

SKRIPSI

MODEL PREDIKSI CURAH HUJAN MENGGUNAKAN ALGORITMA *MACHINE LEARNING*

Oleh:
Muhammad Azizan
065119157



PROGRAM STUDI ILMU KOMPUTER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS PAKUAN
BOGOR
2024

SKRIPSI

MODEL PREDIKSI CURAH HUJAN MENGGUNAKAN ALGORITMA *MACHINE LEARNING*

Diajukan sebagai salah satu syarat untuk memperoleh
Gelar Sarjana Komputer Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam

Oleh:
Muhammad Azizan
065119157



**PROGRAM STUDI ILMU KOMPUTER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS PAKUAN
BOGOR
2024**

HALAMAN KREASI / PERSEMBAHAN SKRIPSI

Bismillahirrohmanirohchim, pertama-tama saya ingin mengucapkan rasa syukur kepada Allah SWT atas kemudahan dan kelancaran yang diberikan-Nya dalam proses penyusunan skripsi ini, sehingga dapat terselesaikan tepat pada waktunya yang telah ditetapkan.

Saya ingin menyampaikan terima kasih yang tak terhingga kepada kedua orang tua saya atas dukungan dan doa mereka yang tanpa henti, yang telah memungkinkan saya menyelesaikan skripsi ini dengan baik.

Saya juga ingin menyampaikan kepada terima kasih kepada Adik ku yang kubanggakan Ridho Rizki dan Nur Zahirah atas dukungan dan doa mereka.

Adik ku Nur Fitri Yana di sisi Allah SWT, meski kita tidak lagi bisa bersama di dunia ini, engkau selalu hadir dalam setiap langkahku. Karya ini kupersembahkan sebagai tanda cinta dan kenangan yang tak akan pernah hilang. Terima kasih telah berjuang menghadapi penyakitmu dengan tabah, bersamaan dengan perjuanganku menyelesaikan skripsi ini. Semoga engkau damai di sisi-Nya.

Tidak lupa, saya juga ingin mengucapkan terima kasih kepada kedua pembimbing saya, yaitu Ibu Dr. Prihastuti Harsani, M.Si dan Bapak Boldson H.Situmorang, MMSI, atas bimbingan dan arahan mereka yang sangat berharga dalam menjalankan penelitian ini, sehingga skripsi ini dapat tersusun dengan baik.

Saya juga ingin mengucapkan terima kasih kepada bapak/ibu dosen FMIPA Universitas Pakuan atas kesempatan dan dukungan yang telah diberikan selama proses penyusunan skripsi ini.

Tak lupa, saya ingin menyampaikan rasa terima kasih kepada Rian Arianti S, Atas dukungan dan doa serta menemani penulis melewati proses penyusunan Skripsi ini.

Serta, saya ingin menyampaikan rasa terima kasih kepada TBC Boim's Family (Hary, Elvan, Rendy, Marco) semua teman-teman, dan pihak lain yang tidak dapat saya sebutkan satu per satu, atas dukungan dan bantuannya dalam menyelesaikan skripsi ini. Semua kontribusi dan dukungan mereka sangat berarti bagi saya.

“Melangkah sejauh mungkin, agar kurasakan betapa nikmatnya pulang”

HALAMAN PENGESAHAN

Judul : Model Prediksi Curah Hujan Menggunakan Algoritma *Machine Learning*

Nama : Muhammad Azizan

NPM : 065119157

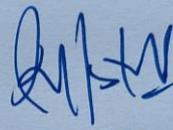
Mengesahkan,

Pembimbing Pendamping
Program Studi Ilmu Komputer
FMIPA-UNPAK



Boldson H. Situmorang, MMSI

Pembimbing Utama
Program Studi Ilmu Komputer
FMIPA-UNPAK



Dr. Prihastuti Harsani, M.Si

Mengetahui,

Ketua Program Studi Ilmu
Komputer FMIPA-UNPAK



Arie Qur'ania, M.Kom

Dekan FMIPA-UNPAK



Asep Denih, S.Kom., M.Sc., Ph.D.

PERNYATAAN KEASLIAN KARYA TULIS SKRIPSI

PERNYATAAN KEASLIAN KARYA TULIS SKRIPSI

Dengan ini saya menyatakan bahwa:

Sejauh yang saya ketahui, karya tulis ini bukan merupakan karya tulis yang pernah dipublikasikan atau sudah pernah dipakai untuk mendapatkan gelar sarjana di Universitas lain, kecuali pada bagian-bagian dimana sumber informasinya dicantumkan dengan cara referensi yang semestinya.

Demikian pernyataan ini saya buat dengan sebenar-benarnya. Apabila kelak dikemudian hari terdapat gugatan, penulis bersedia dikenakan sanksi sesuai dengan peraturan yang berlaku.

Bogor, Juli 2024



Muhammad Azizan
NPM.065119157

PERNYATAAN PELIMPAHAN SKRIPSI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

PERNYATAAN PELIMPAHAN SKRIPSI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA

Saya yang bertanda tangan dibawah ini:

Nama : Muhammad Azizan
NPM : 065119157
Judul Skripsi : Model Prediksi Curah Hujan Menggunakan Algoritma
Machine Learning

Dengan ini saya menyatakan bahwa Paten dan Hak Cipta dari produk skripsi dan Tugas Akhir di atas adalah benar karya saya dengan arahan dari komisi pembimbing dan belum diajukan dalam bentuk apapun kepada perguruan tinggi manapun.

Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka di bagian akhir skripsi ini.

Dengan ini saya melimpahkan Paten, hak cipta dari karya tulis saya kepada Universitas Pakuan.

Bogor, Juli 2024



Muhammad Azizan
NPM.065119157

RIWAYAT HIDUP



Muhammad Azizan (penulis) lahir di Solok, Sumatra Barat pada tanggal 04 Januari 2001 dari pasangan Bapak Eri Friyanto dan Ibu Syurhayati sebagai anak pertama dari empat bersaudara.

Penulis lulus pendidikan pada tahun 2013 di SDN Gunung Batu 2 Bogor, kemudian pada tahun 2016 lulus pendidikan di SMPN 9 Bogor dan pada tahun 2019 lulus pendidikan di SMAN 4 Bogor dengan jurusan IPA.

Pada tahun 2019 penulis meneruskan pendidikan Sarjana di Universitas Pakuan, Program Studi Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Bogor.

Pada tahun 2023, penulis fokus melakukan penelitian di bidang *Data Mining*, dan berhasil menyelesaikannya pada tahun 2024. Judul penelitian penulis adalah *Model Prediksi Curah Hujan Menggunakan Algoritma Machine Learning*.

RINGKASAN

Muhammad Azizan. Model Prediksi Curah Hujan Menggunakan Algoritma *Machine Learning*. Dibawah bimbingan Dr Prihastuti Harsani, M.Si dan Boldson H.Situmorang, MMSI

Indonesia adalah negara yang mayoritas wilayahnya mengalami dua musim, yaitu musim kemarau dan musim penghujan. Perbedaan signifikan antara kedua musim ini terletak pada rata-rata curah hujan bulanan. Curah hujan merupakan salah satu indikator penting dalam mengukur kondisi cuaca, di mana tingginya air hujan yang terukur dapat memberikan gambaran tentang intensitas hujan di suatu wilayah. Pengukuran curah hujan dilakukan dalam satuan milimeter (mm) pada interval waktu bulanan. Hujan terjadi akibat tabrakan butiran air dalam awan, dipengaruhi oleh tekanan angin, dan intensitasnya bervariasi. Curah hujan memiliki dampak besar terhadap kehidupan manusia, baik dalam kondisi kelebihan maupun kekurangan. Kelebihan curah hujan, seperti hujan lebat atau ekstrem, seringkali menyebabkan banjir, terutama di Kota Bogor, yang dikenal sebagai wilayah rawan banjir dan longsor akibat tingginya intensitas curah hujan. Oleh karena itu, diperlukan metode prediksi curah hujan yang efektif untuk membantu mengurangi dampak negatif yang ditimbulkan oleh cuaca ekstrem. Dalam penelitian ini, dilakukan pengembangan model prediksi curah hujan di wilayah Kota Bogor menggunakan algoritma Multilayer Perceptron (MLP) dengan pembagian data 90% untuk pelatihan dan 10% untuk pengujian. Hasil penelitian menunjukkan bahwa model ini mampu memprediksi curah hujan dengan baik, dengan nilai *Root Mean Squared Error* (RMSE) sebesar 17,8763, yang menunjukkan tingkat akurasi model yang cukup baik. Nilai RMSE ini digunakan sebagai indikator utama dalam mengevaluasi performa model, di mana semakin rendah nilainya, semakin akurat prediksi yang dihasilkan. Model prediksi curah hujan berbasis MLP ini memiliki potensi besar untuk diterapkan dalam berbagai sektor, termasuk manajemen sumber daya air, infrastruktur, dan mitigasi bencana. Dengan akurasi yang tinggi, model ini dapat mendukung pengambilan keputusan di wilayah yang rentan terhadap banjir dan kekeringan, sehingga dapat meminimalkan dampak negatif dari variabilitas cuaca.

Kata kunci : Prediksi Curah Hujan. *Multilayer Perceptron, Machine Learning*

KATA PENGANTAR

Puji syukur kehadirat Allah SWT, karena Rahmat dan hidayah-Nya penulis dapat mengajukan usulan penelitian yang berjudul “**Model Prediksi Curah Hujan Menggunakan Algoritma *Machine Learning***”. Penulisan usulan penelitian ini merupakan salah satu syarat untuk memperoleh gelar Sarjana Komputer pada Program Studi Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Pakuan, Bogor.

Dalam penulisan usulan penelitian ini, penulis dengan senang hati ingin mengucapkan terima kasih yang sebesar-besarnya kepada :

1. Dr. Prihastuti Harsani, M.Si selaku Pembimbing Utama yang telah memberikan dorongan moril dan motivasi kepada penulis.
2. Boldson H. Situmorang, MMSI selaku Pembimbing Pendamping yang telah memberikan bimbingan, semangat dan motivasi.
3. Arie Qur'ania, M.Kom, selaku Ketua Program Studi Ilmu Komputer FMIPA Universitas Pakuan Bogor.
4. Kedua orangtua yang telah memberikan doa, semangat dan restunya selama ini.
5. TBC Family dan Sahabat yang telah banyak membantu dalam menyelesaikan usulan penelitian ini.

Saran dan kritik yang membangun dalam penulisan tugas akhir ini akan diterima dengan senang hati. Mudah-mudahan Allah SWT akan membalas semua kebaikan kepada semua pihak yang membantu. Akhir kata, semoga usulan penelitian ini dapat bermanfaat bagi kita semua. Aamiin.

Bogor, Juli 2024

Muhammad Azizan
NPM.065119157

DAFTAR ISI

	Halaman
HALAMAN KREASI / PERSEMBAHAN SKRIPSI	i
HALAMAN PENGESAHAN	ii
PERNYATAAN KEASLIAN KARYA TULIS SKRIPSI	iii
PERNYATAAN PELIMPAHAN SKRIPSI DAN SUMBER INFORMASI SERTA PELIMPAHAN HAK CIPTA	iv
RIWAYAT HIDUP	v
RINGKASAN	vi
KATA PENGANTAR	vii
DAFTAR ISI	viii
DAFTAR TABEL	xii
DAFTAR LAMPIRAN	xiii
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Tujuan.....	2
1.3 Ruang Lingkup.....	2
1.4 Manfaat Penelitian.....	3
BAB II TINJAUAN PUSTAKA	4
2.1 Landasan Teori.....	4
2.1.1 <i>Data Mining</i>	4
2.1.2 <i>Machine Learning</i>	5
2.1.3 Prediksi.....	5
2.1.4 Curah Hujan.....	5
2.1.5 Temperatur.....	5
2.1.6 Kelembapan.....	6
2.1.7 Kecepatan Angin.....	6
2.1.8 Lamanya Penyinaran Matahari.....	6
2.1.9 Jaringan Saraf Tiruan (<i>Artificial Neural Network</i>).....	6
2.1.10 Normalisasi Data.....	6
2.1.11 Tuning Parameter.....	7
2.1.12 MLP (<i>Multilayer Perceptron</i>).....	7
2.1.13 <i>Root Mean Square Error (RMSE)</i>	10

2.2 Penelitian Terdahulu	11
2.3 Tabel Perbandingan Penelitian.....	13
BAB III METODE PENELITIAN	14
3.1 Alur Penelitian.....	14
3.1.1 Pengumpulan Data	14
3.1.2 <i>Flowchart</i> Desain	14
3.1.3 <i>Data Cleaning</i>	16
3.1.4 Seleksi Data.....	16
3.1.5 Transformasi Data	16
3.1.6 Normalisasi Data	16
3.1.7 <i>Data mining</i>	16
3.1.8 Evaluasi Model.....	16
3.1.9 Representasi Pengetahuan	17
3.2 Alat dan Bahan	17
3.2.1 Alat	17
3.2.2 Bahan	17
BAB IV PERANCANGAN DAN IMPLEMENTASI.....	18
4.1 Tahap Analisis Kebutuhan	18
4.1.1 Sumber Data.....	18
4.1.2 Lingkup Pengambilan Data	18
4.1.3 Teknik Pengumpulan Data.....	18
4.1.4 <i>Sample Data</i>	18
4.2 <i>Preprocessing Data</i>	19
4.2.1 Integrasi Data	20
4.2.2 Pembersihan Data.....	21
4.2.3 Seleksi Data.....	25
4.2.4 Transformasi Data	26
4.3 Normalisasi Data	28
4.4 <i>Data Mining</i>	28
BAB V HASIL DAN PEMBAHASAN	36
5.1 Data	36
5.2 Hasil <i>Data Cleaning</i>	37
5.3 Hasil Seleksi Data	41
5.4 Hasil Transformasi Data	42

5.5 Normalisasi Data	43
5.6 <i>Data mining</i>	43
5.7 Evaluasi	49
5.8 Representasi Pengetahuan	54
BAB VI KESIMPULAN DAN SARAN	56
6.1 Kesimpulan	56
6.2 Saran.....	56
DAFTAR PUSTAKA	57
LAMPIRAN	59

DAFTAR GAMBAR

	Halaman
Gambar 1. Arsitektur <i>Multilayer Perceptron</i>	7
Gambar 2. Alur Metode Penelitian KDD	14
Gambar 3. <i>Flowchart Desain</i>	15
Gambar 4. <i>Code</i> Pembacaan Data	20
Gambar 5. <i>Code</i> Pembersihan Nama Kolom.....	20
Gambar 6. <i>Code</i> Menetapkan Nama Kolom Fitur dan Target.....	21
Gambar 7. <i>Code</i> Normalisasi Data	28
Gambar 8. Rancangan Arsitektur MLP	29
Gambar 9. <i>Code</i> Inisialisasi Bobot	32
Gambar 10. <i>Code Fordward Proagation</i>	33
Gambar 11. <i>Code Backward Proagation</i>	34
Gambar 12. <i>Code</i> Pelatihan MLP	35
Gambar 13. Grafik Data Temperatur Sebelum dan Sesudah <i>Cleaning</i>	37
Gambar 14. Grafik Data Kelembapan Sebelum dan Sesudah <i>Cleaning</i>	37
Gambar 15. Grafik Data Penyinaran Matahari Sebelum dan Sesudah <i>Cleaning</i> . 38	
Gambar 16. Grafik Data Kecepatan Angin Sebelum dan Sesudah <i>Cleaning</i>	39
Gambar 17. Grafik <i>Loss/Error</i> Selama Pelatihan	44
Gambar 18. <i>Correlation Matrix</i>	47
Gambar 19. Nilai Hasil RMSE <i>Train-Test</i> : 90% - 10% Pada <i>Data Mining</i>	49
Gambar 20. Visualisasi Grafik Hasil Evaluasi Data	49
Gambar 21. Visualisasi Performa MLP dengan Berbagai Proporsi Data	51
Gambar 22. Grafik Perbandingan Curah Hujan Aktual Dan Hasil Prediksi	54

DAFTAR TABEL

	Halaman
Tabel 1. Keterangan Rumus Normalisasi	6
Tabel 2. Perbandingan Penelitian	13
Tabel 3. Data Penelitian.....	19
Tabel 4. Data Frame.....	20
Tabel 5. Data Penelitian Sebelum <i>Proses Cleaning</i>	21
Tabel 6. Data Temperatur Sebelum Proses <i>Cleaning</i>	22
Tabel 7. Data Kelembapan Sebelum Proses <i>Cleaning</i>	23
Tabel 8. Data Penyinaran Matahari Sebelum Proses <i>Cleaning</i>	23
Tabel 9. Data Kecepatan Angin Sebelum Proses <i>Cleaning</i>	24
Tabel 10. Proporsi Data	25
Tabel 11. Atribut Data.....	25
Tabel 12. Konfigurasi <i>Multilayer Perceptron</i>	26
Tabel 13. Data Penelitian Yang Akan Dilakukan Proses Transformasi.....	27
Tabel 14. Dataset BMKG	36
Tabel 15. Data Hasil Proses <i>Cleaning Data</i>	40
Tabel 16. Hasil Data Tahapan Seleksi Data.....	41
Tabel 17. Data Hasil Tahapan Transformasi Data	42
Tabel 18. Data Hasil Tahapan Normalisasi.....	43
Tabel 19. Data Hasil Prediksi Pada Tahapan <i>Data Mining</i>	45
Tabel 20. Hasil Evaluasi	50

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. SK Dekan Pengangkatan Pembimbing	60
Lampiran 2. Kartu Bimbingan.....	62
Lampiran 3. Data Bulan Januari.....	63
Lampiran 4. Data Bulan Februari.....	64
Lampiran 5. Data Bulan Maret.....	65
Lampiran 6. Data Bulan April	66
Lampiran 7. Data Bulan Mei.....	67
Lampiran 8. Data Bulan Juni.....	68
Lampiran 9. Data Bulan Juli	69
Lampiran 10. Data Bulan Agustus	70
Lampiran 11. Data Bulan September	71
Lampiran 12. Data Bulan Oktober	72
Lampiran 13. Data Bulan November	73
Lampiran 14. Data Bulan Desember	74
Lampiran 15. Data Curah Hujan Bulan September.....	75
Lampiran 16. Data Curah Hujan Bulan Oktober.....	76
Lampiran 17. Data Curah Hujan Bulan November.....	77
Lampiran 18. Data Curah Hujan Bulan Desember.....	78

BAB I PENDAHULUAN

1.1 Latar Belakang

Indonesia adalah negara yang mayoritas wilayahnya terdiri dari dua musim dalam setahun, yaitu musim kemarau dan penghujan, perbedaan dari kedua musim ini adalah rata-rata curah hujan bulannya. Curah hujan adalah ketinggian air hujan yang terkumpul di sebuah alat penakar hujan yang berada pada tempat datar, tidak menyerap, tidak meresap, tidak mengalir, dan tidak menguap. Ketinggian air yang terukur akan menandakan frekuensi hujan, semakin besar nilai yang telah berlangsung di wilayah pengukuran. Pengukuran curah hujan dilakukan dengan mengukur ketinggian air yang terkumpul dalam skala mm dan satuan waktu bulanan (Dhenanta dkk, 2022).

Hujan turun diakibatkan oleh tabrakan butiran-butiran air dalam awan karena pengaruh tekanan angin. Intensitas curah hujan yang turun berbeda tiap waktu. Perbedaan intensitas curah hujan akan mempengaruhi tinggi curah hujan yang terukur. Curah hujan memiliki peran yang sangat signifikan dalam kehidupan manusia di planet ini. Tingkat curah hujan, baik tinggi maupun rendah, memiliki dampak yang besar terhadap kondisi iklim di permukaan bumi. Kelebihan curah hujan dapat menyebabkan berbagai masalah seperti banjir, kegagalan panen, dan peristiwa lainnya. Hujan lebat dengan intensitas tinggi, yang umumnya disebut sebagai hujan ekstrem, dapat memicu banjir. Kota Bogor, salah satu kota di Indonesia, seringkali menjadi korban banjir akibat curah hujan, dan tidak jarang hal ini menyebabkan tanah longsor dan kerusakan bangunan, mengakibatkan kerugian signifikan bagi penduduk setempat. Oleh karena itu, diperlukan suatu perhitungan menggunakan metode khusus agar prediksi curah hujan yang optimal dapat diperoleh (Azriel dkk, 2022).

Jaringan Saraf Tiruan merupakan sistem pemrosesan informasi yang dapat digunakan untuk sistem prediksi dengan menggunakan data lampau dan mengolahnya (Hadimarta dkk., 2020). Jaringan Syaraf Tiruan model *Multilayer perceptron* (JST-MLP) dapat digunakan untuk memprediksi perubahan cuaca secara lebih akurat yang memungkinkan penerapan sistem peramalan ini dalam kehidupan sehari-hari (Priambudi, 2023). Variabel yang digunakan dalam metode MLP ini adalah curah hujan, temperatur rata-rata, kelembapan rata-rata, dan lamanya penyinaran matahari. Penggunaan metode MLP memiliki keunggulan dalam menentukan nilai bobot yang lebih baik dibandingkan dengan metode lainnya (Manalu dkk., 2020).

Berbagai penelitian terkait metode yang digunakan pernah dilakukan, pada penelitian (Azriel dkk, 2022) dengan judul “Klasifikasi Curah Hujan di Kota Bogor Provinsi Jawa Barat dengan Menggunakan Metode *Naive Bayes*” Metode yang digunakan ialah *Naive Bayes*. Penelitian ini dimulai dengan Analisa masalah, perancangan dan pembuatan program, serta serangkaian uji coba terhadap program, maka dapat disimpulkan bahwa system ini mampu memprediksi curah hujan di Bogor menggunakan metode *Naive Bayes* dan dapat melakukan prediksi dengan peluang akurasi mencapai 92%.

Pada penelitian lain yang dilakukan (Sunardi dkk, 2020) dengan judul “Sistem Prediksi Curah Hujan Bulanan Menggunakan Jaringan Saraf Tiruan *Backpropagation*”. Arsitektur jaringan saraf tiruan yang digunakan adalah arsitektur *multilayer perceptron*. Arsitektur *multilayer perceptron* ini terdiri dari beberapa lapisan neuron, termasuk lapisan input, lapisan tersembunyi, dan lapisan *output*. Pada penelitian ini, perancangan dan implementasi sistem prediksi curah hujan berhasil dibangun dengan pengembangan perangkat lunak SDLC *water fall* model. Sistem dapat menjadi alternatif penyedia data curah hujan untuk wilayah yang tidak memiliki stasiun pengamatan serta proses prediksi menjadi lebih mudah karena menggunakan antarmuka web. Pengujian sistem dengan *black box testing* menunjukkan bahwa sistem dapat digunakan untuk memprediksi curah hujan baru dan menghasilkan akurasi pelatihan 93.92% dengan validasi sebesar 73.04%.

Pada penelitian lain yang dilakukan oleh (Haryani dkk, 2023) dengan judul “Algoritma Klasifikasi *Multilayer Perceptron* Dalam Analisa Data Kebakaran Hutan” menjelaskan proses analisis data dilakukan dengan menggunakan teknik *machine learning* tradisional melalui metode *Random Forest*, *Decision Tree*, *Logistic Regression*, *Naive Bayes* dan *Multilayer Perceptron*. Mengetahui keakuratan dan nilai hasil F1 memungkinkan membandingkan metode ini dengan bahasa pemrograman *Python*. Hasil pengujian menunjukkan bahwa pendekatan *Multilayer Perceptron* mengungguli metode *Random Forest*, *Decision Tree*, *Logistic Regression* dan *Nave Bayes* dengan nilai akurasi masing-masing sebesar 93,35% dan F1 Score 93,69% dengan ukuran *hidden layer* sebesar 64,64. Dibandingkan dengan pendekatan lain yang dipelajari, nilai metode *multilayer perceptron* cukup signifikan. Penelitian ini dapat membantu menentukan kemungkinan kebakaran hutan.

Dalam penelitian ini, pemilihan metode *Multilayer Perceptron* diharapkan dapat meningkatkan akurasi prediksi curah hujan dengan memanfaatkan memodelkan hubungan antar variabel yang kompleks dalam konteks data cuaca. *Multilayer Perceptron* (MLP) sebagai representasi kecerdasan buatan yang mampu memahami pola-pola kompleks dalam data. Penelitian ini memiliki tujuan untuk memprediksi curah hujan di Kota Bogor pada tahun 2023. Data yang digunakan dalam penelitian ini ialah data yang diunduh dari website BMKG. Informasi yang dihasilkan dari penelitian ini diharapkan dapat menjadi dasar bagi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kota Bogor dalam upaya mengantisipasi dampak curah hujan di masa mendatang.

1.2 Tujuan

Membuat model prediksi curah hujan di Kota Bogor dengan pendekatan menggunakan metode *Multilayer Perceptron*.

1.3 Ruang Lingkup

Ruang lingkup penelitian ini adalah sebagai berikut:

1. Data yang digunakan adalah data yang diambil dari *database* BMKG, dengan data hasil pengamatan pada wilayah Kota Bogor.
2. Data set yang digunakan adalah data yang diambil dalam kurun waktu satu tahun, Januari – Desember 2023.

