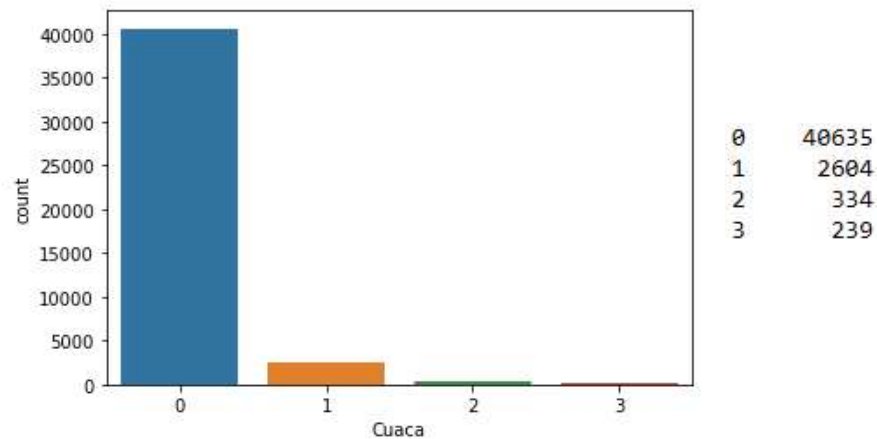
Statistik deskriptif digunakan untuk melihat sebaran, rata-rata, nilai min, max, dan quartil dari setiap unsur pada data. Dapat dilihat pada gambar 4.2, unsur dengan nilai deviasi terkecil adalah tekanan dan yang terbesar adalah jarak pandang. Unsur suhu udara, tekanan, kelembaban, dan angin, memiliki 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. Pada unsur cuaca baik nilai quartil ketiga atau rata-rata memiliki nilai 0 atau mendekati 0 (0.09), yang menandakan bahwa parameter cuaca terbanyak adalah kejadian tak hujan.

4.1.2. Analisis Deskriptif

Untuk memprediksi terjadinya hujan dengan menggunakan *Artificial Neural Network*, maka diperlukan mengetahui jumlah hujan yang terjadi, selama rentang penelitian dilakukan. Untuk itu digunakan gambar 4.3, grafik kejadian hujan atau tidak dari data pengamatan. Dapat dilihat pada gambar, jumlah hujan yang terjadi yaitu 3.177 jam pengamatan, sedangkan jam pengamatan yang tidak terjadi hujan berjumlah 40.635 jam. Berarti jumlah jam terjadinya hujan dibandingkan dengan tidak terjadi hujan adalah 7.4%.




Gambar 4. 4. Grafik Kejadian Hujan atau Tidak



Gambar 4.3 Grafik Kejadian Tidak Hujan, Hujan Ringan, Hujan Sedang, dan Hujan Lebat

Pembagian katagori hujan berdasarkan intensitasnya dapat dilihat pada gambar 4.4. Berdasarkan gambar 4.4, 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 4.5 Grafik Heatmap Korelasi dari Setiap Unsur

Untuk mengetahui hubungan setiap unsur dengan unsur lainnya, maka digunakan grafik heatmap korelasi yang dapat dilihat pada gambar 4.5. Berdasarkan gambar 4.5, 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.

4.2. Preprocessing

Proses preprocessing dilakukan sebelum proses penyiapan data, sebelum dilakukan proses penjalanan atau *fitting* pada model. Proses yang pertama dilakukan adalah pembagian data menjadi data latih (*train*) dan data uji (*test*). Hal ini dilakukan agar

model yang dibangun menggunakan data latih, tidak pernah melihat data uji. Sehingga menghilangkan bias pada model, saat dilakukan pengujian oleh data uji. Pembagian data uji dan data model terdiri dari 80% data latih dan 20% data uji, seperti yang terlihat pada gambar 4.6.

```

1 from sklearn.model_selection import train_test_split
2 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.2, random_state = 0)

```

1 X_train

Waktu	Suhu-3	Suhu-2	Suhu-1	Suhu	Tekanan-3	Tekanan-2	Tekanan-1	Tekanan	Kelembaban-3	Kelembaban-2	...	Awan-1	Awan	Visibility-3	Visibility-2	Visibility-1
15/06/2021 01:00	25.0	24.9	25.2	26.4	1009.5	1010.0	1010.2	1010.8	93	92	...	1400.0	1500.0	6000	6000	6000
27/12/2021 00:00	24.4	24.2	24.1	24.4	1011.7	1012.6	1012.5	1013.5	95	97	...	1400.0	1000.0	6000	6000	6000
18/01/2021 00:00	24.7	24.7	24.6	24.0	1009.4	1009.8	1010.7	1011.2	94	94	...	800.0	1000.0	6000	7000	7000
22/08/2022 03:00	23.2	23.8	24.9	27.2	1009.7	1010.5	1011.0	1011.5	97	96	...	1400.0	1000.0	3000	8000	10000
10/08/2020 11:00	31.8	31.1	30.8	30.0	1008.9	1008.8	1008.9	1009.6	64	64	...	1500.0	1500.0	10000	10000	10000
...
21/06/2021 07:00	29.4	30.4	31.4	31.8	1012.1	1011.7	1010.9	1009.7	67	64	...	1400.0	1400.0	10000	10000	10000
04/06/2020 15:00	25.5	25.1	24.7	24.4	1010.4	1011.5	1012.1	1012.4	93	94	...	1400.0	1400.0	8000	7000	7000
12/11/2022 01:00	25.2	25.1	25.6	27.0	1007.3	1007.7	1009.1	1009.5	81	82	...	1400.0	1500.0	10000	10000	10000
21/12/2022 19:00	25.6	25.5	25.5	25.0	1007.9	1007.4	1006.8	1006.3	91	92	...	1400.0	1400.0	7000	4000	4000
24/04/2018 20:00	24.6	24.6	24.2	24.2	1011.2	1010.4	1010.0	1009.7	92	92	...	1500.0	1500.0	10000	10000	10000

35049 rows x 28 columns

Gambar 4.6 Pembagian data latih dan data uji

Proses selanjutnya adalah standarisasi data, dilakukan agar pada saat proses perjalanan atau *fitting* model, menjadi lebih efektif, karena nilai dari data yang digunakan tidak terlalu besar. Pada penelitian ini, hanya data X atau input yang dilakukan proses standarisasi, karena nilainya yang besar dan bervariasi, sedangkan label data atau y tidak dilakukan proses standarisasi, karena nilainya yang kecil, yaitu 0,1,2,atau 3. Hasil dari proses standarisasi data dapat dilihat pada gambar 4.7.

```

1 from sklearn.preprocessing import StandardScaler
2 sc = StandardScaler()
3 X_train = sc.fit_transform(X_train)
4 X_test = sc.transform(X_test)

