

**PREDIKSI CURAH HUJAN MENGGUNAKAN METODE GRADIENT
BOOSTING BERDASARKAN DATA CUACA HARIAN BMKG**

TESIS

**Oleh :
MOHAMAD ARIF ABDUL SYUKUR
NIM. 240605220008**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

**PREDIKSI CURAH HUJAN MENGGUNAKAN METODE GRADIENT
BOOSTING BERDASARKAN DATA CUACA HARIAN BMKG**

TESIS

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Komputer (M.Kom)**

**Oleh:
MOHAMAD ARIF ABDUL SYUKUR
NIM. 240605220008**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2026**

HALAMAN PERSETUJUAN


PREDIKSI CURAH HUJAN MENGGUNAKAN METODE GRADIENT BOOSTING BERDASARKAN DATA CUACA HARIAN BMKG

TESIS

Oleh :
MOHAMAD ARIF ABDUL SYUKUR
NIM. 240605220008

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 28 Juni 2026

Pembimbing I,



Prof. Dr. Suhartono, S.Si., M.Kom
NIP. 19680519 200312 1 001

Pembimbing II,



Dr. M. Imamudin, Lc., M.A
NIP. 19740602 200901 1 010

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr. Muhammad Faisal, S.Kom., M.T.
NIP. 19740510 200501 1 007

HALAMAN PENGESAHAN

PREDIKSI CURAH HUJAN MENGGUNAKAN METODE GRADIENT BOOSTING BERDASARKAN DATA CUACA HARIAN BMKG


TESIS

Oleh :
MOHAMAD ARIF ABDUL SYUKUR
NIM. 240605220008

Telah Dipertahankan di Depan Dewan Penguji Tesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Magister Komputer (M.Kom)
Tanggal: 30 Juni 2026

Susunan Dewan Penguji

Penguji I	: <u>Dr. Totok Chamidy, S.T., M.Kom</u> NIP. 19691222 200604 1 001
Penguji II	: <u>Dr. M. Ainul Yaqin, S.Si., M.Kom</u> NIP. 19761013 200604 1 004
Pembimbing I	: <u>Prof. Dr. Suhartono, S.Si., M.Kom</u> NIP. 19680519 200312 1 001
Pembimbing II	: <u>Dr. M. Imamudin, Lc., M.A</u> NIP. 19740602 200901 1 010

()
()
()
()

Mengetahui dan Mengesahkan
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Prof. Dr. H. Muhammad Faisal, S.Kom., M.T.
NIP. 19740510 200501 1 007

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Mohamad Arif Abdul Syukur

NIM : 240605220008

Fakultas / Jurusan : Sains dan Teknologi / Magister Informatika

Judul Tesis : Prediksi Curah Hujan Menggunakan Metode Gradient Boosting

Berdasarkan Data Cuaca Harian BMKG

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 30 Juni 2026

Yang membuat pernyataan.



10L 25
METERAI
TEMPEL
E5AOX040990478

Mohamad Arif Abdul Syukur

NIM.240605220008

MOTTO

... Jika tidak segera dilakukan maka kamu akan terus berfikir bagaimana melakukannya, jika memang kamu menginginkannya, Lakukanlah dengan DUIT Do'a, Usaha, Ikhtiyar, Tawakal...

HALAMAN PERSEMBAHAN

Alhamdulillahirabbil'alamin, puji syukur ke hadirat Allah SWT, atas segala rahmat, petunjuk, dan kemudahan yang Engkau berikan sehingga tesis ini dapat terselesaikan. Shalawat serta salam senantiasa tercurah kepada Baginda Rasulullah SAW. Dengan tulus dan rasa bersyukur sebagai penghargaan yang sebesar-besarnya, saya menyampaikan persembahan sebagai bentuk dedikasi dan bukti tanggung jawab dengan selesainya tesis ini. Karya sederhana ini saya persembahkan dengan penuh cinta dan rasa hormat kepada:

1. Kedua orang tua saya yaitu Cariwan dan Wasmi. Terima kasih sudah selalu mendoakan saya di setiap waktunya serta senantiasa memberikan dukungan dengan baik. Terima kasih atas kesabaran, kekuatan dan kepercayaan yang selalu kalian berikan sehingga menjadi sumber semangat untuk menuntut ilmu dan menyelesaikan tesis ini, sosok yang menjadi alasan utama di balik setiap langkah saya. Terima kasih atas doa yang tidak pernah putus, dukungan tiada henti, dan kasih sayang yang menjadi penguat di setiap kesulitan. Semoga tesis ini menjadi bukti kecil dari bakti saya kepada kalian.
2. Keluarga besar, atas dukungan, semangat dan doa yang telah menyertai perjalanan akademik ini.
3. Dosen Pembimbing, yang telah meluangkan waktu, tenaga, dan pikiran untuk membimbing, mengarahkan, serta memberikan ilmu yang sangat berharga selama penyusunan tesis ini.
4. Teman-teman seperjuangan, yang selalu berbagi suka dan duka, semangat dan tempat untuk bertukar pikiran selama perjalanan studi ini.
5. Seluruh pihak yang membantu dan memberi inspirasi dalam penyelesaian penelitian ini.

Semoga ilmu ini menjadi keberkahan dan bermanfaat bagi sesama serta menjadi amal jariyah bagi kita semua *Aamiin Aamiin Ya Rabbal'alamiin*.

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh.

Tidak ada kata-kata yang pantas diucapkan selain rasa syukur kepada Allah *Subhanahu Wa Ta'ala* atas karunia dan rahmat-Nya sehingga tesis ini dapat diselesaikan dengan baik. Shalawat dan salam juga tetap tercurahkan kepada baginda Nabi Muhammad *Shalallahu 'Alaihi Wasallam* yang telah membimbing dari zaman kegelapan kepada zaman yang terang benderang yaitu Agama Islam. Tesis ini ditulis untuk memenuhi syarat kelulusan mahasiswa Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang dengan gelar magister komputer (M.Kom). Melalui kesempatan ini, penulis menyampaikan rasa terimakasih kepada semua pihak yang telah mendukung terselesaikannya tesis ini. Terutama yaitu kedua orang tua yang selalu memberikan dukungan moral dan material serta selalu mendoakan kapan pun dan di mana pun. Selain itu penulis juga mengucapkan terimakasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si., CAHRM., CRMP., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono, M.Kes., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Prof. Dr. Ir. Muhammad Faisal, S. Kom., M.T, selaku Ketua Program Studi Magister Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Prof. Dr. Suhartono, S.Si., M.Kom, selaku dosen pembimbing I dan Dr. M. Imamudin., Lc., M.A, selaku dosen pembimbing II yang telah memberikan bantuan dan arahan kepada penulis pada tesis ini.
6. Dr. Totok Chamidy, S.T., M.Kom, selaku dosen penguji I dan Dr. M. Ainul Yaqin, S.Si., M.Kom, selaku dosen penguji II yang telah menguji serta memberikan masukan sehingga penulis dapat menuntaskan tesis dengan baik.
7. Segenap Dosen, Bu Nia, Bu Citra dan Pak Izzudin selaku Admin, Laboran dan Mahasiswa Program Studi Magister Informatika yang telah memberikan banyak saran dan semangat untuk menyelesaikan tesis ini.
8. Kedua orang tua, Bapak Cariwan dan Ibu Wasmi serta keluarga besar yang telah memberikan dukungan kepada penulis untuk menyelesaikan tesis ini.

9. Teman-teman seperjuangan dan seluruh pihak yang membantu dalam penyelesaian penelitian ini.

Akhir kata, penulis mengakui bahwa penulisan pada tesis ini masih banyak kekurangan. Penulis berharap semoga tesis ini diterima sebagai amal ibadah yang tulus dan bermanfaat di sisi Allah *Subhanahu Wa Ta'ala*.

Wassalamualaikum Warahmatullahi Wabarakatuh.

Malang, 30 Juni 2026

A handwritten signature in black ink, consisting of a stylized 'A' or similar character, followed by a horizontal line.