3. Data yang diambil adalah data iklim harian yang di unduh dalam bentuk data per bulan.
4. Atribut data yang digunakan berupa curah hujan, kelembapan, temperatur rata-rata, dan lamanya penyinaran matahari.

1.4 Manfaat Penelitian

Manfaat penelitian ini adalah sebagai berikut:

1. Penelitian ini memberikan wawasan mendalam tentang bagaimana metode *Multilayer Perceptron* (MLP) dapat diterapkan untuk memprediksi curah hujan.
2. Didapatkannya prediksi curah hujan dari model yang telah dibuat.
3. Menghasilkan sebuah model yang bisa memprediksi curah hujan dengan menggunakan empat atribut data (Kecepatan angin rata-rata, Kelembapan rata-rata, Lamanya penyinaran matahari, Temperatur rata-rata) pada *database* BMKG.

BAB II TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 *Data Mining*

Data mining adalah proses penggalian atau eksplorasi data untuk menemukan pola, hubungan, atau informasi yang bermanfaat dari kumpulan data yang besar dan kompleks. Tujuan dari *data mining* adalah untuk mengidentifikasi wawasan baru, tren, dan pengetahuan yang tersembunyi dalam data, yang dapat digunakan untuk mengambil keputusan dan membuat prediksi yang lebih baik (Azwanti, 2019).

Metode *data mining* adalah cara yang diterapkan, tetapi perlu disesuaikan dengan tujuan penggunaannya. Ada beberapa pembagian metode *data mining* berikut

1. *Classification*

Klasifikasi *data mining* adalah sebuah proses menemukan definisi kesamaan karakteristik dalam suatu kelompok atau kelas (*class*). Klasifikasi *data mining* menjadi salah satu metode yang paling umum untuk digunakan. Metode ini dilakukan bertujuan untuk memperkirakan kelas dari suatu objek yang labelnya belum diketahui.

2. *Association*

Metode *data mining* yang kedua adalah *Market basket analysis* (analisa keranjang pasar) atau *association*. Berhubungan dengan pemasaran, metode ini bertujuan untuk mengidentifikasi produk yang sering dibeli bersamaan oleh pelanggan.

3. *Clustering*

Clustering data mining adalah nama lain untuk metode *segmentation*. Tujuan dari segmentasi pada metode *data mining* adalah mengelompokkan suatu *class* ke dalam beberapa segmen berdasarkan atribut yang ditentukan. Penentuan atribut harus sesuai kesamaan yang dimiliki beberapa *class* tadi.

4. *Regression*

Metode keempat dari *data mining* adalah *regression*. Metode yang satu ini sedikit mirip dengan klasifikasi *data mining*. Bedanya, regresi merupakan metode yang bertujuan untuk mencari pola nilai numerik, bukan kelas. Hasil dari metode *regression* adalah sebuah fungsi sebagai penentu hasil yang didasarkan nilai dari input.

5. *Forecasting*

Forecasting data mining adalah metode yang digunakan untuk memprediksi nilai yang akan dicapai pada satu periode. Dengan menggunakan teknik ini, *noise* data dan nilai pada periode sebelumnya dijadikan dasar bahan prediksi.

6. *Sequencing*

Sequence adalah sebuah urutan peristiwa. Tidak jauh dari namanya, metode *sequence analysis* berfungsi untuk mencari sebuah pola pada serangkaian kejadian atau *sequence*. Contoh sederhananya dalam kehidupan sehari-hari adalah ketika makan. Rangkaian yang umum dilakukan adalah mengambil piring, sendok dan garpu, kemudian baru mengambil lauk pauk. Pola seperti itu lah yang berusaha dicari tahu melalui *sequencing*.

7. *Descriptive*

Metode *data mining* yang satu ini bertujuan untuk memahami lebih dalam mengenai data-data yang masuk dalam pengamatan. Hasil akhirnya adalah mengetahui perilaku dari data itu sendiri.

2.1.2 *Machine Learning*

Machine learning adalah bagian dari bidang kecerdasan buatan yang berfokus pada penerapan algoritma dan metode khusus untuk prediksi, pengenalan pola, dan klasifikasi. Algoritma-algoritma di *machinen learning* yaitu *naural network*, *decision tree*, *k-nearest neighbor*, *naïve bayes*, *random forest* dan lain sebagainya (Novita dkk, 2022).

2.1.3 *Prediksi*

Prediksi merupakan sebuah proses sistematis dalam melakukan perkiraan tentang kemungkinan terjadinya sesuatu di masa depan berdasarkan informasi dari masa lalu dan saat ini. Tujuan prediksi adalah untuk mengurangi kesalahan (perbedaan antara apa yang diprediksi dengan apa yang benar-benar terjadi). Prediksi tidak selalu memberikan jawaban yang pasti mengenai kejadian di masa depan, melainkan berusaha untuk mendapatkan jawaban yang paling dekat mungkin dengan apa yang akan terjadi (Srisulistiowati dkk, 2021).

2.1.4 *Curah Hujan*

Curah hujan merupakan ketinggian air hujan yang terkumpul dalam tempat yang datar, tidak menguap, tidak meresap, dan tidak mengalir. Satuan curah hujan selalu dinyatakan dalam satuan milimeter atau inchi namun untuk di indonesia satuan curah hujan yang digunakan adalah dalam satuan milimeter (mm). Curah hujan dalam 1 (satu) milimeter memiliki arti dalam luasan satu meter persegi pada tempat yang datar tertampung air setinggi satu milimeter atau tertampung air sebanyak satu liter.

Intensitas curah hujan adalah jumlah curah hujan dalam suatu satuan waktu tertentu, yang biasanya dinyatakan dalam mm/jam, mm/hari, mm/tahun, dan sebagainya, yang berturut-turut sering disebut hujan jam-jaman, harian, tahunan, dan sebagainya. Biasanya data yang sering digunakan untuk analisis adalah nilai maksimum, minimum dan nilai rata-ratanya (BMKG).

2.1.5 *Temperatur*

Suhu atau temperatur adalah satu besaran pokok pada fisika yang menyatakan panas dinginnya suatu objek. Satuan Internasional (SI) yang digunakan untuk suhu adalah Kelvin (K). Simbol yang digunakan untuk melambangkan suhu atau temperatur adalah T. Alat ukur yang digunakan untuk mengukur suhu disebut dengan termometer. Secara fisika suhu dianggap sama dengan temperatur. Sedangkan secara bahasa keduanya dianggap sedikit berbeda. Menurut KBBI (Kamus Besar Bahasa Indonesia), suhu adalah ukuran kuantitatif terhadap panas dinginnya sesuatu yang diukur dengan termometer, sedangkan temperatur adalah panas dinginnya badan atau hawa.

2.1.6 Kelembapan

Kelembapan adalah banyaknya air yang terkandung dalam udara, biasanya dinyatakan dengan persentase. Kelembapan ini berhubungan atau dipengaruhi oleh temperatur udara, dan secara bersama-sama antara temperatur (BMKG).

2.1.7 Kecepatan Angin

Kecepatan Angin adalah satuan yang mengukur kecepatan aliran udara dari tekanan tinggi ke tekanan rendah dan diukur dengan menggunakan anemometer atau dapat diklasifikasikan dengan menggunakan skala *Beaufort* yang didasarkan pada pengamatan pengaruh spesifik dari kecepatan angin tertentu (BMKG).

2.1.8 Lamanya Penyinaran Matahari

Lama penyinaran matahari (*Sunshine duration*) adalah lamanya matahari bersinar sampai permukaan bumi dalam periode satu hari, diukur dalam jam. Periode satu hari lebih tepat disebut panjang hari yakni jangka waktu matahari berada diatas horizon (BMKG).

2.1.9 Jaringan Saraf Tiruan (*Artificial Neural Network*)

Jaringan saraf tiruan merupakan algoritma dalam permasalahan pengenalan pola yang bekerja dengan menirukan jaringan saraf manusia yang dapat menyimpan informasi dan bentuk sebuah tujuan dari sistem tersebut (Ghufron dkk., 2019).

2.1.10 Normalisasi Data

Penerapan normalisasi data memiliki peran penting dalam memperlancar proses pada jaringan dengan tujuan tertentu. Normalisasi data dilakukan untuk memastikan bahwa keluaran hasil pelatihan sesuai dengan fungsi aktivasi yang digunakan, sehingga memastikan konsistensi dan akurasi dalam pengolahan data. Proses normalisasi data juga dapat membantu menghindari bias yang mungkin muncul akibat perbedaan skala data, sehingga meningkatkan keakuratan analisis dan prediksi. Dalam konteks normalisasi data, metode yang akan digunakan adalah formula *min max* normalisasi, yang mengubah data menjadi rentang antara 0 hingga 1. Rumus dari min max normalisasi:

$$X_{baru} = \frac{x_{lama} - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Tabel 1. Keterangan Rumus Normalisasi

X_{baru}	:	nilai yang dinormalisasi atau nilai baru setelah proses normalisasi.
x_{lama}	:	nilai asli sebelum normalisasi
x_{baru}	:	nilai yang akan dinormalisasi atau nilai baru setelah normalisasi.

x_{max}	:	nilai maksimum dari seluruh dataset.
x_{min}	:	anilai minimum dari seluruh dataset.

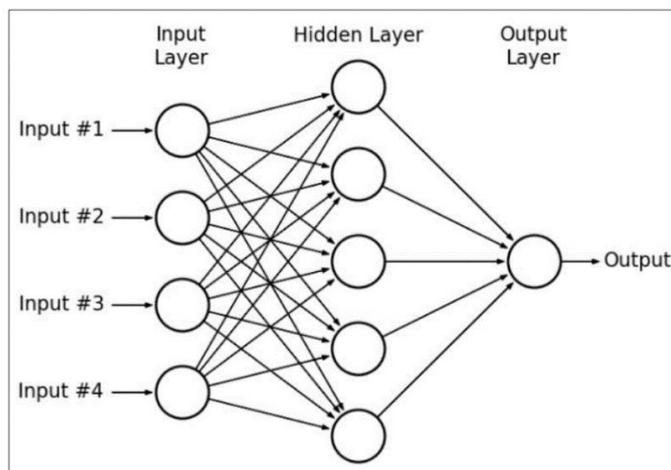
Rumus normalisasi yang diterapkan dalam penelitian ini adalah $X_{baru} = (X_{lama} - X_{min}) / (X_{max} - X_{min})$. Di mana X_{lama} mencakup nilai aktual, X_{max} adalah nilai maksimal dari data aktual, X_{min} adalah nilai minimal dari data aktual, dan X_{baru} adalah nilai yang telah mengalami proses normalisasi.

2.1.11 Tuning Parameter

Tuning parameter merupakan proses penyesuaian parameter pada model *machine learning* untuk meningkatkan performanya. Pada dasarnya, di setiap algoritma *machine learning* memiliki parameter yang dapat disesuaikan, untuk memberikan pengaruh yang signifikan pada performa model.

2.1.12 MLP (*Multilayer Perceptron*)

Multilayer perceptron merupakan proses yang menggunakan Teknik statistika, matematika, kecerdasan buatan dan *machine learning* untuk melakukan ekstraksi dan identifikasi informasi dan pengetahuan yang bermanfaat terkait dari berbagai big data. *Multi-layer perceptron* sering juga disebut sebagai *knowledge discovery in database* (KDD) yang meliputi kegiatan pengumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam set data yang berukuran besar (Andhika dkk, 2021). Arsitektur *Multilayer Perceptron* dapat dilihat pada **Gambar 1**.



Gambar 1. Arsitektur *Multilayer Perceptron*

Jaringan MLP terdiri dari 3 atau lebih *layer* yaitu satu *layer input*, satu atau lebih *hidden layer* dan satu *layer output*. *Input layer* menerima sinyal dari luar dan meneruskan ke *hidden layer* pertama dan akan berlanjut hingga mencapai *output layer*.

Model ini diketahui sebagai jaringan yang terkoneksi penuh (*Fully Connected Network*), dimana *neuron* pada *hidden layer* terkoneksi dengan *neuron* lain pada

layer II-1. Sebagai tambahan, neuron terorganisir dalam layer yang terkoneksi secara maju ke depan dari *layer* satu ke *layer* lain. Pelatihan MLP bertujuan untuk menyesuaikan nilai *output* dengan pola pasangan *input* yang dimasukkan. Proses pelatihan tersebut secara iterasi menentukan bobot-bobot koneksi antar *neuron* agar optimal. Jaringan MLP yang telah dilatih diharapkan memberikan hasil yang baik. *Multi Layer Perceptron* merupakan jaringan yang menggunakan algoritma *backpropagation* yang meliputi 3 tahap yaitu umpan maju (*feed forward*) dari pola input, perhitungan dan propagasi balik dari *error* serta penyesuaian bobot (Fadel dkk, 2022).

Setiap *neuron* dalam jaringan MLP melakukan beberapa operasi matematika pada inputnya, dan biasanya, operasi ini melibatkan perhitungan bobot dan fungsi aktivasi. Inilah beberapa tahapan utama dalam operasi MLP:

1. Perhitungan Bobot (*Weighted Sum*)
Setiap *neuron* menerima input dari *neuron-neuron* dalam lapisan sebelumnya, mengalikannya dengan bobot yang sesuai, dan menjumlahkannya. Ini menciptakan sebuah nilai tertentu yang mewakili "berat" dari setiap input.
2. Penambahan Bias
Setelah perhitungan bobot, bias ditambahkan ke nilai yang dihasilkan. Bias adalah parameter yang membantu model mempelajari pola yang lebih kompleks dan memungkinkan model untuk mengatasi masalah seperti pergeseran nol.
3. Fungsi Aktivasi (*Activation Function*)
Hasil dari perhitungan bobot dan penambahan bias diteruskan melalui fungsi aktivasi. Fungsi ini memutuskan apakah neuron tersebut harus diaktifkan (mengirimkan sinyal) atau tidak. Beberapa fungsi aktivasi umum meliputi ReLU (*Rectified Linear Unit*), *Sigmoid*, dan Tangen Hiperbolik (*Tanh*).
4. Propagasi Mundur (*Backpropagation*)
Setelah mendapatkan hasil dari lapisan *output*, jaringan MLP membandingkan hasil ini dengan target yang sebenarnya (dalam masalah *supervised learning*) dan menghitung kesalahan prediksi. Kesalahan ini kemudian digunakan untuk mengoreksi bobot dan bias dalam seluruh jaringan dengan menggunakan algoritma *backpropagation*.

Neuron dalam *layer* tersembunyi mendeteksi fitur-fitur tersembunyi. Bobot dari neuron dalam *layer* tersembunyi merepresentasikan fitur tersembunyi dalam *vector* masukan. Fitur-fitur tersembunyi ini kemudian digunakan oleh *layer* keluaran dalam penentuan pola/kelas keluaran. Dengan satu *layer* tersembunyi, kita dapat merepresentasikan sembarang fungsi kontinu dari sinyal masukan, dan dengan dua *layer* tersembunyi, fungsi diskontinu pun dapat direpresentasikan. *layer* tersembunyi “menyembunyikan” keluaran yang diinginkan. *Neuron* dalam *layer* tersembunyi tidak dapat diamati melalui perilaku masukan jaringan secara keseluruhan.

Di bawah ini adalah pendekatan pelatihan dasar untuk *Multilayer Perceptron* (MLP) menggunakan metode penurunan gradien (*gradient descent*) dalam konteks pembelajaran berbasis gradien. Ini melibatkan proses *feedforward* (propagasi maju) dan *backward* (propagasi mundur) untuk memperbarui bobot dan mengurangi kesalahan jaringan. Berikut adalah beberapa rumus dasar. (Monica dkk, 2020)

1. Inisialisasi semua bobot dengan bilangan acak kecil.
2. Jika kondisi penghentian belum dipenuhi, lakukan langkah 2-8.
3. Untuk setiap pasang data pelatihan, lakukan langkah 3-8.
4. Tiap unit masukan menerima sinyal dan meneruskan ke unit tersembunyi di atasnya.
5. Hitung semua keluaran di unit tersembunyi Z_j ($j = 1, 2, \dots, p$)

$$Z_{in j} = v_{0j} + \sum_i^n x_i v_{ij} \quad (2)$$

v_{0j} = bias pada unit tersembunyi j aplikasikan fungsi aktivasinya untuk menghitung sinyal keluarannya, $z_j = f(z_{in j})$, dan kirimkan sinyal ini keseluruhan unit pada lapisan di atasnya (unit keluaran). Terapkan fungsi aktivasi dan hasilnya dikirimkan ke *output unit*.

6. Tiap unit keluaran ($y_k, k = 1, \dots, m$) jumlahkan bobot sinyal masukannya $y_{ink} = w_{0k} + \sum_{j=1}^p z_j w_{jk}$ w_{0k} = bias pada unit keluaran k dan aplikasikan fungsi aktivasinya untuk menghitung sinyal keluarannya.

$$y_k = f(y_{ink}) \quad (3)$$

7. Hitung faktor δ unit keluaran berdasarkan kesalahan di setiap unit keluaran $y_k (k = 1, 2, \dots, m)$. $\delta_k = (t_k - y_k) f'(y_{netk}) = (t_k - y_k) y_k (1 - y_k)$, t_k = target δ_k merupakan unit kesalahan yang akan dipakai dalam perubahan bobot layer dibawahnya. Hitung perubahan bobot w_{kj} dengan laju pemahaman α . $\Delta W_{0k} = \alpha \delta_k$

(4)

8. Hitung faktor δ unit tersembunyi berdasarkan kesalahan di setiap unit tersembunyi.

$$\delta_{in j} = \sum_{k=1}^m \delta_k w_{jk} \quad (5)$$

Faktor δ tersembunyi kalikan dengan nilai fungsi turunan aktivasi untuk menghitung *error*

$$s_j = s_{in j} f'(z_{in j}) \quad (6)$$

Hitung nilai perbaikan bobot, (v), $\Delta V_{ij} = \alpha \delta_j x_i$ 16 hitung nilai perbaikan bias (v), $\Delta V_j = \alpha \delta_j$.

9. Hitung semua perubahan bobot, perubahan bobot garis yang menuju ke unit keluaran, yaitu:

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (7)$$

Perubahan bobot garis yang menuju ke unit tersembunyi, yaitu:

$$w_{jk}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{if} \quad (8)$$

2.1.13 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) merupakan akar kuadrat dari kuadrat kesalahan rata-rata yang dihasilkan dari perhitungan. Jika hasil RMSE semakin rendah maka akan semakin baik hasil prediksinya (Prasetyo dkk., 2021).

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (9)$$

RMSE memberikan indikasi tentang sejauh mana deviasi antara prediksi model dan nilai sebenarnya. Semakin kecil nilai RMSE, semakin baik model dapat memprediksi nilai yang sebenarnya. Dalam konteks penelitian meteorologi dan hidrologi, model prediksi curah hujan yang dianggap baik umumnya memiliki nilai RMSE di bawah 20 mm/hari. Rentang ini berlaku tergantung pada frekuensi data yang digunakan, apakah prediksi dilakukan secara harian, mingguan, atau bulanan, serta tujuan spesifik dari prediksi tersebut, seperti perencanaan irigasi, mitigasi bencana banjir, atau prakiraan cuaca.

Jika model menghasilkan nilai RMSE yang melebihi 20 mm/hari, maka model tersebut dapat dianggap kurang akurat, khususnya untuk prediksi jangka pendek, yang sering membutuhkan tingkat kesalahan yang minimal. Nilai RMSE yang tinggi dapat menandakan adanya kesalahan prediksi yang besar, yang tidak diinginkan dalam aplikasi yang memerlukan keandalan tinggi.

Selain itu, dalam evaluasi RMSE, beberapa faktor penting harus dipertimbangkan. Salah satunya adalah kompleksitas model. Model yang lebih sederhana cenderung menghasilkan nilai RMSE yang lebih tinggi dibandingkan dengan model yang lebih kompleks, namun kelebihanannya terletak pada kemudahan interpretasi dan kecepatan perhitungan. Hal ini menjadi penting apabila model prediksi digunakan dalam aplikasi yang menuntut prediksi cepat, seperti prakiraan cuaca harian. Meski demikian, kompromi antara akurasi dan kompleksitas sering kali diperlukan agar model tetap efektif secara praktis. (Sekaranom dkk, 2021).

2.2 Penelitian Terdahulu

Referensi Jurnal penelitian antara lain :

- 1 Nama : Azriel Alfian Rizqi, Dewi Kusumaningsih.
Judul : Klasifikasi Curah Hujan di Kota Bogor Provinsi Jawa Barat dengan Menggunakan Metode *Naive Bayes*.
Tahun : 2022.
Isi : Metode komputasi *Naives Bayes* yang didukung oleh data atribut yang kuat dapat membantu membuat pola komputasi ini lebih akurat. Data yang digunakan diambil dari BMKG 2022 dan memiliki tiga variabel bebas. Dimulai dengan analisa masalah, perancangan dan pembuatan program, serta serangkaian uji coba terhadap program, maka dapat disimpulkan bahwa system ini mampu memprediksi curah hujan di Kota Bogor menggunakan *metode Naive Bayes* dan dapat melakukan prediksi dengan peluang akurasi mencapai 92%.

- 2 Nama : Sunardi, Anton Yudhana, Ghufron Zaida Muflih.
Judul : Sistem Prediksi Curah Hujan Bulanan Menggunakan Jaringan Saraf Tiruan *Backpropagation*.
Tahun : 2020.
Isi : Pada penelitian ini, arsitektur jaringan saraf tiruan yang digunakan adalah arsitektur *multilayer perceptron*. Arsitektur *multilayer perceptron* ini terdiri dari beberapa lapisan neuron, termasuk lapisan *input*, lapisan tersembunyi, dan lapisan *output*. Pada penelitian ini, perancangan dan implementasi sistem prediksi curah hujan berhasil dibangun dengan pengembangan perangkat lunak SDLC *waterfall* model. Sistem dapat menjadi alternatif penyedia data curah hujan untuk wilayah yang tidak memiliki stasiun pengamatan serta proses prediksi menjadi lebih mudah karena menggunakan antarmuka web. Pengujian sistem dengan *black box testing* menunjukkan bahwa sistem dapat digunakan untuk memprediksi curah hujan baru dan menghasilkan akurasi pelatihan 93.92% dengan validasi sebesar 73.04%.

- 3 Nama : Haryani, Cucu Ika Agustyaningrum, Artika Surniandari, Sucitra Sahara, Ratna Kurnia Sari.
- Judul : Algoritma Klasifikasi *Multilayer Perceptron* Dalam Analisa Data Kebakaran Hutan.
- Tahun : 2023
- Isi : Proses analisis data dilakukan dengan menggunakan teknik *machine learning* tradisional melalui metode *Random Forest*, *Decision Tree*, *Logistic Regression*, *Naive Bayes* dan *Multilayer Perceptron*. Mengetahui keakuratan dan nilai hasil F1 memungkinkan membandingkan metode ini dengan bahasa pemrograman *Python*. Hasil pengujian menunjukkan bahwa pendekatan *Multilayer Perceptron* mengungguli metode *Random Forest*, *Decision Tree*, *Logistic Regression* dan *Nave Bayes* dengan nilai akurasi masing-masing sebesar 93,35% dan F1 Score 93,69% dengan ukuran *hidden layer* sebesar 64,64. Dibandingkan dengan pendekatan lain yang dipelajari, nilai metode *multilayer perceptron* cukup signifikan. Penelitian ini dapat membantu menentukan kemungkinan kebakaran hutan.

2.3 Tabel Perbandingan Penelitian

Tabel perbandingan penelitian dapat dilihat pada **Tabel 2**.

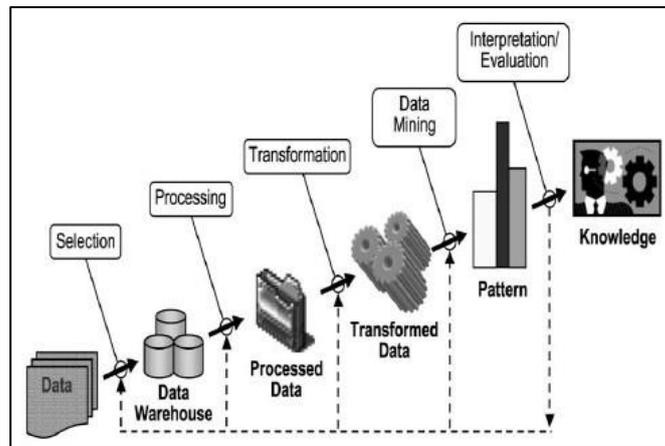
Tabel 2. Perbandingan Penelitian

No.	Nama Peneliti , Tahun	Judul	Jenis Perbandingan				Jumlah Data
			Metode				
			LSTM	MLP	Random Forest	Naives Bayes	
1	Azriel Alfian Rizqi, Dewi Kusumaningsih. 2022	Klasifikasi Curah Hujan di Kota Bogor Provinsi Jawa Barat dengan Menggunakan Metode Naïve Bayes.	-	-	-	✓	612
2	Riza Farikhul Firdaus, Irving Vitra Papatungan. 2022	Prediksi Curah Hujan di Kota Bandung Menggunakan Metode <i>Long Short Term Memory</i>	✓	-	-	-	1.826
3	Sunardi, Anton Yudhana, Ghufro Zaida Muflih, 2020	Sistem Prediksi Curah Hujan Bulanan Menggunakan Jaringan Syaraf Tiruan Backpropagation	-	✓	-	-	1.095
3	Haryani, Cucu Ika Agustyaningrum, Artika Surniadi, Sucitra Sahara, Ratna Kurnia Sari. 2023	Algoritma Klasifikasi <i>Multilayer Perceptron</i> Dalam Analisa Data Kebakaran Hutan	-	✓	-	-	517
4	Muhammad Azizan. 2023	Model Cerdas Prediksi Curah Hujan Menggunakan Algoritma <i>Machine Learning</i>	-	✓	-	-	1.800

BAB III METODE PENELITIAN

3.1 Alur Penelitian

Metode yang digunakan pada penelitian ini yaitu *Knowledge Discovery In Database (KDD)*. Memiliki tujuan yaitu menggunakan data yang tersedia pada basis data, kemudian mengolah data untuk mendapatkan sebuah informasi baru yang bermanfaat. Alur Penelitian dapat dilihat pada **Gambar 2**.