```

```

1 X_train
array([[ -0.65046218, -0.64476888, -0.55998233, ..., -0.2512989 ,
        -0.25077162, -0.24958381],
       [ -0.83105781, -0.84402616, -0.87322163, ..., -0.2512989 ,
        -0.25077162, -0.24958381],
       [ -0.74076    , -0.70169953, -0.73084013, ..., -0.2512989 ,
        -0.25077162, -0.24958381],
       ...,
       [ -0.59026364, -0.58783823, -0.44607713, ..., -0.2512989 ,
        -0.25077162, -0.24958381],
       [ -0.46986656, -0.47397693, -0.47455343, ..., -0.2512989 ,
        -0.25077162, -0.24958381],
       [ -0.77085927, -0.73016486, -0.84474533, ..., -0.2512989 ,
        -0.25077162, -0.24958381]])

```

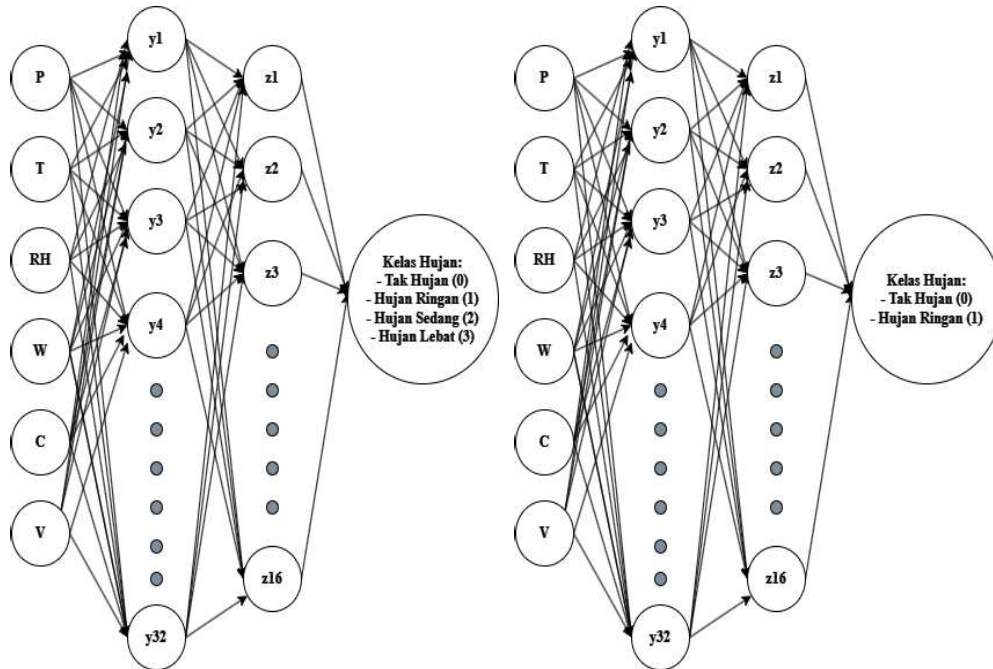
Gambar 4.7 Proses standarisasi data

4.3. Pengaturan Model

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 4.8, baik 4.8.a ataupun 4.8.b 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*.



Gambar 4.8 Pengaturan model pada klasifikasi hujan berbeda (kiri) dan pengaturan model pada satu klasifikasi hujan (kanan)

Pada gambar 4.8.a tahap pertama yang dilakukan adalah penetapan nilai `max_value` dari fungsi aktivasi relu dengan nilai 3, karena pada proses penjalanan 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.


Berbeda dengan model dengan klasifikasi hujan yang berbeda, pada model dengan satu klasifikasi hujan seperti pada gambar 4.8.b, 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.

4.4. Prakiraan Terkini (*Nowcasting*)

Prakiraan terkini (*nowcasting*), dilakukan untuk memprakirakan cuaca tiga jam ke depan. Sehingga data diubah jadi per tiga jam dimulai dari jam pengamatan 00, 03, 06, 09, 12, 15, 18, dan 21.

4.4.1. Prakiraan Hujan Terklasifikasi

Grafik akurasi hasil prakiraan hujan ditampilkan pada gambar 4.9. Pada gambar 4.9, ditunjukkan nilai akurasi tidak meningkat berdasarkan jumlah epochnya. Nilai akurasi justru berubah-ubah, naik turun pada jumlah epoch yang bertambah. Nilai akurasi tertinggi justru terjadi pada jumlah epoch 5 dan epoch 30 dengan nilai akurasi 0.86, sedangkan nilai epoch terendah terjadi pada epoch 50 dengan akurasi 0.8.



Gambar 4.9 Grafik akurasi pada epoch berbeda-beda

Untuk melihat seberapa baik model prakiraan, tidak bisa hanya menggunakan akurasi, maka digunakan matrik konfusi yang ditampilkan pada gambar 4.10. Pada gambar 4.10.a, dengan nilai akurasi yang cukup besar, tetapi epoch 5 bukan model yang baik, karena dengan epoch 5 tidak dapat memprakirakan saat kejadian hujan lebat.

<div style="border: 1px solid black; display: inline-block; padding: 2px;">a</div>	$\begin{bmatrix} 2311 & 186 & 0 & 0 \\ 158 & 179 & 0 & 0 \\ 21 & 14 & 11 & 0 \\ 14 & 12 & 15 & 0 \end{bmatrix}$	<div style="border: 1px solid black; display: inline-block; padding: 2px;">b</div>	$\begin{bmatrix} 2212 & 285 & 0 & 0 \\ 137 & 174 & 26 & 0 \\ 17 & 13 & 9 & 7 \\ 10 & 11 & 8 & 12 \end{bmatrix}$
<div style="border: 1px solid black; display: inline-block; padding: 2px;">c</div>	$\begin{bmatrix} 2326 & 171 & 0 & 0 \\ 156 & 179 & 5 & 0 \\ 16 & 15 & 15 & 0 \\ 9 & 14 & 14 & 4 \end{bmatrix}$	<div style="border: 1px solid black; display: inline-block; padding: 2px;">d</div>	$\begin{bmatrix} 2253 & 244 & 0 & 0 \\ 136 & 80 & 112 & 9 \\ 16 & 13 & 5 & 12 \\ 7 & 13 & 11 & 10 \end{bmatrix}$
<div style="border: 1px solid black; display: inline-block; padding: 2px;">e</div>	$\begin{bmatrix} 2362 & 135 & 0 & 0 \\ 156 & 56 & 122 & 3 \\ 21 & 7 & 10 & 8 \\ 16 & 4 & 18 & 3 \end{bmatrix}$		

Gambar 4.10 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100


Pada gambar 4.10.d dan 4.10.e, terlihat terdapat kesalahan yang cukup besar dalam memprakirakan hujan ringan sebagai hujan sedang. Matriks konfusi menunjukkan model terbaik pada epoch 10 (gambar 4.10.b) dan pada epoch 30 (gambar 10.c). Pada epoch 10, meskipun nilai akurasinya tidak sebesar epoch 5 dan epoch 30, tetapi matriks konfusinya justru menunjukkan hasil prakiraan yang cukup baik.