Penulis

DAFTAR ISI

HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
ABSTRAK.....	xiv
ABSTRACT	xv
المخلص	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Pernyataan Masalah	8
1.3 Tujuan Penelitian.....	9
1.4 Batasan Masalah	9
1.5 Manfaat Penelitian.....	9
BAB II STUDI PUSTAKA	10
2.1 Tinjauan Pustaka	10
2.2 Prediksi Hujan	30
2.3 Gradient Boosting	32
2.4 Kerangka Teori	35
BAB III METODOLOGI PENELITIAN.....	40
3.1 Deskripsi dan Karakteristik Data	40
3.2 Tahap Penelitian	52
3.2.1 Pengumpulan Data	53
3.2.2 Prapemrosesan Data	54
3.2.3 Optimasi	57
3.2.4 Pemodelan	60
3.2.5 Gradient Boosting	62
3.2.6 Evaluasi	64
3.2.7 Kesimpulan	65

3.3 Eksperimen.....	65
BAB IV HASIL DAN PEMBAHASAN.....	69
4.1 Hasil.....	69
4.1.1 Perhitungan Gradient Boosting	70
4.1.2 Pengujian Komposisi 50:50	72
4.1.3 Pengujian Komposisi 70:30	83
4.1.4 Pengujian Komposisi 80:20	95
4.1.5 Pengujian Komposisi 90:10	107
4.1.6 Pengujian Studi Ablasi	118
4.2 Pembahasan.....	118
4.3 Integrasi penelitian dengan Al-Qur'an dan Hadits	128
4.4 Intrumen Penelitian	136
4.4.1 Perangkat Keras	136
4.4.2 Perangkat Lunak.....	137
4.4.3 Pengumpulan dan Variabel Data	137
BAB V KESIMPULAN DAN SARAN	139
5.1 Kesimpulan.....	139
5.2 Saran	139
DAFTAR PUSTAKA	1

DAFTAR GAMBAR

Gambar 2. 1 Kerangka Teori	38
Gambar 3. 1 Lima data teratas.....	43
Gambar 3. 2 Matriks Korelasi Variabel Cuaca.....	45
Gambar 3. 3 Dekomposisi Curah Hujan.....	48
Gambar 3. 4 Tren Perubahan Curah Hujan	49
Gambar 3. 5 Distribusi Data Curah Hujan	50
Gambar 3. 6 Kerangka Konsep.....	52
Gambar 3. 7 Tahap Penelitian	53
Gambar 3. 8 Distribusi curah hujan sebelum vs sesudah imputasi	57
Gambar 3. 9 Hasil RandomSearchCV	60
Gambar 3. 10 Desain Sistem	62
Gambar 3. 11 Algoritma Gradient Boosting	63
Gambar 4. 1 Visualisasi Training, Testing, dan Prediksi Komposisi 50:50 Baseline	73
Gambar 4. 2 Scater Plot Aktual dan Prediksi Komposisi 50:50 Baseline.....	74
Gambar 4. 3 Evaluasi Model Komposisi 50:50 Baseline.....	75
Gambar 4. 4 Visualisasi Training, Testing, dan Prediksi Komposisi 50:50 Optimized..	80
Gambar 4. 5 Scater Plot Aktual dan Prediksi Komposisi 50:50 Optimized.....	81
Gambar 4. 6 Evaluasi Model Komposisi 50:50 Optimized.....	82
Gambar 4. 7 Visualisasi Training, Testing dan Prediksi Komposisi 70:30 Baseline	84
Gambar 4. 8 Scater Plot Aktual dan Prediksi Komposisi 70:30 Baseline.....	85
Gambar 4. 9 Evaluasi Model Komposisi 70:30 Baseline.....	86
Gambar 4. 10 Visualisasi Training, Testing, dan Prediksi Komposisi 70:30 Optimized	91
Gambar 4. 11 Scater Plot Aktual dan Prediksi Komposisi 70:30 Optimized.....	93
Gambar 4. 12 Evaluasi Model Komposisi 70:30 Optimized.....	94
Gambar 4. 13 Visualisasi Training, Testing, dan Prediksi Komposisi 80:20 Baseline..	96
Gambar 4. 14 Scater Plot Aktual dan Prediksi Komposisi 80:20 Baseline.....	97
Gambar 4. 15 Evaluasi Model Komposisi 80:20 Baseline.....	98
Gambar 4. 16 Visualisasi Training, Testing, dan Prediksi Komposisi 80:20 Optimized	103
Gambar 4. 17 Scater Plot Aktual dan Prediksi Komposisi 80:20 Optimized.....	105
Gambar 4. 18 Evaluasi Model Komposisi 80:20 Optimized.....	106
Gambar 4. 19 Visualisasi Training, Testing, dan Prediksi Komposisi 90:10 Baseline	108
Gambar 4. 20 Scater Plot Aktual dan Prediksi Komposisi 90:10 Baseline.....	109
Gambar 4. 21 Evaluasi Model Komposisi 90:10 Baseline.....	110
Gambar 4. 22 Visualisasi Training, Testing, dan Prediksi Komposisi 90:10 Optimized	115
Gambar 4. 23 Scater Plot Aktual dan Prediksi Komposisi 90:10 Optimized.....	116
Gambar 4. 24 Evaluasi Model Komposisi 90:10 Optimized.....	117
Gambar 4. 25 Evaluasi MAE.....	120
Gambar 4. 26 Evaluasi RMSE.....	121
Gambar 4. 27 Evaluasi R2.....	122
Gambar 4. 28 Evaluasi Keseluruhan	123
Gambar 4. 31 Intrumen Penelitian.....	137

