

BAB IV PENGUJIAN DAN ANALISA

4.1 Pengujian Variabel Cuaca pada Sensor Honde

Pengujian dilakukan dengan perbandingan nilai data cuaca yang dilakukan di siang, sore, dan pagi hari dengan membandingkan nilai yang terbaca oleh sensor Honde dengan alat ukur lain. Alat ukur yang digunakan adalah Smart Sensor Humidity AS847 dengan nilai akurasi temperature $\pm 1.5^{\circ}\text{C}$ dan kelembapan $\pm 5\% \text{RH}$ (5~40%) $\pm 3\%$ (41%~80%), serta Solar Power Meter SPM-1116SD dengan akurasi ± 10 .

Tabel 4. 1 Hasil Pengujian Perbandingan Nilai Temperatur Sensor Honde dan Alat Ukur

Pengujian	Sensor Honde ($^{\circ}\text{C}$)	Alat Ukur ($^{\circ}\text{C}$)	Selisih ($^{\circ}\text{C}$)	Error (%)
1	31.00	31.50	0.50	1.59
2	31.00	32.50	1.50	4.62
3	29.00	28.70	0.30	1.05
4	28.00	28.10	0.10	0.36
5	30.00	28.10	1.90	6.76
6	30.00	29.50	0.50	1.69
7	31.00	30.20	0.80	2.65
8	30.00	28.90	1.10	3.81
9	26.00	26.10	0.10	0.38
10	25.00	26.00	1.00	3.85

Berdasarkan Tabel 4.1, hasil pengujian menunjukkan bahwa sensor HONDE memiliki selisih pengukuran suhu terhadap alat ukur pembanding dengan rentang selisih antara $0,10^{\circ}\text{C}$ hingga $1,90^{\circ}\text{C}$. Rata-rata error yang diperoleh dari sepuluh kali pengujian adalah sebesar 2,68% menunjukkan bahwa sensor memiliki tingkat akurasi yang cukup baik. Perbedaan nilai yang terjadi dipengaruhi oleh faktor sensitivitas sensor, kondisi lingkungan, serta waktu respon alat. Meskipun demikian, sensor HONDE tetap mampu mengikuti pola perubahan suhu yang sejalan dengan alat ukur pembanding.

Tabel 4. 2 Hasil Pengujian Perbandingan Nilai Kelembapan Sensor Honde dan Alat Ukur

Pengujian	Sensor Honde (%)	Alat Ukur (%)	Selisih (%)	Error (%)
1	66.18	60.40	5.78	9.57
2	64.94	58.60	6.34	10.82
3	69.61	68.90	0.71	1.03
4	76.76	69.00	7.76	11.25
5	69.23	74.90	5.67	7.57
6	63.96	63.50	0.46	0.72
7	64.96	63.80	1.16	1.82
8	69.25	68.80	0.45	0.65
9	85.19	82.80	2.39	2.89
10	87.82	81.50	6.32	7.75

Berdasarkan Tabel 4.2, hasil yang diperoleh dari sepuluh kali pengujian menunjukkan bahwa sensor HONDE memiliki selisih pengukuran kelembapan terhadap alat ukur pembanding antara 0,45% hingga 7,76%. Rata-rata error yang diperoleh sebesar 5,01% data ini menunjukkan bahwa sensor memiliki tingkat akurasi yang cukup baik dalam mengukur kelembapan udara. Perbedaan nilai yang terjadi dipengaruhi oleh faktor sensitivitas sensor, kondisi lingkungan, serta waktu respon alat. Meskipun demikian, sensor HONDE tetap mampu mengikuti pola perubahan suhu yang sejalan dengan alat ukur pembanding.

Tabel 4. 3 Hasil Pengujian Perbandingan Nilai Iradiasi Sensor Honde dan Alat Ukur

Pengujian	Sensor Honde (W/m²)	Alat Ukur (W/m²)	Selisih (W/m²)	Error (%)
1	803.20	914	110.80	12.12
2	125.60	798	672.40	84.29
3	7.40	25	17.60	70.40
4	8.20	32	23.80	74.38
5	423.80	1000	576.20	57.62
6	716.30	1186	469.70	39.61
7	146.20	186	39.80	21.40

Pengujian	Sensor Honde (W/m²)	Alat Ukur (W/m²)	Selisih (W/m²)	Error (%)
8	14.60	54	39.40	72.96
9	44.90	101	56.10	55.54
10	4.40	12	7.60	63.33

Berdasarkan Tabel 4.3, hasil pengujian menunjukkan bahwa sensor HONDE memiliki selisih pengukuran iradiasi terhadap alat ukur pembanding dengan selisih minimal 7.60 W/m² dan selisih maksimal mencapai 672.40 W/m². Rata-rata error yang diperoleh sebesar 55%. Selisih pembacaan nilai iradiasi yang signifikan dan error yang besar terjadi karena perbedaan karakteristik pengukuran antara sensor HONDE dan alat ukur pembanding. Sensor HONDE mampu menerima radiasi dari berbagai arah, sedangkan alat ukur pembanding hanya optimal saat tegak lurus terhadap arah datangnya sinar matahari. Selain itu, faktor lingkungan seperti bayangan, awan, serta perbedaan waktu pembacaan juga turut mempengaruhi hasil pengukuran. Meskipun demikian, sensor HONDE tetap mampu mengikuti pola perubahan iradiasi secara umum.

Tabel 4. 4 Hasil Pengujian Perbandingan Nilai Curah Hujan Sensor Honde dan Alat Ukur

Pengujian	Sensor Honde (mm/h)	AWS Undip (mm/h)	Selisih (mm/h)	Error (%)
1	0.00	0	0	0
2	0.00	0	0	0
3	0.00	0	0	0
4	0.00	0	0	0
5	0.00	0	0	0
6	0.00	0	0	0
7	0.40	0.2	0.2	50
8	0.40	0.2	0.2	50
9	0.40	0.2	0.2	50
10	0.40	0.2	0.2	50

Berdasarkan Tabel 4.4, hasil perbandingan nilai curah hujan antara sensor HONDE dan data AWS Undip menunjukkan bahwa pada beberapa pengujian terdapat perbedaan nilai sebesar 0,2 mm antara kedua sumber data, yang menghasilkan nilai error hingga 50%. Rata-rata error yang diperoleh dari sepuluh kali pengujian adalah sebesar 20%. Hal ini dipengaruhi oleh karakteristik data curah hujan yang memiliki nilai sangat kecil. Dalam kondisi ini, selisih absolut yang kecil dapat menghasilkan nilai error persentase yang besar. Selain itu, perbedaan resolusi pengukuran dan interval pencatatan antara sensor HONDE dan AWS Undip juga turut mempengaruhi hasil perbandingan.

4.2 Pengujian Akuisisi Data Sensor Fungsi RS-485


Pengujian akuisisi data sensor dilakukan melalui komunikasi RS-485 antara sensor HONDE HD-WSM-U-07 dan mikrokontroler pada modul LoRa Transmitter dengan menggunakan protokol Modbus RTU. Pada komunikasi ini, mikrokontroler berperan sebagai master atau perangkat pengirim permintaan data, sedangkan sensor HONDE HD-WSM-U-07 berperan sebagai slave atau perangkat penerima permintaan sekaligus pengirim respons data. Alamat slave yang digunakan pada sensor adalah 0xFF, dengan function code 03 (Read Holding Register) untuk membaca data parameter cuaca dari register sensor. Data diperoleh melalui pembacaan register Modbus sensor dalam bentuk heksadesimal, kemudian dikonversi ke bentuk desimal dan diolah menggunakan faktor skala serta offset sesuai spesifikasi sensor. Pada proses akuisisi data ini, setiap parameter cuaca memiliki alamat register yang berbeda-beda, seperti pada tabel 4.5.

Tabel 4. 5 Alamat Register Modbus

Address	Operasi	Parameter
0x0009	Read Only (Temperature)	Suhu
0x000A	Read Only (Humidity)	Kelembapan
0x000B	Read Only (PA)	Tekanan Atmosfer
0x000C	Read Only (WS)	Kecepatan Angin
0x000D	Read Only (WD)	Arah Angin
0x000E	Read Only (Rainfall)	Curah Hujan

Address	Operasi	Parameter
0x000F	Read Only (Irradiation)	Iradiasi
0x0000	Read Write	Mengatur Alamat Register

Proses pembacaan sensor dilakukan setiap 5 detik sekali untuk menghindari blocking pada program, sehingga mikrokontroler memiliki jeda waktu yang cukup untuk melakukan akuisisi data, pengolahan data, serta proses komunikasi berikutnya. Setelah data sensor berhasil dibaca dan dikonversi, data tersebut kemudian dikirimkan melalui komunikasi LoRa dan ditampilkan pada OLED yang terdapat pada MCU, seperti yang ditunjukkan pada Gambar 4.1.



Gambar 4. 1 Tampilan OLED MCU

Pada parameter suhu, alamat yang digunakan adalah 0x0009, proses ini dilakukan dengan mengonversi bilangan hexadesimal ke desimal kemudian membaginya dengan angka 100 lalu mengurangnya dengan 40, sebagai contoh nilai yang terbaca adalah 0x1BBC maka nilai tersebut dikonversi menjadi bilangan desimal 7100 kemudian dibagi 100 lalu dikurangi 40 sehingga menghasilkan nilai 31°C. Pada parameter kelembapan, alamat yang digunakan adalah 0x000A, proses ini dilakukan dengan mengonversi bilangan hexadesimal ke desimal kemudian membaginya dengan angka 100, sebagai contoh nilai yang terbaca adalah 0x1B79 maka nilai tersebut dikonversi menjadi bilangan desimal 7033 kemudian dibagi 100 sehingga menghasilkan nilai 70,33 dalam satuan %RH. Pada parameter iradiasi, alamat yang digunakan adalah 0x000B, proses ini dilakukan dengan mengonversi bilangan hexadesimal ke desimal, nilai desimal tersebut merupakan nilai iradiasi, sebagai contoh nilai yang terbaca adalah 0x0429 maka nilai tersebut akan dikonversi menjadi bilangan desimal 1065 dan menjadi nilai parameter dalam

satuan (W/m^2). Pada parameter curah hujan, alamat yang digunakan adalah 0x000E, proses ini dilakukan dengan mengonversi bilangan hexadesimal ke desimal kemudian membaginya dengan angka 10, sebagai contoh nilai yang terbaca adalah 0x0102 maka nilai tersebut dikonversi menjadi bilangan desimal 258 kemudian dibagi 10 sehingga menghasilkan nilai 25,8 dalam satuan mm/h.

Tabel 4. 6 Hasil Akuisisi Data Sensor Melalui RS-485

Waktu	Temperatur (°C)	Kelembapan (%)	Iradiasi (W/m^2)	Curah Hujan (mm/h)
8.00	31.00	70.33	1065	0.0
9:00	31.00	67.24	1180	0.0
12:00	30.00	69.37	211	0.0
13:00	27.00	87.53	570	25.80
16:00	27.00	76.83	180	25.80
17:00	27.00	79.98	22	25.80
8:00	32.00	62.40	1102	25.80
9:00	33.00	58.75	1161	25.80
12:00	34.00	59.48	1217	25.80
13:00	33.00	52.11	909	25.80
16.00	24.00	92.20	21	45.80
17.00	24.00	90.88	3	45.80
8:00	31.00	65.73	1083	46.00
9:00	32.00	62.56	1179	46.00
12:00	34.00	55.77	914	46.00
13:00	31.00	67.81	798	46.00
16.00	25.00	89.26	25	79.19
17.00	25.00	87.62	32	80.40

Tabel 4.6 menunjukkan hasil pengujian parameter cuaca meliputi suhu, kelembapan, iradiasi, dan curah hujan berhasil terbaca tanpa ditemukan nilai negatif maupun nilai kosong. Data yang diperoleh menunjukkan bahwa sistem komunikasi RS-485 mampu mentransmisikan data secara stabil dan konsisten pada berbagai waktu pengambilan data. Nilai curah hujan yang tetap pada angka 25.80 mm dan 45.80 mm dalam beberapa waktu pengujian merupakan nilai akumulasi dari sensor rain gauge, nilai tidak langsung kembali ke nol setelah hujan berhenti. Hal ini disebabkan oleh penyimpanan total curah hujan serta adanya sisa air pada penampungan sensor.

Tabel 4. 7 Hasil Pengujian Latency RS-485

Uji Ke-	Waktu Pembacaan	Latency (ms)	Status
1	12:41:42	50,733	Berhasil
2	12:41:47	51,301	Berhasil
3	12:41:52	50,987	Berhasil
4	12:41:57	50,678	Berhasil
5	12:42:02	51,407	Berhasil
6	12:42:07	51,148	Berhasil
7	12:42:12	50,838	Berhasil
8	12:42:17	51,544	Berhasil
9	12:42:22	51,213	Berhasil
10	12:42:27	50,917	Berhasil
11	12:42:32	51,526	Berhasil
12	12:42:37	51,228	Berhasil
13	12:42:42	50,919	Berhasil
14	12:42:47	51,634	Berhasil
15	12:42:52	51,304	Berhasil
16	12:42:57	50,993	Berhasil
17	12:43:02	50,682	Berhasil
18	12:43:07	51,305	Berhasil
19	12:43:12	50,992	Berhasil
20	12:43:17	50,681	Berhasil
	Average	51,102 ms	
	Minimum	50,678 ms	
	Maksimal	51,634 ms	

Tabel 4.7 menunjukkan hasil pengujian latency akuisisi data RS-485 sebanyak 20 kali, seluruh proses pembacaan data sensor HONDE HD-WSM-U-07 menunjukkan status berhasil. Nilai latency minimum yang diperoleh adalah 50,678 ms, nilai maksimum sebesar 51,634 ms, dan nilai rata-rata sebesar 51,102 ms. Hasil tersebut menunjukkan bahwa proses komunikasi RS-485 antara sensor dan mikrokontroler berlangsung stabil karena nilai latency berada pada rentang yang relatif kecil, yaitu sekitar 50–52 ms. Dengan demikian, komunikasi RS-485 mampu mendukung proses akuisisi data sensor secara efektif tanpa menimbulkan keterlambatan yang signifikan sebelum data ditampilkan pada OLED dan dikirimkan melalui komunikasi LoRa.

4.3 Pengujian Penyimpanan Data pada SD Card LoRa Transmitter

Penyimpanan data pembacaan sensor Honde ke SD Card LoRa Transmitter terjadi pada proses resend data, yaitu ketika modul komunikasi LoRa Transmitter gagal mengirim data ke LoRa Receiver atau gagal menerima paket acknowledgment (ACK) dari Receiver. Data yang disimpan bukanlah data awal yang gagal dikirim, melainkan data hasil pembacaan sensor terbaru pada saat proses pengiriman ulang. Hal ini terjadi karena variabel `dataSendJson` yang digunakan untuk pengiriman dan penyimpanan terus diperbarui (`overwrite`) setiap 5 detik oleh fungsi `setData()`. Pada pengujian ini terdapat 2.000 sampel data yang tersimpan, dan berdasarkan Tabel 4.8, seluruh parameter cuaca meliputi iradiasi, kecepatan angin, arah angin, suhu, kelembapan, tekanan udara, dan curah hujan berhasil tersimpan dengan baik tanpa ditemukan nilai negatif maupun nilai kosong. Dengan demikian, SD Card berfungsi sebagai media penyimpanan cadangan.

Tabel 4. 8 Hasil Penyimpanan Data pada SD Card Transmitter

Iradiasi (W/m²)	WS (m/s)	WD	Temp (°C)	Hum (%)	AP (hpa)	Rainfall (mm/h)
253	0.97	328.1°	31	67.14	986	0.0
214	0.04	250.4°	31	67.21	986	0.0
194	0.78	300.4°	31	67.31	986	0.0
196	0.37	127.2°	31	67.26	986	0.0
196	1.04	301°	31	66.99	985	0.0
192	1.5	309.4°	31	67.5	986	0.0
192	0.62	328.6°	30	67.43	985	0.0
191	1.6	261.29°	30	68.17	985	0.0
189	0.29	221°	30	68.91	985	0.0
190	0.98	16.1°	30	69.35	985	0.0
190	0.77	296.6°	30	69.03	985	0.0
197	0.92	266.5°	30	68.96	985	0.0
214	0.82	313°	30	69.37	985	0.0
214	0.4	233°	30	70.08	985	0.0
175	3.25	306.4°	30	73.6	986	0.4

Iradiasi (W/m²)	WS (m/s)	WD	Temp (°C)	Hum (%)	AP (hpa)	Rainfall (mm/h)
185	1.22	274.1°	28	81.3	986	8.39
223	0.82	307.6°	27	84.64	985	12
242	1.28	227.5°	26	87.26	985	14
253	2.14	24°	26	88.37	985	16.4
256	0.56	348°	26	89.37	985	18,6

4.4 Pengujian Pengiriman Data LoRa

Pada proses pengiriman data melalui LoRa, transmitter melakukan pembacaan data sensor menggunakan komunikasi Modbus RTU setiap 5 detik sekali. Data yang diperoleh kemudian dikonversi ke dalam format JSON dan dikirimkan melalui modul LoRa. Transmitter akan terus mengirimkan data hingga berhasil menerima pesan acknowledgment (ACK) dari receiver. Pesan ACK ini berfungsi sebagai tanda bahwa receiver telah menerima data dengan ID dan format yang sesuai. Apabila dalam rentang waktu 1 hingga 15 detik (secara acak) transmitter belum menerima ACK, maka transmitter akan melakukan pengiriman ulang (resend) data. Proses ini berulang hingga pesan ACK berhasil diterima. Di sisi lain, receiver tidak mengirimkan ACK setiap kali menerima data. Sebaliknya, receiver terlebih dahulu mengakumulasi ID node dari data yang berhasil diterima dalam periode 20 detik, kemudian mengirimkan satu pesan ACK yang berisi daftar ID tersebut, misalnya "ACK#15#16#17#". Hal ini bertujuan untuk mengurangi kepadatan trafik komunikasi LoRa dan meningkatkan efisiensi penggunaan bandwidth. Selain itu, apabila dalam waktu 240 detik transmitter tidak kunjung menerima ACK, maka sistem akan melakukan reset otomatis sebagaimana didefinisikan pada 'unsigned long ackTimeout = 240000'. Reset ini berfungsi sebagai mekanisme pemulihan ketika terjadi gangguan komunikasi atau saat receiver tidak merespons.

Berdasarkan hasil pengujian pada periode 2 April 2026 pukul 05.36.23 hingga 1 Mei 2026 pukul 23.58.47, dengan interval penerimaan data yang dirancang sebesar 120 detik, data yang seharusnya diperoleh sebanyak 21.432 data. Namun, data yang berhasil diterima sebanyak 19.687 baris, sehingga terdapat kehilangan data sebanyak 1.745 baris (8,14%). Dengan demikian, tingkat

keberhasilan transmisi data mencapai 91,86%. Hasil analisis terhadap interval waktu penerimaan menunjukkan bahwa rata-rata interval antar data adalah 130,64 detik, sedikit lebih lambat dibandingkan interval yang dirancang. Nilai median interval yang diperoleh adalah sebesar 120 detik, menunjukkan bahwa sebagian besar data diterima tepat sesuai interval yang dirancang. Dari hasil klasifikasi pergeseran yang bersifat mutually exclusive dengan toleransi ± 2 detik, sebanyak 19.338 data (98,23%) diterima tepat waktu, 342 data (1,74%) mengalami keterlambatan, dan hanya 6 data (0,03%) memiliki interval lebih cepat dari target. Selain itu, terdeteksi 30 data (0,15%) sebagai outlier dengan pergeseran lebih dari 5 menit.