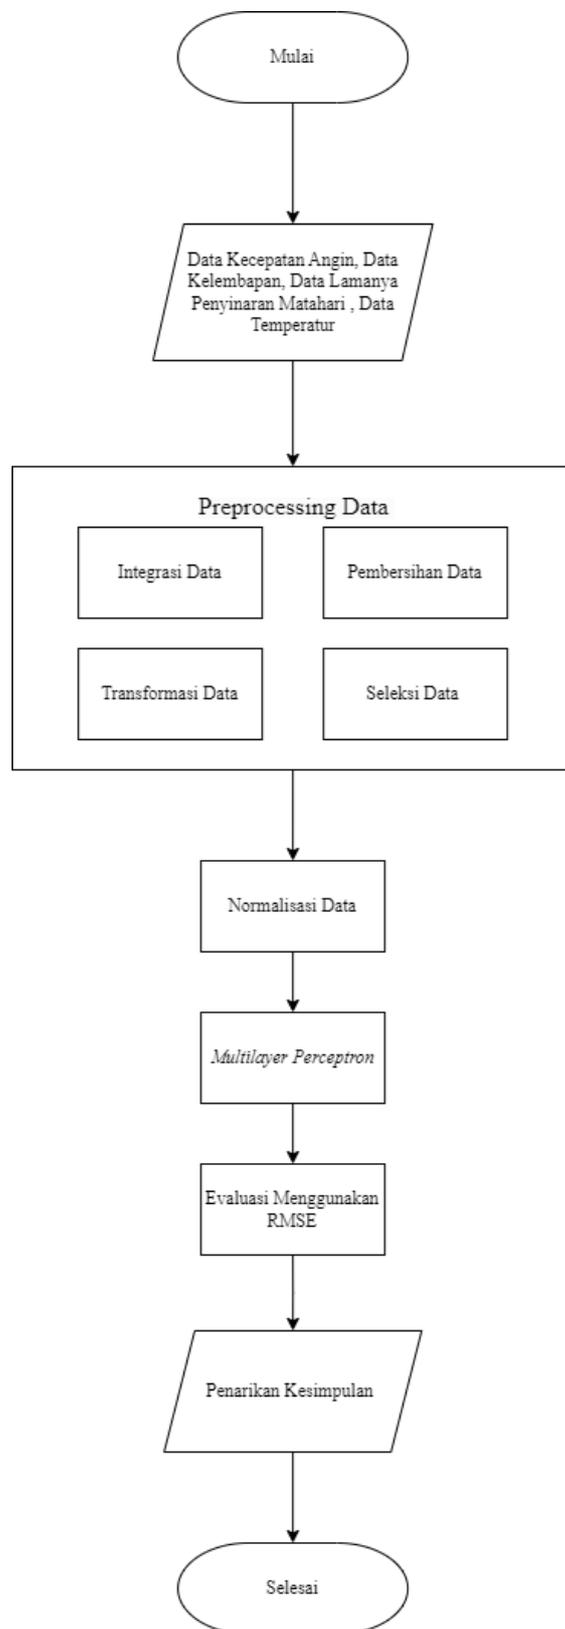
Gambar 2. Alur Metode Penelitian KDD

3.1.1 Pengumpulan Data

Data dikumpulkan dari pengunduhan yang tersedia di *website database* BMKG. Pengambilan data pada penelitian ini menggunakan data resmi yang pengamatannya dilakukan oleh Stasiun Klimatologi Jawa Barat. Dengan parameter data berupa Kecepatan angin rata-rata, Kelembapan rata-rata, Lamanya penyinaran matahari, Temperatur rata-rata. Setelah pengambilan data dari *website*, data tersebut diolah dan dilanjutkan ke tahapan *Data Cleaning*.

3.1.2 Flowchart Desain

Flowchart adalah diagram alur yang menggambarkan langkah, urutan, dan keputusan dalam melakukan sebuah proses dari suatu program. *Flowchart* program Model Prediksi Curah Hujan Menggunakan *Multilayer Perceptron*. Dapat dilihat pada **Gambar 3**.



Gambar 3. *Flowchart* Desain

3.1.3 Data Cleaning

Data Cleaning dilakukan untuk menghilangkan data yang tidak valid, data yang hilang atau kosong. Dataset dimasukkan dalam model maka dilakukan proses *data cleaning* yang meliputi pengisian *missing value* (data yang kosong), menghaluskan *noisy data*, mengidentifikasi atau menghilangkan *outlier*, dan menghilangkan inkonsistensi. Data perlu dilakukan pembersihan sebelum diproses dengan Teknik *data mining*. Data yang didapat dari kasus nyata biasanya tidak siap digunakan, dalam arti mengandung data yang tidak benar. Hal ini bisa jadi karena adanya kesalahan *instrumen faulty*, kesalahan yang dilakukan oleh manusia atau kesalahan transmisi. Setelah data dirasa sudah baik untuk digunakan dalam proses pengolahan, maka data diubah ke bentuk *CSV* (Dwiasnati & Devianto, 2022).

3.1.4 Seleksi Data

Proses seleksi data perlu dilakukan sebelum tahapan penggalian informasi dalam KDD. Data hasil seleksi yang akan digunakan untuk proses *data mining*, disimpan dalam suatu berkas, terpisah dari basis data operasional.

3.1.5 Transformasi Data

Transformasi data adalah merubah skala kedalam bentuk lain sehingga data memiliki distribusi yang diharapkan. Setiap data dilakukan operasi matematika yang sama pada data aslinya. Data yang telah di *cleaning* dan diperbaiki lalu dilakukan transformasi ke dalam file terpisah dengan format *CSV*. Sehingga data tersebut layak dan siap untuk dilakukan proses *data mining*.

3.1.6 Normalisasi Data

Penerapan normalisasi data memiliki peran penting dalam memperlancar proses pada jaringan dengan tujuan tertentu. Normalisasi data dilakukan untuk memastikan bahwa keluaran hasil pelatihan sesuai dengan fungsi aktivasi yang digunakan, sehingga memastikan konsistensi dan akurasi dalam pengolahan data. Proses normalisasi data juga dapat membantu menghindari bias yang mungkin muncul akibat perbedaan skala data, sehingga meningkatkan keakuratan analisis dan prediksi. Dalam konteks normalisasi data, metode yang akan digunakan adalah formula *min max* normalisasi, yang mengubah data menjadi rentang antara 0 hingga 1.

3.1.7 Data mining

Pada proses *data mining* dilakukan pembagian dataset menjadi beberapa bagian yang mana di bagi menjadi data *training* dan data *testing*. Kemudian dimasukkan kedalam proses *Multilayer Perceptron*.

3.1.8 Evaluasi Model

Setelah tahapan *data mining* dilakukan maka dilanjutkan dengan melakukan evaluasi terhadap hasil dari pemodelan tersebut. Evaluasi merupakan suatu pola

informasi yang dihasilkan dalam *data mining* untuk menampilkan suatu bentuk yang mudah di mengerti oleh pihak yang berkepentingan (Pratama, dkk, 2022).

3.1.9 Representasi Pengetahuan

Representasi pengetahuan adalah visualisasi dan penyajian pengetahuan terhadap hasil data dan metode yang digunakan untuk memproses hasil prediksi tersebut. Hasil presentase pengetahuan dapat ditampilkan dalam bentuk grafik atau tabel untuk memudahkan dan interpretasi hasil prediksi.

3.2 Alat dan Bahan

3.2.1 Alat

Alat yang di butuhkan dalam penelitian ini berupa perangkat lunak (*Software*) dan perangkat keras (*Hardware*) yaitu :

a. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan adalah :

1. Sistem Operasi Windows 11 64bit
2. Google Chrome
3. Google Collab
4. Microsoft Excel 2019
5. Microsoft Word 2019
6. Microsoft Visio 2019
7. Mendeley

b. Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan adalah :

1. Laptop
2. AMD Ryzen™ 5 3500U 4 Core 8 Thread
3. RAM 8.00

3.2.2 Bahan

Bahan yang digunakan dalam penelitian ini adalah :

1. Buku panduan penyusunan Praktek Lapang dan Tugas Akhir (Skripsi) tahun 2019 Universitas Pakuan.
2. Data Kecepatan angin rata-rata, Kelembapan rata-rata, Lamanya penyinaran matahari, Temperatur rata-rata, dan Curah hujan yang dikumpulkan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG).
3. Jurnal , Buku referensi , dan koneksi internet sebagai penunjang refensi dalam pelaksanaan penelitian ini.

BAB IV

PERANCANGAN DAN IMPLEMENTASI

4.1 Tahap Analisis Kebutuhan

Proses paling awal dan pertama kali dilakukan dalam penelitian ini adalah pengumpulan data Kecepatan angin rata-rata, Kelembapan rata-rata, Lamanya penyinaran matahari, Temperatur rata-rata, dan Curah hujan yang dikumpulkan oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG).

4.1.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data pengamatan pada Kota Bogor yang dikumpulkan melalui UPT Stasiun Klimatologi Jawa Barat pada Januari 2023 – Desember 2023 dengan jumlah 1.800 Data.

4.1.2 Lingkup Pengambilan Data

Lingkup pengambilan data yang di kumpulkan dalam penelitian ini mencakup data Kecepatan angin rata-rata, Kelembapan rata-rata, Lamanya penyinaran matahari, Temperatur rata-rata, dan Curah hujan Kota Bogor yang dikumpulkan melalui UPT Stasiun Klimatologi Jawa Barat pada Januari 2023 – Desember 2023 dengan Jumlah 1.800 Data.

4.1.3 Teknik Pengumpulan Data

Pengumpulan data secara otomatis menggunakan alat alat canggih untuk mendukung data analisis dan prakiraan. Radar cuaca untuk memonitoring pergerakan awan, curah hujan, jenis awan, intensitas curah hujan secara *real time* pada suatu daerah dengan jangkuan 250 km. *Lightning Detector* atau pendeteksi petir merupakan alat yang digunakan untuk mendeteksi kejadian petir termasuk jenis dan tipe petir. ARG (*Automatic Rain Gauge*) atau dikenal penakar hujan otomatis merupakan alat yang digunakan untuk mengukur curah hujan dalam satuan waktu. AWS (*Automatic Weather Station*) merupakan alat untuk mengukur unsur-unsur cuaca secara otomatis. Unsur yang diukur adalah suhu, angin, kelembaban, radiasi matahari, curah hujan, tekanan udara. Alat ini diletakkan di wilayah yang berada di luar jangkuan stasiun pengamatan.

4.1.4 Sample Data

Sample data mencakup informasi mengenai data Kecepatan angin rata-rata, Kelembapan rata-rata, Lamanya penyinaran matahari, Temperatur rata-rata, dan Curah hujan Kota Bogor yang dikumpulkan melalui UPT Stasiun Klimatologi Jawa Barat. Data dapat dilihat pada **Tabel 3**.

Tabel 3. Data Penelitian

	ID WMO	: 96753
	Nama Stasiun	: Stasiun Klimatologi Jawa Barat
	Lintang	: -6.50000
	Bujur	: 106.75000
	Elevasi	: 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-01-2023	24.3	89	0	1
02-01-2023	24.4	91	0	1
03-01-2023	24.3	89	2.1	2
04-01-2023	25.4	85	0	2
05-01-2023	26	83	2.8	1
06-01-2023			3.2	1
07-01-2023				
08-01-2023	25.6	88	8.8	1
09-01-2023	26.4	80	5.8	2
10-01-2023	26.4	84	6.5	1
11-01-2023			5.8	0
12-01-2023	26.9	80	6	1
13-01-2023	25.9	86	9.7	1
14-01-2023	26.8	80	4.5	1
15-01-2023	25.9	88	8.6	1
.....				
16-08-2023	26	74	8.6	1
17-08-2023	26.2	74	8.8	2
18-08-2023	26.4	73	8.8	1
19-08-2023	26.7	73	8	1
20-08-2023	27.1	76	9.9	1
21-08-2023	26.2	75	9	1
22-08-2023	25.6	77	7.5	1
23-08-2023	26.6	75	6.4	1
24-08-2023	27.2	74	6.6	1
25-08-2023	27	79	8.5	1
26-08-2023	27.1	78	6.9	1
27-08-2023	25.4	84	4.8	1
28-08-2023	25.7	81	6.2	1
29-08-2023	26.1	72	5.7	1
30-08-2023	26	71	8.6	1
31-08-2023	26.4	72	9.1	2
.....				
21-12-2023	27.6	67	10.6	1
22-12-2023	28.1	70	9.6	0
23-12-2023	28.7	72	8.5	2
24-12-2023	27.6	81	6.9	2
25-12-2023	27	83	6.1	1
26-12-2023	26.6	84	3.8	1
27-12-2023	26.8	83	0	1
28-12-2023	27.1	83	4.6	1
29-12-2023	26.7	89	6.9	1
30-12-2023	25.7	92	0	1
31-12-2023	26.2	87	0.2	1

Data yang digunakan dalam penelitian ini merupakan data pengamatan Kota Bogor pada periode Januari 2023 – Desember 2023 dengan Jumlah 1.800 Data.

4.2 Preprocessing Data

Data hujan dari BMKG tidak langsung siap diolah menjadi model, melainkan perlu diolah terlebih dahulu. Proses ini disebut prapemrosesan data. Prapemrosesan data mengubah data mentah menjadi format yang lebih mudah dipahami dan diproses oleh algoritma. Dengan prapemrosesan, prediksi menjadi lebih efisien dan akurat. Tujuan prapemrosesan data adalah untuk memperbaiki kesalahan pada data mentah, seperti data hilang, tidak valid, atau format yang tidak teratur.

Tabel 4. Data Frame

Tanggal	Indeks DataFrame
Temperatur	Data suhu dalam derajat Celsius.
Kelembapan	Data kelembapan dalam persen.
Penyinaran Matahari	Data durasi penyinaran matahari dalam jam.
Kecepatan Angin	Data kecepatan angin dalam meter per detik.
Curah Hujan	Data curah hujan dalam milimeter.

Tabel 4 merupakan sebuah Data Frame yang menyimpan berbagai variabel yang masuk dalam tahapan *preprocessing data*.

4.2.1 Integrasi Data

Integrasi data merupakan langkah awal dalam prapemrosesan data. Pada tahap ini, berbagai berkas data digabungkan menjadi satu kesatuan yang disebut Dataset. Sebelum digabungkan, data-data tersebut perlu diubah ke format yang sama. Hal ini dilakukan agar data dapat terintegrasi dengan mulus dan terhindar dari inkonsistensi. Tujuan integrasi data adalah untuk menciptakan satu Dataset yang konsisten dan siap digunakan untuk analisis data. Dengan Dataset yang terintegrasi, proses analisis data menjadi lebih mudah dan efisien.

1) Pembacaan Data dari File Excel

Pertama, membaca data dari file Excel ke dalam sebuah Data frame menggunakan Pandas. Ini adalah langkah awal yang penting dalam analisis data.

```
import pandas as pd

# Baca file Excel
df = pd.read_excel('/content/dataolah.xlsx')
```

Gambar 4. Code Pembacaan Data

2. Membersihkan Nama Kolom

Kemudian, membersihkan nama kolom dengan menghapus spasi tambahan di awal dan akhir nama kolom.

```
# Membersihkan nama kolom
df.columns = [col.strip() for col in df.columns]
```

Gambar 5. Code Pembersihan Nama Kolom

3. Menetapkan Nama Kolom Fitur dan Target

Selanjutnya, menetapkan nama-nama kolom fitur yang akan digunakan dalam prediksi dan nama kolom target yang akan diprediksi.

```
# Nama kolom fitur dan target
features = ['Kecepatan angin', 'Kelembapan', 'Penyinaran matahari', 'Temperatur']
target = 'Curah hujan'
```

Gambar 6. Code Menetapkan Nama Kolom Fitur dan Target

4.2.2 Pembersihan Data

Langkah selanjutnya adalah pembersihan data. Proses ini bertujuan untuk menyingkirkan data yang tidak valid, tidak relevan, dan tidak sesuai format. Pembersihan data penting untuk memastikan bahwa hanya data berkualitas yang digunakan dalam proses pemodelan. Penjelasan proses pembersihan data, diuraikan sebagai berikut :

- Menangani nilai yang hilang (NaN), mengisi nilai yang hilang dalam kolom fitur dengan rata-rata dari kolom tersebut. Ini membantu menjaga integritas data dan memastikan tidak ada *missing values* yang dapat mempengaruhi hasil model.
- Menghapus data yang tidak relevan atau tidak sesuai dengan kebutuhan proses *data mining*, memastikan bahwa hanya informasi yang penting dan berguna yang digunakan dalam analisis.

Tabel 5. Data Penelitian Sebelum Proses *Cleaning*

Tanggal	Tavg	RH_avg	ss	ff_avg
01-01-2023	243	89	0	1
02-01-2023	244	91	0	1
03-01-2023	243	89	2.1	2
04-01-2023	254	85	0	2
05-01-2023	26	83	2.8	1
06-01-2023			3.2	1
07-01-2023				
08-01-2023	25.6	88	8.8	1
09-01-2023	26.4	80	5.8	2
10-01-2023	26.4	84	6.5	1
11-01-2023			5.8	0
12-01-2023	26.9	80	6	1
13-01-2023	25.9	86	9.7	1
14-01-2023	26.8	80	4.5	1
15-01-2023	25.9	88	8.6	1
16-08-2023	26	74	8.6	1
17-08-2023	26.2	74	8.8	2
18-08-2023	26.4	75	8.8	1
19-08-2023	26.7	73	8	1
20-08-2023	27.1	76	9.9	1
21-08-2023	26.2	75	9	1
22-08-2023	25.6	77	7.5	1
23-08-2023	26.6	75	6.4	1
24-08-2023	27.2	74	6.6	1
25-08-2023	27	79	8.5	1
26-08-2023	27.1	78	6.9	1
27-08-2023	25.4	84	4.8	1
28-08-2023	25.7	81	6.2	1
29-08-2023	26.1	72	5.7	1
30-08-2023	26	71	8.6	1
31-08-2023	26.4	72	9.1	2
21-12-2023	27.6	67	10.6	1
22-12-2023	28.1	70	9.6	0
23-12-2023	28.7	72	8.5	2
24-12-2023	27.6	81	6.9	2
25-12-2023	27	83	6.1	1
26-12-2023	26.6	84	3.8	1
27-12-2023	26.8	83	0	1
28-12-2023	27.1	83	4.6	1
29-12-2023	26.7	89	6.9	1
30-12-2023	25.7	92	0	1
31-12-2023	26.2	87	0.2	1

1. Pembersihan Data Temperatur

Penanganan pada data temperatur, Dalam proses pengumpulan data, terdapat beberapa nilai yang hilang (*missing value*) pada kolom Temperatur. Nilai hilang ini dapat disebabkan oleh berbagai faktor, seperti kesalahan dalam pencatatan, kerusakan alat ukur, atau kondisi lingkungan yang tidak memungkinkan untuk pengambilan data. Nilai hilang ini harus ditangani dengan tepat untuk memastikan integritas dan kualitas *dataset* yang akan digunakan dalam analisis dan pemodelan. Data temperatur yang akan dilakukan proses *cleaning*, dapat dilihat pada **Tabel 6**.

Tabel 6. Data Temperatur Sebelum Proses *Cleaning*

No	Tanggal	Tavg (Temperatur)
1	06-01-2023	
2	07-01-2023	
3	11-01-2023	
4	07-02-2023	
5	28-03-2023	
6	03-04-2023	
7	08-04-2023	
8	09-04-2023	
9	31-07-2023	
10	06-09-2023	

Untuk menangani nilai yang hilang pada kolom Temperatur, metode imputasi digunakan dengan cara mengisi nilai yang hilang dengan nilai rata-rata dari kolom tersebut. Dalam hal ini, rata-rata temperatur yang digunakan untuk mengisi nilai yang hilang adalah 26.5°C. Proses imputasi ini penting untuk menjaga konsistensi data dan memastikan bahwa tidak ada *missing value* yang dapat mempengaruhi hasil analisis dan pemodelan.

Proses penanganan nilai hilang dilakukan dengan menghitung rata-rata kolom. Nilai rata-rata kolom Temperatur dihitung dari data yang ada. Rata-rata yang diperoleh adalah 26.5°C. Setiap nilai yang hilang pada kolom Temperatur diisi dengan nilai rata-rata yang telah dihitung, yaitu 26.5°C. Jumlah nilai yang hilang pada kolom Temperatur adalah sebanyak 10 nilai.

2. Pembersihan Data Kelembapan

Dataset yang digunakan terdiri dari beberapa kolom, termasuk Tanggal dan Kelembapan (RH_avg). Dalam proses pengumpulan data, terdapat beberapa nilai yang hilang *missing value* pada kolom kelembapan. Nilai hilang ini harus ditangani dengan tepat untuk memastikan kualitas dataset yang akan digunakan dalam analisis dan pemodelan. Data kelembapan yang akan dilakukan proses *cleaning*, dapat dilihat pada **Tabel 7**.

Tabel 7. Data Kelembapan Sebelum Proses *Cleaning*

No	Tanggal	RH_avg (Kelembapan)
1	06-01-2023	
2	07-01-2023	
3	11-01-2023	
4	26-06-2023	
5	23-10-2023	

Penanganan nilai yang hilang pada kolom Kelembapan, menggunakan metode imputasi dengan cara mengisi nilai yang hilang dengan nilai rata-rata dari kolom tersebut. Dalam hal ini, rata-rata kelembapan yang digunakan untuk mengisi nilai yang hilang adalah 81. Proses imputasi ini penting untuk menjaga konsistensi data dan memastikan bahwa tidak ada *missing value* yang dapat mempengaruhi hasil analisis dan pemodelan. Proses penanganan nilai hilang dilakukan dengan langkah-langkah menghitung rata-rata kolom. Nilai rata-rata kolom kelembapan dihitung dari data yang ada. Rata-rata yang diperoleh adalah 81%. Mengisi nilai hilang Setiap nilai yang hilang pada kolom Kelembapan diisi dengan nilai rata-rata yang telah dihitung, yaitu 81%. Jumlah nilai yang hilang pada kolom Kelembapan adalah sebanyak 5 nilai.

3. Penyinaran Matahari

Pada penelitian ini, dataset yang digunakan terdiri dari beberapa kolom, termasuk Tanggal dan Penyinaran Matahari (ss). Dalam proses pengumpulan data, terdapat beberapa nilai yang hilang *missing value* pada kolom Penyinaran Matahari. Nilai hilang ini harus ditangani dengan tepat untuk memastikan integritas dan kualitas dataset yang akan digunakan dalam analisis dan pemodelan. Data penyinaran matahari yang akan dilakukan proses *cleaning*, dapat dilihat pada **Tabel 8**.

Tabel 8. Data Penyinaran Matahari Sebelum Proses *Cleaning*

No	Tanggal	ss (Penyinaran Matahari)
1	01-01-2023	
2	02-01-2023	
3	04-01-2023	
4	07-01-2023	
5	26-01-2023	
6	29-01-2023	
7	03-02-2023	
8	13-02-2023	
9	23-02-2023	
10	25-02-2023	
11	30-12-2023	

Proses penanganan nilai yang hilang pada kolom Penyinaran Matahari, menggunakan metode imputasi dengan cara mengisi nilai yang hilang dengan nilai rata-rata dari kolom tersebut. Dalam hal ini, rata-rata penyinaran matahari yang digunakan untuk mengisi nilai yang hilang adalah 6. Proses imputasi ini penting untuk menjaga konsistensi data dan memastikan bahwa tidak ada *missing value* yang dapat mempengaruhi hasil analisis dan pemodelan. Jumlah nilai yang hilang pada kolom Penyinaran Matahari adalah sebanyak 11 nilai.

4. Kecepatan Angin

Pada penelitian ini, dataset yang digunakan terdiri dari beberapa kolom, termasuk tanggal dan kecepatan angin (*ff_avg*). Dalam proses pengumpulan data, terdapat beberapa nilai yang hilang pada kolom kecepatan angin. Nilai hilang ini harus ditangani dengan tepat untuk memastikan kualitas dataset yang akan digunakan dalam analisis dan pemodelan. Data kelembapan yang akan dilakukan proses cleaning, dapat dilihat pada **Tabel 9**.