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	17
Tabel 3. 1 Dataset penelitian	42
Tabel 3. 2 Identifikasi Fitur Dataset	43
Tabel 3. 3 Uji Stasioner ADF	46
Tabel 3. 4 Dataset penelitian	54
Tabel 3. 5 Konversi Data.....	56
Tabel 3. 6 Parameter optimal.....	59
Tabel 3. 8 Pembagian data.....	66
Tabel 4. 1 Data Input	70
Tabel 4. 2 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 50:50.....	76
Tabel 4. 3 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 70:30.....	88
Tabel 4. 4 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 80:20.....	100
Tabel 4. 5 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 90:10.....	111
Tabel 4. 6 Hasil studi ablas.....	118
Tabel 4. 7 Hasil Penelitian Alvines dkk	124
Tabel 4. 8 Hasil Penelitian Zoremsanga	126
Tabel 4. 9 Perbandingan penelitian lain	127

ABSTRAK

Syukur, Mohamad Arif Abdul. 2026. **Prediksi Curah Hujan Menggunakan Metode Gradient Boosting Berdasarkan Data Cuaca Harian BMKG**. Tesis. Program Studi Magister Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Suhartono, S.Si., M.Kom (II) Dr. M. Imamudin, Lc., M.A.

Kata kunci: Prediksi, Curah Hujan, Gradient Boosting, Optimasi Hyperparameter, BMKG

Prediksi curah hujan harian merupakan aspek krusial dalam mitigasi bencana hidrometeorologi dan keseharian masyarakat, namun memiliki tingkat kesulitan tinggi akibat karakteristik data yang bersifat stokastik dan fluktuatif. Penelitian ini bertujuan untuk mengembangkan model prediksi curah hujan harian yang akurat menggunakan algoritma Gradient Boosting dengan optimasi *hyperparameter* melalui RandomizedSearchCV. Data yang digunakan bersumber dari data meteorologi harian di wilayah Malang, meliputi variabel temperatur rata-rata (TAVG), kelembapan rata-rata (RH_AVG), dan durasi penyinaran matahari (SS). Tahapan prapemrosesan data mencakup konversi format, penanganan missing value dengan algoritma KNNImputer $k=5$, dan normalisasi fitur menggunakan StandardScaler. Untuk menguji performa model, dilakukan eksperimen pada empat skenario pembagian data (data splitting) yaitu 50:50, 70:30, 80:20, dan 90:10, serta dilakukan studi ablasi untuk menguji kontribusi setiap variabel input. Hasil penelitian menunjukkan bahwa penggunaan seluruh fitur memberikan konfigurasi terbaik dengan nilai RMSE 9,65, MAE 6,11, dan R^2 0,33 pada skenario 80:20. Studi ablasi mengonfirmasi bahwa setiap fitur memberikan kontribusi unik terhadap akurasi model, di mana durasi penyinaran matahari (SS) menjadi prediktor paling dominan. Dibandingkan dengan penelitian terdahulu pada konteks data BMKG di Indonesia, model Gradient Boosting yang dioptimasi dalam penelitian ini menunjukkan performa yang lebih unggul dan stabil. Penelitian ini menyimpulkan bahwa optimasi parameter yang tepat merupakan langkah krusial dalam meningkatkan kemampuan generalisasi model terhadap dinamika cuaca yang kompleks, sehingga model ini berpotensi sebagai pendukung sistem peringatan dini berbasis data di tingkat regional.