Secara keseluruhan, tingkat keberhasilan transmisi sebesar 91,86% menunjukkan bahwa komunikasi LoRa antara transmitter dan receiver berjalan dengan cukup andal. Kehilangan data sebesar 8,14% dapat disebabkan oleh beberapa faktor, antara lain gangguan sinyal LoRa, troubleshooting, power shutdown, dan kondisi transmitter atau receiver yang sedang sibuk memproses data sehingga melewatkan beberapa paket. Selain pengujian terhadap jumlah data yang diterima, dilakukan pula pemeriksaan terhadap kelengkapan isi data pada sampel data yang berhasil diterima. Tabel 4.9 menunjukkan hasil pengujian terhadap 100 data yang diterima dari transmitter ke receiver. Pada pengujian tersebut, seluruh data memiliki format yang lengkap dan tidak ditemukan nilai NaN, nilai kosong, maupun missing value pada parameter yang dikirimkan. Dengan demikian, tingkat error kelengkapan isi data pada sampel 100 data yang berhasil diterima adalah sebesar 0%. Nilai ini tidak menunjukkan bahwa tidak ada data yang hilang selama transmisi, melainkan menunjukkan bahwa data yang berhasil diterima memiliki isi parameter yang lengkap dan dapat diproses oleh sistem.

Tabel 4. 9 Hasil Transmisi Data Melalui LoRa

ID	Time stamp	Ir (W/m²)	WS (m/s)	WD	Temp (°C)	Hum (%)	AP (hpa)	Rainfall (mm/h)
14	12:49:07	353	0.03	43.6	26	91.9	985	0.20
14	12:51:07	360	0.25	169.9	26	92.6	985	0.39
14	12:53:07	362	0	205.9	26	92.4	985	0.00

ID	Time stamp	Ir (W/m²)	WS (m/s)	WD	Temp (°C)	Hum (%)	AP (hpa)	Rainfall (mm/h)
14	12:55:07	341	0.25	96.5	26	91.9	985	0.19
14	12:57:07	329	0	228.9°	26	91.2	985	0.00
14	12:59:07	352	0.64	112°	26	91.2	985	0.00
14	13:01:07	424	0.16	123.39°	26	91.7	985	0.00
14	13:03:07	467	0.34	32.39°	27	91.1	985	0.00
14	13:05:07	481	0	26°	27	90.0	985	0.00
14	13:07:07	495	0.09	21.1°	27	89.6	985	0.00
14	13:09:07	516	0.11	325.4°	27	89.3	985	0.20
14	13:11:07	528	0.59	332.8°	27	89.3	985	0.20
14	13:13:07	552	0.12	314.69°	27	88.5	985	0.00
14	13:15:07	590	0.14	0.70°	27	87.1	985	0.00
14	13:17:07	634	0.82	308°	27	86.1	985	0.00
14	13:19:07	688	0.42	333.5°	27	85.9	985	0.00
14	13:21:07	771	1.28	351.6°	27	85.5	985	0.00
14	13:23:07	814	1.06	331.7°	27	84.8	985	0.00
14	13:29:07	1140	1.68	309°	28	83.9	985	0.00
14	13:31:07	1210	0.14	250.7°	28	84.4	984	0.00

Pengujian pengiriman ini dilakukan dengan jarak antara transmitter dan receiver sejauh 135 meter seperti yang ditunjukkan pada gambar 4.2. Transmitter ditempatkan di area rooftop gedung sinarmas atau gedung dekanat Sekolah Vokasi Universitas Diponegoro dengan kondisi lingkungan yang memiliki beberapa hambatan berupa bangunan dan pepohonan. Meskipun terdapat hambatan, proses pengiriman data tetap berjalan dengan baik dan stabil.



Gambar 4. 2 Jarak Transmitter-Receiver

Berdasarkan gambar 4.3, sensor ditempatkan pada ketinggian sekitar 3 meter dari permukaan lantai dengan tujuan untuk mengoptimalkan penangkapan data cuaca agar tidak terhalang oleh objek di sekitar. Panel box transmitter dipasang pada tiang untuk mendukung posisi sensor agar lebih representatif terhadap kondisi lingkungan.



Gambar 4. 3 Lokasi Penempatan Sensor dan Transmitter

Receiver ditempatkan di dalam ruangan Laboratorium Teaching Factory Elektronika Terpadu (TEFA-ET) Sekolah Vokasi Universitas Diponegoro, yang disimpan di dalam panel box sebagaimana ditunjukkan pada gambar 4.4. Penempatan ini menunjukkan bahwa sistem komunikasi LoRa tetap mampu bekerja dengan baik meskipun receiver berada di dalam ruangan.



Gambar 4. 4 Lokasi Penempatan Receiver

4.5 Pengujian Penyimpanan Data pada SD Card LoRa Receiver

Data sensor HONDE yang diterima oleh receiver selanjutnya disimpan ke dalam media penyimpanan SD Card. Data yang diterima oleh receiver dari LoRa transmitter dikumpulkan terlebih dahulu dalam satu struktur data 'node_data'. Penyimpanan data ini dipicu oleh fungsi loop() yang memiliki kondisi INTERVAL_MQTT = 120000ms. Pada saat interval ini tercapai, fungsi saveLog() dijalankan untuk menyimpan data ke dalam SD Card. Data akan terus diperbarui selama 120 detik, namun hanya satu data terbaru untuk setiap ID node yang disimpan sementara dalam struktur data node_data, sehingga tidak terjadi duplikasi. Ketika waktu interval terpenuhi, seluruh data dalam 'node_data' disimpan ke file log_receiver.txt dalam format JSON yang dilengkapi dengan timestamp. Setelah proses penyimpanan selesai, data pada node_data akan dikosongkan untuk memulai siklus pengambilan data berikutnya.

Tabel 4. 10 Hasil Penyimpanan Data pada SD Card Receiver

ID	Ir (W/m²)	WS (m/s)	WD	Temp (°C)	Hum (%)	AP (hpa)	Rainfall (mm/h)
14	185	0.81	268.19°	32	68.5	984	0.0
14	131	1.07	290.19°	31	69.29	984	0.0
14	103	2.1	236.6°	31	70.57	984	0.0
14	84	1.89	256.29°	31	72.22	984	0.0
14	77	2.35	257.69°	30	73.47	984	0.0
14	83	1.89	281°	29	73.11	984	0.0
14	77	2.08	268.1°	29	72.79	984	0.0

ID	Ir (W/m²)	WS (m/s)	WD	Temp (°C)	Hum (%)	AP (hpa)	Rainfall (mm/h)
14	55	1.8	228.7°	29	71.9	984	0.0
14	24	0.66	331.7°	28	70.85	984	0.0
14	14	2.14	234.79°	28	70.18	984	0.0
14	14	2.25	210.29°	28	73.96	984	0.0
14	15	6.25	225.9°	28	77.56	984	0.0
14	14	0.56	275.6°	27	79.67	984	0.0
14	18	0.51	237.7°	27	82.14	984	0.2
14	17	2.06	213.1°	26	83.93	984	0.0
14	14	3.22	227°	26	85.65	984	2.6
14	14	1.88	269.69°	26	88.18	985	6.4
14	17	1.99	251.2°	25	90	984	0.0
14	19	0.0	209.9°	25	91.11	984	2.19
14	20	0.72	220.29°	25	92.17	984	0.0

Berdasarkan hasil pengujian pada Tabel 4.10, seluruh parameter cuaca yang meliputi iradiasi, kecepatan angin, arah angin, temperatur, kelembapan, tekanan udara, dan curah hujan berhasil tersimpan tanpa adanya data yang hilang atau tidak terbaca. Data yang tersimpan menunjukkan konsistensi nilai antar parameter pada setiap waktu pengambilan dan proses penyimpanan berjalan dengan stabil. Dengan demikian, SD Card pada receiver dapat berfungsi sebagai media penyimpanan cadangan.

4.6 Pengujian Pengiriman Data melalui MQTT

Data hasil pembacaan sensor yang telah diterima oleh receiver dikirim secara berkala setiap 2 menit melalui protokol MQTT menuju sistem penyimpanan. Namun, proses penyimpanan ke dalam database dilakukan dalam interval 5 menit. Sebelum disimpan ke database melalui MQTT, data terlebih dahulu ditampung sementara pada buffer Redis untuk menjaga kontinuitas data apabila terjadi keterlambatan atau kekosongan nilai pada pengiriman tertentu. Pada proses ini topik yang digunakan adalah struktur berupa `PLN_NP_Testing_Humidity_{ID}`,

PLN_NP_Testing_WindSpeed_{ID}, PLN_NP_Testing_WindDirection_{ID}, PLN_NP_Testing_AtmosphericPressure_{ID}, PLN_NP_Testing_Irradian_{ID}, PLN_NP_Testing_Temperature_{ID}, dan PLN_NP_Testing_RainFall_{ID}. Setiap topik dikirim menggunakan format JSON yang hanya memuat satu key-value pair untuk masing-masing parameter, seperti {"irradiance": 480} untuk iradiasi atau {"temperature": 33} untuk suhu.

Khusus pada parameter curah hujan, sistem melakukan pengolahan tambahan sebelum data dikirim ke MQTT dan disimpan ke database. Sensor curah hujan HONDE menggunakan mekanisme tipping bucket yang menghasilkan data dalam bentuk nilai akumulasi yang terus bertambah seiring waktu. Tanpa pengolahan tambahan, nilai yang tersimpan di database akan berupa total akumulasi sejak awal pengukuran, bukan curah hujan per interval waktu. Oleh karena itu, receiver menghitung selisih antara data curah hujan saat ini dengan data sebelumnya untuk memperoleh nilai curah hujan per interval. Proses ini dilakukan pada sisi receiver menggunakan fungsi pengolahan data float $\text{rain_interval} = \text{received_data.rain} - \text{last_rain}[\text{received_data.id}]$, kemudian hasil perhitungan tersebut disimpan kembali $\text{received_data.rain} = \text{rain_interval}$, sehingga data curah hujan yang dikirim ke MQTT bukan lagi nilai akumulatif sensor, melainkan nilai penambahan curah hujan pada interval tertentu. Selain itu, sistem juga menerapkan validasi $\text{if} (\text{rain_interval} < 0) \text{rain_interval} = 0$ untuk mencegah nilai curah hujan negatif akibat reset atau ketidakstabilan pembacaan sensor.

Tabel 4. 11 Hasil Pengiriman Data Melalui MQTT

ID	Temp (°C)	Hum (%)	WS (m/s)	WD	Rain (mm/h)	Ir (W/m²)	AP (hpa)	Timestamp
331692	34	57.11	0.65	86.9°	0.0	1211	986	2026-04-09 11:20
331691	34	56.14	0.26	249.9°	0.0	1118	986	2026-04-09 11:15
331690	34	56.94	1.34	68.3°	0.0	1206	986	2026-04-09 11:10
331689	33	60.42	0.5	191°	0.0	1168	986	2026-04-09 11:05
331688	33	60.29	0.6	97.1°	0.0	1245	986	2026-04-09 11:00
331687	33	59.54	0.84	57.4°	0.0	1212	986	2026-04-09 10:55
331686	33	56.38	0.55	305.5°	0.0	871	987	2026-04-09 10:50

331685	34	55.93	0.25	103°	0.0	1204	987	2026-04-09 10:45
331684	35	56.41	0.15	50.4°	0.0	1202	987	2026-04-09 10:40
331683	34	57.18	0.48	216°	0.0	1202	987	2026-04-09 10:35

Tabel 4.11 menunjukkan hasil penyimpanan data melalui MQTT. Berdasarkan hasil pengujian dan analisis data pada periode April 2026, total data yang berhasil tersimpan di dalam database pada periode tersebut sebanyak 7.749 baris data. Dari jumlah tersebut, sebanyak 7.740 baris data berada dalam kondisi lengkap, sedangkan 9 baris data memiliki nilai null pada salah satu parameter. Nilai null ditemukan pada parameter temperatur dan kelembapan sebanyak 9 data, serta pada parameter iradiasi sebanyak 1 data. Keberadaan nilai null tersebut dapat terjadi akibat gangguan sementara pada proses pembacaan sensor atau proses transmisi data ketika receiver sedang melakukan pengiriman data menuju MQTT broker dan database. Selain itu, kondisi jaringan, proses restart sistem, atau keterlambatan sinkronisasi data juga dapat menyebabkan beberapa parameter tidak berhasil tersimpan secara sempurna pada waktu tertentu. Namun demikian, jumlah data null yang ditemukan relatif sangat kecil dibandingkan total data keseluruhan. Berdasarkan hasil analisis kelengkapan data, persentase keberhasilan penyimpanan data lengkap pada database mencapai 99,88%. Hasil pengujian menunjukkan bahwa sebagian besar data berhasil diterima dan tersimpan secara konsisten sesuai interval pengambilan data yang telah ditentukan.

Berdasarkan interval penyimpanan database setiap 5 menit, jumlah data yang seharusnya diterima selama periode April 2026 adalah 8.640 baris data. Namun, data aktual yang berhasil tersimpan hanya sebanyak 7.740 baris sehingga terdapat kehilangan data (*data loss*) sebanyak 900 baris dengan persentase keberhasilan transmisi sebesar 89,58%. Kondisi tersebut dapat disebabkan oleh gangguan koneksi internet, proses troubleshooting perangkat, restart sistem, power shutdown, maupun kondisi receiver yang tidak aktif sementara waktu. Meskipun demikian, sebagian besar pengujian tetap menunjukkan jumlah data yang mendekati nilai ideal sebanyak 288 baris per hari, seperti pada tanggal 11 April, 12 April, 26 April, dan 30 April berhasil mencapai jumlah data penuh tanpa kehilangan data. Hal ini

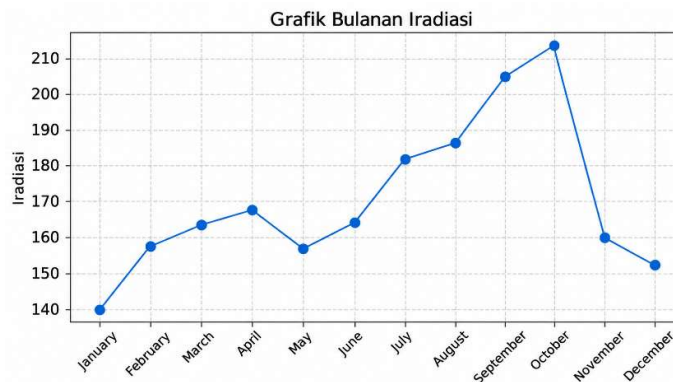
menunjukkan bahwa sistem pengiriman dan penyimpanan data berbasis MQTT, Redis, dan PostgreSQL secara periodik telah berjalan dengan sangat baik dan stabil.

4.7 Dataset Acuan untuk Pembuatan Model

Data sensor HONDE yang digunakan dalam penelitian ini memiliki keterbatasan pada cakupan waktu pengambilan data, yaitu hanya berkisar selama kurang lebih satu hingga dua bulan. Keterbatasan ini menyebabkan data yang diperoleh belum cukup representatif untuk digunakan sebagai dataset utama dalam proses pelatihan model, mengingat performa model machine learning sangat dipengaruhi oleh jumlah dan keberagaman data latih yang digunakan. Dataset dengan jumlah terbatas berpotensi menyebabkan model mengalami overfitting serta kurang mampu melakukan generalisasi terhadap kondisi cuaca yang bervariasi. Terdapat beberapa sumber data cuaca seperti BMKG dan NASA. Namun, penelitian ini menggunakan data Automatic Weather Station (AWS) Universitas Diponegoro sebagai acuan karena mampu menggambarkan kondisi cuaca lokal pada wilayah penelitian dengan baik, serta memiliki jarak yang relatif dekat dengan lokasi sensor, yaitu sekitar ± 400 meter.


4.7.1 Analisis Data AWS Undip

Analisis yang dilakukan pada Data AWS Undip terdiri dari 4 variabel cuaca yaitu temperatur, kelembapan, iradiasi, dan curah hujan dengan rentang waktu 1 Januari 2025 hingga 1 Februari 2026.



Gambar 4. 5 Grafik Iradiasi AWS UNDIP


Gambar 4.5 merupakan grafik rata-rata bulanan nilai iradiasi pada periode 1 Januari 2025 hingga Februari 2026. Berdasarkan hasil analisis rata-rata bulanan nilai iradiasi matahari tertinggi terjadi pada bulan Oktober dengan rata-rata sebesar 212.35 W/m². Sementara itu, nilai iradiasi terendah terjadi pada bulan Januari dengan rata-rata sebesar 139.64 W/m². Pola distribusi iradiasi selama satu tahun menunjukkan adanya peningkatan bertahap mulai dari awal tahun hingga mencapai puncaknya pada bulan September hingga Oktober, kemudian mengalami penurunan kembali menjelang akhir tahun. Hal ini menunjukkan bahwa intensitas radiasi matahari di wilayah penelitian cenderung lebih tinggi pada periode pertengahan hingga akhir tahun. Namun demikian, pada analisis nilai ekstrem, ditemukan nilai minimum iradiasi sebesar 0 W/m². Nilai ini tidak merepresentasikan kondisi cuaca buruk, melainkan terjadi secara alami pada malam hari ketika tidak terdapat radiasi matahari. Oleh karena itu, dalam interpretasi kondisi cuaca, nilai rata-rata bulanan lebih representatif dibandingkan nilai minimum absolut.



Gambar 4. 6 Grafik Suhu AWS UNDIP


Berdasarkan Gambar 4.6, rata-rata bulanan suhu tertinggi terjadi pada bulan Oktober sebesar 27.36°C, sedangkan suhu terendah terjadi pada bulan Januari sebesar 25.37°C. Pola suhu menunjukkan kecenderungan meningkat secara bertahap dari awal tahun hingga mencapai puncaknya pada bulan September–Oktober, kemudian mengalami penurunan pada akhir tahun. Variasi suhu ini relatif stabil dibandingkan parameter lainnya, namun tetap menunjukkan hubungan

dengan intensitas radiasi matahari, dimana peningkatan suhu sejalan dengan peningkatan iradiasi.



Gambar 4. 7 Grafik Kelembapan AWS UNDIP

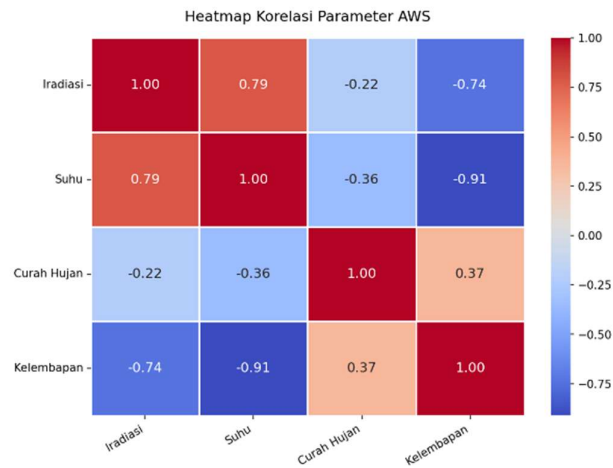
Berdasarkan Gambar 4.7, rata-rata bulanan kelembapan menunjukkan nilai tertinggi terjadi pada bulan Januari sebesar 86.21%, sedangkan nilai terendah terjadi pada bulan September sebesar 71.89%. Pola kelembapan menunjukkan tren penurunan dari awal tahun hingga pertengahan tahun, kemudian meningkat kembali menjelang akhir tahun. Penurunan pada pertengahan tahun mengindikasikan kondisi atmosfer yang relatif lebih kering, umumnya berkaitan dengan musim kemarau. Sebaliknya, peningkatan kelembapan pada awal dan akhir tahun menunjukkan kondisi udara yang lebih lembap, yang berpotensi mendukung terjadinya hujan.