Untuk melihat lebih detil performa dari model, maka digunakan presisi, recall, dan f-1 scorenya. Berdasarkan gambar 4.11, epoch 10 memiliki performa prakiraan yang baik pada saat hujan lebat, sedangkan epoch 30 memiliki performa prakiraan yang baik pada saat terjadi hujan ringan dan hujan sedang. Secara umum, epoch 30 memiliki kemampuan yang lebih baik, karena jumlah prakiraan yang lebih sedikit *miss* (terlewat) dibandingkan dengan epoch 10.

a		precision	recall	f1-score	support
	0	0.93	0.89	0.91	2497
	1	0.36	0.52	0.42	337
	2	0.21	0.20	0.20	46
	3	0.63	0.29	0.40	41
	accuracy			0.82	2921
	macro avg	0.53	0.47	0.48	2921
	weighted avg	0.85	0.82	0.83	2921
b		precision	recall	f1-score	support
	0	0.93	0.93	0.93	2497
	1	0.47	0.53	0.50	337
	2	0.44	0.33	0.38	46
	3	1.00	0.10	0.18	41
	accuracy			0.86	2921
	macro avg	0.71	0.47	0.50	2921
	weighted avg	0.87	0.86	0.86	2921

Gambar 4.11 Hasil performa model pada a) epoch 10 dan b) epoch 30

4.4.2. Prakiraan Hujan Tanpa Klasifikasi



Gambar 4.12 Grafik akurasi pada epoch berbeda-beda

Nilai akurasi dari prakiraan kejadian hujan atau tidak ditampilkan dengan grafik pada gambar 4.12. Berdasarkan gambar 12, nilai akurasi terus meningkat bersamaan dengan jumlah epochnya. Nilai akurasi terendah dimulai pada epoch 5 dengan akurasi 0.73 dan terus meningkat hingga nilai akurasi tertinggi 0.89 pada jumlah epoch 100.

a	[[1835 662] [131 293]]	b	[[2494 3] [414 10]]	c	[[2496 1] [403 21]]
d	[[2284 213] [197 227]]	e	[[2375 122] [207 217]]		

Gambar 4.13 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Matriks konfusi dari prakiraan terjadinya hujan dapat dilihat pada gambar 4.13. Dapat dilihat pada gambar 4.13, meskipun akurasinya cukup tinggi pada epoch 10 dan epoch 30 (gambar 4.13.b dan 4.13.c), tetapi dari matriks konfusinya menggambarkan bahwa model tidak dapat memprakirakan terjadinya hujan. Pada jumlah epoch 50 dan epoch 100 (gambar 4.13.d dan 4.13.e), model baru dapat memprakirakan terjadinya hujan.

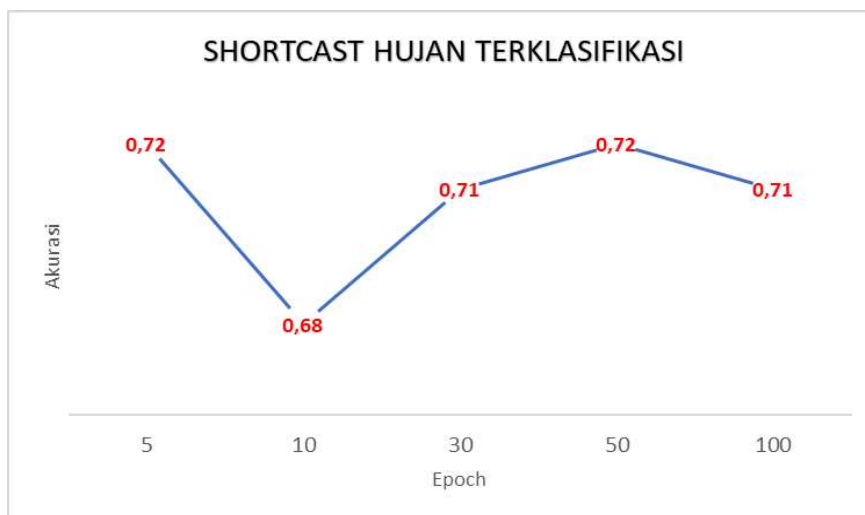
a		precision	recall	f1-score	support
	0	0.92	0.91	0.92	2497
	1	0.52	0.54	0.53	424
	accuracy			0.86	2921
	macro avg	0.72	0.73	0.72	2921
	weighted avg	0.86	0.86	0.86	2921
b		precision	recall	f1-score	support
	0	0.92	0.95	0.94	2497
	1	0.64	0.51	0.57	424
	accuracy			0.89	2921
	macro avg	0.78	0.73	0.75	2921
	weighted avg	0.88	0.89	0.89	2921

Gambar 4.14 Hasil performa model pada a) epoch 50 dan b) epoch 100

Untuk lebih detailnya ditampilkan pada hasil uji performa model yang ditampilkan pada gambar 4.14. Berdasarkan gambar 4.14 dapat dilihat epoch 100 lebih baik dari epoch 50, karena nilai presisinya lebih jauh lebih tinggi meskipun recallnya sedikit lebih rendah. Selain itu, epoch 100 juga memiliki nilai f-1 score yang lebih tinggi saat terjadinya hujan. Secara keseluruhan model ANN dengan jumlah epoch 100 jauh lebih baik, karena jumlah hujan yang tidak dapat diprediksi atau *miss* (terlewat) lebih sedikit dibandingkan epoch 50, dengan perbandingan 122 pada epoch 100 dan 213 pada epoch 50.