ABSTRACT

Syukur, Mohamad Arif Abdul. 2026. **Rainfall Prediction Using Gradient Boosting Method Based on BMKG Daily Weather Data**. Tesis. Master of Informatics Department, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University of Malang. Supervisor: (I) Prof. Dr. Suhartono, S.Si., M.Kom (II) Dr. M. Imamudin, Lc., M.A.

Daily rainfall prediction is a crucial aspect in mitigating hydrometeorological disasters and in people's daily lives, but it has a high level of difficulty due to the stochastic and fluctuating characteristics of the data. This study aims to develop an accurate daily rainfall prediction model using the Gradient Boosting algorithm with hyperparameter optimization through RandomizedSearchCV. The data used are sourced from daily meteorological data in the Malang area, including the variables of average temperature (TAVG), average humidity (RH_AVG), and sunshine duration (SS). Data preprocessing stages include format conversion, handling missing values with the KNNImputer k=5 algorithm, and feature normalization using StandardScaler. To test the model performance, experiments were conducted on four data splitting scenarios: 50:50, 70:30, 80:20, and 90:10, and an ablation study was conducted to test the contribution of each input variable. The results showed that the use of all features provided the best configuration with an RMSE of 9.65, MAE of 6.11, and R2 of 0.33 in the 80:20 scenario. Ablation studies confirmed that each feature provides a unique contribution to model accuracy, with sunshine duration (SS) being the most dominant predictor. Compared with previous studies in the context of BMKG data in Indonesia, the Gradient Boosting model optimized in this study showed superior and stable performance. This study concluded that proper parameter optimization is a crucial step in improving the model's generalization capability to complex weather dynamics, thus making this model potentially a supporter of data-based early warning systems at the regional level.

Keywords: Prediction, Rainfall, Gradient Boosting, Hyperparameter Optimization, BMKG

الملخص

عبد الشكر، محمد عارف. ٢٠٢٦. التنبؤ بهطول الأمطار باستخدام طريقة تعزيز التدرج بناءً على بيانات الطقس اليومية من وكالة الأرصاد الجوية وعلم المناخ والجيوفيزياء. رسالة ماجستير علوم المعلومات، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرفان: (١) الأستاذ الدكتور سوهارتونو ماجستير (٦) الدكتور محمد إمام الدين، ماجستير.

الكلمات الأساسية: التنبؤ، هطول الأمطار، تعزيز التدرج، تحسين المعلمات الفائقة، وكالة الأرصاد الجوية وعلم المناخ والجيوفيزياء