Gambar 4. 8 Grafik Curah Hujan AWS UNDIP

Berdasarkan Gambar 4.8, rata-rata bulanan curah hujan tertinggi terjadi pada bulan Maret sebesar 8.83 mm/jam, sedangkan nilai terendah terjadi pada bulan Juli

sebesar 1.42 mm/jam. Pola curah hujan menunjukkan fluktuasi yang cukup signifikan sepanjang tahun. Curah hujan cenderung tinggi pada awal tahun, kemudian menurun drastis pada pertengahan tahun, dan kembali meningkat pada akhir tahun. Pola ini mencerminkan karakteristik iklim musiman di wilayah penelitian, dimana periode awal dan akhir tahun merupakan musim hujan, sedangkan pertengahan tahun merupakan musim kemarau.




Gambar 4. 9 Heatmap Korelasi Parameter AWS UNDIP

Berdasarkan hasil analisis korelasi pada Gambar 4.9, diketahui bahwa terdapat hubungan yang signifikan antar parameter cuaca. Korelasi positif ditemukan antara iradiasi dan suhu sebesar 0.79, yang menunjukkan bahwa peningkatan radiasi berbanding lurus dengan kenaikan suhu. Selain itu, kelembapan dan curah hujan juga menunjukkan korelasi positif sebesar 0.37, mengindikasikan bahwa kondisi udara yang lebih lembap cenderung meningkatkan kemungkinan terjadinya hujan. Sebaliknya, korelasi negatif ditemukan antara suhu dan kelembapan dengan nilai sebesar -0.91, menunjukkan bahwa peningkatan suhu diikuti dengan penurunan kelembapan. Hubungan negatif juga terlihat antara iradiasi dan kelembapan (-0.74), serta antara curah hujan dengan suhu (-0.36) dan iradiasi (-0.22). Hal ini menunjukkan bahwa kondisi cuaca dengan intensitas radiasi tinggi memiliki kelembapan rendah, sementara kondisi hujan cenderung terjadi pada saat suhu dan radiasi menurun. Secara keseluruhan, hasil korelasi ini menunjukkan bahwa parameter cuaca saling berkaitan secara fisik dan mendukung penggunaan variabel-variabel tersebut sebagai input dalam model klasifikasi cuaca berbasis MLP.

4.7.2 Analisis Data Sensor Honde

Pada subbab ini dilakukan analisis terhadap data hasil akuisisi sensor HONDE yang tersimpan pada database sistem. Data yang digunakan meliputi empat parameter cuaca, yaitu suhu, kelembapan, iradiasi matahari, dan curah hujan pada rentang waktu 1 April 2026 sampai dengan 30 April 2026. Analisis dilakukan untuk mengamati pola perubahan masing-masing parameter cuaca. Selain itu, dilakukan juga analisis korelasi antar parameter menggunakan heatmap untuk melihat hubungan antar variabel cuaca pada dataset sensor HONDE.

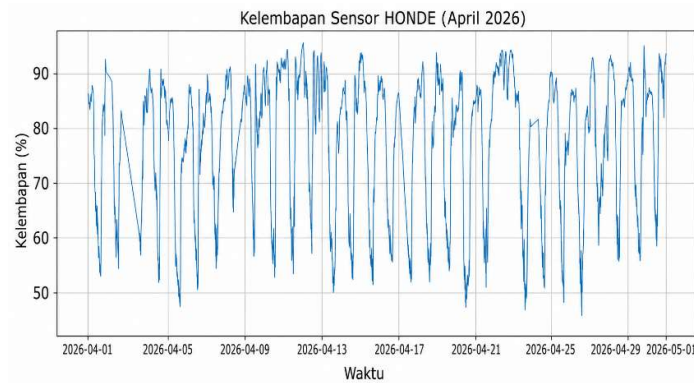


Gambar 4. 10 Grafik Suhu Sensor Honde

Gambar 4.10 menunjukkan grafik suhu berdasarkan pengamatan data sensor Honde. Berdasarkan hasil analisis data sensor HONDE selama bulan April 2026, nilai suhu tertinggi tercatat sebesar 36,00°C yang terjadi pada tanggal 26 April 2026 pukul 12.45. Sementara itu, suhu terendah tercatat sebesar 23,00°C yang terjadi pada tanggal 30 April 2026 pukul 17.25. Rentang suhu sebesar 13,00°C menunjukkan bahwa kondisi suhu lingkungan mengalami variasi yang cukup signifikan antara periode siang dan malam hari. Berdasarkan rata-rata suhu per jam, nilai rata-rata suhu tertinggi terjadi pada pukul 12.00 sebesar 33,23°C. Kondisi ini menunjukkan bahwa puncak pemanasan umumnya terjadi pada tengah hari hingga menjelang siang akhir. Sebaliknya, rata-rata suhu terendah terjadi pada pukul 05.00 dengan nilai sebesar 24,81°C, yang menunjukkan bahwa suhu udara cenderung mencapai kondisi paling rendah pada waktu menjelang pagi hari.

Selain itu, berdasarkan pola perubahan suhu harian, terlihat bahwa suhu mengalami peningkatan secara bertahap sejak pagi hari, kemudian mencapai puncak pada siang

hari, dan kembali menurun pada sore hingga malam hari. Pola ini menunjukkan karakteristik iklim tropis yang dipengaruhi oleh intensitas radiasi matahari selama periode siang hari. Selain itu, pada data sensor HONDE juga ditemukan fenomena *thermal lag* atau keterlambatan termal. Berdasarkan hasil analisis, puncak rata-rata iradiasi terjadi pada pukul 10.00, sedangkan puncak rata-rata suhu baru terjadi pada pukul 12.00, sehingga terdapat keterlambatan termal selama 2 jam. Fenomena ini terjadi karena permukaan lingkungan membutuhkan waktu untuk menyerap dan melepaskan energi panas yang diterima dari radiasi matahari sebelum temperatur udara mencapai nilai maksimum. Nilai standar deviasi temperatur sebesar 3,60 menunjukkan bahwa variasi perubahan suhu selama periode pengamatan masih tergolong stabil dan tidak mengalami fluktuasi ekstrem. Hal ini menandakan bahwa sensor HONDE mampu merekam perubahan suhu lingkungan secara konsisten sepanjang periode pengamatan.




Gambar 4. 11 Grafik Kelembapan Sensor Honde

Gambar 4.11 menunjukkan grafik kelembapan berdasarkan pengamatan data sensor Honde. Berdasarkan hasil analisis data sensor HONDE selama bulan April 2026, nilai kelembapan tertinggi terjadi pada tanggal 12 April 2026 pukul 00.30 sebesar 97,09%. Sementara itu, nilai kelembapan terendah terjadi pada tanggal 26 April 2026 pukul 14.10 sebesar 44,90%. Rentang kelembapan sebesar 52,19% menunjukkan bahwa kondisi atmosfer mengalami perubahan kelembapan yang cukup besar antara periode siang dan malam hari. Berdasarkan rata-rata kelembapan per jam, nilai rata-rata kelembapan tertinggi terjadi pada pukul 03.00 dengan nilai sebesar 88,26%. Kondisi ini menunjukkan bahwa kelembapan udara

cenderung meningkat pada malam hingga dini hari akibat temperatur lingkungan yang lebih rendah dan proses penguapan yang menurun. Sebaliknya, rata-rata kelembapan terendah terjadi pada pukul 12.00 dengan nilai sebesar 59,02%, yang menandakan bahwa udara menjadi lebih kering ketika intensitas radiasi matahari dan temperatur lingkungan meningkat pada siang hari.

Berdasarkan pola grafik kelembapan, terlihat bahwa nilai kelembapan memiliki pola yang berlawanan dengan suhu dan iradiasi. Ketika suhu dan iradiasi meningkat pada siang hari, kelembapan relatif cenderung menurun. Sebaliknya, pada malam hingga pagi hari ketika suhu menurun, kelembapan kembali meningkat. Pola ini menunjukkan hubungan invers antara suhu dan kelembapan. Nilai standar deviasi kelembapan sebesar 13,19 menunjukkan bahwa parameter kelembapan memiliki fluktuasi yang lebih dinamis dibandingkan suhu. Hal ini disebabkan karena kelembapan sangat dipengaruhi oleh perubahan kondisi atmosfer, keberadaan awan, curah hujan, intensitas radiasi matahari, serta proses penguapan air di lingkungan sekitar. Secara umum, pola kelembapan yang diperoleh dari sensor HONDE menunjukkan karakteristik cuaca tropis lokal yang ditandai dengan kelembapan tinggi pada malam hingga pagi hari dan penurunan kelembapan pada siang hari.

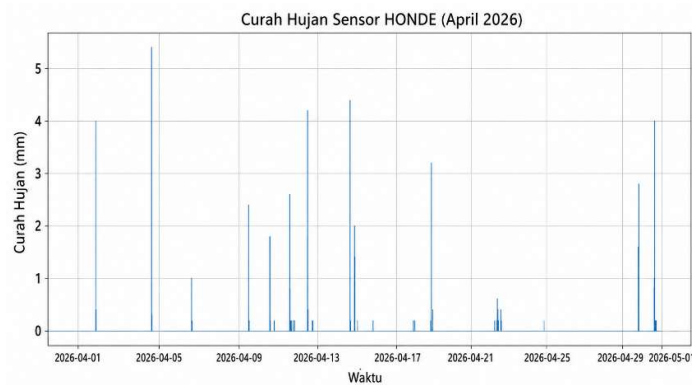


Gambar 4. 12 Grafik Iradiasi Sensor Honde

Gambar 4.12 menunjukkan grafik iradiasi berdasarkan pengamatan data sensor Honde. Berdasarkan hasil analisis data sensor HONDE selama bulan April 2026, nilai iradiasi tertinggi terjadi pada tanggal 4 April 2026 pukul 10.20 sebesar 1270,00 W/m². Sementara itu, nilai iradiasi terendah tercatat sebesar 0,00 W/m²

yang terjadi pada waktu dimana matahari terbenam. Rentang nilai iradiasi sebesar $1270,00 \text{ W/m}^2$ menunjukkan adanya perbedaan intensitas radiasi matahari yang sangat signifikan antara kondisi siang dan malam hari. Berdasarkan rata-rata iradiasi per jam, nilai rata-rata iradiasi tertinggi terjadi pada pukul 10.00 dengan nilai sebesar $1098,36 \text{ W/m}^2$. Kondisi ini menunjukkan bahwa intensitas radiasi matahari mulai mencapai puncaknya pada periode menjelang siang hari.

Berdasarkan pola grafik iradiasi, terlihat bahwa nilai iradiasi mulai meningkat sejak pagi hari, mencapai puncak pada siang hari, dan kembali menurun secara signifikan pada sore hingga malam hari. Penurunan ini terjadi akibat sudut elevasi matahari yang semakin rendah sehingga intensitas radiasi matahari yang diterima permukaan bumi juga berkurang. Selain itu, terdapat beberapa fluktuasi nilai iradiasi pada siang hari yang dipengaruhi oleh kondisi/tutupan awan, bayangan, perubahan kondisi atmosfer, posisi matahari terhadap sensor, maupun perubahan cuaca lokal. Nilai standar deviasi iradiasi sebesar $485,07$ menunjukkan bahwa parameter iradiasi memiliki variasi yang cukup besar dibandingkan parameter cuaca lainnya. Secara umum, pola iradiasi yang diperoleh dari sensor HONDE menunjukkan karakteristik radiasi matahari pada wilayah tropis, di mana intensitas radiasi meningkat tinggi pada siang hari dan menurun mendekati nol pada malam hari sesuai dengan siklus harian matahari.




Gambar 4.13 Grafik Curah Hujan Sensor Honde

Gambar 4.13 menunjukkan grafik curah hujan data sensor Honde. Berdasarkan hasil analisis data sensor HONDE selama bulan April 2026, nilai curah hujan tertinggi terjadi pada tanggal 4 April 2026 pukul 15.20 sebesar $5,39 \text{ mm}$.

Sementara itu, nilai curah hujan terendah 0,00 mm terjadi pada beberapa periode ketika tidak hujan. Rentang nilai curah hujan sebesar 5,39 mm menunjukkan bahwa intensitas hujan selama periode pengamatan cenderung berada pada kategori ringan hingga sedang. Berdasarkan rata-rata curah hujan per jam, nilai rata-rata curah hujan tertinggi terjadi pada pukul 15.00 dengan nilai sebesar 0,06 mm. Kondisi ini menunjukkan bahwa kejadian hujan pada periode pengamatan lebih sering terjadi pada siang hingga sore hari.

Berdasarkan pola grafik curah hujan, terlihat bahwa data curah hujan memiliki karakteristik yang berbeda dibandingkan parameter cuaca lainnya. Nilai curah hujan cenderung berada pada kondisi nol dalam sebagian besar waktu pengamatan dan hanya meningkat pada waktu tertentu ketika terjadi hujan. Pola ini menyebabkan grafik curah hujan terlihat lebih sporadis dan tidak kontinu seperti temperatur, kelembapan, maupun iradiasi. Selain itu, proses pengolahan data curah hujan pada sistem dilakukan menggunakan metode incremental rainfall, di mana nilai yang disimpan merupakan selisih penambahan curah hujan pada setiap interval pengiriman data, bukan nilai akumulasi total tipping bucket. Mekanisme ini diterapkan karena sensor tipping bucket secara inheren menghasilkan nilai akumulasi yang terus bertambah sejak awal pengukuran, sehingga tanpa pengolahan tambahan data yang tersimpan tidak merepresentasikan intensitas curah hujan pada interval tertentu melainkan total akumulasi keseluruhan. Dengan metode tersebut, data curah hujan yang tersimpan menjadi lebih representatif terhadap intensitas hujan aktual pada setiap interval pengamatan. Nilai standar deviasi curah hujan sebesar 0,16 menunjukkan bahwa sebagian besar data berada pada kondisi tanpa hujan, sedangkan kejadian hujan hanya muncul pada waktu tertentu dengan durasi relatif singkat. Hal ini sesuai dengan karakteristik hujan di wilayah tropis yang umumnya bersifat lokal, tidak kontinu, dan memiliki intensitas yang berubah secara cepat dalam waktu singkat.



Gambar 4. 14 Heatmap Korelasi Parameter Cuaca (Sensor Honde)


Gambar 4.14 merupakan heatmap korelasi yang diperoleh dari sensor HONDE selama periode April 2026. Nilai korelasi berada pada rentang -1 hingga 1. Heatmap menunjukkan parameter temperatur dan iradiasi memiliki korelasi positif yang kuat dengan nilai sebesar 0,85 dapat disimpulkan bahwa peningkatan intensitas radiasi matahari diikuti oleh peningkatan temperatur udara. Sebaliknya, parameter kelembapan memiliki korelasi negatif yang sangat kuat terhadap temperatur dengan nilai sebesar -0,97 serta terhadap iradiasi sebesar -0,85. Nilai ini menunjukkan bahwa ketika temperatur dan iradiasi meningkat pada siang hari, kelembapan relatif udara cenderung menurun. Fenomena ini umum terjadi pada wilayah tropis karena udara yang lebih panas memiliki kemampuan menahan uap air lebih besar sehingga nilai kelembapan relatif menjadi lebih rendah. Sementara itu, parameter curah hujan menunjukkan korelasi yang sangat rendah terhadap parameter lainnya, dengan nilai korelasi berkisar antara -0,07 hingga 0,07. Hal ini menunjukkan bahwa kejadian hujan pada data pengamatan bersifat lebih fluktuatif dan tidak selalu terjadi secara langsung bersamaan dengan perubahan temperatur, kelembapan, maupun iradiasi. Selain itu, pola curah hujan pada wilayah tropis cenderung dipengaruhi oleh banyak faktor atmosfer lokal seperti pembentukan awan konvektif, kelembapan udara, arah angin, serta kondisi cuaca regional.

Berdasarkan data sensor HONDE yang diperoleh selama bulan April 2026, pola parameter cuaca menunjukkan karakteristik transisi musim dari musim hujan menuju musim kemarau. Nilai iradiasi yang tinggi dengan maksimum mencapai

1270 W/m² dan rata-rata puncak sebesar 1098,36 W/m² menunjukkan dominasi kondisi cuaca cerah yang identik dengan karakteristik musim kemarau atau musim panas tropis. Selain itu, temperatur maksimum yang mencapai 36°C dengan rata-rata temperatur siang hari sebesar 33,23°C turut memperkuat indikasi tingginya intensitas pemanasan permukaan selama periode pengamatan. Namun demikian, masih ditemukan beberapa kejadian curah hujan dengan intensitas maksimum mencapai 5,39 mm. Hal ini menunjukkan bahwa meskipun kondisi cuaca cenderung cerah dan panas, proses konveksi atmosfer lokal masih mampu memicu terbentuknya hujan pada waktu tertentu, khususnya pada siang hingga sore hari. Oleh karena itu, pola cuaca yang diperoleh selama periode pengamatan dapat dikategorikan sebagai kondisi peralihan atau transisi dari musim hujan menuju musim kemarau.


4.7.3 Analisis Perbandingan Data Sensor Honde dan Data Eksternal

Pada subbab ini dilakukan analisis perbandingan antara data sensor HONDE dengan data AWS Undip sebagai data eksternal pembanding, pada rentang waktu 1 April 2026 sampai dengan 30 April 2026. Garis grafik berwarna biru merupakan grafik data AWS Undip sedangkan grafik berwarna oranye merupakan grafik data Honde. Perbandingan dilakukan terhadap parameter iradiasi matahari, suhu, kelembapan, dan curah hujan untuk mengetahui tingkat kesesuaian pola data yang dihasilkan oleh sistem terhadap data referensi. Analisis ini bertujuan untuk mengevaluasi kemampuan sistem dalam merepresentasikan kondisi cuaca di lingkungan pengujian.



Gambar 4. 15 Grafik Perbandingan Parameter Suhu Sensor Honde dan AWS Undip


Berdasarkan hasil perbandingan data suhu antara sensor HONDE dan AWS UNDIP, grafik menunjukkan pola perubahan suhu harian yang relatif serupa. Gambar 4.15 memperlihatkan bahwa pola umum kenaikan suhu serta penurunan suhu dapat diikuti oleh sensor HONDE dengan cukup baik. Puncak suhu pada kedua sensor juga cenderung terjadi pada waktu yang hampir bersamaan, yaitu pada siang hari saat intensitas radiasi matahari meningkat. Nilai suhu yang terbaca oleh sensor Honde cenderung lebih tinggi dibandingkan AWS Undip dengan rata-rata suhu sensor Honde sebesar $28,0902\text{ }^{\circ}\text{C}$ dan AWS Undip sebesar $27,1196\text{ }^{\circ}\text{C}$, dengan selisih rata-rata sebesar $0,9706\text{ }^{\circ}\text{C}$. Hasil analisis error menunjukkan nilai MAE sebesar $4,1557\text{ }^{\circ}\text{C}$ dan RMSE sebesar $4,9923\text{ }^{\circ}\text{C}$, yang menandakan masih terdapat perbedaan pengukuran yang cukup besar pada beberapa kondisi tertentu. Selain itu, standar deviasi sensor Honde sebesar $3,622$ lebih tinggi dibandingkan AWS Undip sebesar $2,9747$, sehingga data Honde cenderung memiliki fluktuasi yang lebih besar. Perbedaan ini dapat dipengaruhi oleh faktor seperti spesifikasi sensor, posisi pemasangan, ventilasi sensor, maupun pengaruh lingkungan sekitar perangkat. Secara keseluruhan, sensor Honde telah mampu mengikuti pola perubahan suhu lingkungan dengan cukup baik, terutama dalam mendeteksi siklus suhu harian. Namun demikian, masih terdapat perbedaan nilai pengukuran dan tingkat kestabilan data dibandingkan AWS Undip sebagai data acuan.