4.5. Prakiraan Jangka Pendek (Shortcasting)

4.5.1. Prakiraan Hujan Terklasifikasi



Gambar 4.15 Grafik akurasi pada epoch berbeda-beda

Tingkat akurasi pada prakiraan jangka pendek (*shortcasting*) dengan epoch yang berbeda-beda ditampilkan pada gambar 4.15. Pada awalnya dengan epoch 5, akurasi prakiraan cukup tinggi dengan akurasi 0.72, lalu pada epoch 10, turun menjadi 0.68, dan mulai naik kembali pada epoch 30 dengan akurasi 0.71 hingga epoch 50 dengan nilai akurasi 0.72. Akurasi kembali menurun pada epoch 100 dengan nilai akurasi 0.71.

a	[[933	221	0	0]	b	[[867	287	0	0]
	[111	121	2	0]		[101	127	6	0]
	[16	18	1	0]		[13	20	2	0]
	[15	23	0	0]]		[12	26	0	0]]
c	[[906	248	0	0]	d	[[908	246	0	0]
	[102	128	4	0]		[91	137	6	0]
	[12	20	3	0]		[13	20	2	0]
	[7	31	0	0]]		[9	29	0	0]]
e	[[898	256	0	0]					
	[92	142	0	0]					
	[11	24	0	0]					
	[9	29	0	0]]					

Gambar 4.16 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Untuk melihat apakah terjadi *overfitting*, selain menggunakan grafik akurasi terhadap epoch, maka juga dilihat matriks konfusinya pada nilai epoch yang berbeda seperti pada gambar 4.16. Berdasarkan gambar 4.16, meskipun pada epoch 5, akurasi cukup tinggi, tetapi tidak masih terdapat prakiraan hujan yang terlewat (*miss*), dengan 111 kejadian hujan ringan yang diprakirakan sebagai berawan pada gambar 4.16.a. Lalu jumlah prakiraan hujan ringan yang tepat makin lambat makin naik hingga epoch 100, tetapi pada epoch 100 (gambar 4.16.b), tidak dapat memprakirakan terjadinya hujan sedang. Pada epoch 30 (gambar 4.16.c) dan epoch 50 (gambar 4.16.d) menjadi epoch terbaik pada model ini untuk memprakirakan terjadinya hujan.

Hasil uji performa model yang lebih detil mengenai akurasi, presisi, recall, dan f1-score dari performa model ditampilkan pada gambar 4.17. Berdasarkan gambar 4.17, performa model untuk memprakirakan hujan pada kedua epoch yang berbeda, tidak memiliki perbedaan yang signifikan. Pada epoch 30 (gambar 4.17.a), meskipun dapat memprakirakan hujan sedang lebih baik dengan nilai presisi dan recall yang lebih besar, tetapi prakiraan hujan ringannya lebih buruk dibandingkan epoch 50 yang nilai presisi dan recallnya lebih kecil. Oleh karena dampak yang

disebabkan oleh terjadinya hujan sedang lebih besar dibandingkan hujan ringan, maka epoch 30 dengan nilai presisi 0.30 dan recall 0.55 saat hujan ringan, serta nilai presisi 0.43 dan recall 0.09 saat hujan sedang, yang dinyatakan terbaik yang dapat digunakan pada model ini.

a		precision	recall	f1-score	support
	0	0.88	0.79	0.83	1154
	1	0.30	0.55	0.39	234
	2	0.43	0.09	0.14	35
	3	0.00	0.00	0.00	38
	accuracy			0.71	1461
	macro avg	0.40	0.35	0.34	1461
	weighted avg	0.76	0.71	0.72	1461
b		precision	recall	f1-score	support
	0	0.89	0.79	0.83	1154
	1	0.32	0.59	0.41	234
	2	0.25	0.06	0.09	35
	3	0.00	0.00	0.00	38
	accuracy			0.72	1461
	macro avg	0.36	0.36	0.33	1461
	weighted avg	0.76	0.72	0.73	1461

Gambar 4.17 Hasil performa model pada a) epoch 30 dan b) epoch 50

4.5.2. Prakiraan Hujan Tanpa Klasifikasi

Tingkat akurasi pada prakiraan jangka pendek untuk hujan tanpa klasifikasi ditampilkan pada gambar 4.18. Berdasarkan gambar 4.18, akurasi terus meningkat bersamaan dengan meningkatnya jumlah epoch. Akurasi terendah yaitu 0.68 pada jumlah epoch 5 dan terus meningkat hingga akurasi tertingginya 0.74 pada jumlah epoch 100.



Gambar 4.18 Grafik akurasi pada epoch berbeda-beda

Matriks konfusi pada epoch yang berbeda-beda dapat untuk prakiraan jangka pendek dapat dilihat pada gambar 4.19. Berdasarkan gambar 4.19.a, epoch 5, meskipun memiliki nilai akurasi yang lebih rendah, tetapi epoch 5, dapat memprakirakan hujan lebih banyak dibandingkan epoch lainnya, meskipun sering salah memprakirakan berawan sebagai hujan. Pada gambar 4.19.e, dengan epoch 100, meskipun hujan yang diprakirakan tidak sebanyak, dengan epoch 5, tetapi kesalahan prakirakaan hujann lebih sedikit.

a	[[834 320] [141 166]]	b	[[888 266] [180 127]]	c	[[896 258] [187 120]]
d	[[894 260] [166 141]]	e	[[942 212] [161 146]]		

Gambar 4.19 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Untuk lebih jelas maka akan ditampilkan uji performa model pada gambar 4.20 yang menampilkan uji performa model pada epoch 50 dan epoch 100. Dari gambar 4.20.a dan 4.20.b, dapat dilihat bahwa pada epoch 100, hasil uji perfoma model menunjukkan hasil terbaiknya, dimana nilai presisi, recall, dan f-1 scorenya lebih

tinggi dibandingkan pada epoch 50. Untuk itu dapat disimpulkan untuk prakiraan cuaca jangka pendek (*shortcasing*) hujan tanpa klasifikasi, maka epoch 100, paling baik untuk digunakan.


a		precision	recall	f1-score	support
	0	0.84	0.77	0.81	1154
	1	0.35	0.46	0.40	307
	accuracy			0.71	1461
	macro avg	0.60	0.62	0.60	1461
	weighted avg	0.74	0.71	0.72	1461
b		precision	recall	f1-score	support
	0	0.85	0.82	0.83	1154
	1	0.41	0.48	0.44	307
	accuracy			0.74	1461
	macro avg	0.63	0.65	0.64	1461
	weighted avg	0.76	0.74	0.75	1461

Gambar 4.20 Hasil performa model pada a) epoch 50 dan b) epoch 100

4.6. Prakiraan Cuaca 12 Jam (*Forecasting*)

4.6.1. Prakiraan Hujan Terklasifikasi

Nilai akurasi ANN untuk memprakirakan hujan dalam rentang 6-12 jam ke depan dapat dilihat pada gambar 4.21. Berdasarkan gambar 21, akurasi terus meningkat dari hanya 0.52 pada epoch 5 hingga akurasi tertinggi pada jumlah epoch 30 dengan nilai 0.6. Selanjutnya akurasi terus menurun bersamaan dengan meningkatnya jumlah epoch hingga mencapai 0.53 pada jumlah epoch 100. Turunnya tingkat akurasi, meskipun jumlah epochnya meningkat, menandakan bahwa terdapat adanya *overfitting*.