يُعدّ التنبؤ اليومي بهطول الأمطار جانبًا بالغ الأهمية في التخفيف من آثار الكوارث الهيدرولوجية وفي حياة الناس اليومية، إلا أنه ينطوي على صعوبة كبيرة نظرًا لطبيعة البيانات العشوائية والمتقلبة. تهدف هذه الدراسة إلى تطوير نموذج دقيق للتنبؤ اليومي بهطول الأمطار باستخدام خوارزمية تعزيز التدرج مع تحسين المعلمات الفائقة من خلال البحث العشوائي المتقاطع. تُستقى البيانات المستخدمة من بيانات الأرصاد الجوية اليومية في منطقة مالانج، وتشمل متغيرات متوسط درجة الحرارة، ومتوسط الرطوبة، ومدة سطوع الشمس. تتضمن مراحل المعالجة المسبقة للبيانات تحويل التنسيق، ومعالجة القيم المفقودة باستخدام خوارزمية KNN Imputer $k=5$ ، وتطبيق الميزات باستخدام. لاختبار أداء النموذج، أُجريت تجارب على أربعة سيناريوهات لتقسيم البيانات: ٥٠:٥٠، ٣٠:٧٠، ٢٠:٨٠، و ١٠:٩٠، كما أُجريت دراسة تحليلية لاختبار مساهمة كل متغير من متغيرات الإدخال. أظهرت النتائج أن استخدام جميع الخصائص وقر أفضل تكوين، حيث بلغ متوسط الجذر التربيعي للخطأ ٦٥.٩، ومتوسط الخطأ المطلق ١١.٦، ومعامل التحديد ٣٣.٠ في سيناريو ٢٠:٨٠. وأكدت دراسات الاستبعاد أن لكل خاصية مساهمة فريدة في دقة النموذج، مع كون مدة سطوع الشمس هي المتنبئ الأكثر تأثيرًا. وبالمقارنة مع الدراسات السابقة التي استخدمت بيانات وكالة الأرصاد الجوية وعلم المناخ والجيوفيزياء في إندونيسيا، أظهر نموذج تعزيز التدرج المُحسن في هذه الدراسة أداءً متفوقًا ومستقرًا. وخلصت هذه الدراسة إلى أن التحسين الأمثل للمعلمات يُعد خطوة حاسمة في تحسين قدرة النموذج على التعميم على ديناميكيات الطقس المعقدة، مما يجعل هذا النموذج داعمًا محتملاً لأنظمة الإنذار المبكر القائمة على البيانات على المستوى الإقليمي.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Cuaca memiliki dampak signifikan pada banyak aspek kehidupan manusia, termasuk transportasi, pariwisata, pertanian, dan penanggulangan bencana. Proses pengambilan keputusan di banyak industri ini membutuhkan informasi cuaca yang cepat dan akurat. Namun, memprediksi cuaca harus dilakukan dengan teliti dan benar karena ketidakstabilan iklim dan osilasi atmosfer yang cepat, terutama di wilayah tropis seperti Indonesia agar mendapatkan prediksi yang akurat dan cepat (Oettl & Veratti, 2021). Variasi curah hujan berdampak pada pasokan air, pertanian, dan kemungkinan terjadinya tanah longsor dan banjir. Karena musim hujan dan musim kemarau di Indonesia sangat bervariasi, BMKG (Badan Meteorologi, Klimatologi, dan Geofisika) memberikan peringatan dan prediksi musiman. Kondisi ini memerlukan prediksi harian yang lebih tepat untuk perencanaan dan mitigasi (Reuters, 2024).

Badan Nasional Penanggulangan Bencana BNPB menyatakan bahwa jumlah korban meninggal dunia akibat bencana hidrometeorologi yang terjadi pada sejumlah wilayah Sumatera mencapai 1.177 orang per 4 Januari 2026 (Prameswari, 2026). BMKG juga menyatakan bahwa kejadian di Sumatera menunjukkan bencana tetap dapat terjadi akibat curah hujan ekstrem yang turun di wilayah topografi curam. BMKG menyatakan bahwa bencana ini menjadikannya salah satu bencana terburuk dalam sejarah modern Indonesia karena 3,3 juta jiwa terdampak kehilangan tempat tinggal, harta benda, serta pola hidup sehari-hari. Kerugian ekonomi diperkirakan mencapai Rp68,8 triliun, dengan 3.500 bangunan rusak berat, 271 akses jembatan hancur, dan 282 fasilitas pendidikan mengalami kerusakan (Bariri, 2025). Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) telah menyediakan data historis cuaca harian yang komprehensif dan berkelanjutan, tetapi masih ada sejumlah kendala dalam penggunaan data ini secara optimal untuk menghasilkan prediksi curah hujan yang akurat, terutama ketika menggunakan

metode statistik dan model fisika tradisional (Sinaga et al., 2025).

Berdasarkan data dari Dinas Pangan dan Pertanian (Dispaperta) Batang per 23 Januari 2026, tercatat seluas 469 hektare areal sawah terdampak luapan air. Dari jumlah tersebut, kondisi yang paling memprihatinkan menimpa 139 hektare lahan yang dinyatakan puso atau gagal panen. Kepala Bidang Tanaman Pangan Dispaperta Batang Rini Diana Anggriani menjelaskan, bahwa tingginya intensitas hujan menjadi pemicu utama lumpuhnya aktivitas pertanian di beberapa wilayah. Total areal terdampak banjir 469 Ha dan Total areal puso (gagal panen) mencapai 139 Ha di wilayah terdampak yaitu Kec. Batang, Kandeman, Gringsing, dan Banyuputih (Jumadi, 2026).