Tabel 9. Data Kecepatan Angin Sebelum Proses *Cleaning*

No	Tanggal	ff_avg (Kecepatan Angin)
1	07-01-2023	
2	03-04-2023	
3	14-08-2023	
4	22-12-2023	

Penanganan nilai yang hilang pada kolom Kecepatan Angin, menggunakan metode imputasi dengan cara mengisi nilai yang hilang dengan nilai rata-rata dari kolom tersebut. Dalam hal ini, rata-rata kecepatan angin yang digunakan untuk mengisi nilai yang hilang adalah 1 m/s. Proses imputasi ini penting untuk menjaga konsistensi data dan memastikan bahwa tidak ada *missing value* yang dapat mempengaruhi hasil analisis dan pemodelan. Setiap nilai yang hilang pada kolom Kecepatan Angin diisi dengan nilai rata-rata yang telah dihitung, yaitu 1 m/s. Jumlah nilai yang hilang pada kolom Kecepatan Angin adalah sebanyak 4 nilai.

Dataset yang digunakan dalam penelitian ini terdiri dari beberapa kolom, yaitu Tanggal, Temperatur, Kelembapan, Penyinaran Matahari, dan Kecepatan Angin. Sebelum dilakukan pembersihan data, terdapat beberapa nilai yang hilang di kolom Temperatur (10 nilai hilang), Kelembapan (5 nilai hilang), Penyinaran Matahari (11 nilai hilang), dan Kecepatan Angin (4 nilai hilang). Proses ini memastikan bahwa tidak ada nilai yang hilang di seluruh kolom setelah pembersihan, mengubah total dataset menjadi lengkap tanpa ada *missing values*. Secara keseluruhan, proses ini mengisi 30 nilai yang hilang. Pembersihan data ini sangat penting untuk meningkatkan kualitas dataset sehingga analisis dan pemodelan dapat dilakukan dengan lebih akurat.

4.2.3 Seleksi Data

Setelah ditransformasi, data dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*validation data*). Data latih digunakan untuk melatih algoritma agar dapat mengenali pola dan informasi dalam data. Sedangkan data uji digunakan untuk mengevaluasi kemampuan model yang telah dilatih. Pada penelitian ini, beberapa skenario pembagian data latih dan data uji digunakan. Proporsi pembagian data tersebut dapat dilihat pada **Tabel 10**.

Tabel 10. Proporsi Data

No	Data <i>Training</i>	Data <i>Testing</i>
1	90%	10%
2	80%	20%
3	70%	30%
4	60%	40%

Tabel 10 merupakan proporsi pengujian model memiliki empat skenario berbeda dalam pembagian *data training* dan *testing*. Mulai dari 90% *data training* dan 10% *data testing*, hingga 60% *data training* dan 40% *data testing*. Pembagian ini krusial karena berpengaruh pada kinerja model yang dibangun. Semakin besar proporsi data yang digunakan untuk melatih model, biasanya model akan lebih baik dalam memahami pola-pola dalam data tersebut.

Tabel 11. Atribut Data

No	Kategori	Atribut
1	Angin	Kecepatan angin
2	Suhu	Temperatur Rata - Rata
3	Kelembapan	Kelembapan Rata - Rata
4	Matahari	Lamanya penyinaran Matahari

Tabel 11 menyajikan kategori dan atribut-atribut yang digunakan dalam analisis dan prediksi curah hujan. Atribut kecepatan angin, suhu rata-rata, kelembapan rata-rata, dan lamanya penyinaran matahari merupakan variabel yang signifikan dalam memprediksi curah hujan. Kecepatan angin dapat memengaruhi pola dan distribusi awan serta transportasi uap air, sementara suhu dan kelembapan memainkan peran penting dalam membentuk kondisi atmosfer yang mendukung terbentuknya hujan. Lamanya penyinaran matahari juga memengaruhi pemanasan dan penguapan air di permukaan, yang kemudian berkontribusi pada pembentukan awan dan potensi hujan. Kombinasi atribut-atribut ini memberikan informasi yang kaya dalam membangun model prediksi curah hujan yang akurat dan dapat diandalkan.

Tabel 12. Konfigurasi *Multilayer Perceptron*

Proporsi Data	<i>Hidden layer Sizes</i>	<i>Learning Rate</i>	<i>Epochs</i>
(0.9, 0.1)	(10)	0.001	10000
(0.8, 0.2)	(10)	0.001	10000
(0.7, 0.3)	(10)	0.001	10000
(0.6, 0.4)	(10)	0.001	10000

Tabel 12 memberikan gambaran tentang bagaimana model MLP dibangun dan dilatih dengan berbagai konfigurasi proporsi data, ukuran *hidden layer*, *learning rate*, dan jumlah *epochs*. Proses ini penting untuk mengoptimalkan performa model dalam memprediksi data yang belum pernah dilihat sebelumnya.

- *Proporsi Data*: Menunjukkan proporsi data *training* dan *testing* dalam tuple (proporsi *training*, proporsi *testing*). Contohnya, (0.9, 0.1) berarti 90% data digunakan untuk *training* dan 10% untuk *testing*.
- *Hidden Layer Sizes*: Merupakan ukuran *hidden layer* dalam model MLP. Pada contoh ini, digunakan satu *hidden layer* dengan 10 neuron.
- *Learning Rate*: Menentukan seberapa cepat model akan belajar dari data. *Learning rate* 0.001 dipilih untuk mengatur kecepatan pembelajaran model.
- *Epochs*: Jumlah iterasi yang dilakukan saat melatih model. Dengan 10000 *epochs*, model memiliki cukup iterasi untuk belajar pola-pola yang kompleks dalam data.

Dengan jumlah *epoch* (10000) memungkinkan model untuk melihat data berkali-kali, yang membantu model untuk lebih baik dalam menangkap pola-pola yang kompleks dan konvergen ke solusi optimal. (Mahmudah dkk, 2020)

4.2.4 Transformasi Data

Transformasi data merupakan proses mengubah data mentah menjadi format yang lebih mudah diolah dalam proses *data mining*. Kolom tanggal dalam dataset belum ditransformasi. Kolom Tanggal ini penting untuk diolah menjadi format yang lebih sesuai untuk analisis dan pemodelan, mengubahnya menjadi format *datetime* yang dapat diolah oleh berbagai fungsi analisis waktu. Transformasi ini diperlukan agar analisis waktu, seperti tren musiman atau analisis deret waktu, dapat dilakukan dengan lebih akurat dan efisien. Data yang akan dilakukan tahapan transformasi data, dapat dilihat pada **Tabel 13**.

Tabel 13. Data Penelitian Yang Akan Dilakukan Proses Transformasi

Tanggal	Tavg (Temperatur)	RH_avg (Kelembapan)	ss (Penyinaran Matahari)	ff_avg (Kecepatan Angin)
01-01-2023	24.3	89	6	1
02-01-2023	24.4	91	6	1
03-01-2023	24.3	89	2.1	2
04-01-2023	25.4	85	6	2
05-01-2023	26	83	2.8	1
06-01-2023	26.5	81	3.2	1
07-01-2023	26.5	81	6	1
08-01-2023	25.6	88	8.8	1
09-01-2023	26.4	80	5.8	2
10-01-2023	26.4	84	6.5	1
11-01-2023	26.5	81	5.8	1
12-01-2023	26.9	80	6	1
13-01-2023	25.9	86	9.7	1
14-01-2023	26.8	80	4.5	1
15-01-2023	25.9	88	8.6	1
.....				
16-06-2023	24.5	95	6.1	1
17-06-2023	25.9	86	6	1
18-06-2023	26.3	86	0.4	1
19-06-2023	25.7	91	9.4	1
20-06-2023	26.9	80	5.7	1
21-06-2023	26.8	84	9.6	1
22-06-2023	27.7	80	7.2	1
23-06-2023	27.2	83	7.7	1
24-06-2023	26.7	87	7.7	1
25-06-2023	25.7	86	8.9	1
26-06-2023	25.9	81	6.5	1
27-06-2023	25.9	84	8	1
28-06-2023	26.8	78	9	1
29-06-2023	26.5	85	9.2	1
30-06-2023	27.1	82	8.9	1
.....				
01-12-2023	25.6	90	3.1	1
02-12-2023	27.1	83	6	1
03-12-2023	26.4	85	6.4	1
04-12-2023	24.9	90	4	1
05-12-2023	26.9	80	6	1
06-12-2023	26.6	85	7.2	2
07-12-2023	27.3	83	7.2	1
08-12-2023	27	87	5.7	1
09-12-2023	26.8	85	5.2	2
10-12-2023	27.3	83	3.7	1
11-12-2023	27.1	84	1.2	2
12-12-2023	27.5	79	7.4	1
13-12-2023	27.8	78	6.4	1
14-12-2023	28.2	73	9.7	2
15-12-2023	28.6	70	9.5	1

4.3 Normalisasi Data

Normalisasi dilakukan untuk memastikan bahwa keluaran hasil pelatihan sesuai dengan fungsi aktivasi yang digunakan, sehingga memastikan konsistensi dan akurasi dalam pengolahan data. Normalisasi yang dilakukan yaitu normalisasi min-max. Yaitu untuk mengubah skala fitur-fitur ke rentang (0, 1). Rumus untuk normalisasi data dapat dilihat pada persamaan (1). Implementasi *code* pada program untuk tahapan normalisasi data dapat dilihat pada **Gambar 7**.

```
# Fungsi untuk normalisasi data
def normalize_data(X_train, X_test, y_train, y_test):
    scaler = MinMaxScaler()
    X_train_scaled = scaler.fit_transform(X_train)
    X_test_scaled = scaler.transform(X_test)

    target_scaler = MinMaxScaler()
    y_train_scaled = target_scaler.fit_transform(y_train.values.reshape(-1, 1))
    y_test_scaled = target_scaler.transform(y_test.values.reshape(-1, 1))

    return X_train_scaled, X_test_scaled, y_train_scaled, y_test_scaled, target_scaler
```

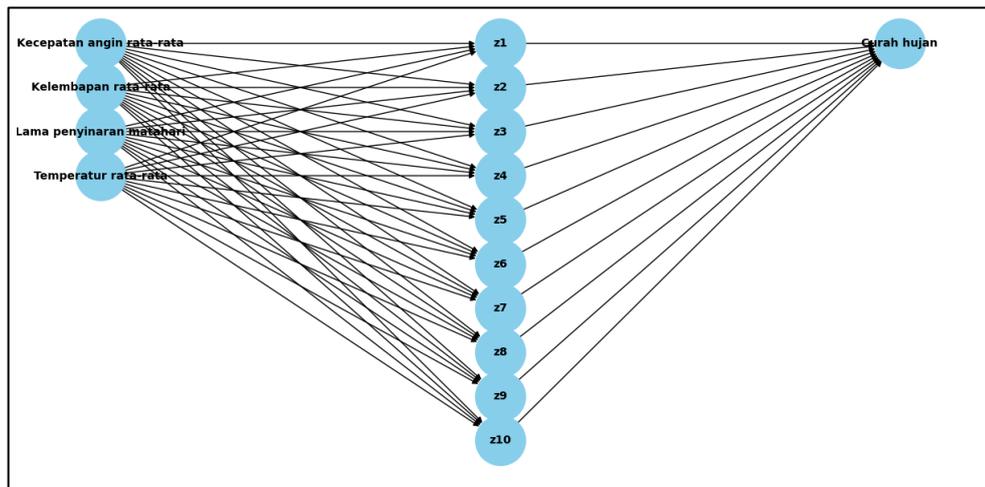
Gambar 7. Code Normalisasi Data

Dengan menggunakan fungsi *normalize_data* seperti di atas, memastikan bahwa data yang digunakan dalam pelatihan model *machine learning* telah diproses dengan benar sesuai dengan prinsip normalisasi *min-max*.

4.4 Data Mining

Tahapan ini termasuk proses mencari pola atau informasi yang menarik dalam data terpilih dengan menggunakan metode tertentu. Dalam konteks penelitian prediksi curah hujan dengan menggunakan metode MLP (*Multilayer Perceptron*).

Metode *Multilayer Perceptron* (MLP) adalah jenis arsitektur dalam jaringan saraf tiruan (*neural network*) yang terdiri dari setidaknya tiga lapisan node: lapisan masukan, satu atau lebih lapisan tersembunyi, dan lapisan keluaran. Setiap *node* dalam lapisan tersembunyi menggunakan fungsi aktivasi untuk menghasilkan outputnya. Seringkali, fungsi aktivasi yang digunakan adalah fungsi *sigmoid* atau RELU (*Rectified Linear Unit*).



Gambar 8. Rancangan Arsitektur MLP

Gambar 8 menunjukkan arsitektur jaringan saraf tiruan (*Artificial Neural Network, ANN*) yang digunakan untuk memprediksi curah hujan. Jaringan ini terdiri dari beberapa lapisan:

1. Lapisan Input

Lapisan input terdiri dari empat neuron yang mewakili atribut data cuaca:

- 1) *Neuron* 1: Kecepatan angin rata-rata
- 2) *Neuron* 2: Kelembapan rata-rata
- 3) *Neuron* 3: Lama penyinaran matahari
- 4) *Neuron* 4: Temperatur rata-rata

2. Lapisan Tersembunyi

Lapisan tersembunyi terdiri dari sepuluh neuron yang terhubung dengan neuron input. *Neuron* di lapisan tersembunyi dapat dibagi menjadi dua kelompok: z1 hingga z5 dan z6 hingga z9, dengan z10 sebagai keluaran akhir sebelum lapisan *output*. *Neuron* z1 hingga z5 *Neuron*-*neuron* ini menerima sinyal dari keempat *neuron* di lapisan *input*. (Sunardi dkk, 2022).

Pengelompokan *neuron* bertujuan untuk :

1) Pengelompokan Berdasarkan Fitur Input:

- a. *Neuron* z1 hingga z5 mengolah sinyal langsung dari lapisan input, memungkinkan fokus pada kombinasi linear awal dari fitur cuaca.
- b. *Neuron* z6 hingga z9 mengolah sinyal dari *neuron* z1 hingga z5, memungkinkan pengolahan yang lebih dalam dan kompleks.

2) Mengurangi Interferensi Antar Fitur:

- a. Dengan memisahkan *neuron* ke dalam dua tahap pengolahan, jaringan dapat mengurangi interferensi antara fitur yang berbeda, meningkatkan kemampuan deteksi pola yang lebih halus dari kombinasi fitur cuaca.

3) Efisiensi Komputasi:

- a. Memisahkan pengolahan dalam dua tahap memungkinkan komputasi yang lebih efisien, dengan setiap tahap berfokus pada pengolahan data.

4) Fokus Deteksi Pola:

- a. Tahap pertama (z1-z5) mungkin lebih sensitif terhadap pola dasar dari data cuaca, sementara tahap kedua (z6-z9) lebih mampu mendeteksi pola yang lebih kompleks dan hubungan antar fitur.

5) Meningkatkan Akurasi Prediksi:

- a. Kombinasi dua tahap pengolahan ini membantu meningkatkan akurasi prediksi dengan menyediakan lapisan pengolahan tambahan untuk menangkap variasi dan hubungan yang lebih kompleks dalam data input.

Berikut adalah proses detailnya:

Setiap *neuron* (z1 hingga z5) menghitung nilai input terakumulasi nya berdasarkan bobot yang terhubung ke setiap *neuron input* dan biasanya.

Misalnya, untuk *neuron* z1:

$$\begin{aligned} Z_{in1} = & b_1 + (w_{1,1} \times \text{kecepatan angin rata - rata}) \\ & + (w_{2,1} \times \text{kelembapan rata - rata}) \\ & + (w_{3,1} \times \text{lamanya penyinaran matahari}) \\ & + (w_{4,1} \times \text{temperatur rata - rata}) \end{aligned}$$

Setelah nilai input terakumulasi dihitung, fungsi aktivasi diterapkan untuk mendapatkan *output*:

$$Z_6 = f(Z_{in6})$$

Proses yang sama berlaku untuk z7 hingga z9 dengan bobot dan bias yang sesuai.

Neuron z6 hingga z9:

Neuron-neuron ini menerima sinyal dari *neuron-neuron* z1 hingga z5.

Setiap *neuron* (z6 hingga z9) menghitung nilai input terakumulasi nya berdasarkan bobot yang terhubung ke setiap *neuron* z1 hingga z5 dan biasanya. Misalnya, untuk *neuron* z6:

$$\begin{aligned} Z_{in6} = & b_6 + (w_{1,6} \times z_1) \\ & + (w_{2,6} \times z_2) + (w_{3,6} \times z_3) + (w_{4,6} \times z_4) + (w_{5,6} \times z_5) \end{aligned}$$

Setelah nilai input terakumulasi dihitung, fungsi aktivasi diterapkan untuk mendapatkan *output*:

$$Z_{10} = f(Z_{in10})$$

- b. Setiap *neuron* di lapisan ini terhubung dengan semua *neuron* di lapisan *input*, menunjukkan bahwa setiap atribut cuaca mempengaruhi setiap *neuron* di lapisan tersembunyi.

3. Lapisan *Output*

- 1) Terdiri dari satu *neuron* yang merepresentasikan nilai curah hujan yang diprediksi.

2) *Neuron* di lapisan output menerima sinyal dari z_{10} :

Neuron output menghitung nilai input terakumulasinya berdasarkan bobot yang terhubung ke *neuron* z_{10} dan biasanya. Misalnya:

$$y_{in} = b_{out} + w_{10,out} \times z_{10} \quad (10)$$

Setelah nilai input terakumulasi dihitung, fungsi aktivasi diterapkan untuk mendapatkan *output*:

$$y = f(y_{in}) \quad (11)$$

Proses *data mining* prediksi menggunakan metode *Multilayer Perceptron* (MLP) melibatkan serangkaian langkah untuk menggali pola dan informasi yang terkandung dalam data dengan tujuan untuk membuat prediksi atau estimasi.

Untuk memastikan pelatihan model berjalan secara efisien dan efektif, beberapa kondisi penghentian telah ditetapkan. Kondisi penghentian ini bertujuan untuk mencegah *overfitting*, mengoptimalkan waktu pelatihan, dan mencapai konvergensi model. Berikut adalah kondisi penghentian yang diterapkan:

1. Jumlah *Epoch* Maksimal: Pelatihan model dihentikan setelah mencapai 10,000 *epoch*, untuk memastikan proses pelatihan tidak berjalan terlalu lama dan menghindari *overfitting*.
2. Konvergensi *Loss Function*: Pelatihan dihentikan jika perubahan nilai *loss* kurang dari 0.001 dalam 10 *epoch* berturut-turut. Hal ini menandakan bahwa model telah mencapai konvergensi dan tidak ada peningkatan signifikan lebih lanjut.
3. *Early Stopping*: Jika performa model pada set validasi tidak membaik setelah 20 *epoch* berturut-turut, pelatihan akan dihentikan. Ini dilakukan untuk mencegah *overfitting*.

Proses pengolahan data dilanjutkan dengan menggugalkan *Multilayer Perceptron*. Langkah – langkah pengolah data dengan *Multilayer Perceptron* sebagai berikut:

1. Inisialisasi Bobot

Bobot di inisialisasi secara acak untuk masing-masing *layer*, termasuk bias pada *output layer*. Implementasi ini menggunakan *NumPy* untuk membuat matriks bobot dengan elemen-elemen yang diinisialisasi secara acak antara 0 dan 1 menggunakan fungsi *np.random.rand()*. Inisialisasi bobot secara acak ini dilakukan untuk menghindari simetri yang dapat terjadi selama proses pelatihan jaringan saraf.

$$V = \begin{bmatrix} 0.1 & 0.2 & 0.3 \\ 0.4 & 0.5 & 0.6 \\ 0.7 & 0.8 & 0.9 \end{bmatrix}$$

Nilai tersebut berasal dari langkah inisialisasi bobot (V) pada *hidden layer*. Bobot ini di inisialisasi secara acak pada awal pelatihan untuk masing-masing koneksi antara *input layer* dan *hidden layer*. Setiap elemen *matriks* ini merupakan bobot yang akan diperbarui selama proses pelatihan jaringan untuk meminimalkan kesalahan prediksi. Implementasi rumus pada program dapat dilihat pada **Gambar 9**.

```
def initialize_weights(input_size, hidden_size, output_size):
    np.random.seed(42)
    v_o = np.random.rand(1, hidden_size)
    v = np.random.rand(input_size, hidden_size)
    w = np.random.rand(hidden_size, output_size)

    return v_o, v, w
```

Gambar 9. Code Inisialisasi Bobot

2. Forward Propagation

Proses ini mencakup perhitungan nilai pada setiap *layer* dari *input* hingga output menggunakan fungsi aktivasi sigmoid. Rumus dari *forward propagation*. Rumus untuk perhitungan manual dari *forwad propagation* dapat dilihat pada persamaan (2) dan persamaan (3).

$$Z_{in} = [0.204081633 \quad 0.72727227 \quad 0.44363104 \quad 0.354166667] \cdot$$

$$\begin{bmatrix} 0.1 & 0.2 & 0.3 \\ 0.4 & 0.5 & 0.6 \\ 0.7 & 0.8 & 0.9 \end{bmatrix} + [0.01 \quad 0.02 \quad 0.03]$$

$$Z_{in} = [Z_{in1} \quad Z_{in2} \quad Z_{in3}]$$

$$Z_{in} = [0.17477354 \quad 0.459073352 \quad 0.631553775] \cdot$$

$$\begin{bmatrix} 0.1 & 0.2 & 0.3 \\ 0.4 & 0.5 & 0.6 \\ 0.7 & 0.8 & 0.9 \end{bmatrix} + [0.01 \quad 0.02 \quad 0.03]$$

$$Z_{in} = [0.17477354 \quad 0.459073352 \quad 0.631553775]$$

Aktivasi Hidden Layer (Z)

$$Z = [\sigma(0.17477354) \quad \sigma(0.459073352) \quad \sigma(0.631553775)]$$

$$Z = [0.543553773 \quad 0.613077684 \quad 0.652862857]$$

Menghitung y_{in} :

$$y_{in} = Z \cdot W$$

di mana Z adalah nilai *output* dari *hidden layer*, dan W adalah matriks bobot untuk koneksi antara *hidden* dan *output layer*.

$$y_{in} = [0.543553773 \quad 0.613077684 \quad 0.652862857]$$

$$\begin{bmatrix} 0.001 \\ 0.002 \\ 0.003 \end{bmatrix}$$

$$y_{in} = [0.001202494]$$

Aktivasi *Output Layer* (y_{pred}):

$$y_{pred} = \sigma(y_{in})$$

di mana *sigmoid* (x) adalah fungsi *sigmoid*.

$$y_{pred} = \sigma(0.001202494)$$

$$y_{pred} = 0.500300623$$

Perhitungan *Error* :

$$S_y = (y - y_{pred}) \cdot \text{sigmoid_derivative}(y_{pred})$$

di mana y adalah nilai sebenarnya, y_{pred} adalah nilai prediksi dari *output layer*, dan *sigmoid_derivative* (x) adalah turunan fungsi *sigmoid* terhadap x .

$$S_y = (0.44363104 - 0.500300623) \cdot \sigma'(0.500300623)$$

$$S_y = -0.0566669583 \cdot 0.249924$$

$$S_y = -0.014166795$$

Jadi, S_y adalah gradien kesalahan terhadap *output layer* yang akan digunakan dalam langkah-langkah selanjutnya dari *propagation* untuk memperbarui bobot dan bias jaringan. Implementasi code pemrograman *forward propagation* dapat dilihat pada **Gambar 10**.

```
def forward_propagation(X, v_o, v, w):
    z_in = np.dot(X, v) + v_o
    z = sigmoid(z_in)

    y_in = np.dot(z, w)
    y_pred = sigmoid(y_in)

    return z_in, z, y_in, y_pred
```

Gambar 10. Code Forward Propagation

3. *Backward Propagation*

Proses ini menghitung gradien kesalahan terhadap bobot dan bias, lalu menggunakan gradien tersebut untuk memperbarui bobot dan bias melalui *gradient descent*. Di bawah ini adalah tahapan proses perhitungan manual untuk iterasi pertama. Sesuai dengan rumus perhitungan manual untuk tahapan *backward propagation* yang dapat dilihat pada persamaan (4), persamaan (5), persamaan (6), persamaan (7) dan persamaan (8).

Menghitung Gradien Kesalahan terhadap *Output* (S_y) :

$$S_y = -0.014166795$$

Dengan y adalah nilai sebenarnya, y_{pred} adalah nilai prediksi dari *output layer*, dan *sigmoid_derivative* (x) adalah turunan fungsi *sigmoid* terhadap x .