Gambar 4.21 Grafik akurasi pada epoch berbeda-beda

<p>a [[296 253 0 0]</p> <p> [45 84 0 0]</p> <p> [9 20 0 0]</p> <p> [2 22 0 0]]</p>	<p>b [[305 244 0 0]</p> <p> [31 98 0 0]</p> <p> [7 22 0 0]</p> <p> [5 19 0 0]]</p>
<p>c [[346 200 3 0]</p> <p> [36 91 2 0]</p> <p> [8 19 2 0]</p> <p> [6 18 0 0]]</p>	<p>d [[350 199 0 0]</p> <p> [59 70 0 0]</p> <p> [12 17 0 0]</p> <p> [5 19 0 0]]</p>
<p>e [[328 218 3 0]</p> <p> [64 62 3 0]</p> <p> [13 16 0 0]</p> <p> [9 15 0 0]]</p>	

Gambar 4.22 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Untuk melihat lebih jelas pengaruh epoch terhadap performa model memprakirakan hujan, ditampilkan matriks konfusi pada gambar 4.22. Berdasarkan gambar 4.22.a-e, pada prakiraan 6-12 jam, tidak dapat memprakirakan hujan dengan intensitas lebat, sedangkan untuk intensitas sedang hanya bisa diprakirakan dengan menggunakan epoch 30 (gambar 4.22.c). Prakiraan kejadian hujan ringan terbanyak dengan jumlah 98 kejadian dapat dilakukan dengan menggunakan ANN pada epoch berjumlah 10 (gambar 4.22.b).

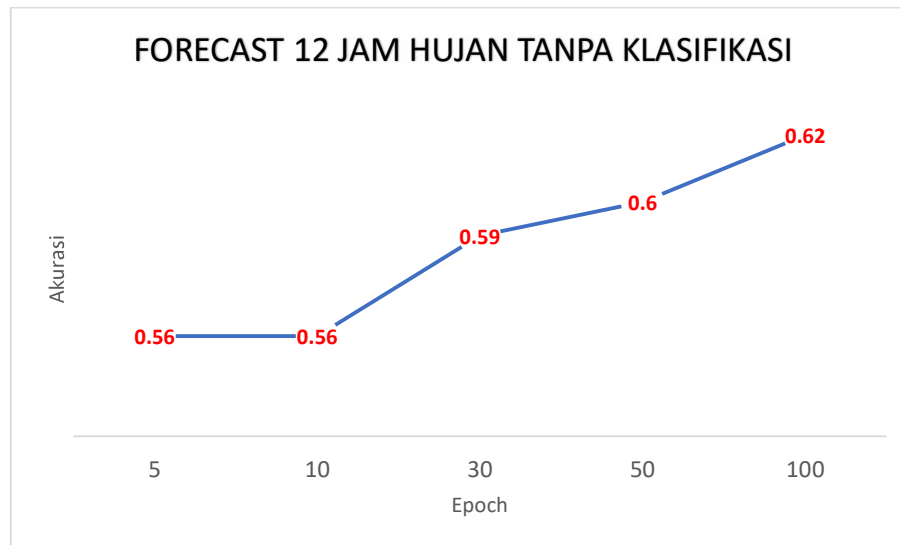
Uji performa model ANN yang lebih detil dengan menampilkan presisi, recall, dan f-1 score dapat dilihat pada gambar 4.23. Berdasarkan gambar 4.23, dapat dilihat akurasi pada epoch 30 dengan nilai 0.60 lebih tinggi dibandingkan pada epoch 10 dengan nilai 0.55, tetapi recall epoch 10 dengan nilai 0.76 lebih tinggi dibandingkan epoch 30 dengan nilai 0.71 saat terjadi hujan ringan. Epoch 30 memiliki hasil uji performa yang lebih baik, karena epoch 30 dapat memprakirakan hujan sedang dengan nilai recall 0.07, sedangkan epoch 10 tidak bisa.

a	precision	recall	f1-score	support
0	0.88	0.56	0.68	549
1	0.26	0.76	0.38	129
2	0.00	0.00	0.00	29
3	0.00	0.00	0.00	24
accuracy			0.55	731
macro avg	0.28	0.33	0.27	731
weighted avg	0.70	0.55	0.58	731

b	precision	recall	f1-score	support
0	0.87	0.63	0.73	549
1	0.28	0.71	0.40	129
2	0.29	0.07	0.11	29
3	0.00	0.00	0.00	24
accuracy			0.60	731
macro avg	0.36	0.35	0.31	731
weighted avg	0.72	0.60	0.62	731

Gambar 4.23 Hasil performa model pada a) epoch 10 dan b) epoch 30

4.6.2. Prakiraan Hujan Tanpa Klasifikasi



Gambar 4.24 Grafik akurasi pada epoch berbeda-beda

Besaran akurasi berdasarkan epoch berbeda-beda untuk prakiraan hujan 12 jam ke depan tanpa klasifikasi ditampilkan pada gambar 4.24. Nilai akurasi dimulai dari 0.56 pada epoch 5 dan terus meningkat hingga 0.62 pada epoch 100. Berdasarkan gambar 4.24, dapat dilihat bahwa jumlah epoch 100 menjadi jumlah epoch terbaik, karena memiliki nilai akurasi paling tinggi, tetapi untuk melihat lebih detail performa dari model, maka akan dilihat matriks konfusi (gambar 4.25) dan uji performa model (gambar 4.26).

a	[[304 245] [73 109]]	b	[[328 221] [100 82]]	c	[[292 257] [40 142]]
d	[[318 231] [57 125]]	e	[[321 228] [51 131]]		

Gambar 4.25 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

Jumlah prakiraan yang benar dan salah dapat dilihat dengan matriks konfusi pada gambar 4.25. Berdasarkan gambar 4.25, jumlah hujan yang berhasil diprakirakan

berubah-ubah pada jumlah epoch yang berbeda-beda. Pada gambar 4.25.e, dengan epoch 100 yang memiliki akurasi yang paling tinggi dibandingkan yang lain, terdapat 131 jumlah hujan yang dapat diprediksi, tetapi terdapat 51 yang tidak dapat diprediksi dan 228 tidak hujan yang diprakirakan sebagai hujan. Jumlah prakiraan hujan terbanyak yang dapat diprakirakan terjadi pada epoch 30 (gambar 4.25.c), dengan jumlah hujan yang dapat diprakirakan berjumlah 142 kali, dengan 40 kali gagal, dan 257 salah prakiraan.