Pada tanggal 1 Desember 2024 Pkl. 17.00 WIB tentang sebaran kejadian bencana hidrometeorologi yang terjadi pada hari Kamis, 28 November 2024. Berdasarkan informasi dan laporan dari masyarakat serta relawan setempat telah terjadi beberapa kejadian banjir dan tanah longsor yang tersebar di Wilayah Kecamatan Bantur, Donomulyo, Pagak, Kalipare, Gedangan, Sumbermanjing Wetan, Sumberpucung dan Wajak. Berdasarkan hasil identifikasi sementara, sekitar 975 jiwa terdampak, 9 rumah rusak ringan, 16 infrastruktur mengalami kerusakan serta 356 rumah tergenang banjir. Berdasarkan informasi dari BMKG bahwa dalam beberapa hari terdapat potensi cuaca ekstrem termasuk di wilayah Kabupaten Malang (BPBD, 2024). Update dari Satu Data Malang Kota mencatat persentase penambahan jumlah korban bencana banjir pada tahun 2023 sebesar 46,13 dan pada tahun 2024 sebesar 67,35 serta pada tahun 2025 sebesar 53,45 (KOMINFO, 2024).

Asosiasi maskapai nasional Indonesia National Air Carrier Association (INACA) mencatat kondisi curah hujan tinggi dan cuaca ekstrem yang melanda kawasan Jabodetabek sebagai hub penerbangan nasional berimbas langsung pada penurunan pendapatan atau omzet para operator penerbangan. Saat terjadi extreme weather dan terjadi delays atau cancel flight, kerugian omzet bisa mencapai 20–25 persen, karena perlu waktu recovery agar operasi kembali normal. Kerugian tersebut berasal dari biaya operasional yang tetap harus dikeluarkan, seperti bahan bakar avtur dan biaya kru, serta potensi kehilangan pendapatan akibat penundaan

dan pembatalan penerbangan. Cuaca ekstrem berpengaruh bagi operasi penerbangan, baik berupa hujan deras dengan durasi yang cukup lama maupun badai tropis. Hal ini khususnya memengaruhi ketepatan waktu take off maupun landing yang selalu didasari prinsip keselamatan atau safety first. Dampak cuaca buruk ini menyebabkan berkurangnya jam terbang atau utilisasi pesawat. Selain itu, gangguan operasional juga berdampak pada kepadatan di bandara akibat penumpukan penumpang yang mengalami penundaan maupun pembatalan penerbangan (Jatim, 2026).

Karena aktivitas manusia modern sangat bergantung pada informasi meteorologi yang tepat untuk pengambilan keputusan sehari-hari, prediksi curah hujan menjadi semakin penting. Jika curah hujan tidak diketahui atau terlambat diketahui karena perubahan iklim dan peningkatan variabilitas cuaca, dapat meningkatkan kemungkinan penundaan, kerugian finansial, dan gangguan aktivitas. Prediksi curah hujan sangat penting bagi masyarakat umum untuk merencanakan aktivitas luar ruangan yang lebih aman dan efektif, seperti pekerjaan, pendidikan, dan mobilitas, secara teratur. Data curah hujan harian menurunkan risiko kecelakaan dan keterlambatan pengiriman untuk industri transportasi dan logistik. Prediksi curah hujan membantu dalam jadwal penanaman, irigasi, dan panen di industri pertanian, mencegah kegagalan panen. Selain itu, prediksi curah hujan harian digunakan oleh pemerintah dan organisasi penanggulangan bencana sebagai dasar untuk mitigasi dini tanah longsor, banjir, dan genangan, yang semuanya memiliki pengaruh langsung terhadap keselamatan publik. Untuk meningkatkan keberlanjutan aktivitas masyarakat dan kualitas hidup di masa ketidakpastian iklim saat ini, prediksi curah hujan yang tepat dan adaptif berdasarkan data harian kini lebih dari sekadar persyaratan ilmiah tetapi telah menjadi kebutuhan praktis yang krusial untuk menunjang keberlanjutan aktivitas masyarakat.