Menghitung Gradien Kesalahan terhadap *Hidden Layer* (δz) :

Dengan δy adalah gradien kesalahan terhadap *output layer*, W^T adalah transpose dari matriks bobot yang menghubungkan *hidden layer* dan *output layer*, dan *sigmoid derivative* (Z) adalah turunan fungsi *sigmoid* terhadap Z .

$$\delta z = -0.014166795 \cdot [0.001 \quad 0.002 \quad 0.003]^T \cdot \begin{bmatrix} \sigma'(0.543553773) \\ \sigma'(0.613077684) \\ \sigma'(0.652862857) \end{bmatrix}$$

$$\delta z = -0.014166795 \cdot [0.001 \quad 0.002 \quad 0.003]^T \cdot \begin{bmatrix} 0.24651628 \\ 23844312 \\ 22772162 \end{bmatrix}$$

$$\delta z = -0.014166795 \cdot [0.001 \quad 0.002 \quad 0.003]^T \cdot \begin{bmatrix} 0.00024651628 \\ 0.00023844312 \\ 0.00022772162 \end{bmatrix}$$

$$\delta z = -0.014166795 \cdot \begin{bmatrix} 0.00024651628 \\ 0.00047688624 \\ 0.00068316486 \end{bmatrix}$$

$$\delta z = [-0.00000349013 \quad 0.00000676115 \quad 0.00000969002]$$

Implementasi rumus pada *code* pemrograman untuk tahapan *backward propagation* dapat dilihat pada **Gambar 11**.

```
def backward_propagation(X, y, v_o, v, w, z_in, z, y_in, y_pred, learning_rate):
    delta_y = (y - y_pred) * sigmoid_derivative(y_pred)
    delta_z = delta_y.dot(w.T) * sigmoid_derivative(z)

    w += learning_rate * z.T.dot(delta_y)
    v_o += learning_rate * np.sum(delta_z, axis=0)
    v += learning_rate * X.T.dot(delta_z)

    return v_o, v, w
```

Gambar 11. Code Backward Proagation

4. Pelatihan Model

Fungsi ini melatih model menggunakan metode *gradient descent* dengan jumlah *epoch* tertentu. Pada setiap *epoch*, model melalui setiap data latih dan memperbarui bobot menggunakan algoritma *backpropagation*. Kesalahan total dihitung dan dicetak setiap 100 *epoch*. Kesalahan tersebut juga disimpan dalam *error_history*. Rumus simulasi perhitungan manual tahapan pelatihan dapat dilihat pada persamaan (3), persamaan (4) dan persamaan (5). Di bawah ini adalah simulasi pelatihan untuk iterasi pertama.

Memperbarui Bobot pada *Output Layer* (V_0):

$$V_{o_{baru}} = V_0 + \text{Learning rate} \cdot \sum \delta z$$

$$V_{o_{baru}} = [0.01 \quad 0.02 \quad 0.03] + 0.01 \cdot$$

$$[-0.00000349013 \quad 0.00000676115 \quad 0.00000969002]$$

$$V_{o_{baru}} = \begin{bmatrix} 0.01 \\ 0.02 \\ 0.03 \end{bmatrix} + \begin{bmatrix} -0.0000000349013 \\ -0.0000000676115 \\ -0.0000000969002 \end{bmatrix}$$

$$V_{o_{baru}} = \begin{bmatrix} -0.0099999650987 \\ -0.199999323885 \\ -0.0299999030998 \end{bmatrix}$$

Memperbarui Bobot pada *Hidden Layer* (V):

$$V_{baru} = V + \text{Learning rate} \cdot X^T \cdot \delta z$$

$$V_{baru} = \begin{bmatrix} 0.1 & 0.2 & 0.3 \\ 0.4 & 0.5 & 0.6 \\ 0.7 & 0.8 & 0.9 \end{bmatrix} + 0.01 \cdot$$

$$\begin{bmatrix} 0.204081633 & 0.727272727 & 0.44363104 \end{bmatrix}^T \cdot$$

$$\begin{bmatrix} -0.00000349013 & -0.00000676115 & -0.00000969002 \end{bmatrix}$$

$$V_{baru} = \begin{bmatrix} 0.1 & 0.2 & 0.3 \\ 0.4 & 0.5 & 0.6 \\ 0.7 & 0.8 & 0.9 \end{bmatrix} +$$

$$\begin{bmatrix} -0.0000007145741587 & -0.0000025371166302 & -0.0000015493131939 \\ -0.0000012286665746 & -0.0000043640906307 & -0.0000026618311387 \\ -0.0000006372013419 & -0.0000022637150557 & -0.00000013802125005 \end{bmatrix}$$

$$V_{baru} = \begin{bmatrix} 0.0999992854258 & 0.1999974628834 & 0.2999984506868 \\ 0.3999987713334 & 0.4999956359094 & 0.5999973381689 \\ 0.999993627987 & 0.7999977362849 & 0.8999986197875 \end{bmatrix}$$

Setelah satu iterasi, bobot pada layer *output* V_0 dan *hidden* (V) di perbarui sesuai dengan metode *gradient descent*. Proses ini diulang pada setiap iterasi selama pelatihan untuk meningkatkan akurasi model. Oleh karena itu maka di implementasikan kedalam program untuk iterasi yang berikutnya sehingga mencapai jumlah iterasi yang diperintahkan. Agar proses pelatihan bisa maksimal dan nilai yang dihasilkan bisa dijadikan pedoman. Untuk melihat sejauh mana proses implementasi program pelatihan berjalan. Implementasi *code* program dapat dilihat pada **Gambar 12**.

```
def train(X, y, hidden_size, learning_rate, epochs):
    input_size = X.shape[1]
    output_size = y.shape[1]
    v_o, v, w = initialize_weights(input_size, hidden_size, output_size)
    error_history = []
```

Gambar 12. Code Pelatihan MLP

BAB V HASIL DAN PEMBAHASAN

5.1 Data

Proses awal penelitian ini melibatkan pengumpulan data dari situs web resmi BMKG. Penelitian ini berlandaskan data resmi yang bersumber dari pihak terkait objek penelitian, Proses pengumpulan data dilakukan dengan cara mengunduh data yang tersedia di situs web BMKG. Data yang diperoleh dari situs web BMKG akan dianalisis dan diolah untuk memahami pola dan karakteristiknya sebelum digunakan dalam prediksi curah hujan. Maka dilanjutkan pada tahapan Data Cleaning.

 BMKG	ID WMO	: 96753
	Nama Stasiun	: Stasiun Klimatologi Jawa Barat
	Lintang	: -6.50000
	Bujur	: 106.75000
	Elevasi	: 207

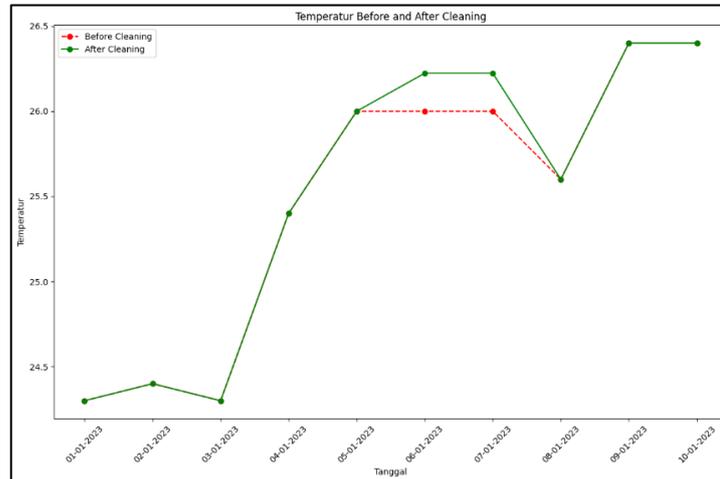
Tanggal	Tavg	RH_avg	ss	ff_avg
01-01-2023	24.3	89	0	1
02-01-2023	24.4	91	0	1
03-01-2023	24.3	89	2.1	2
04-01-2023	25.4	85	0	2
05-01-2023	26	83	2.8	1
06-01-2023			3.2	1
07-01-2023				
08-01-2023	25.6	88	8.8	1
09-01-2023	26.4	80	5.8	2
10-01-2023	26.4	84	6.5	1
11-01-2023			5.8	0
12-01-2023	26.9	80	6	1
13-01-2023	25.9	86	9.7	1
14-01-2023	26.8	80	4.5	1
15-01-2023	25.9	88	8.6	1
.....
16-08-2023	26	74	8.6	1
17-08-2023	26.2	74	8.8	2
18-08-2023	26.4	73	8.8	1
19-08-2023	26.7	73	8	1
20-08-2023	27.1	76	9.9	1
21-08-2023	26.2	75	9	1
22-08-2023	25.6	77	7.5	1
23-08-2023	26.6	75	6.4	1
24-08-2023	27.2	74	6.6	1
25-08-2023	27	79	8.5	1
26-08-2023	27.1	78	6.9	1
27-08-2023	25.4	84	4.8	1
28-08-2023	25.7	81	6.2	1
29-08-2023	26.1	72	5.7	1
30-08-2023	26	71	8.6	1
31-08-2023	26.4	72	9.1	2

Tabel 14. *Dataset* BMKG

Tabel 14 adalah data set , yang diambil oleh BMKG. Data tersebut diunduh pada wabsite https://dataonline.bmkg.go.id/data_iklim

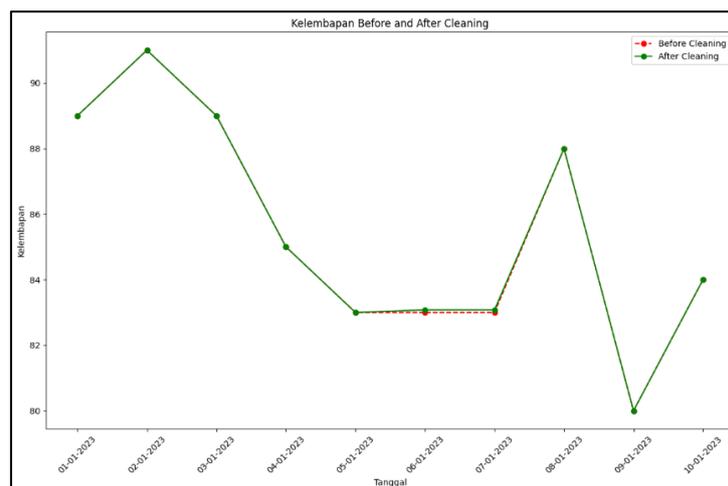
5.2 Hasil Data Cleaning

Hasil Data Cleaning Temperatur, Hasil Data Cleaning Kelembapan, Hasil Data Cleaning Penyinaran Matahari, dan Hasil Data Cleaning Kecepatan Angin. dapat dilihat pada **Gambar 13**, **Gambar 14**, **Gambar 15**, dan **Gambar 16**.



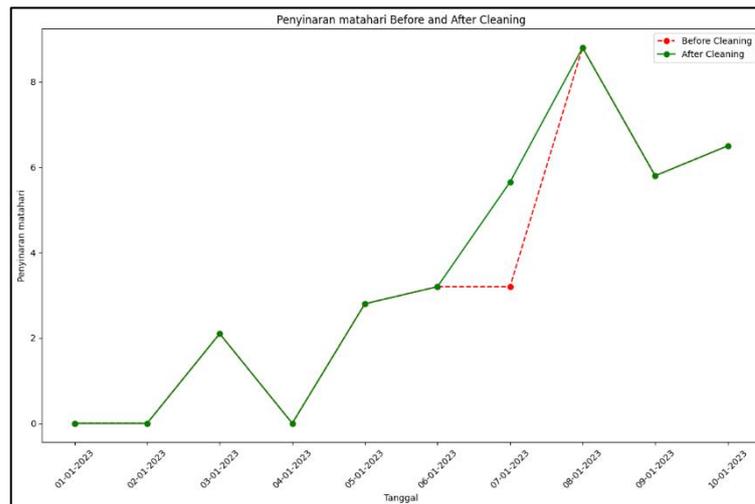
Gambar 13. Grafik Data Temperatur Sebelum dan Sesudah *Cleaning*

Gambar 13 menampilkan grafik yang menggambarkan perubahan temperatur sebelum dan sesudah proses pembersihan data. Garis merah menunjukkan temperatur sebelum pembersihan data, di mana data ditampilkan dengan garis putus-putus berwarna merah. Data ini mengandung nilai yang hilang. Garis hijau menampilkan temperatur setelah pembersihan data. Hasilnya adalah data yang lebih konsisten dan lebih representatif, yang siap untuk tahap analisis dan pemodelan lebih lanjut.



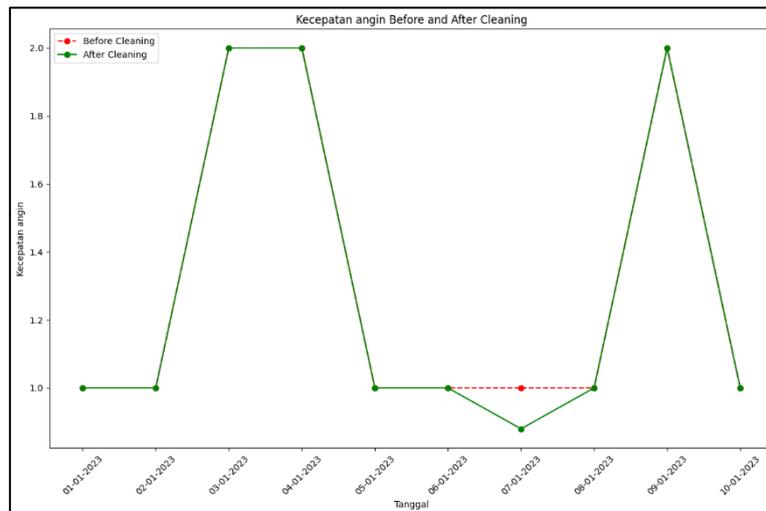
Gambar 14. Grafik Data Kelembapan Sebelum dan Sesudah *Cleaning*

Gambar 14 menampilkan grafik yang menggambarkan perubahan kelembapan sebelum dan sesudah proses pembersihan data. Garis merah menunjukkan kelembapan sebelum pembersihan data, di mana data ditampilkan dengan garis putus-putus berwarna merah. Data ini mengandung nilai yang hilang. Garis hijau menampilkan kelembapan setelah pembersihan data. Hasilnya adalah data yang lebih konsisten dan lebih representatif, yang siap untuk tahap analisis dan pemodelan lebih lanjut.



Gambar 15. Grafik Data Penyinaran Matahari Sebelum dan Sesudah *Cleaning*

Gambar 15 menampilkan grafik yang menggambarkan perubahan penyinaran matahari sebelum dan sesudah proses pembersihan data. Garis merah menunjukkan penyinaran matahari sebelum pembersihan data, di mana data ditampilkan dengan garis putus-putus berwarna merah. Data ini mengandung nilai yang hilang. Garis hijau menampilkan penyinaran matahari setelah pembersihan data. Hasilnya adalah data yang lebih konsisten dan lebih representatif, yang siap untuk tahap analisis dan pemodelan lebih lanjut.



Gambar 16. Grafik Data Kecepatan Angin Sebelum dan Sesudah *Cleaning*

Gambar 16 menampilkan grafik yang menggambarkan perubahan kecepatan angin sebelum dan sesudah proses pembersihan data. Garis merah menunjukkan penyinaran matahari sebelum pembersihan data, di mana data ditampilkan dengan garis putus-putus berwarna merah. Data ini mengandung nilai yang hilang. Garis hijau menampilkan penyinaran matahari setelah pembersihan data. Hasilnya adalah data yang lebih konsisten dan lebih representatif, yang siap untuk tahap analisis dan pemodelan lebih lanjut.

Tabel 15. Data Hasil Proses *Cleaning Data*

Tanggal	Tavg (Temperatur)	RH_avg (Kelembapan)	ss (Penyinaran Matahari)	ff_avg (Kecepatan Angin)
01-01-2023	24.3	89	6	1
02-01-2023	24.4	91	6	1
03-01-2023	24.3	89	2.1	2
04-01-2023	25.4	85	6	2
05-01-2023	26	83	2.8	1
06-01-2023	26.5	81	3.2	1
07-01-2023	26.5	81	6	1
08-01-2023	25.6	88	8.8	1
09-01-2023	26.4	80	5.8	2
10-01-2023	26.4	84	6.5	1
11-01-2023	26.5	81	5.8	1
12-01-2023	26.9	80	6	1
13-01-2023	25.9	86	9.7	1
14-01-2023	26.8	80	4.5	1
15-01-2023	25.9	88	8.6	1
.....				
16-06-2023	24.5	95	6.1	1
17-06-2023	25.9	86	6	1
18-06-2023	26.3	86	0.4	1
19-06-2023	25.7	91	9.4	1
20-06-2023	26.9	80	5.7	1
21-06-2023	26.8	84	9.6	1
22-06-2023	27.7	80	7.2	1
23-06-2023	27.2	83	7.7	1
24-06-2023	26.7	87	7.7	1
25-06-2023	25.7	86	8.9	1
26-06-2023	25.9	81	6.5	1
27-06-2023	25.9	84	8	1
28-06-2023	26.8	78	9	1
29-06-2023	26.5	85	9.2	1
30-06-2023	27.1	82	8.9	1
.....				
01-12-2023	25.6	90	3.1	1
02-12-2023	27.1	83	6	1
03-12-2023	26.4	85	6.4	1
04-12-2023	24.9	90	4	1
05-12-2023	26.9	80	6	1
06-12-2023	26.6	85	7.2	2
07-12-2023	27.3	83	7.2	1
08-12-2023	27	87	5.7	1
09-12-2023	26.8	85	5.2	2
10-12-2023	27.3	83	3.7	1
11-12-2023	27.1	84	1.2	2
12-12-2023	27.5	79	7.4	1
13-12-2023	27.8	78	6.4	1
14-12-2023	28.2	73	9.7	2
15-12-2023	28.6	70	9.5	1

Data hasil *cleaning* menunjukkan bahwa semua nilai yang kosong dalam kolom 'Tavg (Temperatur)', 'RH_avg (Kelembapan)', 'ss (Penyinaran Matahari)', dan 'ff_avg (Kecepatan Angin)' telah diisi dengan nilai rata-rata dari masing-masing kolom. Proses pengisian ini bertujuan untuk menjaga konsistensi data serta memastikan analisis yang lebih akurat dan valid. Dengan mengisi nilai kosong menggunakan rata-rata, dapat mengurangi dampak negatif dari data yang hilang tanpa memperkenalkan bias yang signifikan. Langkah ini penting untuk mempersiapkan data sebelum digunakan dalam model prediksi curah hujan, sehingga model dapat belajar dari dataset yang lengkap dan terstruktur dengan baik

5.3 Hasil Seleksi Data

Hal seleksi data ini dapat dilihat pada **Tabel 16**.

Tabel 16. Hasil Data Tahapan Seleksi Data

Tanggal	Tavg	RH_avg	ss	ff_avg
01-01-2023	24.3	89	6	1
02-01-2023	24.4	91	6	1
03-01-2023	24.3	89	2.1	2
04-01-2023	25.4	85	6	2
05-01-2023	26	83	2.8	1
06-01-2023	26.5	81	3.2	1
07-01-2023	26.5	81	6	1
08-01-2023	25.6	88	8.8	1
09-01-2023	26.4	80	5.8	2
10-01-2023	26.4	84	6.5	1
.....
01-07-2023	26.6	85	7.5	1
02-07-2023	26.5	80	7.8	1
03-07-2023	26.8	81	7.2	1
04-07-2023	26.1	81	7.2	1
05-07-2023	26.7	80	5.4	1
06-07-2023	25.8	90	7.6	1
07-07-2023	24.8	90	2	1
08-07-2023	25.3	88	4	1
09-07-2023	26	82	5.5	1
10-07-2023	26.5	80	4.2	1
.....
21-12-2023	27.6	67	10.6	1
22-12-2023	28.1	70	9.6	1
23-12-2023	28.7	72	8.5	2
24-12-2023	27.6	81	6.9	2
25-12-2023	27	83	6.1	1
26-12-2023	26.6	84	3.8	1
27-12-2023	26.8	83	6	1
28-12-2023	27.1	83	4.6	1
29-12-2023	26.7	89	6.9	1
30-12-2023	25.7	92	0	1
31-12-2023	26.2	87	0.2	1

Tabel 16 menunjukkan hasil seleksi data yang terdiri dari lima kolom: Tanggal, Temperatur, Kelembapan, Penyinaran Matahari, dan Kecepatan Angin, dengan total 365 baris.

5.4 Hasil Transformasi Data

Transformasi data melibatkan mengubah skala data menjadi bentuk lain untuk mencapai distribusi yang diinginkan. Hasil Transformasi data dapat dilihat pada Tabel 17.

Tabel 17. Data Hasil Tahapan Transformasi Data

Tanggal	Tavg	RH_avg	ss	ff_avg
01/01/2023	24.3	89	6	1
02/01/2023	24.4	91	6	1
03/01/2023	24.3	89	2.1	2
04/01/2023	25.4	85	6	2
05/01/2023	26	83	2.8	1
06/01/2023	26.5	81	3.2	1
07/01/2023	26.5	81	6	1
08/01/2023	25.6	88	8.8	1
09/01/2023	26.4	80	5.8	2
10/01/2023	26.4	84	6.5	1
11/01/2023	26.5	81	5.8	1
12/01/2023	26.9	80	6	1
13/01/2023	25.9	86	9.7	1
14/01/2023	26.8	80	4.5	1
15/01/2023	25.9	88	8.6	1
.....
16/06/2023	24.5	95	6.1	1
17/06/2023	25.9	86	6	1
18/06/2023	26.3	86	0.4	1
19/06/2023	25.7	91	9.4	1
20/06/2023	26.9	80	5.7	1
21/06/2023	26.8	84	9.6	1
22/06/2023	27.7	80	7.2	1
23/06/2023	27.2	83	7.7	1
24/06/2023	26.7	87	7.7	1
25/06/2023	25.7	86	8.9	1
26/06/2023	25.9	81	6.5	1
27/06/2023	25.9	84	8	1
28/06/2023	26.8	78	9	1
29/06/2023	26.5	85	9.2	1
30/06/2023	27.1	82	8.9	1
.....
01/12/2023	25.6	90	3.1	1
02/12/2023	27.1	83	6	1
03/12/2023	26.4	85	6.4	1
04/12/2023	24.9	90	4	1
05/12/2023	26.9	80	6	1
06/12/2023	26.6	85	7.2	2
07/12/2023	27.3	83	7.2	1
08/12/2023	27	87	5.7	1
09/12/2023	26.8	85	5.2	2
10/12/2023	27.3	83	3.7	1
11/12/2023	27.1	84	1.2	2
12/12/2023	27.5	79	7.4	1
13/12/2023	27.8	78	6.4	1
14/12/2023	28.2	73	9.7	2
15/12/2023	28.6	70	9.5	1

Dengan mengubah kolom tanggal ke format *datetime*, sangat berguna untuk analisis dan pemrosesan yang lebih mendalam dan akurat, dan sangat penting untuk memahami dan memprediksi pola curah hujan berdasarkan data historis.

5.5 Normalisasi Data

Normalisasi menggunakan metode *Min-Max Scaler*, yang memastikan bahwa nilai minimum dan maksimum dari setiap fitur masing-masing menjadi 0 dan 1. Data hasil normalisasi data dapat dilihat pada **Tabel 18**.

Tabel 18. Data Hasil Tahapan Normalisasi

Tanggal	Tavg	RH_avg	ss	ff_avg
01/01/2023	0.166666667	0.806451613	0.566037736	0.333333333
02/01/2023	0.183333333	0.870967742	0.566037736	0.333333333
03/01/2023	0.166666667	0.806451613	0.198113208	0.666666667
04/01/2023	0.35	0.677419355	0.566037736	0.666666667
05/01/2023	0.45	0.612903226	0.264150943	0.333333333
06/01/2023	0.533333333	0.548387097	0.301886792	0.333333333
07/01/2023	0.533333333	0.548387097	0.566037736	0.333333333
08/01/2023	0.383333333	0.774193548	0.830188679	0.333333333
09/01/2023	0.516666667	0.516129032	0.547169811	0.666666667
10/01/2023	0.516666667	0.64516129	0.613207547	0.333333333
.....
01/06/2023	0.583333333	0.387096774	0.811320755	0.333333333
02/06/2023	0.683333333	0.548387097	0.896226415	0.333333333
03/06/2023	0.733333333	0.612903226	0.754716981	0.333333333
04/06/2023	0.55	0.64516129	0.537735849	0.333333333
05/06/2023	0.466666667	0.709677419	0.79245283	0.333333333
06/06/2023	0.4	0.870967742	0.698113208	0.333333333
07/06/2023	0.566666667	0.612903226	0.075471698	0.333333333
08/06/2023	0.6	0.580645161	0.820754717	0.333333333
09/06/2023	0.533333333	0.548387097	0.679245283	0.333333333
10/06/2023	0.466666667	0.709677419	0.886792453	0.333333333
.....
01/12/2023	0.383333333	0.838709677	0.29245283	0.333333333
02/12/2023	0.633333333	0.612903226	0.566037736	0.333333333
03/12/2023	0.516666667	0.677419355	0.603773585	0.333333333
04/12/2023	0.266666667	0.838709677	0.377358491	0.333333333
05/12/2023	0.6	0.516129032	0.566037736	0.333333333
06/12/2023	0.55	0.677419355	0.679245283	0.666666667
07/12/2023	0.666666667	0.612903226	0.679245283	0.333333333
08/12/2023	0.616666667	0.741935484	0.537735849	0.333333333
09/12/2023	0.583333333	0.677419355	0.490566038	0.666666667
10/12/2023	0.666666667	0.612903226	0.349056604	0.333333333

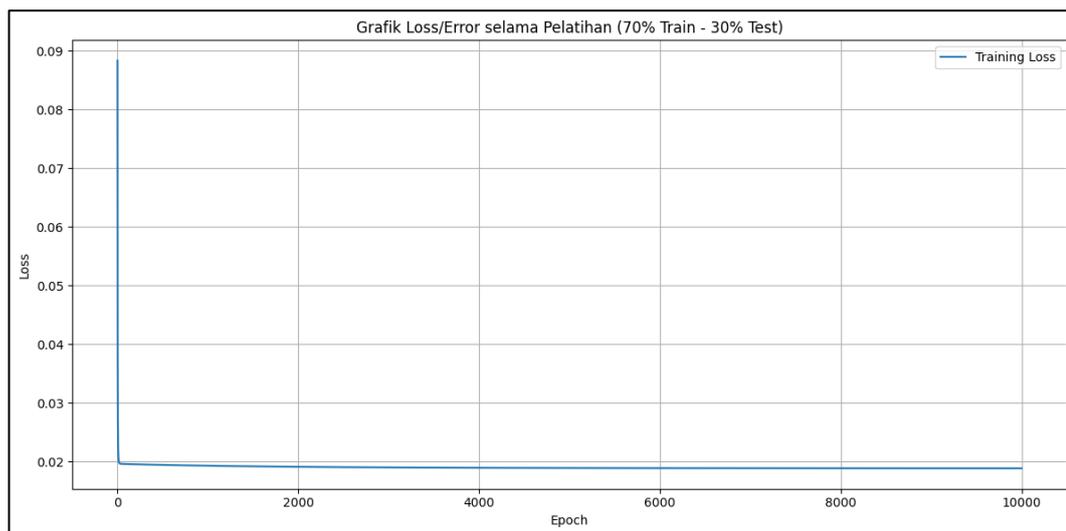
Normalisasi ini penting untuk meningkatkan kinerja algoritma pembelajaran mesin.