Hasil perbandingan yang lebih detil dapat dilihat pada uji performa model antara epoch 30 dan epoch 100 yang ditampilkan pada gambar 4.26. Berdasarkan gambar 4.26, meskipun epoch 100 memiliki nilai akurasi yang lebih besar, tetapi saat memprakirakan kejadian hujan, epoch 30, memiliki nilai presisi dan recall yang lebih rendah dibandingkan epoch 100, meskipun untuk recall tidak hujan nilai epoch 30 lebih rendah. Sehingga dapat disimpulkan bahwa epoch 30 merupakan epoch terbaik untuk memprakirakan terjadinya hujan atau tidak pada prakiraan 12 jam ke depan.


a		precision	recall	f1-score	support
	0	0.88	0.53	0.66	549
	1	0.36	0.78	0.49	182
	accuracy			0.59	731
	macro avg	0.62	0.66	0.58	731
	weighted avg	0.75	0.59	0.62	731
b		precision	recall	f1-score	support
	0	0.86	0.58	0.70	549
	1	0.36	0.72	0.48	182
	accuracy			0.62	731
	macro avg	0.61	0.65	0.59	731
	weighted avg	0.74	0.62	0.64	731

Gambar 4.26 Hasil performa model pada a) epoch 30 dan b) epoch 100

4.7. Prakiraan 24 Jam (*Forecasting*)

4.7.1. Prakiraan Hujan Dengan Klasifikasi

Untuk melihat akurasi prakiraan hujan 12-24 jam ke depan dengan klasifikasi, maka digambarkan akurasi prakiraan pada epoch yang berbeda-beda yang ditunjukkan pada gambar 4.27. Berdasarkan gambar 4.27, akurasi prakiraan awalnya cukup rendah pada epoch 5 dengan nilai akurasi 0.48. Secara perlahan-lahan nilai akurasi terus meningkat, peningkatan paling besar terjadi dari epoch 30 ke epoch 50, sebesar 0.04. Akurasi maksimum prakiraan terjadi pada epoch berjumlah 100, dengan nilai akurasi 0.54.



Gambar 4.27 Grafik akurasi pada epoch berbeda-beda

Untuk melihat lebih detail performa dari model, maka ditampilkan matriks konfusi pada gambar 4.28, untuk melihat berapa banyak prakiraan yang berhasil dan berapa banyak prakiraan yang gagal. Berdasarkan gambar 4.28, pada setiap nilai epoch, model ANN tidak dapat memprakirakan terjadinya hujan lebat, sedangkan untuk hujan sedang berhasil diprakirakan beberapa hujan yang diklasifikasikan sebagai hujan sedang pada epoch 10 (gambar 4.28.b) dan epoch 100 (gambar 4.28.e). Untuk hujan ringan terbanyak yang dapat diprakirakan oleh BPNN yaitu pada epoch 50

dengan jumlah kejadian hujan ringan yang dapat diperkirakan berjumlah 149 kejadian.

a	[[200	277	0	0]	b	[[209	244	24	0]
	[41	147	0	0]		[28	147	12	1]
	[9	27	0	0]		[7	24	4	1]
	[5	24	0	0]]		[8	15	6	0]]
c	[[223	253	1	0]	d	[[237	239	1	0]
	[51	137	0	0]		[39	149	0	0]
	[13	23	0	0]		[7	29	0	0]
	[8	21	0	0]]		[6	23	0	0]]
e	[[261	210	5	1]					
	[55	127	6	0]					
	[10	23	3	0]					
	[6	22	1	0]]					

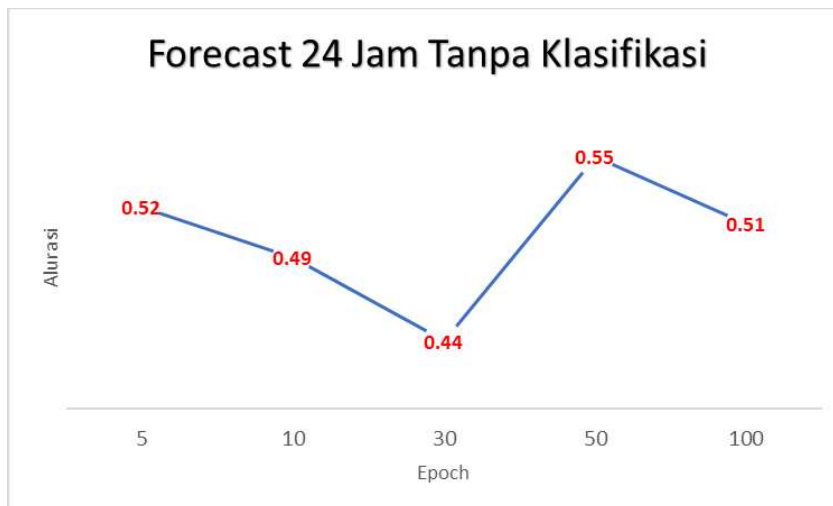
Gambar 4.28 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

a		precision	recall	f1-score	support
	0	0.83	0.44	0.57	477
	1	0.34	0.78	0.48	188
	2	0.09	0.11	0.10	36
	3	0.00	0.00	0.00	29
	accuracy			0.49	730
	macro avg	0.31	0.33	0.29	730
	weighted avg	0.63	0.49	0.50	730
b		precision	recall	f1-score	support
	0	0.79	0.55	0.65	477
	1	0.33	0.68	0.45	188
	2	0.20	0.08	0.12	36
	3	0.00	0.00	0.00	29
	accuracy			0.54	730
	macro avg	0.33	0.33	0.30	730
	weighted avg	0.61	0.54	0.54	730

Gambar 4.29 Hasil performa model pada a) epoch 10 dan b) epoch 100

Selain menggunakan akurasi dan matriks konfusi, digunakan uji performa model untuk mencari jumlah epoch terbaik dalam memprakirakan hujan. Berdasarkan gambar 4.29a, pada epoch 10, nilai akurasi yang rendah ditunjukkan dengan presisi dan recall yang lebih rendah saat tidak terjadi hujan, meskipun nilai presisi. Sedangkan pada gambar 4.29.b (epoch 100), nilai akurasi lebih tinggi, tetapi nilai presisi dan recall saat terjadi hujan ringan dan hujan sedang bernilai lebih rendah dibandingkan dengan epoch 10. Untuk itu, epoch 10, dinyatakan sebagai epoch terbaik untuk memprakirakan hujan 24 jam dengan klasifikasi, karena dapat memprakirakan hujan ringan dan hujan sedang yang lebih baik dibandingkan epoch lainnya.