Gambar 4. 16 Grafik Perbandingan Parameter Kelembapan Sensor Honde dan AWS Undip

Berdasarkan hasil perbandingan data kelembapan antara sensor HONDE dan AWS UNDIP, grafik menunjukkan pola perubahan kelembapan yang relatif serupa. Gambar 4.16 memperlihatkan bahwa ketika kelembapan meningkat maupun menurun, sensor HONDE masih mampu mengikuti pola perubahan yang


ditunjukkan oleh AWS UNDIP. Secara umum, nilai kelembapan cenderung tinggi pada malam hingga pagi hari dan menurun pada siang hari seiring meningkatnya suhu lingkungan. Meskipun pola perubahan kedua sensor terlihat mirip, nilai kelembapan yang dihasilkan HONDE cenderung lebih rendah dibandingkan AWS UNDIP. Rata-rata kelembapan HONDE tercatat sebesar 77,3472%, sedangkan AWS UNDIP sebesar 81,3662%, dengan selisih rata-rata sebesar -4,0190%. Hasil analisis error menunjukkan nilai MAE sebesar 16,8373% dan RMSE sebesar 19,8744%, yang menunjukkan masih terdapat perbedaan pengukuran yang cukup besar antara kedua sensor. Dari sisi kestabilan data, standar deviasi HONDE sebesar 13,1676 hampir mendekati AWS UNDIP sebesar 13,2581, sehingga tingkat variasi data kedua sensor relatif serupa. Namun demikian, grafik menunjukkan bahwa data kelembapan HONDE cenderung memiliki fluktuasi yang lebih tajam pada beberapa periode pengamatan. Secara keseluruhan, sensor HONDE telah mampu mengikuti pola perubahan kelembapan lingkungan dengan cukup baik, terutama dalam mendeteksi siklus kelembapan harian. Akan tetapi, masih terdapat selisih pengukuran dan perbedaan akurasi dibandingkan AWS UNDIP sebagai data acuan.



Gambar 4. 17 Grafik Perbandingan Parameter Iradiasi Sensor Honde dan AWS Undip

Berdasarkan hasil perbandingan data iradiasi antara sensor HONDE dan AWS UNDIP, grafik menunjukkan pola perubahan iradiasi yang relatif serupa, terutama pada siang dan malam hari. Gambar 4.17 memperlihatkan bahwa nilai iradiasi meningkat pada pagi hingga siang hari dan menurun kembali pada sore hingga malam hari. Hal ini menunjukkan bahwa sensor HONDE telah mampu mendeteksi perubahan intensitas radiasi matahari secara umum. Namun demikian, terdapat perbedaan nilai pengukuran yang cukup besar antara kedua sensor. Rata-

rata nilai iradiasi HONDE sebesar $360,8483 \text{ W/m}^2$, sedangkan AWS UNDIP sebesar $185,7332 \text{ W/m}^2$, dengan selisih rata-rata mencapai $175,1151 \text{ W/m}^2$. Selain itu, hasil analisis error menunjukkan nilai MAE sebesar $474,2918 \text{ W/m}^2$ dan RMSE sebesar $655,2999 \text{ W/m}^2$, yang menandakan perbedaan pengukuran yang cukup signifikan. Dari sisi kestabilan data, standar deviasi HONDE sebesar $483,8502$ lebih tinggi dibandingkan AWS UNDIP sebesar $301,1616$. Hal ini menunjukkan bahwa data iradiasi HONDE memiliki fluktuasi yang lebih besar dan cenderung lebih *noisy* dibandingkan data AWS UNDIP. Secara keseluruhan, sensor HONDE telah mampu mendeteksi pola umum perubahan iradiasi matahari, khususnya siklus siang dan malam. Namun akurasi nilai pengukuran masih memiliki deviasi yang cukup besar.




Gambar 4. 18 Grafik Perbandingan Parameter Curah Hujan Sensor Honde dan AWS Undip

Berdasarkan hasil perbandingan data curah hujan antara sensor HONDE dan AWS UNDIP, pola perubahan curah hujan pada sensor HONDE belum sepenuhnya mampu mengikuti data AWS UNDIP. Gambar 4.18 memperlihatkan bahwa AWS UNDIP mencatat beberapa kejadian hujan dengan intensitas yang cukup tinggi, sedangkan sensor HONDE cenderung menghasilkan nilai curah hujan yang sangat rendah dan relatif konstan mendekati nol. Perbedaan tersebut terlihat dari rata-rata curah hujan AWS UNDIP sebesar $7,0192 \text{ mm/h}$, sedangkan sensor HONDE hanya sebesar $0,0138 \text{ mm/h}$, dengan selisih rata-rata mencapai $-7,0054 \text{ mm/h}$. Selain itu, hasil analisis error menunjukkan nilai MAE sebesar $7,0059 \text{ mm/h}$ dan RMSE sebesar $15,2862 \text{ mm/h}$, menunjukkan adanya perbedaan pengukuran yang cukup besar antara kedua sensor.

Dari sisi kestabilan data, standar deviasi HONDE sebesar 0,1840 jauh lebih kecil dibandingkan AWS UNDIP sebesar 13,6102. Perbedaan ini terutama disebabkan oleh metode pengolahan data pada sistem HONDE yang menggunakan nilai selisih antar pembacaan (interval rainfall) bukan nilai akumulasi total, sehingga sebagian besar nilai tersimpan bernilai nol ketika tidak terjadi hujan dan secara langsung menyebabkan standar deviasi menjadi sangat kecil. Selain itu, resolusi tipping bucket sebesar 0,2 mm per tip menyebabkan hujan intensitas sangat rendah tidak terdeteksi apabila akumulasi belum mencapai ambang batas satu tip dalam satu interval. Faktor lain yang turut berkontribusi meliputi perbedaan kalibrasi, resolusi pembacaan, dan kondisi lokal di sekitar masing-masing sensor. Secara keseluruhan, perbedaan statistik antara HONDE dan AWS UNDIP lebih mencerminkan perbedaan metode pengolahan dan resolusi sensor daripada ketidakmampuan sensor dalam merepresentasikan kondisi cuaca aktual.


4.8 Hasil dan Analisis Perbandingan Prediksi XGBoost dan Aktual

Pada subbab ini dilakukan analisis perbandingan antara data hasil prediksi XGBoost dengan data aktual sensor Honde pada rentang waktu 1 April 2026 sampai dengan 30 April 2026. Garis grafik berwarna biru merupakan grafik data aktual sedangkan grafik berwarna oranye merupakan grafik data prediksi XGBoost. Perbandingan dilakukan terhadap parameter iradiasi matahari, suhu, kelembapan, dan curah hujan untuk mengetahui tingkat kesesuaian pola data yang dihasilkan oleh sistem prediksi terhadap data aktual. Analisis ini bertujuan untuk mengevaluasi kemampuan sistem dalam memprediksi kondisi cuaca aktual di lingkungan pengujian.



Gambar 4. 19 Grafik Perbandingan Nilai Suhu Prediksi dan Aktual


Gambar 4.19 menunjukkan perbandingan suhu antara hasil prediksi XGBoost dan data aktual selama April 2026, terlihat bahwa model prediksi telah mampu mengikuti pola perubahan suhu secara umum. Hal ini terlihat dari tren kenaikan dan penurunan suhu yang relatif serupa antara data prediksi dan data aktual pada sebagian besar periode pengamatan. Secara visual, pola harian suhu masih dapat dikenali dengan cukup baik oleh model, terutama pada perubahan suhu dari pagi menuju siang dan penurunan suhu pada sore hari. Namun, rentang perubahan suhu pada hasil prediksi cenderung lebih kecil dibandingkan data aktual. Data aktual menunjukkan fluktuasi yang lebih tajam dengan rentang suhu sekitar 24–36 °C, sedangkan hasil prediksi lebih stabil pada rentang sekitar 27–32 °C. Berdasarkan analisis selisih rata-rata, nilai prediksi suhu memiliki rata-rata sebesar 29,5169 °C, sedangkan data aktual sebesar 30,9831 °C. Selisih rata-rata sebesar -1,4661 °C menunjukkan bahwa model XGBoost menghasilkan prediksi suhu yang lebih rendah dibandingkan kondisi aktual. Dari hasil analisis error diperoleh nilai MAE sebesar 2,6863 °C dan RMSE sebesar 3,2375 °C, yang menunjukkan bahwa rata-rata deviasi prediksi terhadap data aktual masih berada dalam rentang yang cukup dapat diterima untuk pemodelan cuaca lokal.



Gambar 4. 20 Grafik Perbandingan Nilai Kelembapan Prediksi dan Aktual

Gambar 4.20 menunjukkan perbandingan kelembapan antara hasil prediksi XGBoost dan data aktual selama April 2026, terlihat bahwa model masih mampu mengikuti pola umum perubahan kelembapan, namun tingkat kesesuaiannya relatif lebih rendah dibandingkan parameter suhu. Secara visual, tren naik dan turun kelembapan masih terlihat mengikuti pola harian yang serupa, terutama pada beberapa periode ketika kelembapan meningkat pada pagi atau malam hari dan


menurun pada siang hari. Meskipun demikian, hasil prediksi cenderung menghasilkan nilai kelembapan yang lebih tinggi dibandingkan data aktual. Hal ini terlihat dari dominasi kurva prediksi yang berada pada rentang sekitar 78–93%, sedangkan data aktual memiliki variasi yang lebih luas, yaitu sekitar 50–95%. Selain itu, data aktual menunjukkan fluktuasi yang lebih tajam dan dinamis, dibandingkan dengan hasil prediksi yang terlihat lebih halus dan stabil. Nilai rata-rata prediksi kelembapan sebesar 84,1151% lebih tinggi dibandingkan data aktual sebesar 67,0831%, dengan selisih rata-rata sebesar 17,0321%. Dari hasil analisis error diperoleh nilai MAE sebesar 19,4918% dan RMSE sebesar 22,2599%. Walaupun akurasi prediksi kelembapan belum optimal, model masih mampu mempertahankan pola umum perubahan kelembapan harian.



Gambar 4. 21 Grafik Perbandingan Nilai Iradiasi Prediksi dan Aktual

Gambar 4.21 menunjukkan perbandingan iradiasi antara hasil prediksi XGBoost dan data aktual selama April 2026, pola kenaikan iradiasi pada siang hari serta penurunan pada pagi dan sore hari masih dapat dikenali pada hasil prediksi. Namun terdapat perbedaan yang cukup signifikan antara nilai prediksi dan data aktual. Data aktual menunjukkan fluktuasi iradiasi yang sangat tajam dengan rentang sekitar 0–1200 W/m², sedangkan hasil prediksi cenderung lebih stabil pada rentang sekitar 400–900 W/m². Pada beberapa periode, data aktual mengalami penurunan iradiasi secara drastis hingga mendekati nol akibat pengaruh awan, hujan, atau perubahan cuaca mendadak. Rata-rata hasil prediksi iradiasi sebesar 683,6051 W/m², sedangkan data aktual sebesar 735,7401 W/m². Selisih rata-rata sebesar -52,1350 W/m² menunjukkan bahwa model cenderung menghasilkan prediksi iradiasi yang lebih rendah dibandingkan kondisi aktual. Dari hasil analisis

error diperoleh nilai MAE sebesar 390,7135 W/m² dan RMSE sebesar 435,1444 W/m², menunjukkan bahwa deviasi prediksi terhadap data aktual masih cukup besar. Meskipun demikian, model masih mampu mempertahankan pola umum iradiasi harian dan mendeteksi kecenderungan perubahan radiasi matahari.




Gambar 4. 22 Grafik Perbandingan Nilai Curah Hujan Prediksi dan Aktual

Gambar 4.22 menunjukkan perbandingan curah hujan antara hasil prediksi XGBoost dan data aktual selama April 2026, Data aktual menunjukkan bahwa kejadian hujan muncul pada waktu tertentu saja dengan intensitas yang berubah secara cepat. Sebaliknya, hasil prediksi cenderung lebih stabil dengan nilai curah hujan rendah dan kontinu. Pada beberapa kejadian hujan, model XGBoost masih mampu mendeteksi adanya peningkatan curah hujan, namun besar intensitas yang diprediksi umumnya jauh lebih kecil dibandingkan data aktual. Hal ini terlihat pada beberapa puncak hujan aktual yang mencapai lebih dari 3–6 mm/h, sementara hasil prediksi hanya berada pada kisaran di bawah 1 mm/h. Selain itu, terdapat beberapa kondisi ketika model memprediksi adanya hujan ringan meskipun data aktual menunjukkan tidak terjadi hujan. Rata-rata curah hujan hasil prediksi sebesar 0,1595 mm/h sedikit lebih tinggi dibandingkan data aktual sebesar 0,1356 mm/h. Dari hasil analisis error diperoleh nilai MAE sebesar 0,2629 mm/h dan RMSE sebesar 0,7247 mm/h. Secara numerik nilai error terlihat kecil karena sebagian besar data curah hujan berada pada kondisi tanpa hujan atau bernilai rendah. Meskipun akurasi prediksi curah hujan belum optimal, model masih mampu memberikan gambaran umum mengenai potensi terjadinya hujan ringan pada beberapa periode tertentu.

4.9 Hasil dan Analisis Prediksi XGBoost dengan Visual Crossing


Pada tahap ini dilakukan proses evaluasi dan analisis terhadap hasil prediksi parameter cuaca yang dihasilkan oleh model XGBoost pada periode 1 April 2026 hingga 30 April 2026 dengan membandingkannya terhadap data weather forecasting dari platform Visual Crossing. Visual Crossing dipilih sebagai data pembandingan karena pada pengujian menggunakan ground truth awal berbasis BMKG, platform ini menunjukkan tingkat akurasi klasifikasi yang paling tinggi dibandingkan platform forecasting lainnya. Selain itu, Visual Crossing juga memiliki pola prediksi yang relatif lebih stabil dan tingkat error yang lebih kecil. Garis grafik berwarna biru merupakan grafik data prediksi XGBoost sedangkan grafik berwarna kuning merupakan grafik data Visual Crossing.



Gambar 4. 23 Grafik Perbandingan Nilai Suhu XGBoost dan Visual Crossing

Berdasarkan grafik perbandingan suhu antara hasil prediksi model XGBoost dan data Visual Crossing yang tersaji pada gambar 4.23, terlihat bahwa pola perubahan suhu yang dihasilkan oleh model XGBoost memiliki kesesuaian yang cukup baik dengan data pembandingan. Kedua kurva menunjukkan tren fluktuasi harian yang relatif serupa, baik pada saat terjadi kenaikan maupun penurunan suhu, meskipun masih terdapat selisih pada beberapa titik pengamatan. Hasil evaluasi statistik menunjukkan bahwa nilai rata-rata suhu hasil prediksi sebesar $29,72^{\circ}\text{C}$, sedangkan nilai rata-rata Visual Crossing sebesar $29,49^{\circ}\text{C}$, dengan selisih yang sangat kecil yaitu sebesar $0,22^{\circ}\text{C}$. Hal ini menunjukkan bahwa model memiliki tingkat bias yang rendah dalam memprediksi suhu. Nilai MAE sebesar $1,3965^{\circ}\text{C}$ dan RMSE sebesar $1,7085^{\circ}\text{C}$ mengindikasikan bahwa tingkat kesalahan prediksi relatif kecil. Nilai korelasi Pearson sebesar $0,5244$ menunjukkan adanya hubungan linear sedang


antara hasil prediksi dan data aktual, yang menandakan bahwa model cukup mampu menangkap pola perubahan suhu. Hasil prediksi pada parameter suhu menunjukkan performa yang baik. Hal ini disebabkan oleh pola perubahan suhu yang cenderung stabil dan berlangsung secara bertahap. Dibandingkan dengan parameter lain seperti curah hujan dan iradiasi matahari yang dapat berubah secara cepat, suhu memiliki fluktuasi yang lebih rendah sehingga pola datanya lebih mudah dikenali oleh model XGBoost. Kondisi tersebut membuat hasil prediksi suhu mampu mengikuti pola data aktual dengan cukup baik.



Gambar 4. 24 Grafik Perbandingan Nilai Kelembapan XGBoost dan Visual Crossing


Berdasarkan grafik perbandingan kelembapan antara hasil prediksi XGBoost dan data Visual Crossing yang tersaji pada gambar 4.24, terlihat bahwa pola perubahan kelembapan yang dihasilkan model XGBoost memiliki kecenderungan yang relatif mengikuti pola data Visual Crossing, meskipun masih terdapat selisih nilai pada beberapa waktu pengamatan. Secara umum, prediksi XGBoost cenderung menghasilkan nilai kelembapan yang lebih tinggi dibandingkan Visual Crossing. Hasil evaluasi statistik menunjukkan bahwa nilai rata-rata kelembapan hasil prediksi sebesar 74,90%, sedangkan Visual Crossing sebesar 84,07%. Nilai MAE sebesar 11,61% dan RMSE sebesar 14,81% menunjukkan bahwa masih terdapat perbedaan yang cukup signifikan antara hasil prediksi dan data Visual Crossing. Selain itu, nilai korelasi sebesar -0,2094 menunjukkan hubungan linear yang lemah antara kedua data. Meskipun demikian, pola fluktuasi kelembapan harian pada beberapa periode masih menunjukkan kecenderungan perubahan yang serupa. Perbedaan nilai yang cukup besar dipengaruhi oleh karakteristik cuaca lokal, perbedaan metode pengukuran pada platform Visual Crossing, serta keterbatasan

model XGBoost dalam memprediksi parameter kelembapan secara real-time. Hasil ini menunjukkan bahwa model XGBoost masih mampu mengikuti pola umum perubahan kelembapan, namun akurasi prediksi kelembapan terhadap data Visual Crossing masih perlu ditingkatkan.



Gambar 4. 25 Grafik Perbandingan Nilai Iradiasi XGBoost dan Visual Crossing

Berdasarkan grafik perbandingan iradiasi antara hasil prediksi model XGBoost dan data Visual Crossing yang tersaji pada gambar 4.25, terlihat bahwa pola iradiasi yang dihasilkan oleh model XGBoost memiliki kecenderungan yang lebih stabil dibandingkan dengan data Visual Crossing yang menunjukkan fluktuasi harian yang cukup tajam. Hasil evaluasi statistik menunjukkan bahwa nilai prediksi XGBoost cenderung berada di bawah nilai aktual Visual Crossing dimana nilai rata-rata prediksi sebesar $471,77 \text{ W/m}^2$, sedangkan nilai rata-rata aktual sebesar $686,49 \text{ W/m}^2$, dengan selisih rata-rata sebesar $-214,72 \text{ W/m}^2$. Nilai bias negatif ini menunjukkan bahwa model memiliki kecenderungan underestimate terhadap nilai iradiasi yang sebenarnya. Dari sisi error, nilai MAE sebesar $292,27 \text{ W/m}^2$ dan RMSE sebesar $343,11 \text{ W/m}^2$ menunjukkan bahwa terdapat perbedaan yang cukup signifikan antara hasil prediksi dan data pembandingan. Nilai korelasi Pearson sebesar $0,2413$ menunjukkan bahwa hubungan linear antara hasil prediksi dan data aktual tergolong lemah. Hal ini disebabkan oleh karakteristik iradiasi yang sangat dinamis dan dipengaruhi perubahan kondisi atmosfer, terutama tutupan awan yang dapat berubah secara cepat. Hal ini menyebabkan fluktuasi iradiasi yang tinggi dalam waktu singkat sehingga sulit diprediksi oleh model yang tidak mempertimbangkan aspek temporal seperti cloud cover, berbeda dengan suhu yang cenderung stabil.