5.6 Data mining

Model yang digunakan dalam penelitian ini adalah *Multilayer Perceptron* (MLP), yang merupakan jenis jaringan saraf tiruan. Untuk membangun dan melatih model MLP, pertama-tama data dibagi menjadi fitur (*input*) dan target (*output*). Fitur yang digunakan adalah 'Kecepatan angin', 'Kelembapan', 'Penyinaran matahari', dan 'Temperatur', sedangkan targetnya adalah 'Curah hujan'. Data kemudian dibagi menjadi data latih dan data uji dengan berbagai proporsi, yaitu 90:10, 80:20, 70:30, dan 60:40, untuk mengevaluasi kinerja model pada berbagai ukuran set pelatihan dan pengujian.

Sebelum melatih model, fitur-fitur tersebut dinormalisasi menggunakan *MinMaxScaler* dari pustaka *sklearn* untuk memastikan bahwa semua nilai berada dalam rentang yang sama, yaitu 0 hingga 1. Normalisasi ini penting untuk mempercepat konvergensi model selama pelatihan. Setelah normalisasi, model MLP dilatih menggunakan algoritma *backpropagation*. Proses pelatihan melibatkan inisialisasi bobot menggunakan metode *Glorot (Xavier) Initialization*, yang membantu menjaga distribusi bobot tetap dalam rentang yang sesuai untuk menghindari masalah *vanishing* atau *exploding gradients*.

Selama pelatihan, model melakukan *forward pass* untuk menghitung *output* dari jaringan, kemudian melakukan *backward pass* untuk memperbarui bobot berdasarkan *gradien error* yang dihitung. Fungsi aktivasi *sigmoid* digunakan di setiap *neuron*, dan turunan *sigmoid* digunakan untuk menghitung gradien selama *backward pass*. Proses pelatihan diulang selama sejumlah *epoch* yang telah ditentukan (dalam penelitian ini, 10000 *epoch*), dan *loss* atau *error* dicatat pada setiap *epoch*



Gambar 17. Grafik *Loss/Error* Selama Pelatihan

1. Titik Awal (*Epoch* 0): Pada awal pelatihan, nilai loss berada pada level yang relatif tinggi, sekitar 0.35. Hal ini menunjukkan bahwa model pada tahap awal belum mampu memprediksi dengan baik karena belum terlatih.
2. Penurunan Cepat: Terlihat bahwa dalam beberapa ratus *epoch* pertama, nilai *loss* mengalami penurunan yang sangat tajam. Ini adalah indikasi bahwa model dengan cepat belajar dari data yang diberikan dan memperbaiki prediksinya secara signifikan.
3. Kestabilan: Setelah penurunan awal yang tajam, nilai loss mendatar dan mencapai stabilitas mendekati nol. Ini terjadi sekitar setelah 1000 *epoch*. Pada titik ini, model tampaknya telah mencapai konvergensi.

4. *Epoch* Lanjutan: Dari *epoch* 1000 hingga 10000, nilai loss tetap stabil mendekati nol. Hal ini menunjukkan bahwa model telah mencapai performa optimal dan tidak mengalami *overfitting*, di mana model terlalu menyesuaikan dengan data pelatihan hingga kehilangan kemampuan generalisasi terhadap data baru.

Data hasil prediksi, dari proses data mining menggunakan algoritma *Multilayer Perceptron* dapat dilihat pada **Tabel 19**. Untuk data curah hujan aktual bulan September, bulan Oktober, bulan November, dan bulan Desember dapat dilihat pada **Lampiran 11**, **Lampiran 12**, **Lampiran 13**, dan **Lampiran 14**.

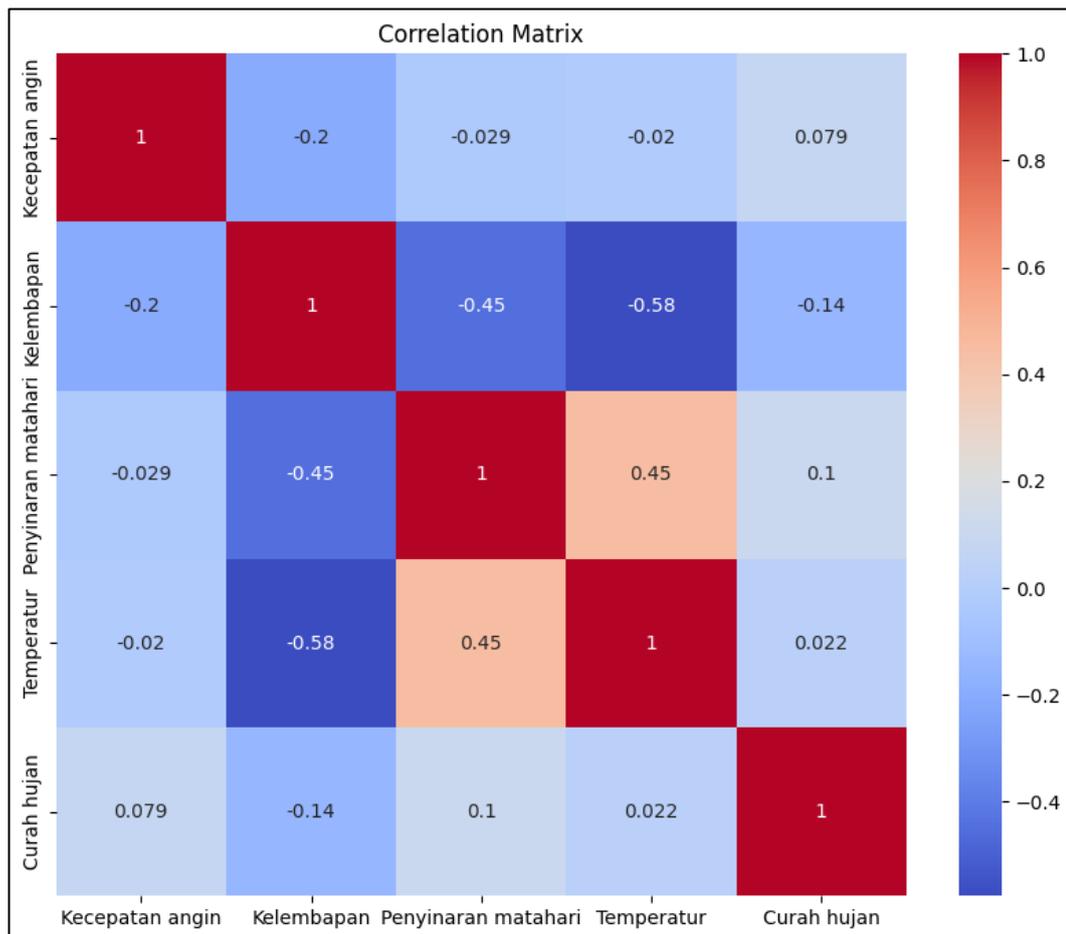
Tabel 19. Data Hasil Prediksi Pada Tahapan Data Mining

Tanggal	Actual	Prediksi Curah Hujan
2023-09-01 00:00:00	0.4	36.53480389
2023-09-02 00:00:00	30.5	30.73544566
2023-09-03 00:00:00	34.6	34.68539857
2023-09-04 00:00:00	45	48.85585374
2023-09-05 00:00:00	42.5	42.35104457
2023-09-06 00:00:00	26.5	25.61368672
2023-09-07 00:00:00	29.8	29.96161628
2023-09-08 00:00:00	30.91	29.98679169
2023-09-09 00:00:00	20	21.91121046
2023-09-10 00:00:00	78.6	40.43238237
2023-09-11 00:00:00	33.2	32.72906087
2023-09-12 00:00:00	30	31.06910588
2023-09-13 00:00:00	24	23.55269571
2023-09-14 00:00:00	33.5	33.57573293
2023-09-15 00:00:00	30	30.64076344
2023-09-16 00:00:00	26.8	27.62678019
2023-09-17 00:00:00	25.7	25.88767268
2023-09-18 00:00:00	30.9	30.97358575
2023-09-19 00:00:00	23	22.08206399
2023-09-20 00:00:00	21	20.95410786
2023-09-21 00:00:00	25.2	24.68721243
2023-09-22 00:00:00	36	36.29665406
2023-09-23 00:00:00	29.29	29.31010499
2023-09-24 00:00:00	29.7	30.33628672
2023-09-25 00:00:00	37.13	36.46155197
2023-09-26 00:00:00	24	25.06356808
2023-09-27 00:00:00	43.77	44.33905818
2023-09-28 00:00:00	49.32	49.45915704
2023-09-29 00:00:00	35	35.37296531
2023-09-30 00:00:00	33	33.90067332
2023-10-01 00:00:00	24	24.53841504
2023-10-02 00:00:00	25	28.05117145
2023-10-03 00:00:00	28	25.44049695
2023-10-04 00:00:00	26	27.75394707
2023-11-09 00:00:00	26	28.1922441
2023-11-10 00:00:00	18	19.31580251
2023-11-11 00:00:00	24	25.41094392
2023-11-12 00:00:00	25	26.60504082
2023-11-13 00:00:00	16	18.548401
2023-11-14 00:00:00	25	25.01680563
2023-11-15 00:00:00	22	22.05360021
2023-11-16 00:00:00	17	18.70632039
2023-11-17 00:00:00	15	15.02199639
2023-11-18 00:00:00	17	18.48088721
2023-11-19 00:00:00	21	22.69306823
2023-11-20 00:00:00	24	25.47572376
2023-11-21 00:00:00	24	25.38513722
2023-11-22 00:00:00	19	19.93913006
2023-11-23 00:00:00	18	17.93124804
2023-11-24 00:00:00	10	13.40881908
2023-11-25 00:00:00	14	19.91155151
2023-11-26 00:00:00	15	15.11716243
2023-11-27 00:00:00	18	19.40959725
2023-11-28 00:00:00	11	14.89136114
2023-11-29 00:00:00	20	21.28217889
2023-11-30 00:00:00	18	19.45690732
2023-12-01 00:00:00	8.5	13.77994373
2023-12-02 00:00:00	13	14.24839145
2023-12-03 00:00:00	20	20.19750413
2023-12-04 00:00:00	14	15.99628854
2023-12-05 00:00:00	14	16.07702957
2023-12-06 00:00:00	20	24.68367738
2023-12-07 00:00:00	18	19.45111188
2023-12-08 00:00:00	15	16.77563392
2023-12-09 00:00:00	23.1	21.79163398
2023-12-10 00:00:00	15	16.45717594
2023-12-11 00:00:00	15	17.75681191
2023-12-12 00:00:00	17.4	17.75866302
2023-12-13 00:00:00	16.5	16.68936247

2023-10-05 00:00:00	25	29.56112968	2023-12-14 00:00:00	29	30.97207617
2023-10-06 00:00:00	26	26.92145238	2023-12-15 00:00:00	25	26.32229254
2023-10-07 00:00:00	17	18.77082679	2023-12-16 00:00:00	17	19.28922524
2023-10-08 00:00:00	26	27.04030842	2023-12-17 00:00:00	20.5	20.84636646
2023-10-09 00:00:00	23	24.56763233	2023-12-18 00:00:00	33	30.53341593
2023-10-10 00:00:00	21	22.61109173	2023-12-19 00:00:00	39	37.31708507
2023-10-11 00:00:00	20	21.79717548	2023-12-20 00:00:00	35	34.4254112
2023-10-12 00:00:00	16	18.74783632	2023-12-21 00:00:00	35	34.72823277
2023-10-13 00:00:00	24	26.66523692	2023-12-22 00:00:00	21	23.6559562
2023-10-14 00:00:00	23	23.30056365	2023-12-23 00:00:00	27.8	28.07912606
2023-10-15 00:00:00	25	26.42666217	2023-12-24 00:00:00	21.5	23.58552819
2023-10-16 00:00:00	20	21.04915038	2023-12-25 00:00:00	18.7	19.31196731
2023-10-17 00:00:00	22	24.24586562	2023-12-26 00:00:00	16	17.83269184
2023-10-18 00:00:00	28	29.94339721	2023-12-27 00:00:00	18	14.89937297
2023-10-19 00:00:00	33	35.13062057	2023-12-28 00:00:00	20	17.70453492
2023-10-20 00:00:00	25	27.73511262	2023-12-29 00:00:00	20	17.50216131
2023-10-21 00:00:00	20	21.00056219	2023-12-30 00:00:00	12	13.40417235
2023-10-22 00:00:00	16	19.81205419	2023-12-31 00:00:00	11	14.58208641
2023-10-23 00:00:00	20	23.7893789			
2023-10-24 00:00:00	17	26.17993639			
2023-10-25 00:00:00	20	21.24174074			
2023-10-26 00:00:00	17	18.94572801			
2023-10-27 00:00:00	15	16.81027471			
2023-10-28 00:00:00	27	28.81249922			
2023-10-29 00:00:00	31	32.90747989			
2023-10-30 00:00:00	24	26.53991165			
2023-10-31 00:00:00	27	29.38436972			
2023-11-01 00:00:00	20	21.82749952			
2023-11-02 00:00:00	18	19.38801656			
2023-11-03 00:00:00	20	20.78492098			
2023-11-04 00:00:00	21	21.38069672			
2023-11-05 00:00:00	21	21.25421068			
2023-11-06 00:00:00	21	13.23253206			
2023-11-07 00:00:00	17	17.49113077			
2023-11-08 00:00:00	23	24.22617152			

Hasil prediksi curah hujan untuk periode 1 September 2023 hingga 31 Desember 2023 menggunakan model dengan perbandingan data latih dan data uji 90:10 menunjukkan variasi curah hujan harian yang signifikan, dengan nilai tertinggi mencapai 49.459 mm pada 28 September 2023 dan nilai terendah 13.233 mm pada 6 November 2023. Data ini mengindikasikan adanya pola musiman dengan puncak curah hujan pada beberapa hari tertentu.

Matriks korelasi antar variabel yang digunakan dalam penelitian ini, yaitu kecepatan angin, kelembapan, penyinaran matahari, temperatur, dan curah hujan. Matriks korelasi ini memperlihatkan hubungan antar variabel yang dapat membantu dalam memahami pola dan keterkaitan antar variabel tersebut. Matriks korelasi dapat dilihat pada **Gambar 18**.



Gambar 18. *Correlation Matrix*

Berdasarkan matriks korelasi yang ditampilkan, dapat disimpulkan bahwa terdapat beberapa hubungan antar variabel.

Keterkaitan Kecepatan Angin dan Kelembapan: Korelasi antara kecepatan angin dan kelembapan adalah -0.2. Nilai ini menunjukkan korelasi negatif yang lemah, artinya semakin tinggi kecepatan angin, maka kelembapan cenderung menurun.

Keterkaitan Kecepatan Angin dan Penyinaran Matahari: Korelasi antara kecepatan angin dan penyinaran matahari adalah -0.029. Ini menunjukkan korelasi negatif yang sangat lemah. Artinya, tidak ada hubungan yang signifikan antara kedua variabel ini.

Keterkaitan Kecepatan Angin dan Temperatur: Korelasi antara kecepatan angin dan temperatur adalah -0.02. Ini menunjukkan korelasi negatif yang sangat lemah. Artinya, tidak ada hubungan yang signifikan antara kedua variabel ini.

Keterkaitan Kecepatan Angin dan Curah Hujan: Korelasi antara kecepatan angin dan curah hujan adalah 0.079. Ini menunjukkan korelasi positif yang sangat lemah. Artinya, tidak ada hubungan yang signifikan antara kedua variabel ini.

Keterkaitan Kelembapan dan Penyinaran Matahari: Korelasi antara kelembapan dan penyinaran matahari adalah -0.45. Ini menunjukkan korelasi negatif yang sedang. Artinya, semakin tinggi kelembapan, maka penyinaran matahari cenderung menurun.

Keterkaitan Kelembapan dan Temperatur: Korelasi antara kelembapan dan temperatur adalah -0.58. Ini menunjukkan korelasi negatif yang lemah. Artinya, semakin tinggi kelembapan, maka temperatur cenderung menurun.

Keterkaitan Kelembapan dan Curah Hujan: Korelasi antara kelembapan dan curah hujan adalah -0.14. Ini menunjukkan korelasi negatif yang lemah. Artinya, semakin tinggi kelembapan, maka curah hujan cenderung menurun.

Keterkaitan Penyinaran Matahari dan Temperatur: Korelasi antara penyinaran matahari dan temperatur adalah 1. Ini menunjukkan korelasi positif yang sangat kuat. Artinya, semakin tinggi penyinaran matahari, maka temperatur cenderung meningkat.

Keterkaitan Penyinaran Matahari dan Curah Hujan: Korelasi antara penyinaran matahari dan curah hujan adalah 0.1. Ini menunjukkan korelasi positif yang sangat lemah. Artinya, tidak ada hubungan yang signifikan antara kedua variabel ini.

Keterkaitan Temperatur dan Curah Hujan: Korelasi antara temperatur dan curah hujan adalah 0.022. Ini menunjukkan korelasi positif yang sangat lemah. Artinya, tidak ada hubungan yang signifikan antara kedua variabel ini.

Secara keseluruhan, data ini menunjukkan bahwa terdapat hubungan yang signifikan antara kelembapan dan temperatur, dan antara penyinaran matahari dan temperatur.

5.7 Evaluasi

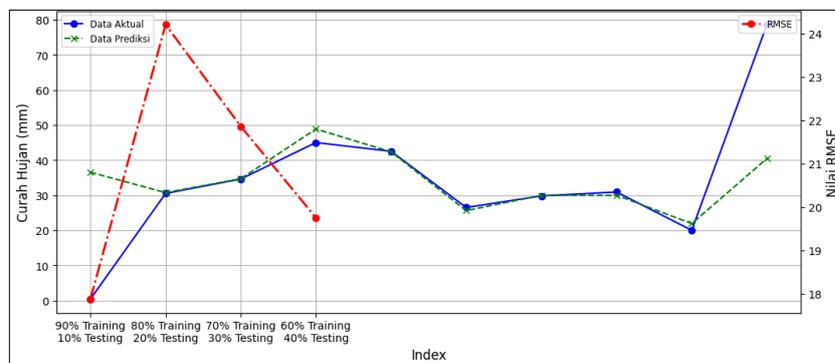
Setelah tahapan *Data mining*, maka selanjutnya adalah melakukan tahapan Evaluasi. Hasil *Root Mean Squared Error* (RMSE) pada proses data mining untuk proporsi data 90% - 10%. Dapat dilihat pada **Gambar 19**. Serta penyajian dalam bentuk tabel untuk hasil evaluasi setiap proporsi data dapat dilihat pada **Tabel 20**.

```
Index(['Tanggal', 'Temperatur', 'Kelembapan', 'Penyinaran matahari', 'Kecepatan angin', 'Curah hujan'], dtype='object')

Proporsi Data Train-Test: 90% - 10%
RMSE: 17.8763
```

Gambar 19. Nilai Hasil RMSE *Train-Test* : 90% - 10% Pada Proses Data Mining

Gambar 19 menampilkan evaluasi menggunakan *Root Mean Squared Error* (RMSE), model yang dilatih dengan proporsi data 90% untuk pelatihan dan 10% untuk pengujian menunjukkan performa terbaik dengan nilai RMSE sebesar 17.8763. Hasil ini lebih unggul dibandingkan dengan proporsi data lainnya, yaitu 80% - 20%, 70% - 30%, dan 60% - 40%. Nilai RMSE yang lebih rendah ini menunjukkan bahwa model dengan proporsi data 90% - 10% memiliki tingkat kesalahan prediksi yang paling kecil, sehingga dapat dianggap sebagai model yang paling akurat dalam memprediksi curah hujan di antara berbagai proporsi data yang diuji.



Gambar 20. Visualisasi Grafik Hasil Evaluasi Data

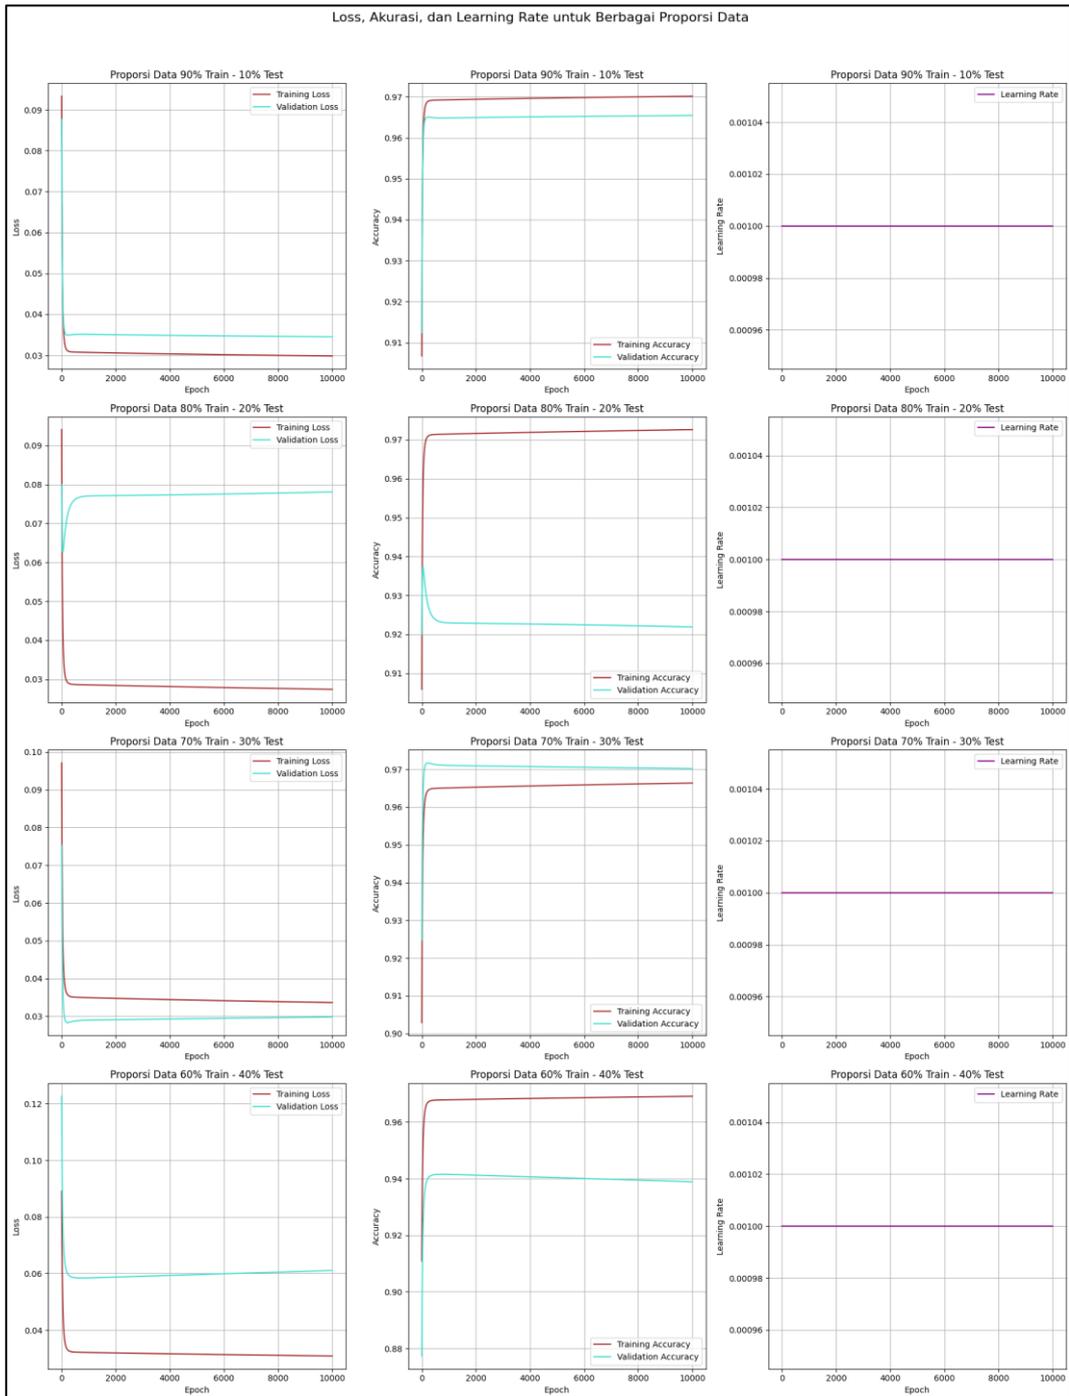
Gambar 20 menampilkan grafik perbandingan antara data aktual, data prediksi, dan nilai RMSE pada berbagai proporsi pembagian data pelatihan dan pengujian. Sumbu horizontal (x-axis) mewakili pembagian data (90% Training - 10% Testing, 80% Training - 20% Testing, dan seterusnya), sementara sumbu vertikal (y-axis) menunjukkan nilai curah hujan (mm) untuk data aktual dan prediksi, serta nilai RMSE yang dihasilkan.