4.7.2. Prakiraan Hujan Tanpa Klasifikasi



Gambar 4.30 Grafik akurasi pada epoch berbeda-beda

Grafik akurasi prakiraan dengan epoch yang berbeda-beda untuk memprakirakan hujan 24 jam ke depan tanpa klasifikasi ditunjukkan pada gambar 4.30. Berdasarkan gambar 4.30, 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.

a	[[265 212] [137 116]]	b	[[265 212] [157 96]]	c	[[198 279] [128 125]]
d	[[255 222] [104 149]]	e	[[250 227] [131 122]]		

**Gambar 4.31 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30,
d)epoch 50, dan e)epoch 100**

Matriks konfusi pada gambar 4.31, akan menunjukkan seberapa banyak hujan 24 jam kemudian yang berhasil diprakirakan. Berdasarkan gambar 4.31, jumlah prakiraan hujan yang berhasil atau tidak diprakiraan berubah-ubah pada epoch yang berbeda-beda. Pada gambar 4.31.b, prakiraan hujan paling sedikit dengan 96 kejadian terjadi pada epoch 10. Jumlah prakiraan terbanyak dengan 149 kejadian terjadi pada epoch 50 (gambar 4.31.d).


Hasil uji performa model prakiraan hujan 24 jam ke depan akan menampilkan presisi, recall, dan f1-score dapat dilihat pada gambar 4.32. Berdasarkan gambar 4.32, pada epoch 50 (gambar 4.32.a), bukan hanya nilai akurasinya yang lebih tinggi, tetapi juga presisi, recall, dan f1-score dibandingkan epoch 100 (gambar 4.32.b), baik untuk prakiraan hujan ataupun tidak hujan. Presisi dan recall untuk memprakiraan 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	0.62	0.66	0.58	730
	weighted avg	0.75	0.59	0.62	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 4.32 Hasil performa model pada a) epoch 30 dan b) epoch 100

4.8. Prakiraan 1 Hari Ke Depan (*Forecasting*)

4.8.1. Prakiraan Hujan Dengan Klasifikasi



Gambar 4.33 Grafik akurasi pada epoch berbeda-beda

Grafik tingkat akurasi berbanding dengan epoch untuk prakiraan cuaca 1 hari ke depan ditampilkan pada gambar 4.33. Berdasarkan gambar 4.33, 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.

Untuk melihat seberapa banyak prakiraan yang benar dan salah untuk prakiraan 1 hari ke depan, maka digunakan matriks konfusi pada gambar 4.34. Berdasarkan gambar 4.34, model BPNN menghasilkan prakiraan yang berbeda-beda pada epoch yang berbeda. Pada epoch 5 (gambar 4.34.a), BPNN tidak dapat memprakirakan hujan sedang dan hujan lebat. Pada epoch 10 (gambar 4.34.b) dan epoch 50 (gambar 4.34.d), BPNN tidak dapat memprakirakan hujan lebat, meskipun masih bisa memprakirakan hujan sedang. Pada epoch 30 (gambar 4.34.c) dan epoch 100 (gambar 4.34.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]	b	[[91	230	5	0]
	[76	186	0	0]		[45	213	4	0]
	[16	53	0	0]		[14	52	3	0]
	[20	53	0	0]]		[10	61	2	0]]
c	[[127	164	22	13]	d	[[98	217	11	0]
	[47	178	27	10]		[41	212	9	0]
	[11	44	12	2]		[13	51	5	0]
	[9	47	15	2]]		[12	60	1	0]]
e	[[165	135	22	4]					
	[77	144	35	6]					
	[17	41	9	2]					
	[15	49	7	2]]					


Gambar 4.34 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

a		precision	recall	f1-score	support
	0	0.65	0.39	0.46	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 4.35 Hasil performa model pada a) epoch 30 dan b) epoch 100

Untuk melihat lebih detail kemampuan dari model BPNN, maka akan ditampilkan presisi, recall, dan f-1 score pada gambar 4.35. Berdasarkan gambar 4.35, 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.

4.8.2. Hujan Tanpa Klasifikasi



Gambar 4.36 Grafik akurasi pada epoch berbeda-beda

Grafik akurasi prakiraan hujan 1 hari ke depan dengan epoch yang berbeda-beda untuk hujan tanpa klasifikasi ditampilkan pada gambar 4.36. Berdasarkan gambar 36, akurasi antara epoch 5 sampai epoch 50, tidak memiliki perbedaan yang signifikan, hanya berkisar antara rendah 0.48 hingga 0.5. Nilai akurasi yang berbeda jauh sekaligus menjadi nilai akurasi maksimum terjadi pada saat epoch 100 dengan nilai akurasi 0.56.

Matriks konfusi pada gambar 4.37 digunakan untuk melihat seberapa banyak hujan yang dapat diprakirakan. Berdasarkan gambar 4.37, dapat dilihat bahwa prakiraan hujan terbanyak yang dapat diprakirakan yaitu 186 pada epoch 100 (gambar 4.37.e) dan 184 pada epoch 5 (gambar 4.37.a), sedangkan yang paling sedikit yaitu 147 pada epoch 30 (gambar 4.37.c). Sementara itu di antara epoch 100 menjadi epoch yang memiliki kesalahan prakiraan tidak hujan paling sedikit yaitu 104 kejadian, sedangkan yang paling banyak yaitu pada epoch 5 dengan 149 kejadian.

a	[[177 149] [220 184]]	b	[[184 142] [236 168]]	c	[[209 117] [257 147]]
d	[[211 115] [247 157]]	e	[[222 104] [218 186]]		

Gambar 4.37 Matriks konfusi pada a)epoch 5, b)epoch 10, c)epoch 30, d)epoch 50, dan e)epoch 100

a		precision	recall	f1-score	support
	0	0.45	0.54	0.49	326
	1	0.55	0.46	0.50	404
	accuracy			0.49	730
	macro avg	0.50	0.50	0.49	730
	weighted avg	0.50	0.49	0.49	730
b		precision	recall	f1-score	support
	0	0.50	0.68	0.58	326
	1	0.64	0.46	0.54	404
	accuracy			0.56	730
	macro avg	0.57	0.57	0.56	730
	weighted avg	0.58	0.56	0.56	730

Gambar 4.38 Hasil performa model pada a) epoch 30 dan b) epoch 100

Hasil uji performa model BPNN dapat dilihat pada gambar 4.38. Berdasarkan gambar 4.38, epoch 100 memiliki nilai presisi, recall, dan f-1 score yang lebih baik dibandingkan dengan epoch 30, baik dalam memprakirakan terjadinya hujan maupun tidak hujan. Dari nilai akurasi, matriks konfusi, dan uji performa, maka

dapat disimpulkan bahwa epoch 100 merupakan epoch terbaik untuk memprakirakan hujan 1 hari ke depan tanpa klasifikasi.