Gambar 4. 26 Grafik Perbandingan Nilai Curah Hujan XGBoost dan Visual Crossing

Berdasarkan grafik perbandingan curah hujan antara hasil prediksi model XGBoost dan data Visual Crossing yang tersaji pada gambar 4.26, terlihat bahwa pola curah hujan yang dihasilkan oleh model XGBoost cenderung lebih stabil dan berada pada nilai dibawah 1 mm/h, sedangkan data Visual Crossing menunjukkan pola fluktuatif dengan beberapa lonjakan nilai yang signifikan pada waktu tertentu. Secara umum, model XGBoost belum mampu menangkap kejadian hujan dengan intensitas tinggi yang ditunjukkan oleh data Visual Crossing. Visual Crossing menunjukkan lonjakan curah hujan hingga lebih dari 6 mm/h, sementara prediksi model tetap berada pada rentang 0-0,66 mm/h. Hasil evaluasi statistik menunjukkan bahwa nilai rata-rata curah hujan hasil prediksi sebesar 0,3828 mm/h, sedangkan nilai rata-rata aktual sebesar 0,1547 mm/h, dengan selisih sebesar 0,228 mm/h. Nilai MAE sebesar 0,4052 dan RMSE sebesar 0,9186 menunjukkan adanya deviasi yang cukup besar antara hasil prediksi dan data aktual. Nilai korelasi Pearson sebesar -0,0312 menunjukkan bahwa hubungan linear antara hasil prediksi dan data aktual hampir tidak ada. Hal ini menandakan bahwa model tidak mampu mengikuti pola perubahan curah hujan secara konsisten, dikarenakan karakteristik curah hujan yang bersifat sporadis dan tidak kontinu. Pola ini sulit dipelajari oleh model seperti XGBoost, dibandingkan parameter lain seperti suhu dan kelembapan yang lebih stabil, curah hujan memiliki fluktuasi tinggi dalam waktu singkat.

4.10 Pengujian Sistem Klasifikasi

Pada tahap ini dilakukan pengujian terhadap sistem klasifikasi cuaca berbasis Multilayer Perceptron (MLP). Pengujian dilakukan untuk mengetahui kemampuan

model dalam mengklasifikasikan data parameter cuaca menjadi kategori cuaca, yaitu cerah, berawan, hujan sedang, dan hujan lebat. Data yang digunakan pada proses klasifikasi terdiri dari parameter iradiasi matahari, suhu udara, curah hujan, dan kelembapan. Secara umum, pembahasan pada subbab ini meliputi rancangan dan konfigurasi model MLP, hasil pelatihan dan validasi, evaluasi kinerja model, serta analisis proses klasifikasi berdasarkan bobot dan aktivasi neuron. Dataset yang digunakan berasal dari tabel collect_mlpdataset yang merupakan gabungan dari dataset AWS undip pada rentang 1 Januari 2025 hingga 2 Februari 2026 yang kemudian dilanjutkan dengan proses akuisisi data dari sistem hingga 31 Mei 2026.

4.10.1 Rancangan dan Konfigurasi Model MLP

Model klasifikasi cuaca yang digunakan pada penelitian ini adalah Multilayer Perceptron (MLP). Model ini dirancang sebagai tahap klasifikasi akhir pada sistem stasiun cuaca berbasis LoRa, yaitu untuk mengubah data parameter cuaca berbentuk numerik menjadi label kategori cuaca. Parameter input yang digunakan terdiri dari empat variabel, yaitu iradiasi matahari, suhu udara, curah hujan, dan kelembapan. Keempat parameter tersebut dipilih karena memiliki hubungan langsung terhadap perubahan kondisi cuaca dan digunakan sebagai dasar dalam proses pembentukan label klasifikasi. Tabel 4.12 menunjukkan model yang digunakan merupakan Multilayer Perceptron dengan empat parameter input, yaitu iradiasi, suhu, curah hujan, dan kelembapan. Model terdiri dari tiga hidden layer dengan masing-masing 32, 16, dan 8 neuron, serta satu output layer dengan 4 neuron yang merepresentasikan kelas kondisi cuaca, yaitu cerah, berawan, hujan sedang, dan hujan lebat. Fungsi aktivasi yang digunakan pada hidden layer adalah ReLU, sedangkan pada output layer menggunakan Softmax untuk menghasilkan probabilitas klasifikasi.

Tabel 4. 12 Konfigurasi Pelatihan Model

Parameter	Konfigurasi
Input Features	Irradiance, Temperature, Precipitation, Humidity
Hidden Layer 1	32 Neuron
Hidden Layer 2	16 Neuron

Parameter	Konfigurasi
Hidden Layer 3	8 Neuron
Output Layer	4 Neuron
Hidden Activation	ReLU
Output Activation	Softmax
Optimizer	Adam
Loss Function	Sparse Categorical Crossentropy
Epoch	100
Batch Size	32
Dropout	0.2 (layer 1), 0.1 (layer 2)
Class Weight	Balanced
Early Stopping	Patience = 10

Selain arsitektur layer, model juga dikonfigurasi menggunakan optimizer Adam dengan fungsi loss sparse categorical crossentropy. Adam optimizer digunakan karena mampu melakukan pembaruan bobot secara adaptif selama proses pelatihan, sedangkan sparse categorical crossentropy digunakan karena permasalahan yang diselesaikan merupakan klasifikasi multi-kelas dengan label numerik. Untuk mengurangi risiko overfitting, model dilengkapi dengan teknik regularisasi berupa dropout sebesar 0,2 pada hidden layer pertama dan 0,1 pada hidden layer kedua. Selain itu, diterapkan early stopping dengan nilai patience sebesar 10 agar proses pelatihan berhenti secara otomatis ketika performa validasi tidak lagi mengalami peningkatan yang signifikan.

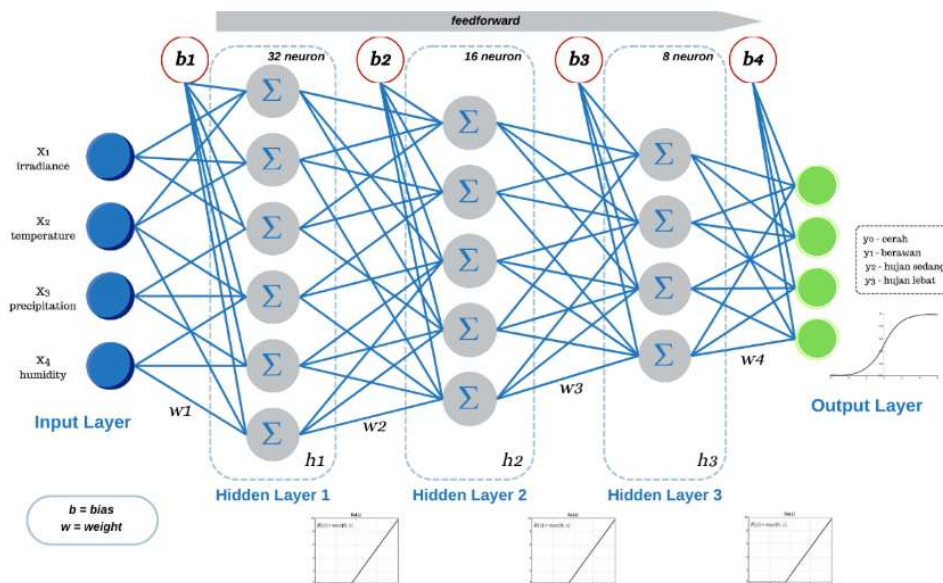
Selain itu, distribusi jumlah data pada setiap kelas juga diperhatikan karena dataset yang digunakan memiliki kondisi tidak seimbang. Kelas Berawan memiliki jumlah data terbanyak, yaitu 25.071 data, sedangkan kelas Hujan Lebat memiliki jumlah data paling sedikit, yaitu 3.752 data. Ketidakseimbangan jumlah data ini dapat menyebabkan model lebih cenderung mempelajari kelas dengan jumlah data dominan dan kurang optimal dalam mengenali kelas minoritas. Untuk mengatasi kondisi tersebut, digunakan metode class weight balanced selama proses pelatihan. Class weight berfungsi untuk memberikan bobot yang berbeda pada setiap kelas

saat perhitungan loss dilakukan. Kelas dengan jumlah data lebih sedikit diberikan bobot yang lebih besar agar pengaruhnya terhadap proses pembaruan bobot model menjadi lebih seimbang. Berdasarkan hasil perhitungan, kelas Hujan Lebat memperoleh nilai class weight paling besar, yaitu 4,104, karena memiliki jumlah data paling sedikit. Sebaliknya, kelas Berawan memperoleh class weight paling kecil, yaitu 0,614, karena memiliki jumlah data paling banyak. Hasil perhitungan class weight ditunjukkan pada tabel 4.13.

Tabel 4. 13 Hasil Class Weight

Kelas	Jumlah	Class Weight
Cerah	19788	0,778
Berawan	25071	0,614
Hujan Sedang	12971	1,187
Hujan Lebat	3752	4,104
Total	61582	

Setelah konfigurasi pelatihan dan penanganan ketidakseimbangan kelas ditentukan, arsitektur model MLP direpresentasikan pada Gambar 4.27. Gambar tersebut menunjukkan alur pemrosesan data dari input layer, hidden layer hingga output layer.



Gambar 4. 27 Arsitektur MLP pada Sistem Klasifikasi LoRa

4.10.2 Hasil Pelatihan dan Validasi Model

Setelah rancangan dan konfigurasi model MLP ditentukan, tahap selanjutnya adalah melakukan proses pelatihan dan validasi model. Proses ini bertujuan untuk membentuk parameter model berupa bobot dan bias, serta menguji kemampuan model dalam mengklasifikasikan kondisi cuaca ke dalam empat kategori, yaitu Cerah, Berawan, Hujan Sedang, dan Hujan Lebat. Dataset yang digunakan merupakan dataset gabungan yang terdiri dari data AWS Universitas Diponegoro dan data hasil pengembangan sistem. Setelah dilakukan proses pembersihan data dan penghapusan data duplikat, diperoleh total dataset bersih sebanyak 72.630 baris data. Dataset tersebut kemudian dibagi menjadi dua bagian utama. Sebanyak 10% data atau 7.263 baris data dipisahkan sebagai data holdout independen yang tidak digunakan dalam proses pelatihan maupun validasi silang. Sementara itu, sebanyak 90% data atau 65.367 baris data digunakan sebagai training pool. Data pada training pool digunakan dalam proses pelatihan, validasi, dan pengujian menggunakan metode 5-Fold Cross Validation. Pembagian data ini dilakukan agar model tidak hanya diuji pada data yang digunakan selama proses pelatihan, tetapi juga dapat dievaluasi terhadap data yang belum pernah dilihat sebelumnya.

1. Pelatihan Model

Pada tahap pelatihan, model MLP dibangun berdasarkan arsitektur yang telah dirancang sebelumnya, yaitu 4 neuron input, tiga hidden layer dengan jumlah neuron 32, 16, dan 8, serta 4 neuron output. Empat neuron input digunakan untuk menerima parameter iradiasi matahari, suhu udara, curah hujan, dan kelembapan, sedangkan neuron output digunakan untuk menghasilkan klasifikasi ke dalam kelas Cerah, Berawan, Hujan Sedang, dan Hujan Lebat. Data input kemudian diproses melalui tahap feed forward untuk menghasilkan prediksi awal. Pada proses ini, setiap nilai input dikalikan dengan bobot, dijumlahkan dengan bias, dan diproses menggunakan fungsi aktivasi ReLU pada hidden layer. Hasil prediksi model selanjutnya dibandingkan dengan label aktual menggunakan sparse categorical crossentropy. Nilai loss yang diperoleh menunjukkan besar kesalahan prediksi model terhadap label sebenarnya. Nilai loss tersebut kemudian digunakan pada proses backpropagation untuk menghitung arah perubahan bobot dan bias pada

setiap layer. Setelah gradien diperoleh, Adam optimizer digunakan untuk memperbarui parameter model secara bertahap agar nilai loss semakin kecil. Dengan demikian, proses feed forward, loss function, backpropagation, dan Adam optimizer berperan dalam membentuk bobot dan bias model hingga mampu membedakan kategori cuaca dengan baik.

Untuk memperjelas proses pelatihan model, dilakukan contoh peninjauan terhadap perhitungan *loss function*, *backpropagation*, dan pembaruan bobot menggunakan Adam optimizer. Pada contoh perhitungan ini digunakan satu sampel data cuaca dengan nilai input iradiasi matahari sebesar $1021,59 \text{ W/m}^2$, suhu udara sebesar $26,73^\circ\text{C}$, curah hujan sebesar $0,17 \text{ mm/h}$, dan kelembapan sebesar $75,85\%$. Nilai input tersebut terlebih dahulu dinormalisasi menggunakan StandardScaler sehingga diperoleh nilai terstandarisasi sebesar $[2.4471, 0.01034, -0.3288, -0.3375]$. Selanjutnya, nilai hasil normalisasi diproses melalui tahapan feed forward pada model MLP dan menghasilkan probabilitas Softmax sebesar 0.987684 untuk kelas Cerah, 0.012315 untuk kelas Berawan, 0.000001 untuk kelas Hujan Sedang, dan $0,000000$ untuk kelas Hujan Lebat. Karena probabilitas tertinggi terdapat pada kelas Cerah, maka sampel data tersebut diklasifikasikan sebagai Cerah. Hasil output Softmax ini kemudian digunakan sebagai dasar dalam contoh perhitungan loss function, backpropagation, dan pembaruan bobot menggunakan Adam optimizer.

$$y_{pred} = [0.987684, 0.012315, 0.000001, 0]$$

Urutan kelas pada output model adalah: [Cerah, Berawan, Hujan Sedang, Hujan Lebat]. Karena label aktual pada sampel tersebut adalah kelas Cerah, maka target aktual dapat ditulis dalam bentuk:

$$y_{target} = [1, 0, 0, 0]$$

Nilai loss dihitung dengan menggunakan sparse categorical crossentropy. Karena kelas aktual adalah Cerah, maka nilai loss dihitung berdasarkan probabilitas kelas Cerah. Sehingga didapatkan nilai *loss* sebesar 0.012392 menunjukkan bahwa kesalahan prediksi model pada sampel tersebut tergolong kecil. Hal ini disebabkan model memberikan probabilitas yang tinggi pada kelas aktual, yaitu Cerah.

Setelah nilai *loss* diperoleh, proses *backpropagation* dilakukan untuk menghitung gradien error pada output model. Pada kombinasi fungsi Softmax dan *categorical crossentropy*, gradien output dapat dihitung dari selisih antara probabilitas prediksi dan target aktual. Sehingga didapat gradien output:

$$dZ_{out} = [0.987684, 0.012315, 0.000001, 0] - [1, 0, 0, 0]$$

$$dZ_{out} = [-0.012316, 0.012315, 0.000001, 0.000000]$$

Nilai gradien negatif pada kelas Cerah menunjukkan bahwa kontribusi bobot menuju kelas aktual perlu diperkuat. Sebaliknya, nilai gradien positif pada kelas Berawan, Hujan Sedang, dan Hujan Lebat menunjukkan bahwa kontribusi terhadap kelas tersebut perlu dikurangi karena bukan merupakan label aktual. Gradien pada output layer kemudian digunakan untuk menghitung perubahan bobot dari *hidden layer* terakhir menuju output layer. Pada contoh perhitungan, neuron aktif pada *hidden layer* 3 memiliki nilai aktivasi $y_3[6] = 0.913721$ dan $y_3[7] = 7.681093$. Gradien bobot menuju output kelas Cerah dihitung dengan mengalikan nilai aktivasi neuron dengan gradien kelas Cerah. Sehingga didapatkan

$$dW_{6,Cerah} = -0.011253$$

$$dW_{7,Cerah} = -0.094600.$$

Nilai gradien bobot tersebut menunjukkan arah perubahan parameter pada koneksi menuju output kelas Cerah. Karena gradien bernilai negatif, maka proses optimasi akan meningkatkan bobot yang berkontribusi terhadap kelas Cerah agar probabilitas kelas aktual dapat meningkat pada iterasi berikutnya. Selanjutnya, pembaruan bobot dilakukan menggunakan Adam optimizer. Parameter Adam optimizer yang digunakan adalah *learning rate* $\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$, dan $\epsilon = 1 \times 10^{-7}$. Sebagai contoh, digunakan gradien bobot $dW_{6,Cerah} = -0.011253$. Jika bobot lama pada koneksi neuron ke-6 *hidden layer* 3 menuju kelas Cerah adalah $W_{lama} = 1.497534$, maka hasil pembaruan menggunakan Adam optimizer menghasilkan bobot baru sekitar:


$$W_{baru} \approx 1.498534$$

Berdasarkan hasil perhitungan tersebut, bobot pada koneksi neuron ke-6 *hidden layer* 3 menuju kelas Cerah mengalami perubahan dari 1,497534 menjadi sekitar 1,498534. Peningkatan bobot ini terjadi karena gradien bernilai negatif, sehingga

Adam optimizer memperbesar kontribusi bobot yang mengarah pada kelas aktual, yaitu Cerah. Proses pembaruan yang sama dilakukan pada bobot dan bias lainnya selama proses pelatihan berlangsung. Berdasarkan proses tersebut, dapat diketahui bahwa loss function berperan untuk mengukur besar kesalahan prediksi, backpropagation digunakan untuk menghitung arah perubahan bobot dan bias, sedangkan Adam optimizer digunakan untuk memperbarui parameter model secara bertahap. Proses ini dilakukan secara berulang pada setiap epoch hingga model memperoleh bobot dan bias terbaik untuk membedakan kelas Cerah, Berawan, Hujan Sedang, dan Hujan Lebat.

2. Validasi Model

Setelah proses pembaruan bobot dan bias dilakukan secara berulang selama pelatihan, diperoleh bobot dan bias akhir pada model MLP. Bobot dan bias tersebut merepresentasikan hasil pembelajaran model terhadap hubungan antara parameter cuaca dan label kelas yang telah ditentukan. Selanjutnya, bobot dan bias akhir digunakan untuk melakukan klasifikasi pada data validasi. Untuk mengetahui kemampuan model dalam mengenali setiap kelas cuaca, evaluasi awal dilakukan menggunakan confusion matrix. Confusion matrix digunakan untuk mengetahui sebaran hasil klasifikasi model terhadap setiap kelas, baik data yang diklasifikasikan dengan benar maupun data yang mengalami kesalahan klasifikasi. Dari confusion matrix tersebut dapat diketahui nilai true positive, false positive, false negative, dan true negative pada masing-masing kelas. Nilai-nilai tersebut kemudian menjadi dasar perhitungan metrik evaluasi, seperti accuracy, precision, recall, dan F1-score.



Gambar 4. 28 Confusion Matrix Model


Berdasarkan confusion matrix pada Gambar 4.28, dominasi nilai pada diagonal utama matriks menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar. Pada kelas Cerah, seluruh 3.578 data berhasil diklasifikasikan dengan benar. Pada kelas Berawan, 5.049 data berhasil diklasifikasikan dengan benar dan 9 data salah diklasifikasikan sebagai Cerah. Pada kelas Hujan Sedang, 2.471 data berhasil diklasifikasikan dengan benar dan 3 data salah diprediksi sebagai Hujan Lebat. Sementara itu, pada kelas Hujan Lebat, 830 data berhasil diklasifikasikan dengan benar dan 2 data salah diklasifikasikan sebagai Hujan Sedang. Dengan demikian, confusion matrix model awal menunjukkan bahwa model sudah mampu membedakan pola pada setiap kelas cuaca dengan tingkat kesalahan yang rendah. Kemudian, dilakukan perhitungan metrik evaluasi untuk memperoleh nilai performa model secara kuantitatif. Metrik evaluasi yang digunakan terdiri dari accuracy, precision, recall, dan F1-score.