Tabel 20. Hasil Evaluasi

No	Data <i>Training</i>	RMSE
1	90% <i>Training</i> 10% <i>Testing</i>	17.8763
2	80% <i>Training</i> 20% <i>Testing</i>	24.2118
3	70% <i>Training</i> 30% <i>Testing</i>	21.8626
4	60% <i>Training</i> 40% <i>Testing</i>	19.7543

Dari hasil evaluasi yang ditunjukkan dalam **Tabel 20**, dapat ditarik beberapa kesimpulan penting mengenai kinerja model berdasarkan proporsi data training dan testing. Ketika 90% data digunakan untuk training dan 10% untuk testing, nilai RMSE yang diperoleh adalah 17.8763, yang menunjukkan tingkat kesalahan yang relatif rendah. Saat proporsi data training dikurangi menjadi 80% dan data testing ditingkatkan menjadi 20%, RMSE meningkat menjadi 24.2118, menunjukkan peningkatan kesalahan prediksi. Pada proporsi ketiga, di mana 70% data digunakan untuk training dan 30% untuk testing, nilai RMSE sedikit menurun menjadi 21.8626. Terakhir, dengan 60% data untuk training dan 40% untuk testing, RMSE turun lebih lanjut menjadi 19.7543. Dari hasil ini, dapat disimpulkan bahwa penggunaan lebih banyak data untuk training cenderung menghasilkan nilai RMSE yang lebih rendah, yang mengindikasikan model yang lebih akurat. Namun, ada juga indikasi bahwa setelah titik tertentu, pengurangan data training tidak selalu meningkatkan kesalahan secara proporsional. Pada proporsi ketiga, di mana 70% data digunakan untuk training, terlihat adanya penurunan RMSE dibandingkan dengan 80% training, menunjukkan bahwa optimalisasi model tidak hanya bergantung pada proporsi data tetapi juga pada karakteristik data itu sendiri.

Nilai RMSE yang tinggi atau rendah dipengaruhi oleh proporsi data pelatihan dan pengujian serta kualitas dan keragaman data. Penggunaan data training yang lebih banyak (90%) cenderung menghasilkan prediksi yang lebih akurat, tetapi setelah titik tertentu, seperti pada 80% dan 70%, penurunan jumlah data pelatihan tidak selalu meningkatkan performa. Ini juga mengindikasikan bahwa karakteristik data memegang peran penting dalam meminimalkan kesalahan prediksi.



Gambar 21. Visualisasi Performa MLP dengan Berbagai Proporsi Data

Gambar 21 menampilkan hasil pelatihan model *Multilayer Perceptron* (MLP) pada empat konfigurasi proporsi data *train-test* yang berbeda: 90% *train* - 10% *test*, 80% *train* - 20% *test*, 70% *train* - 30% *test*, dan 60% *train* - 40% *test*. Masing-masing konfigurasi ditampilkan dalam satu baris, dengan tiga kolom yang memperlihatkan metrik *loss*, akurasi, dan *learning rate* selama 10.000 *epoch* pelatihan.

Kolom Pertama: *Loss*

Grafik di kolom pertama setiap baris menunjukkan bagaimana nilai *loss* (kerugian) berubah selama pelatihan untuk data *training* dan *validation*.

1. 90% *Train* - 10% *Test*:

- *Training Loss*: Terlihat penurunan drastis di awal pelatihan, mencapai stabilitas setelah sekitar 2.000 *epoch*. Ini menunjukkan bahwa model cepat belajar pola dari data.
- *Validation Loss*: Mengikuti pola serupa dengan *training loss*, yang menandakan bahwa model juga generalisasi dengan baik pada data yang tidak terlihat (*validation data*).

2. 80% *Train* - 20% *Test*:

- *Training Loss*: Menurun tajam dan stabil setelah 2.000 *epoch*.
- *Validation Loss*: Sedikit lebih fluktuatif dibandingkan dengan *training loss*, namun secara umum menurun dan stabil setelah beberapa *epoch*. Fluktuasi ini mungkin disebabkan oleh variasi yang lebih besar dalam *data validation* yang proporsinya lebih besar.

3. 70% *Train* - 30% *Test*:

- *Training Loss*: Menurun secara cepat dan stabil setelah 2.000 *epoch*, serupa dengan proporsi yang lebih tinggi.
- *Validation Loss*: Meskipun lebih fluktuatif dibandingkan dengan *training loss*, pattern keseluruhan menunjukkan penurunan dan stabilisasi.

4. 60% *Train* - 40% *Test*:

- *Training Loss*: Pola penurunan cepat dan stabil setelah sekitar 2.000 *epoch* tetap konsisten.
- *Validation Loss*: Fluktuasi lebih terlihat, menunjukkan bahwa dengan lebih banyak data *validation*, model mungkin memerlukan lebih banyak *epoch* untuk mencapai stabilitas.

Kolom Kedua: Akurasi

Grafik di kolom kedua menunjukkan bagaimana akurasi berubah selama pelatihan untuk data *training* dan *validation*.

1. 90% *Train* - 10% *Test*:

- *Training Accuracy*: Akurasi meningkat tajam pada awal pelatihan, mencapai lebih dari 97% setelah 2.000 *epoch*, menunjukkan model dapat memprediksi dengan sangat baik pada data *training*.
- *Validation Accuracy*: Pola peningkatan serupa dengan *training accuracy*, menunjukkan bahwa model tidak *overfitting* dan performa baik pada data *validation*.

2. 80% *Train* - 20% *Test*:
 - *Training Accuracy*: Mencapai stabilitas tinggi di awal pelatihan.
 - *Validation Accuracy*: Pola peningkatan serupa dengan training, menunjukkan generalisasi yang baik meskipun ada sedikit fluktuasi yang lebih tinggi dibandingkan proporsi 90% *train*.
3. 70% *Train* - 30% *Test*:
 - *Training Accuracy*: Meningkat pesat dan stabil setelah sekitar 2.000 *epoch*.
 - *Validation Accuracy*: Peningkatan tajam dan stabilisasi pada level yang hampir sama dengan training *accuracy*, menunjukkan konsistensi dalam performa model.
4. 60% *Train* - 40% *Test*:
 - *Training Accuracy*: Menunjukkan pola peningkatan yang konsisten dan stabilisasi cepat.
 - *Validation Accuracy*: Meskipun ada beberapa fluktuasi, secara keseluruhan pola menunjukkan peningkatan dan stabilisasi, meskipun sedikit lebih lambat dibandingkan proporsi yang lebih tinggi.

Kolom Ketiga: *Learning Rate*

Grafik di kolom ketiga menunjukkan learning rate selama 10.000 *epoch*.

- Semua Proporsi Data:
 - *Learning rate* tetap konstan di 0.001 sepanjang pelatihan. Tidak ada perubahan *learning rate* yang menunjukkan bahwa nilai yang digunakan cukup optimal untuk pelatihan tanpa memerlukan penyesuaian selama *epoch*.

Kesimpulan Tahapan Evaluasi

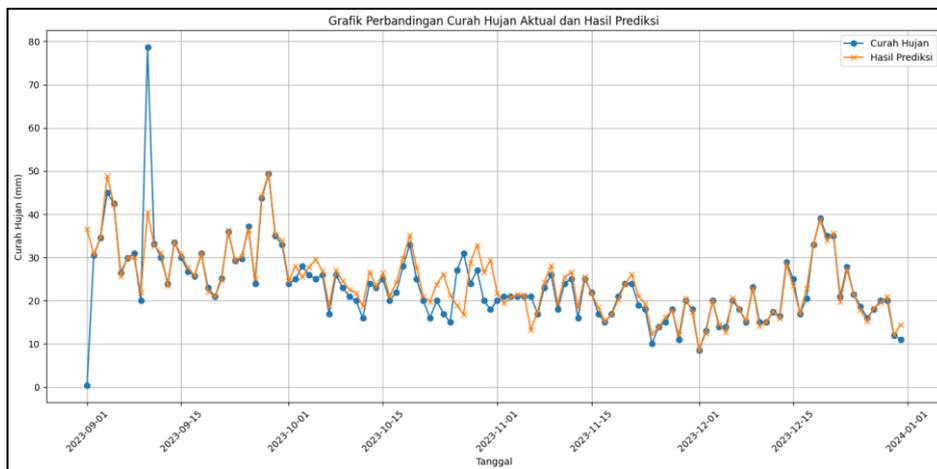
1. Konvergensi Model: Model Multilayer Perceptron secara konsisten menunjukkan penurunan *loss* dan peningkatan akurasi di seluruh konfigurasi proporsi data. Ini menandakan bahwa model belajar dengan efektif dari data, baik untuk data training maupun *validation*.
2. Generalisasi: *Grafik loss* dan akurasi *validation* menunjukkan bahwa model mampu generalisasi dengan baik ke data yang tidak terlihat, meskipun dengan fluktuasi yang sedikit lebih tinggi pada proporsi data *validation* yang lebih besar.
3. Stabilitas: Semua konfigurasi menunjukkan stabilisasi *loss* dan akurasi setelah sekitar 2.000 *epoch*, menunjukkan bahwa pelatihan lebih dari ini mungkin tidak meningkatkan performa secara signifikan.
4. *Learning Rate*: *Learning rate* konstan di 0.001 tampaknya cukup baik untuk pelatihan model MLP ini, karena model berhasil mencapai konvergensi tanpa perubahan *learning rate*.
5. Proporsi 80% *train* - 20% *test* adalah pilihan yang lebih baik dibandingkan dengan konfigurasi lainnya. Dengan proporsi ini, model mendapatkan

jumlah data *training* yang cukup besar untuk mempelajari pola-pola dari data dengan baik, sementara jumlah data testing yang memadai memungkinkan evaluasi performa model dengan representasi yang lebih akurat terhadap variasi data yang mungkin ditemui di dunia nyata. Analisis menunjukkan bahwa model dengan proporsi 80% *train* - 20% *test* memiliki generalisasi yang lebih baik, sebagaimana ditunjukkan oleh penurunan loss yang konsisten dan peningkatan akurasi pada data validation. Meskipun terdapat sedikit fluktuasi dibandingkan dengan proporsi 90% *train* - 10% *test*, fluktuasi ini tidak signifikan dan masih berada dalam batas yang dapat diterima. Stabilitas performa model juga tercermin dari pola akurasi yang meningkat dan kemudian stabil setelah sekitar 2.000 *epoch*, baik untuk data training maupun validation.

6. Performa model tidak semata-mata ditentukan dari evaluasi *loss*, akurasi, dan *learning rate*, tetapi juga dari pengukuran RMSE. RMSE yang rendah menunjukkan prediksi yang lebih dekat dengan nilai aktual, menandakan model yang efektif. Implementasi *Multilayer Perceptron* menunjukkan hasil yang baik dengan RMSE sebesar 17.8763 pada proporsi 90% *train* - 10% *test*. Model memberikan estimasi yang relatif dekat dengan nilai aktual meskipun masih ada variabilitas.

5.8 Representasi Pengetahuan

Hasil perbandingan data aktual dan prediksi curah hujan dalam bentuk visualisasi grafik dapat dilihat pada **Gambar 22**.



Gambar 22. Grafik Perbandingan Curah Hujan Aktual Dan Hasil Prediksi

Gambar 22 merupakan perbandingan antara curah hujan aktual dan hasil prediksi model *Multilayer Perceptron* selama periode dari awal September 2023 hingga akhir Desember 2023. Grafik ini berfungsi untuk mengevaluasi performa model dalam memprediksi curah hujan.

Sumbu X dan Sumbu Y

- Sumbu X (Tanggal): Sumbu ini merepresentasikan rentang waktu mulai dari 1 September 2023 hingga 31 Desember 2023. Tanggal-tanggal ini menunjukkan data harian yang diambil untuk menganalisis curah hujan.
- Sumbu Y (Curah Hujan): Sumbu ini menunjukkan besaran curah hujan dalam milimeter (mm). Nilai curah hujan bervariasi dari 0 hingga lebih dari 80 mm, yang merepresentasikan variasi intensitas hujan selama periode waktu tersebut.

Komponen Grafik

- Curah Hujan Aktual (Garis Biru dengan Titik): Garis biru yang terhubung dengan titik-titik biru menunjukkan nilai curah hujan aktual yang diukur pada setiap hari dalam periode tersebut. Titik-titik ini menandakan nilai sebenarnya dari curah hujan yang terjadi.
- Hasil Prediksi (Garis Oranye dengan X): Garis oranye dengan simbol 'X' menunjukkan hasil prediksi curah hujan yang dihasilkan oleh model *Multilayer Perceptron*. Garis ini memperlihatkan bagaimana model memprediksi curah hujan berdasarkan data input yang telah dilatih sebelumnya.

Analisis Performa Model

- Kesesuaian antara Aktual dan Prediksi: Secara umum, garis prediksi (oranye) cenderung mengikuti pola garis aktual (biru), menunjukkan bahwa model *Multilayer Perceptron* berhasil memprediksi tren umum curah hujan. Namun, terdapat beberapa titik di mana prediksi model berbeda cukup signifikan dari nilai aktual, terutama pada puncak-puncak curah hujan yang tinggi.
- Perbedaan pada Puncak Curah Hujan: Pada awal September, terdapat puncak curah hujan yang sangat tinggi sekitar 79 mm, di mana model memprediksi nilai yang sedikit lebih rendah dari aktual. Perbedaan ini dapat menunjukkan keterbatasan model dalam menangkap kejadian curah hujan ekstrem.
- Variabilitas Harian: Pada sebagian besar periode, model menunjukkan kemampuan yang baik dalam mengikuti fluktuasi harian curah hujan. Perbedaan kecil antara prediksi dan aktual menunjukkan akurasi yang cukup baik dalam kondisi cuaca yang lebih stabil.

Grafik ini memberikan gambaran visual mengenai kemampuan model *Multilayer Perceptron* dalam memprediksi curah hujan. Meskipun terdapat beberapa perbedaan antara hasil prediksi dan nilai aktual, terutama pada kejadian ekstrem, secara keseluruhan model menunjukkan performa yang memadai dalam memprediksi pola curah hujan.

BAB VI KESIMPULAN DAN SARAN

6.1 Kesimpulan

Penelitian ini mengembangkan model prediksi curah hujan Pada Wilayah Kota Bogor menggunakan algoritma *Multilayer Perceptron* (MLP) dengan pembagian data 90% untuk pelatihan dan 10% untuk pengujian. Hasilnya menunjukkan model mampu memprediksi dengan baik, dengan nilai *Root Mean Squared Error* (RMSE) sebesar 17.8763. RMSE mengukur perbedaan antara prediksi dan nilai aktual, di mana semakin mendekati nol, semakin akurat model tersebut.

Dalam penelitian ini, RMSE menjadi indikator utama performa model. Nilai 17.8763 menunjukkan prediksi yang cukup baik, mengingat adanya variabilitas yang wajar dalam prediksi curah hujan. Proporsi data pelatihan dan pengujian yang digunakan membantu model memberikan hasil yang cukup general untuk data baru, memastikan model terlatih dengan baik dan akurat.

Model prediksi curah hujan berbasis MLP ini berpotensi besar untuk diaplikasikan dalam berbagai sektor, seperti infrastruktur, manajemen air, dan mitigasi bencana. Dengan akurasi yang tinggi berdasarkan nilai RMSE yang rendah, model ini dapat mendukung pengambilan keputusan di wilayah yang rawan banjir atau kekeringan, sehingga membantu meminimalkan dampak negatif variabilitas cuaca.

6.2 Saran

Dalam penelitian yang sudah dilakan masih banyak kekurangan-kekurangan yang diharapkan bisa disempurnakan oleh peneliti-peneliti selanjutnya, berikut adalah beberapa saran yang mungkin bisa membantu penelitian selanjutnya :

1. Eksplorasi Metode Lain: Selain MLP, lakukan eksperimen dengan metode lain seperti *Support Vector Machine* (SVM), *Decision Tree*, atau model ensemble seperti *Random Forest* untuk membandingkan performa dan akurasi prediksi.
2. *Real-Time Prediction*: Pertimbangkan pengembangan model yang dapat digunakan untuk prediksi curah hujan secara *real-time* agar dapat mendukung pengambilan keputusan yang lebih cepat dalam manajemen sumber daya alam dan mitigasi risiko.

Dengan menerapkan saran-saran di atas dan terus melakukan eksperimen serta peningkatan kualitas data, diharapkan penelitian ini dapat memberikan kontribusi yang lebih besar dalam pengembangan prediksi curah hujan yang akurat dan berguna bagi berbagai kebutuhan praktis dalam bidang meteorologi dan manajemen sumber daya alam.

DAFTAR PUSTAKA

- Andhika Octa Indarso, AB Pangaribuan 2021. Penggunaan *Metode Multilayer Perceptron* Pada Prediksi Indeks Saham LQ45. *JURNAL INFORMATIKA Edisi ke-17, Nomor 1, April 2021*.
- Azwanti, N. 2019. Combination, Pola Apriori Analisis Pola Belanja Konsumen Menggunakan Algoritma Apriori Pada Raffa Photo Copy. *Jurnal Teknologi Dan Open Source, 2(2), 63-73*.
- Azriel Alfian Rizqi, Dewi Kusumaningsih 2022. Klasifikasi Curah Hujan di Kota Bogor Provinsi Jawa Barat dengan Menggunakan Metode *Naives Bayes*. Seminar Nasional Mahasiswa Fakultas Teknologi Informasi (SENAFTI) Jakarta – Indonesia, 6 September 2022.
- Dhenanta, R. P., & Kholifah, I. B. 2022. Prediksi Curah Hujan Bulanan Kabupaten Trenggalek Tahun 2022 dan 2023 Menggunakan Metode ARIMA. *Seminar Nasional Official Statistics, 2022(1), 1135–1144*.
- Dwiasnati, S., & Devianto, Y. (2022). Optimization of Flood Prediction using SVM Algorithm to determine Flood Prone Areas. *Journal of Systems Engineering and Information Technology (JOSEIT), 1(2), 40-46*.
- Fadel Muhammad Madjid, Tri Basuki Kurniawan. 2022. Prediksi *Visibility* Menggunakan Lstm Dan Mlp Di Bandara Sultan Mahmud Badaruddin II Palembang. *Jurnal Sistem Informasi (JSI), VOL. 14, NO. 1, April, 2022*.
- Ghufron Z.M., Sunardi, Anton Yudhana. 2019. Jaringan Saraf Tiruan *Backpropagation* untuk Prediksi Curah Hujan di Wilayah Kabupaten Wonosobo. *MUST: Journal of Mathematics Education, Science and Technology*. Vol.4. Hal 45-46.
- Hadimarta, Tommy Ferdian, ani Rotul Muhima, Muchammad Kurniawan. 2020. Implementasi *Multilayer Perceptron* pada Jaringan Syaraf Tiruan untuk memprediksi Nilai Valuta Asing. *Integer: Journal of Information Technology*. Vol. 5 No. 1 April 2020: 56:63.
- Luthfiarta, A., Febriyanto, A., Lestiawan, H., & Wicaksono, W. (2020). Analisa Prakiraan Cuaca dengan Parameter Suhu, Kelembaban, Tekanan Udara, dan Kecepatan Angin Menggunakan Regresi Linear Berganda. *JOINS (Journal of Information System), 5(1), 10–17*.
<https://doi.org/10.33633/joins.v5i1.2760>

- Manalu, D. R., Zarlis, M., Mawengkang, H., & Sitompul, O. S. (2020). Forest Fire Prediction in Northern Sumatera using Support Vector Machine Based on the Fire Weather Index. April 2021, 187–196. <https://doi.org/10.5121/csit.2020.101915>.
- Monika, D., Wahyudi, M., Lubis, M. R., Saputra, W., & Solikhun, S. (2020, February). Penerapan Jaringan Syaraf Tiruan Dalam Memprediksi Ketersediaan Tanaman Cabai Berdasarkan Provinsi di Indonesia. In Seminar Nasional Teknologi Komputer & Sains (SAINTEKS) (Vol. 1, No. 1, pp. 197-201).
- Novita Ranti Muntari , Kharis Hudaiby Hanif. 2022. Klasifikasi Penyakit Kanker Payudara Menggunakan Perbandingan Algoritma *Machine Learning*. JURNAL ILMU KOMPUTER DAN TEKNOLOGI. Vol. 3. No 1, May 2022, pp. 1-6.
- Priambudi Agung Nugroho. 2023. Implementasi Jaringan Syaraf Tiruan *Multi-Layer Perceptron* untuk Prediksi Penyinaran Matahari Kota Bandung. *Komputa : Jurnal Ilmiah Komputer dan Informatika*. Vol. 12.
- Syahrani Lonang , Dwi Normawati. 2022. Klasifikasi Status Stunting Pada Balita Menggunakan *K-Nearest Neighbor* Dengan *Feature Selection Backward Elimination*. JURNAL MEDIA INFORMATIKA BUDIDARMA. Volume 6, Nomor 1, Januari 2022, Page 49-56.
- Sunardi, S. (2022). Pengaruh Nilai Hidden layer dan Learning rate Terhadap Kecepatan Pelatihan Jaringan Saraf Tiruan Backpropagation. *JIKO (Jurnal Informatika dan Komputer)*, 6(1), 27-33.
- Sekaranom, Andung Bayu. KEJADIAN HUJAN EKSTREM WILAYAH TROPIS: Kombinasi Observasi Permukaan dan Satelit Meteorologis serta Karakteristik Lingkungan Pembentukannya. UGM PRESS, 2021.

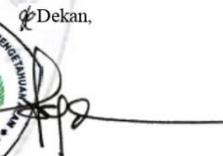
LAMPIRAN

Lampiran 1. SK Dekan Pengangkatan Pembimbing

	<p style="text-align: center;">YAYASAN PAKUAN SILIWANGI Universitas Pakuan FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM <i>Unggul, Mandiri & Berkarakter Dalam Bidang MIPA</i></p>
<p>KEPUTUSAN DEKAN FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM UNIVERSITAS PAKUAN No. : 392/KEP/D/FMIPA-UP/VI/2024</p>	
<p>T E N T A N G</p>	
<p>PENGANGKATAN PEMBIMBING TUGAS AKHIR PADA PROGRAM STUDI ILMU KOMPUTER FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM UNIVERSITAS PAKUAN</p>	
<p>DEKAN FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM UNIVERSITAS PAKUAN,</p>	
Menimbang	: a. bahwa setiap mahasiswa tingkat akhir Program Strata Satu (S1) harus melaksanakan Tugas Akhir sebagaimana tercantum di dalam kurikulum setiap Program Studi di lingkungan Fakultas MIPA Universitas Pakuan. b. bahwa untuk pelaksanaan Tugas Akhir diperlukan pengawasan dari pembimbing. c. bahwa sehubungan dengan point a dan b di atas perlu dituangkan dalam suatu Keputusan Dekan.
Mengingat	: 1. Undang-undang RI No.: 20 Tahun 2003 tentang Sistem Pendidikan Nasional. 2. Peraturan Pemerintah No.: 60 Tahun 1999 tentang Pendidikan Tinggi. 3. Statuta Universitas Pakuan Tahun 2022. 4. Surat Keputusan Rektor Nomor: 35/KEP/REK/VIII/2020 tanggal 03 Agustus 2020 tentang Pemberhentian Dekan dan Wakil Dekan Masa Bakti 2015-2020 serta Pengangkatan Dekan dan Wakil Dekan Masa Bakti 2020-2025 di lingkungan Universitas Pakuan. 5. Ketentuan Akademik yang tercantum dalam Buku Panduan Studi Fakultas MIPA, Universitas Pakuan Tahun 2023.
Memperhatikan	: Usulan dari Ketua Program Studi Ilmu Komputer FMIPA UNPAK.
<p>M E M U T U S K A N</p>	
Menetapkan	:
Pertama	: Mengangkat pembimbing yang namanya tersebut di bawah ini : 1. Pembimbing Utama : Dr. Prihastuti Harsani, M.Si. 2. Pembimbing Pendamping : Boldson H.S., S.Kom., MMSI.
	Untuk membimbing dalam rangka melaksanakan tugas akhir bagi mahasiswa : Nama : Muhammad Azizan NPM : 065119157 Program Studi : Ilmu Komputer Judul Skripsi : Model Prediksi Curah Hujan Menggunakan Algoritma Machine Learning
<p>Jl. Pakuan P.O. Box 452, Bogor 16143, Telp./Fax. (0251) 8375547 Website : https://fmipa.unpak.ac.id</p>	

- Kedua : Kepada para pembimbing diharapkan dapat menjalankan tugasnya sebagai pembimbing dengan sebaik-baiknya.
- Ketiga : Dalam waktu 1 (satu) bulan setelah diterbitkannya SK ini, mahasiswa wajib melaksanakan Seminar Rencana Penelitian yang diselenggarakan oleh Program Studi Ilmu Komputer dengan dihadiri oleh Pembimbing dan Penguji.
- Keempat : Dana untuk honorarium pembimbing dibebankan kepada mahasiswa yang ketentuannya diatur oleh Fakultas MIPA.
- Kelima : Surat Keputusan ini berlaku untuk jangka waktu 1 (satu) tahun sejak tanggal ditetapkan sampai dengan mahasiswa tersebut Lulus Sidang/Ujian Skripsi, dengan ketentuan akan diadakan perubahan/perbaikan sebagaimana mestinya bila dikemudian hari terdapat kekeliruan dalam penetapannya.