4.9. Perbandingan Dengan Metode Lain

Untuk melihat sebaik apa metode BPNN digunakan dalam memprakirakan hujan satu hari ke depan, maka dilakukan perbandingan dengan metode lainnya. Metode pembanding yang digunakan adalah *Support Vector Machine* (SVM) dan *Logistic Regression* (LR).

4.9.1. Perbandingan Dengan SVM

	precision	recall	f1-score	support				
0	0.63	0.61	0.62	353				
1	0.42	0.64	0.51	251				
2	0.00	0.00	0.00	60	[[217	136	0	0]
3	0.00	0.00	0.00	66	[90	161	0	0]
					[21	39	0	0]
accuracy			0.44	730	[17	49	0	0]]
macro avg	0.32	0.32	0.30	730				
weighted avg	0.46	0.44	0.42	730				

Gambar 4.39 Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode SVM pada hujan dengan klasifikasi

Hasil uji performa dan matriks konfusi untuk metode SVM ditampilkan pada gambar 4.39. Berdasarkan gambar 4.39, akurasi prakiraan cuaca dengan metode SVM lebih besar dengan nilai 0.52 dimana dengan metode BPNN hanya 0.44 (gambar 35.a). Jika dilihat lebih detil, nilai recall untuk prakiraan hujan ringan dengan metode SWM 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 4.39 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	0.65	0.66	0.65	377	[[217	136]
					[128	249]]
accuracy			0.49	730		
macro avg	0.50	0.50	0.49	730		
weighted avg	0.50	0.49	0.49	730		

Gambar 4.40 Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode SVM pada hujan tanpa klasifikasi

Hasil uji performa menggunakan metode SVM untuk memprakirakan hujan satu hari ke depan tanpa klasifikasi ditunjukkan pada gambar 4.40. Berdasarkan gambar 4.40, akurasi metode SVM mencapai 0.64 sedangkan akurasi metode BPNN hanya sekitar 0.56 (gambar 4.38). 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.

4.9.2. Perbandingan Dengan LR

Hasil pengujian metode *logistic regression* (LR) untuk prakiraan hujan dengan klasifikasi ditunjukkan pada gambar 4.41. Jika dibandingkan dengan metode BPNN (gambar 4.35), 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				
1	0.41	0.56	0.47	251				
2	0.00	0.00	0.00	60	[[231	122	0	0]
3	0.00	0.00	0.00	66	[110	140	0	1]
					[27	33	0	0]
accuracy			0.44	730	[19	47	0	0]]
macro avg	0.32	0.32	0.30	730				
weighted avg	0.46	0.44	0.42	730				

Gambar 4.41 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 4.42. Berdasarkan gambar 4.42, 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		

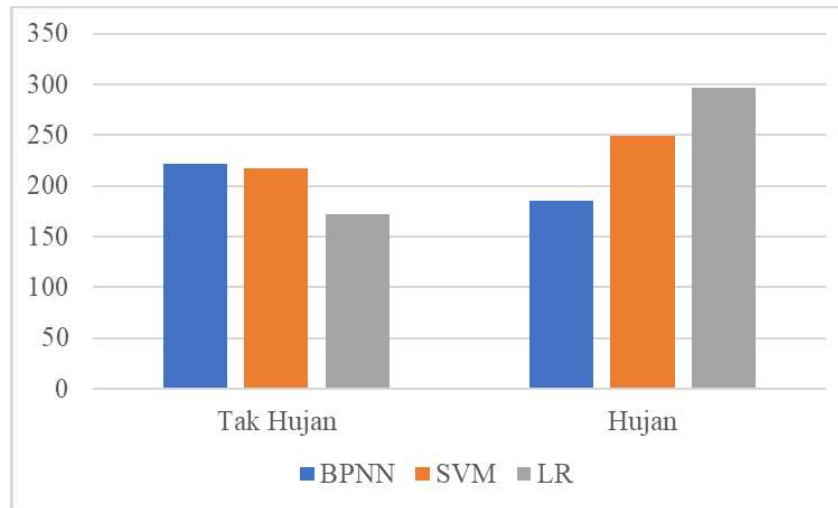
Gambar 4.42 Hasil uji performa (kiri) dan matrik konfusi (kanan) untuk metode LR pada hujan dengan klasifikasi

4.9.3. Pembahasan

Perbandingan performa untuk ketiga algoritma dapat dilihat pada gambar 4.43. Berdasarkan gambar 4.43, algoritma BPNN dapat memprakirakan hujan ringan lebih tinggi dibandingkan dua algoritma lainnya. Selain itu, BPNN juga dapat memprakirakan kejadian hujan sedang dan hujan lebat, sedangkan SVM dan LR tidak bisa. Kekurangan algoritma SVM dan LR untuk memprakirakan hujan sedang dan hujan lebat menunjukkan bahwa SVM dan LR hanya dapat digunakan untuk memprakirakan hasil output yang bernilai 0 atau 1. Ini ditunjukkan pada prakiraan hujan tanpa klasifikasi dengan menggunakan SVM dan LR gambar 4.44, LR memprakirakan lebih banyak kejadian hujan, yang disusul oleh SVM, sedangkan BPNN menjadi algoritma yang memprakirakan hujan paling sedikit.

Hal ini dapat terjadi karena algoritma SVM dan LR pada fungsi aktivasi akhirnya hanya bisa menggunakan fungsi aktivasi sigmoid, sedangkan fungsi aktivasi ini hanya dapat memprakirakan kejadian dengan dua kemungkinan yaitu 0 (tidak) dan 1 (ya). Berbeda dengan SVM dan LR, BPNN dapat dimodifikasi fungsi aktivasi akhirnya, seperti yang dilakukan pada penelitian ini pada BPNN untuk hujan dengan klasifikasi fungsi aktivasi akhir menggunakan ReLU advanced, bukan fungsi aktivasi Sigmoid. Fungsi aktivasi ReLU advanced adalah fungsi aktivasi ReLU yang telah dimodifikasi, sehingga nilai output akhirnya bernilai antara 0 – 3.





Gambar 4.44 Perbandingan prediksi hujan dengan berbagai algoritma untuk hujan tanpa klasifikasi