Tabel 4. 14 Hasil Evaluasi Metrik

Label	Kategori	Precision	Recall	F1-Score	Data Support
0	Cerah	0.99749	1	0.99874	3578
1	Berawan	1	0.99822	0.99911	5058
2	Hujan Sedang	0,9991	0.99879	0.99899	2474
3	Hujan Lebat	0.99640	0.99760	0.99700	832

Label	Kategori	Precision	Recall	F1-Score	Data Support
	Akurasi			0.99883	11942
	Macro Avg.	0.99827	0.99865	0.99846	11942
	Weighted Avg.	0.99883	0.99883	0.99883	11942

Berdasarkan Tabel 4.14, model awal memperoleh nilai accuracy sebesar 99,883%. Nilai precision, recall, dan F1-score pada setiap kelas juga berada pada nilai yang tinggi. Hal ini menunjukkan bahwa model MLP mampu mempelajari hubungan antarparameter cuaca dengan baik pada data pelatihan dan validasi. Namun, meskipun hasil evaluasi awal menunjukkan performa yang sangat baik, pengujian pada data real-time menunjukkan bahwa model tidak pernah menghasilkan klasifikasi pada kategori Hujan Sedang maupun Hujan Lebat, sehingga seluruh hasil prediksi hanya berada pada kategori Cerah dan Berawan. Permasalahan tersebut terjadi karena input model MLP pada sistem real-time berasal dari hasil prediksi parameter cuaca menggunakan model XGBoost. Berdasarkan hasil pengamatan terhadap output XGBoost, nilai curah hujan hasil prediksi memiliki rentang yang lebih sempit dibandingkan data historis AWS Universitas Diponegoro yang digunakan sebagai dasar pelabelan awal. Nilai curah hujan hasil prediksi XGBoost tidak mencapai batas threshold tertentu yang sebelumnya digunakan untuk membedakan kategori Hujan Sedang dan Hujan Lebat. Akibatnya, model MLP tidak menghasilkan klasifikasi pada kategori hujan secara optimal ketika diterapkan pada data hasil prediksi sistem.




Gambar 4. 29 Grafik Curah Hujan XGboost

Berdasarkan Gambar 4.29, nilai curah hujan hasil prediksi XGBoost cenderung berada pada rentang rendah. Kondisi ini menunjukkan adanya perbedaan karakteristik distribusi antara data historis yang digunakan pada proses pelatihan dan data hasil prediksi XGBoost yang digunakan pada sistem. Oleh karena itu, diperlukan penyesuaian threshold pelabelan seperti pada tabel 4.15 agar kategori cuaca yang digunakan dalam pelatihan model MLP lebih sesuai dengan karakteristik data input pada sistem. Penyesuaian threshold dilakukan dengan mempertimbangkan distribusi hasil prediksi XGBoost serta karakteristik parameter cuaca yang digunakan sebagai input model MLP. Penyesuaian ini dilakukan untuk mengakomodasi karakteristik prediksi XGBoost yang tidak pernah menghasilkan nilai curah hujan melebihi 0,66 mm/h, sehingga threshold yang semula mengacu pada distribusi data AWS Universitas Diponegoro tidak lagi relevan untuk kondisi real-time.

Tabel 4. 15 Treshold Curah Hujan

Kategori Cuaca	Kondisi
Cerah	Iradiasi > 950 W/m ² atau Curah hujan = 0 mm/h dan kelembapan < 76%
Berawan	Curah hujan > 0 mm/h atau kelembapan ≥ 76%
Hujan Sedang	$0.25 \leq \text{Curah Hujan} < 20 \text{ mm/h}$
Hujan Lebat	Curah Hujan ≤ 20 mm/h

Setelah threshold pelabelan disesuaikan, model MLP kembali dilatih dan dievaluasi. Evaluasi model hasil penyesuaian threshold diawali dengan melihat confusion matrix untuk mengetahui perubahan distribusi hasil klasifikasi pada setiap kelas. Confusion matrix setelah penyesuaian threshold ditunjukkan pada Gambar 4.30.



Gambar 4. 30 Confussion Matrix Model (Update)


Berdasarkan confusion matrix pada gambar 4.30, model MLP tetap menunjukkan performa klasifikasi yang sangat baik setelah penyesuaian threshold. Pada kelas Cerah, 3.998 data berhasil diklasifikasikan dengan benar dan 5 data salah diklasifikasikan sebagai Berawan. Pada kelas Berawan, 5.644 data berhasil diklasifikasikan dengan benar dan 4 data salah diklasifikasikan sebagai Cerah. Pada kelas Hujan Sedang, 2.637 data berhasil diklasifikasikan dengan benar dan 3 data salah diklasifikasikan sebagai Hujan Lebat. Sementara itu, pada kelas Hujan Lebat, 783 data berhasil diklasifikasikan dengan benar tanpa kesalahan prediksi. Hasil ini menunjukkan bahwa penyesuaian threshold mampu membuat model tetap mempertahankan performa klasifikasi yang tinggi pada empat kategori cuaca. Setelah confusion matrix diperoleh, dilakukan perhitungan metrik evaluasi untuk melihat performa model secara kuantitatif. Hasil evaluasi metrik model setelah penyesuaian threshold ditunjukkan pada Tabel 4.16.

Tabel 4. 16 Hasil Evaluasi Metrik (Update)

Label	Kategori	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Data Support</i>
0	Cerah	0.99900	0.99875	0.99888	4003
1	Berawan	0.99911	0.99929	0.99920	5648
2	Hujan Sedang	1	0.99886	0.99943	2640
3	Hujan Lebat	0.99618	1	0.99809	783

Label	Kategori	Precision	Recall	F1-Score	Data Support
	Akurasi			0.99908	13074
	Macro Avg.	0.99857	0.99923	0.99890	13074
	Weighted Avg.	0.99908	0.99908	0.99908	13074

Berdasarkan Tabel 4.16, performa klasifikasi model MLP setelah penyesuaian threshold tetap menunjukkan hasil yang sangat baik. Model memperoleh nilai accuracy sebesar 99,908% pada 13.074 data validasi. Nilai precision, recall, dan F1-score pada seluruh kelas juga berada di atas 99%, termasuk kelas Hujan Lebat yang memiliki jumlah data paling sedikit, yaitu 783 data, namun tetap memperoleh F1-score sebesar 0,99809. Hasil tersebut menunjukkan bahwa penyesuaian threshold mampu menyesuaikan batas klasifikasi model dengan karakteristik distribusi data yang digunakan tanpa menurunkan kemampuan model dalam membedakan setiap kelas cuaca. Selain melalui confusion matrix dan metrik evaluasi, proses pelatihan model juga dianalisis menggunakan learning curve untuk melihat perkembangan nilai loss dan accuracy selama pelatihan. Analisis ini digunakan untuk mengetahui apakah model mampu belajar secara stabil serta untuk mengidentifikasi kemungkinan terjadinya overfitting maupun underfitting. Learning curve model final ditunjukkan pada Gambar 4.31.



Gambar 4. 31 Learning Curve Final Model

Gambar 4.31 menunjukkan learning curve pada proses pelatihan final model dengan menggunakan seluruh data pengembangan model dan proporsi data validasi sebesar 20%. Berdasarkan grafik tersebut, nilai loss mengalami penurunan cukup cepat pada awal pelatihan, terutama pada rentang 5 hingga 10 epoch pertama.

Setelah itu, penurunan loss mulai melambat dan cenderung stabil mendekati nilai minimum. Pola ini menunjukkan bahwa model mampu mempelajari pola data secara bertahap dan mencapai kondisi konvergen. Selama proses pelatihan, kurva training loss dan validation loss tidak menunjukkan perbedaan yang besar, sehingga model tidak memperlihatkan indikasi overfitting maupun underfitting yang signifikan. Nilai accuracy pada data pelatihan dan validasi juga berada pada tingkat yang tinggi serta cenderung stabil. Terdapat fluktuasi sementara pada sekitar epoch ke-40 hingga ke-42, ditandai dengan peningkatan singkat pada validation loss. Namun, setelah fluktuasi tersebut, model kembali menunjukkan pola konvergen. Kondisi validation loss yang berada sedikit di bawah training loss pada beberapa epoch awal masih tergolong wajar karena mekanisme dropout hanya aktif saat proses training dan dinonaktifkan pada tahap validasi.

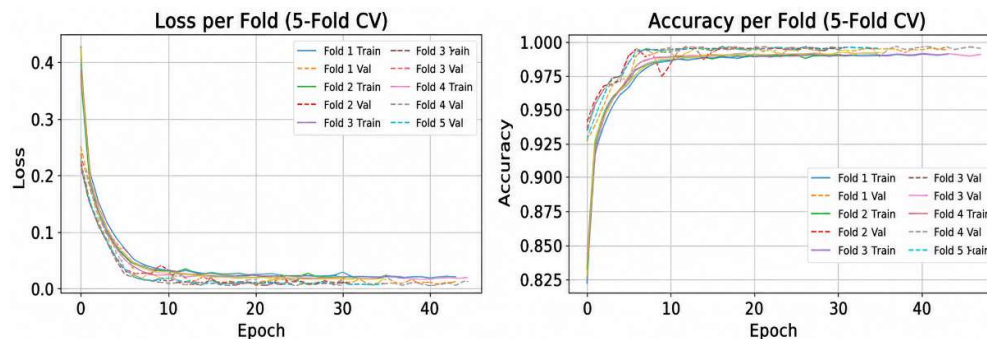
Proses pelatihan berhenti secara otomatis melalui mekanisme early stopping pada sekitar epoch ke-53 karena tidak terdapat peningkatan performa validasi yang signifikan. Penggunaan early stopping bertujuan untuk mencegah model melakukan pelatihan terlalu lama pada data training yang dapat meningkatkan risiko overfitting. Model final menghasilkan akurasi validasi sebesar 99,908% dengan waktu inferensi sebesar 0,0238 ms per sampel. Hasil tersebut menunjukkan bahwa model memiliki performa klasifikasi yang tinggi, stabil, serta cukup ringan untuk digunakan dalam proses klasifikasi cuaca pada sistem. Sebagai tahap lanjutan, dilakukan pengujian menggunakan metode 5-Fold Cross Validation untuk mengetahui kestabilan performa model pada beberapa pembagian data yang berbeda. Pada metode ini, dataset dibagi menjadi lima bagian atau fold. Setiap fold secara bergantian digunakan sebagai data validasi, sedangkan fold lainnya digunakan sebagai data pelatihan. Hasil pengujian 5-Fold Cross Validation ditunjukkan pada Tabel 4.17.

Tabel 4. 17 Hasil 5-Fold Cross Validation

Fold	Accuracy
1	0.99671
2	0.99839
3	0.99916

Fold	Accuracy
4	0.99885
5	0.99832
Mean	0.99829 ± 0.00085

Berdasarkan Tabel 4.17, seluruh fold menghasilkan nilai accuracy yang tinggi, yaitu berada di atas 99,67% dengan rentang 99,671% hingga 99,916%. Nilai rata-rata accuracy yang diperoleh sebesar 0,99829 dengan standar deviasi sebesar 0,00085. Hasil tersebut menunjukkan bahwa performa model tidak bergantung pada satu skenario pembagian data tertentu, melainkan tetap konsisten ketika diuji pada subset data yang berbeda. Selain metrik pada setiap fold, learning curve pada proses 5-Fold Cross Validation juga dianalisis untuk melihat kestabilan proses pelatihan pada setiap pembagian data. Learning curve loss dan accuracy pada 5-Fold Cross Validation ditunjukkan pada Gambar 4.32.



Gambar 4. 32 *Learning Curve Loss dan Accuracy 5 Fold*

Berdasarkan Gambar 4.32, grafik learning curve pada proses 5-Fold Cross Validation menunjukkan pola konvergensi yang stabil pada seluruh fold. Nilai loss pada data pelatihan dan validasi mengalami penurunan signifikan pada 5 hingga 10 epoch pertama, kemudian melandai dan mendekati nilai minimum. Sementara itu, nilai accuracy meningkat pada awal pelatihan dan cenderung stabil pada epoch berikutnya. Kurva training dan validation terlihat bergerak berdekatan tanpa adanya kesenjangan yang signifikan, sehingga model tidak menunjukkan indikasi overfitting maupun underfitting selama proses validasi silang. Fluktuasi kecil yang muncul pada beberapa fold, terutama sekitar epoch ke-25 hingga ke-35, tidak

memberikan pengaruh besar terhadap performa akhir model karena mekanisme early stopping membantu mempertahankan bobot terbaik selama proses pelatihan. Secara keseluruhan, hasil confusion matrix, metrik evaluasi, 5-Fold Cross Validation, dan analisis learning curve menunjukkan bahwa model MLP memiliki performa klasifikasi yang sangat baik. Model mampu membedakan empat kategori cuaca dengan tingkat kesalahan yang rendah, mempertahankan nilai accuracy yang tinggi, serta menunjukkan kestabilan performa pada berbagai subset data. Dengan demikian, model MLP dinilai layak digunakan sebagai model klasifikasi cuaca pada sistem stasiun cuaca berbasis LoRa yang dikembangkan..

4.10.3 Struktur Model Hasil pelatihan dan Bobot-Bias

Model MLP yang telah melalui proses pelatihan disimpan dalam format .keras. File tersebut memuat konfigurasi arsitektur jaringan serta parameter hasil pelatihan berupa bobot dan bias pada setiap Dense layer. Bobot merupakan nilai penghubung antar-neuron dari satu layer ke layer berikutnya, sedangkan bias merupakan nilai tambahan pada setiap neuron yang digunakan untuk membantu model menyesuaikan batas keputusan selama proses klasifikasi. Pada model MLP yang digunakan, parameter trainable terdapat pada hubungan antar-layer, yaitu Input Layer ke Hidden Layer 1, Hidden Layer 1 ke Hidden Layer 2, Hidden Layer 2 ke Hidden Layer 3, serta Hidden Layer 3 ke Output Layer. Setiap hubungan antar-layer memiliki matriks bobot dan vektor bias yang terbentuk dari hasil proses pelatihan.

Tabel 4. 18 Struktur Bobot dan Bias Model

Layer	Shape Bobot	Shape Bias	Jumlah Parameter
Input – Hidden Layer 1	4×32	32	160
Hidden Layer 1 – Hidden Layer 2	32×16	16	528
Hidden Layer 2 – Hidden Layer 3	16×8	8	136
Hidden Layer 3 – Output Layer	8×4	4	36
Total			860

Berdasarkan Tabel 4.18, model MLP memiliki total 860 parameter trainable. Jumlah tersebut merupakan akumulasi dari seluruh bobot dan bias pada setiap Dense layer. Karena jumlah parameter cukup banyak, nilai bobot dan bias lengkap disajikan pada lampiran. Pada subbab ini, pembahasan difokuskan pada struktur bobot-bias dan contoh sebagian nilai parameter untuk menunjukkan bahwa model hasil pelatihan telah terbentuk dan dapat digunakan pada proses klasifikasi.

Tabel 4. 19 Bobot Input Layer ke Hidden Layer 1

	Neuron 1	Neuron 2	Neuron 3	Neuron 4	...	Neuron 32
Input 1	-0.02133	-0.00269	-0.10115	-0.27977	...	0.435323
Input 2	-0.00234	-0.0185	0.134177	-0.05891	...	0.066536
Input 3	1.347319	-0.61752	0.711156	0.40839	...	0.662989
Input 4	-0.01202	0.73407	0.025179	-0.13011	...	0.073323

Tabel 4.19 menunjukkan sebagian nilai bobot pada hubungan Input Layer menuju Hidden Layer 1. Pada layer ini, empat parameter input yang terdiri dari iradiasi, suhu, curah hujan, dan kelembapan masing-masing terhubung dengan 32 neuron pada Hidden Layer 1. Nilai bobot pada tabel menunjukkan besar kontribusi setiap parameter input terhadap neuron pada hidden layer pertama.

Tabel 4. 20 Bias Hidden Layer 1

Neuron Ke-	Bias
1	0.437055
2	0.042625
3	-0.92242
...	...
32	-0.66651

Tabel 4.20 menunjukkan nilai bias pada Hidden Layer 1. Bias diberikan pada setiap neuron dan ditambahkan pada hasil perhitungan linear sebelum fungsi aktivasi ReLU diterapkan. Pada Hidden Layer 1 terdapat 32 nilai bias sesuai dengan jumlah neuron pada layer tersebut.

Tabel 4. 21 Bobot Hidden Layer 1 ke Hidden Layer 2

	Neuron 1	Neuron 2	Neuron 3	Neuron 4	...	Neuron 16
Input 1	0.19087	-0.03905	-2.6056	-0.01483	...	0.014102
Input 2	0.002471	-0.08073	-0.00683	0.143619	...	0.831103
Input 3	4.679471	-2.85876	-0.35897	3.010296	...	-2.12866
Input 4	0.271588	-0.45025	-0.04212	0.545927	...	-0.17326
...
Input 32	1.675433	-0.08665	0.396681	0.589667	...	-1.82788

Tabel 4.21 menunjukkan sebagian nilai bobot pada hubungan Hidden Layer 1 menuju Hidden Layer 2. Hidden Layer 1 memiliki 32 neuron, sedangkan Hidden Layer 2 memiliki 16 neuron, sehingga bobot pada layer ini membentuk matriks berukuran 32×16 . Nilai bobot tersebut digunakan untuk meneruskan hasil aktivasi dari Hidden Layer 1 menuju Hidden Layer 2.

Tabel 4. 22 Bias Hidden Layer 2

Neuron Ke-	Bias
1	0.079462
2	0.926205
3	0.187136
...	...
16	0.031191

Tabel 4.22 menunjukkan nilai bias pada Hidden Layer 2. Setiap neuron pada Hidden Layer 2 memiliki satu nilai bias yang digunakan untuk membantu model menyesuaikan hasil aktivasi pada layer tersebut. Nilai bias ini merupakan parameter hasil pelatihan yang ikut diperbarui melalui proses backpropagation.

Tabel 4. 23 Bobot Hidden Layer 2 ke Hidden Layer 3

	Neuron 1	Neuron 2	Neuron 3	Neuron 4	...	Neuron 8
Input 1	-4.39908	-0.00984	0.011002	0.121779	...	0.073087
Input 2	0.667154	0.137878	0.224829	0.529364	...	1.159224

	Neuron 1	Neuron 2	Neuron 3	Neuron 4	...	Neuron 8
Input 3	0.933369	-1.33566	-2.38734	-1.30304	...	-3.56882
Input 4	-0.18259	-0.23029	-0.28636	-0.300483	...	-0.32539
...
Input 16	0.722135	0.156105	-0.44478	0.477876	...	0.574266

Tabel 4.23 menunjukkan sebagian nilai bobot pada hubungan Hidden Layer 2 menuju Hidden Layer 3. Pada layer ini, 16 neuron dari Hidden Layer 2 terhubung dengan 8 neuron pada Hidden Layer 3. Bobot pada layer ini digunakan untuk membentuk representasi fitur yang lebih ringkas sebelum diteruskan ke output layer.

Tabel 4. 24 Bias Hidden Layer 3

Neuron Ke-	Bias
1	0.796546
2	1.26315
3	0.187219
...	...
8	0.047198

Tabel 4.24 menunjukkan nilai bias pada Hidden Layer 3. Hidden Layer 3 terdiri dari 8 neuron, sehingga terdapat 8 nilai bias pada layer tersebut. Bias pada layer ini ditambahkan sebelum aktivasi ReLU untuk membantu model menentukan neuron yang aktif dan informasi yang diteruskan menuju output layer.

Tabel 4. 25 Bobot Hidden Layer 3 ke Output Layer

	Neuron 1	Neuron 2	Neuron 3	Neuron 4
Input 1	-0.73518	1.190543	-1.05673	-4.08997
Input 2	-2.92073	-0.59177	0.468974	0.654795
Input 3	-1.05133	-0.64521	0.320607	-0.11227
Input 4	-2.3283	-0.33493	0.787248	-0.97481
...
Input 8	-0.66246	-0.76037	0.685239	-1.2611

Tabel 4.25 menunjukkan nilai bobot pada hubungan Hidden Layer 3 menuju Output Layer. Hidden Layer 3 memiliki 8 neuron, sedangkan Output Layer memiliki 4 neuron yang merepresentasikan kelas Cerah, Berawan, Hujan Sedang, dan Hujan Lebat. Nilai bobot pada layer ini menentukan kontribusi masing-masing neuron Hidden Layer 3 terhadap setiap kelas keluaran.