Ditetapkan di : Bogor
Pada tanggal : 08 Juni 2024


Dekan,

Asep Denih, S.Kom., M.Sc., Ph.D.

Tembusan :

1. Yth. Ketua Program Studi Ilmu Komputer;
2. Yth. Dr. Prihastuti Harsani, M.Si.;
3. Yth. Boldson H.S., S.Kom., MMSI.;
4. Arsip.

Lampiran 2. Kartu Bimbingan

Kartu Bimbingan Mahasiswa Program Studi Ilmu Komputer FMIPA - UNPAK

Nama Mahasiswa : MUHAMMAD AZIZAN
 NPM : 0651119157
 Judul Skripsi : Model Cerdas Prediksi Curah Hujan
 Mengguhakan Algoritma Machine Learning
 Pembimbing Utama : Dr. Prihastuti Harsani, M.si
 Pembimbing Pendamping : Boldson H. Situmorang, M.M.Si

No.	Hari, tanggal	Catatan	Tanda Tangan	
			Pembimbing Utama	Pembimbing Pendamping
1.	08 / 03 - 2023	Bimbingan Konsep dan Topik.	1.....	1.....
2.	16 / 03 - 2023	Bimbingan Konsep dan Topik.	2.....	2.....
3.	23 / 05 - 2023	Bimbingan Bab I - Bab III	3.....	3.....
4.	16 / 05 - 2023	Bimbingan Bab I - Bab III	4.....	4.....
5.	02 / 11 - 2023	Perbaiki Bab III	5.....	5.....
6.	Kamis, 30-11-2023	Perbaiki penulisan proposal	6.....	6.....
7.	28 / 11 - 2023	Perbaiki Evaluasi Data	7.....	7.....
8.	Jumat, 8-12-2023	Revisi proses pengolahan data	8.....	8.....
9.	9 / 01 / 2024	Menambah 9 atribut	9.....	9.....
10.	10 / 01 / 2024	Tambahkan simulasi MLP yg memonit ke kecupit atribut	10.....	10.....
11.	17 / 01 - 2024	Rapikan Laporan	11.....	11.....
12.	17 / 1 2024	Rapikan laporan	12.....	12.....
13.	24 / 01 - 2024	Acc Sidang Sempro	13.....	13.....
14.	19 / 1 2024	Perbaiki sub bab evaluasi & daftar sempro	14.....	14.....
15.	05 / 06 - 2024	Acc sidang Semhas	15.....	15.....
16.	26 / 6 2024	Perbaiki Bab 4 & 5	16.....	16.....
17.	27 / 6 - 2024	Acc sidang Skripsi	17.....	17.....
18.	27 / 06 - 2024	Acc sidang Skripsi	18.....	18.....

Bogor, 20.....

Mengetahui,
 Program Studi Ilmu Komputer
 FMIPA - UNPAK
 Ketua,

Arie Qur'ania, M.Kom.

Lampiran 3. Data Bulan Januari

	ID WMO	: 96753
	Nama Stasiun	: Stasiun Klimatologi Jawa Barat
	Lintang	: -6.50000
	Bujur	: 106.75000
	Elevasi	: 207

Tanggal	Tavg	RH_avg	RR	ss	ff_avg
01-01-2023	24.3	89	30.5	0	1
02-01-2023	24.4	91	25	0	1
03-01-2023	24.3	89	21.8	2.1	2
04-01-2023	25.4	85	10.6	0	2
05-01-2023	26	83	1.9	2.8	1
06-01-2023			0	3.2	1
07-01-2023					
08-01-2023	25.6	88		8.8	1
09-01-2023	26.4	80	17	5.8	2
10-01-2023	26.4	84	0	6.5	1
11-01-2023			0.5	5.8	0
12-01-2023	26.9	80		6	1
13-01-2023	25.9	86	0.6	9.7	1
14-01-2023	26.8	80	41.3	4.5	1
15-01-2023	25.9	88	0.5	8.6	1
16-01-2023	26	85	13	6.1	1
17-01-2023	24.4	92	0	5.7	0
18-01-2023	24.7	92	3.8	2.5	0
19-01-2023	25.2	88		2.5	1
20-01-2023	25.4	86	0	1	1
21-01-2023	25	86		3.1	1
22-01-2023	25.9	84	1.1	5.2	1
23-01-2023	26.1	84	0.4	5	1
24-01-2023	25.5	84	1	1.8	1
25-01-2023	23.9	93	0.8	3.6	2
26-01-2023	25	85	11	0	0
27-01-2023	26.2	86	0.2	3.5	1
28-01-2023	24.6	92	1.4	0.3	0
29-01-2023	25.6	89	27.7	0	1
30-01-2023	25.9	87	1	0.1	0
31-01-2023	25.8	90		3.2	0

Lampiran 4. Data Bulan Februari



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-02-2023	25.2	89	0.6	0
02-02-2023	25.9	88	1.7	1
03-02-2023	25.6	82	0	2
04-02-2023	27.1	74	0.4	1
05-02-2023	26	76	0.2	2
06-02-2023	26.7	78	7.5	1
07-02-2023			2.2	1
08-02-2023	26.1	79	5.3	2
09-02-2023	26.2	73	1	2
10-02-2023	26	81	2.1	1
11-02-2023	25.9	89	4.4	2
12-02-2023	23.3	94	0.5	1
13-02-2023	23.9	88	0	1
14-02-2023	25.1	84	2.8	2
15-02-2023	24.9	85	0.5	2
16-02-2023	24.9	88	3.9	1
17-02-2023	24.7	93	0.5	1
18-02-2023	25	90	2.1	1
19-02-2023	25.4	88	6.2	1
20-02-2023	25.9	82	2.8	1
21-02-2023	25.8	86	7.6	1
22-02-2023	24.5	94	4.5	0
23-02-2023	25	92	0	1
24-02-2023	25.4	92	1	0
25-02-2023	25.3	92	0	0
26-02-2023	24.6	93	1	0
27-02-2023	25.2	90	0	1
28-02-2023	25.1	89	1	2

Lampiran 5. Data Bulan Maret



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-03-2023	24.9	90	3.4	1
02-03-2023	23.9	95	0.2	0
03-03-2023	26	82	0	2
04-03-2023	24.3	88	6	2
05-03-2023	25.2	87	1.6	1
06-03-2023	26.1	82	5.3	1
07-03-2023	25.5	84	8.4	1
08-03-2023	24.7	88	7.8	1
09-03-2023	26.7	82	3.8	0
10-03-2023	25	88	5.5	1
11-03-2023	25.2	89	6	0
12-03-2023	26	87	4.4	1
13-03-2023	25.2	88	3.4	1
14-03-2023	25.7	89	8.4	1
15-03-2023	25	90	2.7	0
16-03-2023	25.6	84	0.4	1
17-03-2023	26.1	83	8.3	1
18-03-2023	26.6	80	7.2	1
19-03-2023	26.1	87	8.8	1
20-03-2023	25.9	88	6.2	1
21-03-2023	26.1	82	5.3	0
22-03-2023	27.4	82	7.2	1
23-03-2023	28.2	83		1
24-03-2023	26.1	90	4.6	1
25-03-2023	25.4	90	6.5	1
26-03-2023	25.9	90	4.1	1
27-03-2023	25.2	90	5.5	1
28-03-2023			2.7	1
29-03-2023	26.1	86	3.7	1
30-03-2023	26.2	82	4.6	2
31-03-2023	26.9	83	7.4	1

Lampiran 6. Data Bulan April



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-04-2023	26.1	82	4.6	0
02-04-2023	26.2	84	1.8	0
03-04-2023				
04-04-2023	26.4	81	9	1
05-04-2023	27.5	74	6.9	1
06-04-2023	26.9	74	9.6	1
07-04-2023	26.4	78	6.5	1
08-04-2023			9.8	0
09-04-2023			7.5	1
10-04-2023	26.4	86	8.4	1
11-04-2023	25.9	85	2.9	0
12-04-2023	26.4	85	5.1	1
13-04-2023	26.4	82	6.4	1
14-04-2023	26.5	83	3.6	2
15-04-2023	27.6	79	5.7	1
16-04-2023	27	84	9.2	1
17-04-2023	27.6	80	4.5	1
18-04-2023	27.3	84	8.8	1
19-04-2023	26.5	88	3.4	1
20-04-2023	27	88	3.3	1
21-04-2023	26.5	86	5.7	1
22-04-2023	27.1	84	6	1
23-04-2023	26.3	89	8.3	1
24-04-2023	26.1	88	6.9	1
25-04-2023	25.6	90	8	1
26-04-2023	26.6	87	4.6	1
27-04-2023	26.5	86	7.3	1
28-04-2023	27.4	86	7.4	1
29-04-2023	27.5	84	4.7	0
30-04-2023	27.4	84	3.6	1

Lampiran 7. Data Bulai Mei



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-05-2023	27.5	84	6.1	0
02-05-2023	27.1	85	4.1	1
03-05-2023	26.3	90	7.5	1
04-05-2023	26.8	88	4.8	1
05-05-2023	27.3	86	5.5	1
06-05-2023	27.3	84	7.2	1
07-05-2023	26.5	90	4.4	1
08-05-2023	26.3	90	4.8	0
09-05-2023	28.2	80	3.3	0
10-05-2023	28.3	80	6.9	1
11-05-2023	26.8	86	8.5	1
12-05-2023	28.4	76	3.9	2
13-05-2023	26.7	87	10.5	1
14-05-2023	27.5	74	7.9	1
15-05-2023	26.9	79	7	1
16-05-2023	27.2	74	8.7	1
17-05-2023	26.8	78	7.8	1
18-05-2023	27.1	80	8.8	0
19-05-2023	26.8	84	1.8	1
20-05-2023	27.6	82	3.1	0
21-05-2023	26.9	86	3.6	0
22-05-2023	26.4	83	0	1
23-05-2023	27.2	79	8.9	1
24-05-2023	27	82	7.6	0
25-05-2023	25.9	84	6.5	0
26-05-2023	27.5	80	7.8	0
27-05-2023	26.6	87	7.1	0
28-05-2023	27.1	82	4.7	1
29-05-2023	27.1	84	8.2	0
30-05-2023	26.7	82	5.4	1
31-05-2023	27.4	76	9	1

Lampiran 8. Data Bulan Juni



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-06-2023	26.8	76	8.6	1
02-06-2023	27.4	81	9.5	1
03-06-2023	27.7	83	8	1
04-06-2023	26.6	84	5.7	1
05-06-2023	26.1	86	8.4	1
06-06-2023	25.7	91	7.4	1
07-06-2023	26.7	83	0.8	1
08-06-2023	26.9	82	8.7	1
09-06-2023	26.5	81	7.2	1
10-06-2023	26.1	86	9.4	0
11-06-2023	26.8	78	8.3	0
12-06-2023	27.5	79	9.6	1
13-06-2023	26.9	84	8.6	1
14-06-2023	25.4	89	5.6	0
15-06-2023	27.2	81	3.9	1
16-06-2023	24.5	95	6.1	0
17-06-2023	25.9	86	0	0
18-06-2023	26.3	86	0.4	1
19-06-2023	25.7	91	9.4	0
20-06-2023	26.9	80	5.7	0
21-06-2023	26.8	84	9.6	1
22-06-2023	27.7	80	7.2	1
23-06-2023	27.2	83	7.7	1
24-06-2023	26.7	87	7.7	1
25-06-2023	25.7	86	8.9	1
26-06-2023	25.9		6.5	0
27-06-2023	25.9	84	8	1
28-06-2023	26.8	78	9	1
29-06-2023	26.5	85	9.2	0
30-06-2023	27.1	82	8.9	0

Lampiran 9. Data Bulan Juli



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-07-2023	26.6	85	7.5	1
02-07-2023	26.5	80	7.8	1
03-07-2023	26.8	81	7.2	1
04-07-2023	26.1	81	7.2	0
05-07-2023	26.7	80	5.4	1
06-07-2023	25.8	90	7.6	1
07-07-2023	24.8	90	2	1
08-07-2023	25.3	88	4	1
09-07-2023	26	82	5.5	1
10-07-2023	26.5	80	4.2	1
11-07-2023	26.1	80	5.6	1
12-07-2023	26.8	82	8	1
13-07-2023	26.6	80	7.8	0
14-07-2023	26.1	83	8.4	1
15-07-2023	27	79	7.1	1
16-07-2023	26.7	80	7.4	1
17-07-2023	26.7	77	8.9	1
18-07-2023	26.2	74	9.5	1
19-07-2023	26.2	72	10.4	1
20-07-2023	25.7	72	9.9	0
21-07-2023	26.7	75	8.7	1
22-07-2023	27.1	74	6.5	1
23-07-2023	26.6	80	5.7	1
24-07-2023	26.1	83	5.5	1
25-07-2023	25.8	83	7.6	1
26-07-2023	26.8	80	5	1
27-07-2023	26.9	78	4.6	1
28-07-2023	26.5	77	7.6	1
29-07-2023	26.5	74	8.6	1
30-07-2023	26.5	73	4.5	1
31-07-2023			6.3	1

Lampiran 10. Data Bulan Agustus



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-08-2023	25.7	74	9.4	2
02-08-2023	26.9	78	10	0
03-08-2023	26.1	85	2.3	1
04-08-2023	26.5	82	6.9	0
05-08-2023	26.8	76	8.9	1
06-08-2023	26.6	78	8	1
07-08-2023	26.7	80	8	1
08-08-2023	27.9	74	7.3	1
09-08-2023	26.8	77	6.8	1
10-08-2023	26.7	76	9.6	1
11-08-2023	26.4	78	9.3	1
12-08-2023	25.7	74	8.6	1
13-08-2023	25.2	78	6.8	1
14-08-2023	25.9	74	7.2	0
15-08-2023	26.3	74	10	1
16-08-2023	26	74	8.6	1
17-08-2023	26.2	74	8.8	2
18-08-2023	26.4	73	8.8	1
19-08-2023	26.7	73	8	1
20-08-2023	27.1	76	9.9	1
21-08-2023	26.2	75	9	1
22-08-2023	25.6	77	7.5	1
23-08-2023	26.6	75	6.4	1
24-08-2023	27.2	74	6.6	1
25-08-2023	27	79	8.5	1
26-08-2023	27.1	78	6.9	1
27-08-2023	25.4	84	4.8	1
28-08-2023	25.7	81	6.2	1
29-08-2023	26.1	72	5.7	1
30-08-2023	26	71	8.6	1
31-08-2023	26.4	72	9.1	2

Lampiran 11. Data Bulan September



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-09-2023	26.7	68	9.5	1
02-09-2023	26.8	72	8.4	1
03-09-2023	26.4	68	7.3	1
04-09-2023	25.8	64	7.3	2
05-09-2023	25.8	66	8.9	1
06-09-2023			9	1
07-09-2023	27.1	72	8.8	1
08-09-2023	26	78	9.1	1
09-09-2023	26.4	77	3	1
10-09-2023	26.2	72	8.8	2
11-09-2023	26.3	72	8.2	1
12-09-2023	26.9	72	4.9	2
13-09-2023	27.6	72	9.2	0
14-09-2023	27	68	8.5	1
15-09-2023	27	70	7.7	1
16-09-2023	27.4	70	6.7	1
17-09-2023	27.2	74	7.2	1
18-09-2023	27.8	73	8.4	2
19-09-2023	26.8	81	7	1
20-09-2023	25.9	83	4.3	1
21-09-2023	26.5	81	8.4	1
22-09-2023	26.6	72	7.5	2
23-09-2023	26.7	70	9.8	0
24-09-2023	26.2	78	10	1
25-09-2023	26.8	73	8.9	2
26-09-2023	27.7	68	8.3	0
27-09-2023	27.1	64	9	2
28-09-2023	27.3	65	9.2	3
29-09-2023	27.9	64	10.1	1
30-09-2023	27	70	10	1

Lampiran 12. Data Bulan Oktober



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-10-2023	27.2	78	8.6	1
02-10-2023	27	74	8.3	1
03-10-2023	27.3	72	9.9	0
04-10-2023	27.5	72	8.4	1
05-10-2023	27.8	77	9.9	2
06-10-2023	27.1	76	9	1
07-10-2023	27.6	77	7.6	0
08-10-2023	28	71	8.8	1
09-10-2023	28.2	72	8	1
10-10-2023	28.2	74	7.5	1
11-10-2023	28.3	73	6.4	1
12-10-2023	28.3	73	3.2	1
13-10-2023	27.7	74	5.4	2
14-10-2023	27.2	78	7.5	1
15-10-2023	28.1	74	6.5	2
16-10-2023	28.9	69	5	1
17-10-2023	29.3	66	7.4	1
18-10-2023	28.3	65	8.2	1
19-10-2023	27.5	70	8.4	2
20-10-2023	27.7	74	10.3	1
21-10-2023	27.1	81	6.9	1
22-10-2023	28.1	77	6.3	1
23-10-2023				
24-10-2023	27	74	6.8	1
25-10-2023	26.3	84	6.5	1
26-10-2023	27	83	5.7	1
27-10-2023	27.6	80	7.2	0
28-10-2023	28.4	66	8.3	1
29-10-2023	27.8	67	10	1
30-10-2023	28.7	70	10	1
31-10-2023	26.9	81	9.4	2

Lampiran 13. Data Bulan November



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-11-2023	26.1	86	7.7	1
02-11-2023	26.9	84	6.5	1
03-11-2023	26.6	84	7	1
04-11-2023	26.1	87	7.9	1
05-11-2023	25.6	90	4	2
06-11-2023	27.8	81	3.4	0
07-11-2023	28.3	77	8.3	0
08-11-2023	27.9	80	7.8	2
09-11-2023	26.3	85	9.1	2
10-11-2023	27.4	81	6.1	1
11-11-2023	27	82	7.2	2
12-11-2023	26.1	85	7.2	2
13-11-2023	27.7	81	6.2	1
14-11-2023	26.5	86	7.8	2
15-11-2023	27.2	84	6.1	2
16-11-2023	26.6	84	4.8	1
17-11-2023	27.2	86	7.4	0
18-11-2023	26.9	84	5.5	1
19-11-2023	28.4	77	6.1	2
20-11-2023	28	80	9.2	2
21-11-2023	27.1	82	7.5	2
22-11-2023	27.4	82	7.4	1
23-11-2023	27.3	83	5.5	1
24-11-2023	26.7	87	0	1
25-11-2023	24.8	91	4.8	1
26-11-2023	26.3	85	0	1
27-11-2023	26	88	6.2	1
28-11-2023	26.4	85	0	1
29-11-2023	26.7	83	3.1	2
30-11-2023	26.1	89	7.2	1

Lampiran 14. Data Bulan Desember



ID WMO : 96753
 Nama Stasiun : Stasiun Klimatologi Jawa Barat
 Lintang : -6.50000
 Bujur : 106.75000
 Elevasi : 207

Tanggal	Tavg	RH_avg	ss	ff_avg
01-12-2023	25.6	90	3.1	0
02-12-2023	27.1	83	0	1
03-12-2023	26.4	85	6.4	1
04-12-2023	24.9	90	4	0
05-12-2023	26.9	80	0	1
06-12-2023	26.6	85	7.2	2
07-12-2023	27.3	83	7.2	1
08-12-2023	27	87	5.7	1
09-12-2023	26.8	85	5.2	2
10-12-2023	27.3	83	3.7	1
11-12-2023	27.1	84	1.2	2
12-12-2023	27.5	79	7.4	0
13-12-2023	27.8	78	6.4	0
14-12-2023	28.2	73	9.7	2
15-12-2023	28.6	70	9.5	1
16-12-2023	28.2	73	7.5	0
17-12-2023	27.9	76	10.1	0
18-12-2023	28	75	10	2
19-12-2023	27.9	66	8.6	2
20-12-2023	27.3	64	7.5	1
21-12-2023	27.6	67	10.6	1
22-12-2023	28.1	70	9.6	0
23-12-2023	28.7	72	8.5	2
24-12-2023	27.6	81	6.9	2
25-12-2023	27	83	6.1	1
26-12-2023	26.6	84	3.8	1
27-12-2023	26.8	83	0	1
28-12-2023	27.1	83	4.6	1
29-12-2023	26.7	89	6.9	1
30-12-2023	25.7	92	0	1
31-12-2023	26.2	87	0.2	1

Lampiran 15. Data Curah Hujan Bulan September



ID WMO : 96753
Nama Stasiun : Stasiun Klimatologi Jawa Barat
Lintang : -6.50000
Bujur : 106.75000
Elevasi : 207

Tanggal	RR
01-09-2023	0.4
02-09-2023	30.5
03-09-2023	34.6
04-09-2023	45
05-09-2023	42.5
06-09-2023	26.5
07-09-2023	29.8
08-09-2023	30.91
09-09-2023	20
10-09-2023	78.6
11-09-2023	33.2
12-09-2023	30
13-09-2023	24
14-09-2023	33.5
15-09-2023	30
16-09-2023	26.8
17-09-2023	25.7
18-09-2023	30.9
19-09-2023	23
20-09-2023	21
21-09-2023	25.2
22-09-2023	36
23-09-2023	29.29
24-09-2023	29.7
25-09-2023	37.13
26-09-2023	24
27-09-2023	43.77
28-09-2023	49.32
29-09-2023	35
30-09-2023	33

Lampiran 16. Data Curah Hujan Bulan Oktober



ID WMO : 96753
Nama Stasiun : Stasiun Klimatologi Jawa Barat
Lintang : -6.50000
Bujur : 106.75000
Elevasi : 207

Tanggal	RR
01-10-2023	24
02-10-2023	25
03-10-2023	28
04-10-2023	26
05-10-2023	25
06-10-2023	26
07-10-2023	17
08-10-2023	26
09-10-2023	23
10-10-2023	21
11-10-2023	20
12-10-2023	16
13-10-2023	24
14-10-2023	23
15-10-2023	25
16-10-2023	20
17-10-2023	22
18-10-2023	28
19-10-2023	33
20-10-2023	25
21-10-2023	20
22-10-2023	16
23-10-2023	20
24-10-2023	17
25-10-2023	20
26-10-2023	17
27-10-2023	15
28-10-2023	27
29-10-2023	31
30-10-2023	24
31-10-2023	27

Lampiran 17. Data Curah Hujan Bulan November



ID WMO : 96753
Nama Stasiun : Stasiun Klimatologi Jawa Barat
Lintang : -6.50000
Bujur : 106.75000
Elevasi : 207

Tanggal	RR
01-11-2023	20
02-11-2023	18
03-11-2023	20
04-11-2023	21
05-11-2023	21
06-11-2023	21
07-11-2023	17
08-11-2023	23
09-11-2023	26
10-11-2023	18
11-11-2023	24
12-11-2023	25
13-11-2023	16
14-11-2023	25
15-11-2023	22
16-11-2023	17
17-11-2023	15
18-11-2023	17
19-11-2023	21
20-11-2023	24
21-11-2023	24
22-11-2023	19
23-11-2023	18
24-11-2023	10
25-11-2023	14
26-11-2023	15
27-11-2023	18
28-11-2023	11
29-11-2023	20
30-11-2023	18

Lampiran 18. Data Bulan Desember



ID WMO : 96753
Nama Stasiun : Stasiun Klimatologi Jawa Barat
Lintang : -6.50000
Bujur : 106.75000
Elevasi : 207

Tanggal	RR
01-12-2023	8.5
02-12-2023	13
03-12-2023	20
04-12-2023	14
05-12-2023	14
06-12-2023	20
07-12-2023	18
08-12-2023	15
09-12-2023	23.1
10-12-2023	15
11-12-2023	15
12-12-2023	17.4
13-12-2023	16.5
14-12-2023	29
15-12-2023	25
16-12-2023	17
17-12-2023	20.5
18-12-2023	33
19-12-2023	39
20-12-2023	35
21-12-2023	35
22-12-2023	21
23-12-2023	27.8
24-12-2023	21.5
25-12-2023	18.7
26-12-2023	16
27-12-2023	18
28-12-2023	20
29-12-2023	20
30-12-2023	12
31-12-2023	11