Tabel 4. 26 Bias Output Layer

Neuron Ke-	Bias
1	0.036724
2	0.599076
3	-0.224967
4	-0.29424

Tabel 4.26 menunjukkan nilai bias pada Output Layer. Output Layer memiliki 4 neuron, sehingga terdapat 4 nilai bias yang masing-masing berkaitan dengan kelas Cerah, Berawan, Hujan Sedang, dan Hujan Lebat. Nilai bias pada output layer ditambahkan sebelum fungsi Softmax digunakan untuk menghasilkan probabilitas pada setiap kelas. Kelas dengan probabilitas tertinggi kemudian dipilih sebagai hasil klasifikasi akhir.

4.10.4 Proses Klasifikasi MLP pada Satu Sampel Data

Pada subbab ini dijelaskan proses klasifikasi model Multilayer Perceptron (MLP) menggunakan satu sampel data cuaca. Pembahasan ini bertujuan untuk menunjukkan bagaimana parameter input diproses oleh model hingga menghasilkan kategori cuaca dan nilai confidence. Sampel data yang digunakan terdiri dari empat parameter, yaitu iradiasi matahari, suhu udara, curah hujan, dan kelembapan. Proses klasifikasi dilakukan melalui beberapa tahapan, yaitu normalisasi input, perhitungan pada hidden layer, aktivasi ReLU, perhitungan output layer, aktivasi Softmax, dan penentuan kelas akhir.

Pada tahap ini dilakukan pengujian terhadap model Multilayer Perceptron (MLP) menggunakan satu sampel data cuaca yang terdiri atas parameter irradiance, temperature, precipitation, dan humidity. Pada pengujian model, nilai parameter

yang digunakan adalah iradiasi sebesar 1021,59 W/m², suhu sebesar 26,73°C, curah hujan sebesar 0,17 mm/h, dan kelembapan sebesar 75,85%. Sebelum masuk ke model MLP, setiap nilai input terlebih dahulu diproses melalui normalisasi menggunakan StandardScaler. Normalisasi dilakukan agar seluruh parameter memiliki skala yang seragam sesuai dengan distribusi data pelatihan. Proses normalisasi dilakukan menggunakan nilai rata-rata dan standar deviasi dari data pelatihan, sehingga diperoleh nilai input terstandarisasi yang kemudian digunakan sebagai masukan pada proses klasifikasi model MLP. Hasil normalisasi input ditunjukkan pada Tabel 4.27.

Tabel 4. 27 Normalisasi Input (StandarScaler)

Parameter	Nilai Asli (x)	Mean (μ)	Std Deviasi (σ)	Hasil Scaled (xi)
Irradiance	1021.59	208.4409	332.2892	2.4471
Temperature	26.73	26.6987	3.0076	0.01034
Precipitation	0.17	3.8475	11.1830	-0.3288
Humidity	75.85	80.4411	13.6049	-0.3375

Nilai input yang telah melalui proses normalisasi atau *scaling* digunakan sebagai masukan dalam proses perhitungan pada hidden layer 1. Perhitungan nilai pada setiap neuron di hidden layer dilakukan menggunakan fungsi linear, yaitu dengan menjumlahkan hasil perkalian antara setiap input yang telah dinormalisasi dengan bobot yang bersesuaian, kemudian ditambahkan dengan nilai bias. Secara umum, proses ini menghasilkan nilai z_{1j} yang merepresentasikan output sebelum aktivasi. Berdasarkan hasil perhitungan menggunakan Persamaan (2.9), diperoleh nilai pada setiap neuron hidden layer 1 sebagai hasil kombinasi antara input terstandarisasi dengan bobot dan bias pada layer tersebut. Sebagai contoh, neuron ke-1 menghasilkan nilai $z_1[1] = -0.54188$. Selanjutnya, nilai tersebut diproses menggunakan fungsi aktivasi ReLU pada persamaan (2.11) untuk menghasilkan output neuron y_1 . Hasil aktivasi menunjukkan bahwa neuron dengan nilai positif akan diteruskan sebagai output, sedangkan neuron dengan nilai negatif akan diubah menjadi nol. Sebagai contoh, neuron ke-1 dengan nilai $z_1[1] = -0.054188$ menghasilkan $y_1[1] = 0$, sedangkan neuron ke-7 dengan nilai $z_1[7] = 0.331726$

menghasilkan $y_1[7] = 0.331726$. Nilai output hasil aktivasi tersebut kemudian digunakan sebagai input pada hidden layer 2. Diperoleh nilai output sebelum dan sesudah aktivasi sebagaimana ditunjukkan pada Tabel 4.28.

Tabel 4. 28 Neuron Hidden Layer 1

Neuron (j)	(y_{1j}) Sebelum Aktivasi	(y_{1j}) Sesudah Aktivasi
1	-0.054188	0.000000
2	-0.008798	0.000000
3	-1.410920	0.000000
4	-1.212572	0.000000
5	-1.365464	0.000000
6	-0.492703	0.000000
7	0.331726	0.331726
...	...	
32	0.156694	0.156694

Nilai z_j pada hidden layer 2 diperoleh dari hasil kombinasi linier antara output aktivasi hidden layer 1 (y_j) dengan bobot antar layer serta bias. Dengan demikian, input pada hidden layer 2 bukan lagi nilai awal (input parameter), melainkan nilai hasil aktivasi dari hidden layer sebelumnya. Pada hidden layer 2, proses perhitungan dilakukan menggunakan output aktivasi hidden layer 1 sebagai input. Berdasarkan Persamaan (2.9), diperoleh nilai sebelum aktivasi (z_2) sebagai hasil kombinasi antara output layer sebelumnya dengan bobot dan bias pada hidden layer 2. Sebagai contoh, neuron ke-1 menghasilkan nilai $z_2[1] = 1.338403$. Selanjutnya, nilai z_2 diproses menggunakan fungsi aktivasi ReLU pada persamaan (2.11) untuk menghasilkan output y_2 . Karena nilai $z_2[1]$ bernilai positif, maka diperoleh $y_2[1] = 1.338403$. Hasil aktivasi menunjukkan bahwa sebagian neuron tetap aktif setelah proses ReLU, sedangkan neuron dengan nilai negatif dinonaktifkan menjadi nol. Output aktivasi ini kemudian digunakan sebagai input pada hidden layer 3. Hasil aktivasi pada Tabel 4.29 menunjukkan bahwa sebagian neuron tetap aktif setelah proses ReLU, sementara neuron dengan nilai negatif dinonaktifkan menjadi

nol. Proses ini memungkinkan model untuk membentuk representasi fitur yang lebih kompleks dibandingkan layer sebelumnya.

Tabel 4. 29 Neuron Hidden Layer 2

Neuron (j)	(y_{2j}) Sebelum Aktivasi	(y_{2j}) Sesudah Aktivasi
1	1.338403	1.338403
2	0.822239	0.822239
3	0.845400	0.845400
4	0.242187	0.242187
5	0.294931	0.294931
...	...	
32	-1.164077	0.000000

Perhitungan pada hidden layer 3 dilakukan dengan menggunakan nilai hasil aktivasi dari hidden layer 2 (y_2) sebagai input. Nilai tersebut kemudian dikalikan dengan bobot antar layer dan ditambahkan bias untuk menghasilkan nilai z_j sebagai nilai sebelum aktivasi. Pada hidden layer 3, output aktivasi dari hidden layer 2 digunakan sebagai input untuk menghasilkan nilai sebelum aktivasi (z_3). Berdasarkan hasil perhitungan menggunakan Persamaan (2.9), diperoleh variasi nilai positif dan negatif pada setiap neuron. Sebagai contoh, neuron ke-1 menghasilkan nilai $z_3[1] = -7.403811$, sedangkan neuron ke-6 menghasilkan nilai $z_3[6] = 0.913721$. Nilai tersebut kemudian diproses menggunakan fungsi aktivasi ReLU pada persamaan (2.11). Hasil aktivasi menunjukkan bahwa neuron ke-1 menghasilkan $y_3[1] = 0$ karena memiliki nilai negatif, sedangkan neuron ke-6 menghasilkan $y_3[6] = 0.913721$ karena bernilai positif. Kondisi ini menunjukkan bahwa hidden layer 3 melakukan proses seleksi fitur dengan meneruskan informasi yang dianggap relevan ke output layer. Berdasarkan Tabel 4.30, hanya neuron dengan nilai z_j positif yang tetap aktif, sedangkan neuron bernilai negatif dinonaktifkan menjadi nol. Hal ini menunjukkan bahwa hidden layer 3 melakukan proses seleksi fitur dengan meneruskan informasi yang relevan ke output layer untuk tahap klasifikasi menggunakan Softmax.

Tabel 4. 30 Neuron Hidden Layer 3

Neuron (j)	(y_{2j}) Sebelum Aktivasi	(y_{2j}) Sesudah Aktivasi
1	-7.403811	0.000000
2	-2.040936	0.000000
3	-4.849922	0.000000
4	-3.145167	0.000000
5	-0.894315	0.000000
6	0.913721	0.913721
7	7.681093	7.681093
8	-7.109036	0.000000

Perhitungan pada output layer dilakukan dengan menggunakan nilai hasil aktivasi dari hidden layer 3 (y_j) sebagai input. Nilai tersebut kemudian dikalikan dengan bobot antar layer dan ditambahkan bias untuk menghasilkan nilai z_{ou} sebagai nilai sebelum aktivasi. Sebagai contoh pada neuron pertama, nilai $z_{out}[1]$ diperoleh dari hasil kombinasi linier beberapa neuron aktif pada hidden layer 3, yaitu neuron ke-6 dan ke-8. Hasil perhitungan menunjukkan bahwa $z_{out}[1] = 4.039903$. Proses yang sama dilakukan pada neuron lainnya sehingga diperoleh nilai z_{ou} untuk seluruh kelas, yaitu Cerah, Berawan, Hujan Sedang, dan Hujan Lebat.

Tabel 4. 31 Neuron Output Layer Pre-Aktivasi

Neuron (j)	z_{out}
1	4.039903
2	-0.344668
3	-9.926916
4	-13.438157

Berdasarkan tabel 4.31 terlihat bahwa nilai z_{out} memiliki rentang yang cukup jauh antar kelas, dimana nilai tertinggi terdapat pada neuron 1 yaitu kategori cerah sebesar 4.039903, sedangkan nilai terendah terdapat pada neuron 4 yaitu hujan lebat sebesar -13.438157. Hal ini menunjukkan bahwa model mulai membedakan pola antar kelas. Sebelum dilakukan aktivasi Softmax, dilakukan proses stabilisasi

numerik dengan mengurangkan setiap nilai z_{out} dengan nilai maksimum dari vektor tersebut. Proses ini bertujuan untuk mencegah terjadinya overflow pada operasi eksponensial tanpa mengubah distribusi probabilitas yang dihasilkan. Berdasarkan perhitungan hasil aktivasi Softmax menggunakan persamaan (2.8), diperoleh probabilitas setiap kelas sebagaimana ditunjukkan pada Tabel 4.32.

Tabel 4. 32 Hasil Probabilitas Softmax Output Layer

Label	Kelas	Output Layer	Softmax	Persentase
0	Cerah	4.039903	0.987684	98.77%
1	Berawan	-0.344668	0.012315	1.23%
2	Hujan Sedang	-9.926916	0.000001	0%
3	Hujan Lebat	-13.438157	0.000000	0%

Berdasarkan Tabel 4.32, kelas Cerah memiliki probabilitas tertinggi sebesar 0,987684 atau 98,77%, diikuti oleh kelas Berawan sebesar 1,23%, sedangkan kelas Hujan Sedang dan Hujan Lebat memiliki probabilitas yang sangat kecil. Dengan demikian, model MLP mengklasifikasikan sampel data tersebut ke dalam kategori Cerah dengan tingkat keyakinan atau confidence sebesar 98,77%. Selain menghasilkan label klasifikasi, model MLP juga menghasilkan nilai probabilitas pada setiap kelas melalui fungsi Softmax, sehingga total probabilitas seluruh kelas bernilai satu. Nilai probabilitas ini digunakan sebagai indikator tingkat keyakinan model terhadap hasil prediksi yang diberikan. Selain contoh perhitungan pada satu sampel data, model MLP juga digunakan untuk mengklasifikasikan beberapa data hasil prediksi XGBoost yang terdiri atas parameter suhu, kelembapan, curah hujan, dan iradiasi. Hasil klasifikasi tersebut disajikan pada Tabel 4.33 dalam bentuk distribusi confidence untuk empat kategori cuaca, yaitu Cerah, Berawan, Hujan Sedang, dan Hujan Lebat.

Tabel 4. 33 MLP Confidence Classification

Tanggal	Temp. (°C)	Hum. (%)	Rainfall (mm/h)	Irradiance (W/m ²)	Cerah	Berawan	Hujan Sedang	Hujan Lebat
04/04/26, 08:00	29.01	78.52	0.24	911.95	48.70%	50.33%	0.93%	0.04%
04/04/26, 09:00	29.05	81.45	0.09	942.86	84.28%	15.71%	0.00%	0.00%

Tanggal	Temp. (°C)	Hum. (%)	Rainfall (mm/h)	Irradiance (W/m ²)	Cerah	Berawan	Hujan Sedang	Hujan Lebat
04/04/26, 12:00	30.85	82.38	0.14	590.98	0.00%	100.00%	0.00%	0.00%
04/04/26, 13:00	30.04	93.56	0.08	566.75	0.00%	100.00%	0.00%	0.00%
04/04/26, 16:00	28.66	85.37	0.19	647.55	0.00%	99.98%	0.02%	0.00%
04/04/26, 17:00	27.63	86.55	0.13	675.12	0.00%	100.00%	0.00%	0.00%
05/04/26, 08:00	26.86	79.2	0.25	758.42	0.00%	90.18%	9.81%	0.00%
05/04/26, 09:00	27.82	89.44	0.24	704.34	0.01%	59.01%	40.98%	0.00%
05/04/26, 12:00	29.22	77.61	0.03	699.86	0.20%	99.80%	0.00%	0.00%
05/04/26, 13:00	31.76	75.9	0.05	648.9	28.24%	71.76%	0.00%	0.00%
05/04/26, 16:00	29.85	77.08	0.21	623.68	0.01%	99.80%	0.19%	0.00%
05/04/26, 17:00	27.22	83.31	0.07	612.99	0.00%	100.00%	0.00%	0.00%
06/04/26, 08:00	27.31	84.96	0.11	613.89	0.00%	100.00%	0.00%	0.00%
06/04/26, 09:00	27.22	82.76	0.23	634.65	0.00%	99.52%	0.48%	0.00%
06/04/26, 12:00	31.84	91.66	0.06	625.76	0.00%	100.00%	0.00%	0.00%
06/04/26, 13:00	29.1	93.66	0.23	588.96	0.00%	83.56%	16.44%	0.00%
06/04/26, 16:00	28.92	82.06	0.22	603.59	0.00%	99.85%	0.15%	0.00%
06/04/26, 17:00	28.36	82.61	0.13	611.11	0.00%	100.00%	0.00%	0.00%

Nilai confidence yang dihasilkan model berada pada rentang sekitar 51% hingga lebih dari 99%, menunjukkan bahwa model memiliki tingkat keyakinan yang cukup baik dalam mengklasifikasikan kondisi cuaca. Kondisi Cerah umumnya diprediksi saat nilai iradiasi tinggi dan curah hujan rendah, sedangkan kondisi Berawan cenderung muncul pada kelembapan yang lebih tinggi dengan iradiasi yang lebih rendah. Hasil tersebut menunjukkan bahwa model MLP mampu mempelajari hubungan antar parameter cuaca dan menghasilkan klasifikasi yang konsisten. Meskipun demikian, model MLP memiliki kecenderungan overconfidence yang umum terjadi pada arsitektur neural network modern. Hal tersebut disebabkan oleh penggunaan fungsi aktivasi softmax pada output layer yang memaksa model untuk selalu memilih satu probabilitas terbesar dari kelas yang tersedia, sehingga model

tidak memiliki mekanisme untuk merepresentasikan ketidakpastian karena arsitektur neural network berbasis softmax bersifat closed-world [61].

Untuk mengatasi hal tersebut, diterapkan temperature scaling yang secara efektif mampu menurunkan nilai confidence tanpa mengubah hasil klasifikasi kelas yang dipilih. Metode ini bekerja dengan membagi nilai logits menggunakan parameter skalar T_s sehingga distribusi probabilitas antar kelas menjadi lebih merata dan lebih representatif terhadap ketidakpastian model. Semakin besar nilai parameter temperatur T_s , distribusi probabilitas yang dihasilkan akan semakin menyebar sehingga confidence model menjadi lebih rendah, namun kelas dengan probabilitas tertinggi tetap tidak berubah [60]. Nilai parameter T_s diperoleh melalui proses minimasi ECE. Hasil kalibrasi menghasilkan nilai T_s optimal sebesar 0,42 yang menunjukkan model cenderung underconfident secara statistik pada data pelatihan. Namun, untuk menghasilkan distribusi probabilitas multi-kelas yang lebih realistis terhadap dinamika cuaca, penelitian ini menggunakan $T_s = 4$ agar confidence antar kelas menjadi lebih menyebar dan mampu merepresentasikan ketidakpastian kondisi cuaca. Hasil sebaran MLP confidence setelah temperature scaling disajikan pada Tabel 4.34.

Tabel 4. 34 MLP Confidence Setelah Temperature Scalling

Tanggal	Cerah	Berawan	Hujan Sedang	Hujan Lebat
04/04/26, 08:00	39.22%	39.54%	14.57%	6.67%
04/04/26, 09:00	56.87%	37.37%	4.40%	1.36%
04/04/26, 12:00	5.08%	93.14%	1.78%	0.01%
04/04/26, 13:00	0.83%	99.05%	0.12%	0.00%
04/04/26, 16:00	5.56%	84.21%	10.22%	0.02%
04/04/26, 17:00	2.77%	96.36%	0.87%	0.00%
05/04/26, 08:00	5.12%	59.91%	34.41%	0.56%
05/04/26, 09:00	5.58%	49.34%	45.04%	0.04%
05/04/26, 12:00	17.16%	81.63%	1.19%	0.02%
05/04/26, 13:00	43.64%	55.10%	1.19%	0.07%
05/04/26, 16:00	6.88%	76.57%	16.02%	0.52%

Tanggal	Cerah	Berawan	Hujan Sedang	Hujan Lebat
05/04/26, 17:00	5.83%	93.59%	0.57%	0.00%
06/04/26, 08:00	3.37%	95.93%	0.69%	0.00%
06/04/26, 09:00	4.12%	75.84%	19.98%	0.05%
06/04/26, 12:00	1.20%	98.69%	0.10%	0.00%
06/04/26, 13:00	3.63%	57.84%	38.52%	0.01%
06/04/26, 16:00	4.33%	79.92%	15.69%	0.05%
06/04/26, 17:00	5.03%	93.51%	1.45%	0.01%

4.10.5 Evaluasi Performa Model pada Data Uji

Evaluasi performa model pada data uji dilakukan dalam dua tahap untuk memperoleh gambaran yang komprehensif terhadap kemampuan model MLP dalam kondisi nyata. Tahap pertama adalah evaluasi holdout independen menggunakan data yang sama sekali tidak terlibat dalam proses pelatihan maupun validasi silang. Tahap kedua adalah validasi ground truth menggunakan metode majority voting dari tiga layanan API cuaca eksternal dan analisis stabilitas temporal menggunakan pendekatan *sliding window* untuk mengamati konsistensi performa model dari waktu ke waktu serta dengan mengambil sampel klasifikasi dan membandingkannya dengan kondisi aktual.

a. Evaluasi Holdout Independen

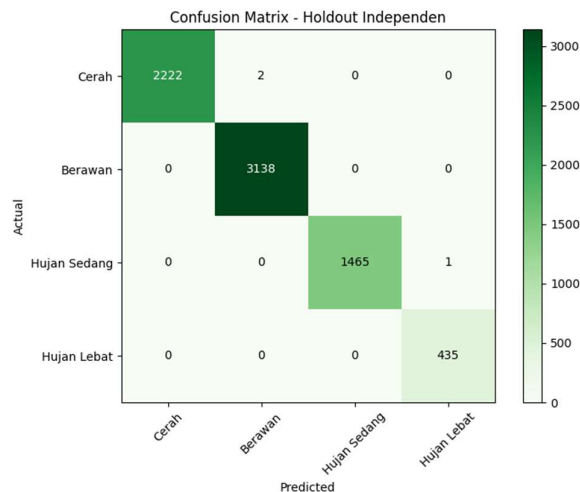
Evaluasi holdout dilakukan menggunakan 7.263 data yang telah dipisahkan sejak awal sebelum proses pelatihan model dan tidak pernah digunakan pada proses training maupun K-Fold Cross Validation. Data holdout mencakup periode 1 Januari 2025 hingga 28 Mei 2026 dengan distribusi kelas yang terdiri atas 2.224 data Cerah (30,6%), 3.138 data Berawan (43,2%), 1.466 data Hujan Sedang (20,2%), dan 435 data Hujan Lebat (6,0%). Berdasarkan Tabel 4.35, model MLP menunjukkan performa yang sangat baik pada data holdout dengan nilai akurasi sebesar 99,959%. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik terhadap data yang belum pernah dilihat sebelumnya.

Tabel 4. 35 Hasil Evaluasi Metrik Holdout Independen

Label	Kategori	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Data Support</i>
-------	----------	------------------	---------------	-----------------	---------------------

0	Cerah	1	0.99910	0.99955	2224
1	Berawan	0.99785	0.99964	0.99968	3138
2	Hujan Sedang	1	0.99653	0.99966	1466
3	Hujan Lebat	0.98815	1	0.99885	435
	Akurasi			0.99959	6842
	Macro Avg.	0.99927	0.99960	0.99944	6842
	Weighted Avg.	0.99959	0.99959	0.99959	6842

Berdasarkan confusion matrix pada Gambar 4.33, nilai pada diagonal utama matriks menunjukkan bahwa mayoritas data holdout berhasil diklasifikasikan dengan benar. Pada kelas Cerah, 2.222 data berhasil diklasifikasikan dengan benar dan 2 data salah diklasifikasikan sebagai Berawan. Pada kelas Berawan, seluruh 3.138 data berhasil diklasifikasikan dengan benar tanpa kesalahan prediksi. Pada kelas Hujan Sedang, 1.465 data berhasil diklasifikasikan dengan benar dan 1 data salah diklasifikasikan sebagai Hujan Lebat. Sementara itu, pada kelas Hujan Lebat, seluruh 435 data berhasil diklasifikasikan dengan benar tanpa kesalahan prediksi.



Gambar 4. 33 Confussion Matrix Holdout Independen

Hasil evaluasi holdout ini menunjukkan bahwa model MLP tidak mengalami overfitting terhadap data pelatihan dan mampu mempertahankan performa yang konsisten pada data baru. Konsistensi performa antara evaluasi validasi, K-Fold Cross Validation, dan holdout independen mengindikasikan bahwa model cukup andal untuk diterapkan pada kondisi real-time.

b. Evaluasi Hasil Klasifikasi dengan Weather Forecasting dan Cuaca Aktual

Selain evaluasi pada data historis melalui holdout, dilakukan pula pengujian pada data real-time dengan membandingkan hasil klasifikasi model MLP terhadap tiga layanan prakiraan cuaca eksternal, yaitu Open Meteo, Visual Crossing, dan Weather API. Tabel 4.36 hanya menampilkan beberapa sampel representatif dari masing-masing kondisi cuaca untuk memberikan hasil klasifikasi model terhadap layanan forecasting eksternal. Evaluasi keseluruhan dilakukan menggunakan seluruh 270 data observasi melalui pendekatan majority voting. Hasil perbandingan menunjukkan bahwa klasifikasi yang dihasilkan MLP memiliki kesesuaian terhadap sebagian besar hasil forecasting, meskipun pada beberapa waktu pengamatan masih terdapat perbedaan antar sumber prakiraan cuaca.

Tabel 4. 36 Perbandingan Hasil Klasifikasi MLP dengan Layanan Cuaca Eksternal

Tanggal	Klasifikasi MLP	MLP Confidence	Open Meteo	Visual Crossing	Weather API
01/04/26, 08:00	Cerah	68,53%	Cerah	Cerah	Cerah
25/04/26, 16:00	Cerah	46,79%	Hj. Sedang	Hj. Sedang	Berawan
29/05/26, 09:00	Cerah	65,59%	Berawan	Cerah	Cerah
12/04/26, 08:00	Berawan	95,44%	Berawan	Cerah	Berawan
13/05/26, 16:00	Berawan	77,68%	Berawan	Berawan	Berawan
29/05/26, 13:00	Berawan	72,51%	Berawan	Berawan	Hj. Sedang
12/04/26, 13:00	Hj. Sedang	48,49%	Hj. Sedang	Berawan	Hj. Sedang
22/04/26, 08:00	Hj. Sedang	87,1%	Hj. Sedang	Hj. Sedang	Hj. Sedang
22/05/26, 16:00	Hj. Sedang	86,68%	Hj. Sedang	Berawan	Hj. Sedang

Berdasarkan Tabel 4.36 tingkat confidence yang dihasilkan model terlihat memiliki keterkaitan dengan kesesuaian hasil klasifikasi dari beberapa sumber forecasting. Pada kondisi Berawan tanggal 12 April 2026, model menghasilkan confidence sebesar 95,44% dan hasil tersebut didukung oleh dua dari tiga layanan forecasting yang juga mengklasifikasikan kondisi cuaca sebagai Berawan. Sebaliknya, pada kondisi Cerah tanggal 25 April 2026, confidence model hanya sebesar 46,79% dan seluruh layanan forecasting memberikan hasil klasifikasi yang berbeda. Hal ini menunjukkan bahwa nilai confidence dapat digunakan untuk menggambarkan

tingkat keyakinan model, terutama pada kondisi cuaca yang memiliki karakteristik parameter saling berdekatan. Perbedaan klasifikasi paling sering terjadi pada kelas Berawan dan Hujan Sedang karena kedua kondisi tersebut memiliki karakteristik atmosfer yang relatif mirip, terutama pada kondisi setelah hujan ketika kelembapan masih tinggi, tetapi intensitas hujan sudah berhenti. Kondisi ini dapat menyebabkan model MLP maupun layanan forecasting eksternal memberikan interpretasi yang berbeda terhadap kondisi cuaca yang sama. Oleh karena itu, penggunaan satu layanan forecasting saja sebagai pembanding dinilai kurang representatif. Untuk mengurangi pengaruh perbedaan tersebut, penelitian ini menggunakan pendekatan majority voting dengan menggabungkan hasil klasifikasi dari Open Meteo, Visual Crossing, dan Weather API. Hasil klasifikasi yang memperoleh suara terbanyak dari ketiga layanan tersebut kemudian digunakan sebagai ground truth pembanding terhadap hasil klasifikasi MLP.

Setelah ground truth pembanding ditentukan menggunakan majority voting, pengujian dilakukan terhadap data hasil klasifikasi MLP pada periode 1 April hingga 15 Mei 2026. Data yang digunakan berjumlah 270 data observasi yang tersebar pada 45 hari pengamatan. Hasil perbandingan menunjukkan bahwa dari 270 prediksi, sebanyak 165 prediksi sesuai dengan hasil majority voting, sedangkan 105 prediksi lainnya tidak sesuai. Berdasarkan hasil tersebut, diperoleh akurasi keseluruhan sebesar 61,11%. Nilai akurasi ini lebih rendah dibandingkan akurasi pada data holdout karena pembanding yang digunakan bukan berasal dari data observasi langsung, melainkan dari layanan forecasting yang juga bersifat prediktif. Selain itu, masing-masing layanan forecasting memiliki model numerik atmosfer, resolusi spasial, dan metode pengolahan data yang berbeda. Perbedaan tersebut dapat memengaruhi hasil klasifikasi, terutama pada wilayah tropis seperti Semarang yang memiliki perubahan cuaca lokal cukup dinamis.

Selain menghitung akurasi keseluruhan, dilakukan juga analisis stabilitas untuk melihat konsistensi performa model selama periode pengamatan. Analisis ini menggunakan metode sliding window dengan ukuran window 3, 4, 5, 6, dan 7 hari. Pada proses ini, setiap hasil klasifikasi MLP dibandingkan dengan hasil majority voting. Nilai TRUE (1) diberikan apabila hasil klasifikasi MLP sesuai dengan

majority voting, sedangkan nilai FALSE (0) diberikan apabila hasilnya tidak sesuai. Selanjutnya, akurasi dihitung pada setiap window dengan cara menggeser jendela evaluasi satu hari sekali sepanjang periode pengamatan. Melalui analisis ini, dapat diketahui apakah performa model cenderung stabil atau mengalami perubahan pada rentang waktu tertentu.

Tabel 4. 37 Hasil Analisis Sliding Window

Window (Hari)	Jumlah Window	Rata-rata Akurasi	Std. Deviasi	Min	Max	Trend (Slope)
3	43	61,63%	14,44%	33,33%	88,89%	0.32%
4	42	62,00%	12,49%	41,67%	91,67%	0.35%
5	41	61,95%	11,59%	46,67%	86,67%	0.38%
6	40	61,88%	10,88%	44,44%	86,11%	0.38%
7	39	61,84%	10,20%	47,62%	88,10%	0.38%

Berdasarkan Tabel 4.37, seluruh ukuran window menghasilkan rata-rata akurasi yang relatif serupa, yaitu berkisar antara 61,63% hingga 62,00%. Namun, tingkat kestabilan performa menunjukkan perbedaan seiring bertambahnya ukuran window. Window 3 hari memiliki standar deviasi tertinggi sebesar 14,44%, sedangkan window 7 hari memiliki standar deviasi paling rendah sebesar 10,20%. Dalam konteks pengujian sliding window, standar deviasi menunjukkan besar penyimpangan nilai akurasi pada setiap periode pengamatan terhadap rata-rata akurasi keseluruhan. Nilai standar deviasi yang lebih tinggi menunjukkan bahwa akurasi model pada setiap window lebih banyak menyimpang dari nilai rata-ratanya, sehingga performa model cenderung lebih fluktuatif. Sebaliknya, nilai standar deviasi yang lebih rendah menunjukkan bahwa akurasi antar window lebih dekat terhadap rata-ratanya, sehingga performa model lebih stabil dan konsisten. Dengan demikian, window 7 hari menunjukkan kestabilan performa yang lebih baik dibandingkan ukuran window lainnya. Selain itu, seluruh ukuran window menunjukkan nilai trend positif dengan slope berkisar antara 0,32% hingga 0,38%, yang menandakan adanya kecenderungan peningkatan performa model secara bertahap selama periode pengamatan dari awal April hingga pertengahan Mei 2026.

Konsistensi tren positif pada seluruh ukuran window mencerminkan adanya pola peningkatan performa pada data pengujian.

Tabel 4. 38 Evaluasi Hasil Klasifikasi MLP Terhadap Cuaca Aktual

Tanggal	MLP Klasifikasi	Confidence	Cuaca Aktual
22/04/26, 08:00	Hujan Sedang	C: 0,42%; B: 12,23%; HS: 87,31%; HL: 0,05%	Hujan, Rainfall 0,4 mm/h
22/04/26, 09:00	Hujan Sedang	C: 0,26%; B: 11,06%; HS: 88,66%; HL: 0,02%	Hujan, Rainfall 0,6 mm/h
22/04/26, 12:00	Berawan	C: 34,96%; B: 63,44%; HS: 1,60%; HL: 0%	Berawan, Iradiasi 286 W/m ² (masih tersisa hujan kecil)
22/04/26, 13:00	Berawan	C: 21,58%; B: 74,14%; HS: 4,28%; HL: 0%	Berawan, Iradiasi 269 W/m ²
22/04/26, 16:00	Hujan Sedang	C: 0,25%; B: 10,47%; HS: 89,26%; HL: 0,02%	Berawan, Iradiasi 219 W/m ²
22/04/26, 17:00	Hujan Sedang	C: 0,72%; B: 13,74%; HS: 85,37%; HL: 0,17%	Berawan, Iradiasi 76 W/m ²
29/05/26, 08:00	Cerah	C: 72,61%; B: 24,26%; HS: 2,21%; HL: 0,92%	Cerah, Iradiasi 1084 W/m ²
29/05/26, 09:00	Cerah	C: 65,59%; B: 29,34%; HS: 3,91%; HL: 1,15%	Cerah, Iradiasi 1155 W/m ²
29/05/26, 12:00	Berawan	C: 31,54%; B: 64,51%; HS: 3,68%; HL: 0,27%	Berawan, Iradiasi 1191 W/m ²
29/05/26, 13:00	Berawan	C: 11,27%; B: 72,51%; HS: 16,08%; HL: 0,14%	Berawan, Iradiasi 522 W/m ² (awan pekat)
29/05/26, 16:00	Berawan	C: 4,47%; B: 94,69%; HS: 0,84%; HL: 0%	Berawan, Iradiasi 120 W/m ² (awan dan elevasi matahari)
29/05/26, 17:00	Berawan	C: 4,75%; B: 72,51%; HS: 22,67%; HL: 0,07%	Berawan, Iradiasi 5 W/m ² (awan dan elevasi matahari)

Tabel 4.38 menampilkan hasil evaluasi klasifikasi MLP terhadap cuaca aktual. Pada tanggal 22 April 2026, model berhasil mengklasifikasikan kondisi pagi hari pukul 08.00 dan 09.00 sebagai Hujan Sedang, sesuai dengan kondisi aktual yang menunjukkan adanya hujan ringan dengan curah hujan sekitar 0,4-0,6 mm/h. Memasuki siang hari pukul 12.00 dan 13.00, model mengklasifikasikan kondisi sebagai Berawan yang juga masih sesuai dengan kondisi aktual berdasarkan nilai iradiasi yang relatif rendah. Namun, pada pukul 16.00 dan 17.00 model memprediksi Hujan Sedang, sedangkan kondisi aktual lebih mendekati Berawan. Meskipun demikian, confidence kelas Berawan tetap muncul sebagai probabilitas terbesar kedua, masing-masing sebesar 10,47% dan 13,74%. Hal ini menunjukkan bahwa model masih mempertimbangkan kemungkinan kondisi Berawan, kelembapan udara yang masih tinggi setelah hujan menyebabkan model lebih condong memilih kelas Hujan Sedang. Sementara itu, pada tanggal 29 Mei 2026 model mampu mengklasifikasikan kondisi pagi hari sebagai Cerah dengan cukup baik, sejalan dengan nilai iradiasi yang mencapai lebih dari 1.000 W/m². Pada siang hingga sore hari, model secara konsisten mengklasifikasikan kondisi sebagai Berawan yang sesuai dengan kondisi aktual ketika awan mulai meningkat dan intensitas matahari berkurang. Secara umum, pengujian hasil klasifikasi menunjukkan bahwa model MLP mampu mengikuti pola perubahan cuaca harian dengan cukup baik. Selain menghasilkan prediksi utama, model juga mampu memberikan probabilitas alternatif pada kelas lain yang masih relevan terhadap kondisi aktual. Hal ini menunjukkan bahwa model juga mampu merepresentasikan kemungkinan transisi antar kondisi cuaca yang memiliki karakteristik parameter serupa.



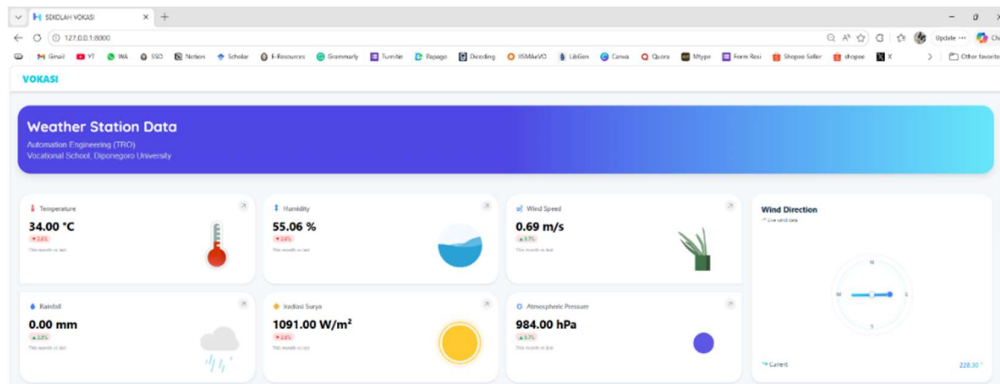
Gambar 4. 34 Cuaca Berawan



Gambar 4. 35 Cuaca Cerah

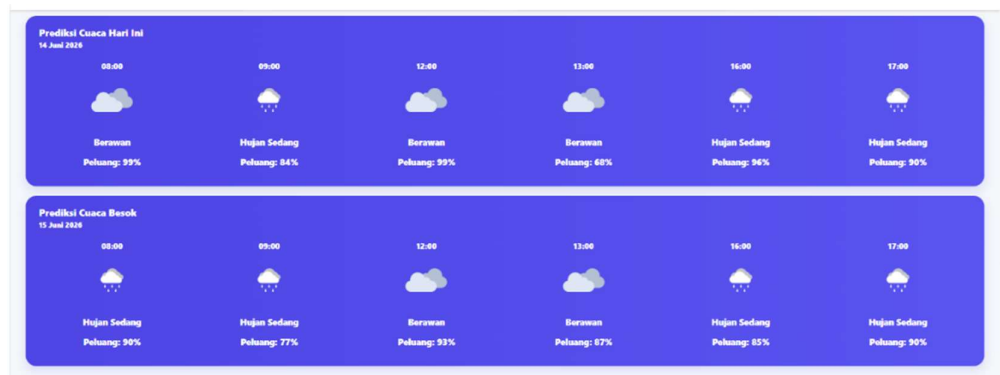
4.11 Tampilan Dashboard Monitoring dan Prediksi Cuaca

Dashboard monitoring dan prediksi cuaca digunakan untuk menampilkan data cuaca yang diterima dari sistem stasiun cuaca serta hasil prediksi yang telah klasifikasi oleh sistem. Tampilan dashboard ini dibuat agar pengguna dapat memantau kondisi cuaca dengan lebih mudah melalui tampilan web.




Gambar 4. 36 Tampilan Dashboard Data Cuaca Real-Time

Gambar 4.36 menyajikan tampilan dashboard yang menunjukkan hasil monitoring data cuaca secara real-time. Pada tampilan ini, data cuaca seperti yaitu temperatur, kelembapan, kecepatan angin, arah angin, curah hujan, iradiasi surya, dan tekanan atmosfer yang terbaca dari sistem ditampilkan.



Gambar 4. 37 Tampilan Dashboard Klasifikasi Data Prediksi Cuaca

Gambar 4.37 menyajikan dashboard hasil prediksi kategori cuaca yang menampilkan ikon cuaca, kategori cuaca, serta nilai peluang cuaca. Pada bagian ini ditampilkan prediksi cuaca untuk hari ini dan esok hari berdasarkan dengan variasi waktu pukul 08.00, 09.00, 12.00, 13.00, 16.00, dan 17.00. Setiap waktu



Gambar 4. 38 Tampilan Dashboard Grafik dan Tabel Hasil Prediksi Cuaca Selama Tiga Hari

Gambar 4.38 menyajikan grafik dan tabel hasil prediksi cuaca. Grafik prediksi menampilkan perubahan nilai parameter cuaca selama tiga hari, seperti iradiasi, suhu, kelembapan, dan curah hujan. Selain grafik, data prediksi dan klasifikasi juga ditampilkan dalam bentuk tabel agar pengguna dapat melihat nilai prediksi secara lebih rinci dan sajian informasi mengenai kategori cuaca yang lebih mudah dipahami.