Berita yang sudah ada menunjukkan bahwa kejadian hujan lebat dan dampaknya bukan hanya teoretis, namun terjadi secara nyata sehingga kondisi ini menimbulkan konsekuensi langsung bagi kehidupan sehari-hari seperti perlu peringatan dini untuk keselamatan, keputusan logistik untuk perjalanan dan kerja

lapangan, mitigasi risiko bencana dan penanggulangan dampak ekonomi maupun sosial. Oleh karena itu prediksi hujan harian yang lebih akurat menjadi kebutuhan penting dan mendesak, bukan hanya untuk pengetahuan ilmiah tetapi demi perlindungan masyarakat dan perencanaan kegiatan sehari-hari.

Menurut perspektif Islam, fenomena perkembangan dan perubahan cuaca bukan hanya subjek penelitian ilmiah, tetapi juga manifestasi kekuasaan Allah SWT yang patut dipertimbangkan. Ayat 48 Surat Ar-Rum, yang menjelaskan bagaimana Allah menciptakan awan, mengarahkan angin, menurunkannya sebagai hujan, dan memelihara kehidupan di Bumi, menegaskan klaim ini. Berikut adalah bunyi ayatnya :

اللَّهُ الَّذِي يُرْسِلُ الرِّيَّحَ فَتُثِيرُ سَحَابًا فَيَبْسُطُهُ فِي السَّمَاءِ كَيْفَ يَشَاءُ وَيَجْعَلُهُ كِسْفًا فَتَرَى الْوَدْقَ
يَخْرُجُ مِنْ خِلَالِهِ فَإِذَا أَصَابَ بِهِ مَنْ يَشَاءُ مِنْ عِبَادِهِ إِذَا هُمْ يَسْتَبْشِرُونَ

Artinya : “Allah, Dialah yang mengirim angin, lalu angin itu menggerakkan awan dan Allah membentangkannya di langit menurut yang dikehendaki-Nya, dan menjadikannya bergumpal-gumpal; lalu kamu lihat hujan keluar dari celah-celahnya, maka apabila hujan itu turun mengenai hamba-hamba-Nya yang dikehendaki-Nya, tiba-tiba mereka menjadi gembira”.(QS Ar-Rum Ayat 48)

Sebagaimana dijelaskan dalam *Fathul Karim Mukhtashar Tafsir al-Qur'an al-Adzhim*, karya Syaikh Muhammad Abduh bahwa Allah SWT menjelaskan bagaimana Dia menciptakan awan tempat jatuhnya air dari ayat tersebut baik itu berasal dari laut, sebagaimana telah dinyatakan oleh banyak ulama, maupun dari mana saja yang Allah SWT kehendaki dan Allah SWT menyebarkannya, menjadikannya melimpah, dan menumbuhkannya dari yang sedikit menjadi banyak. Pada mulanya Dia menjadikan awan-awan itu tampak bagi mata sebagai perisai, kemudian Dia menyebarkannya hingga menutupi cakrawala. Makna dari “dan menjadikannya bergumpal-gumpal” adalah menggumpal, menurut Mujahid, Abu Amr bin Al-'Ala', Mathar Al-Warraaq, dan Qatadah. Dan Allah SWT menjelaskan bahwa hujan muncul dari celah-celah awan sehingga hamba yang mendapatkan hujan tersebut menjadi bergembira. Artinya mereka

membutuhkannya dan karena itu merasa senang ketika hujan turun kepada mereka (Abduh et al., 1935).

Ayat ini menggambarkan bagaimana kehendak Allah SWT dan sistem hukum yang diatur dengan cermat menentukan cuaca dan hujan. Manusia berkewajiban untuk memahami manifestasi kebesaran Allah SWT melalui penyelidikan ilmiah dengan menganalisis dan menggunakan informasi untuk kebaikan umat manusia. Oleh karena itu, untuk memahami pola ciptaan Allah SWT dan menjaga keberlanjutan kehidupan di Bumi, upaya pengembangan sistem prediksi cuaca harian berdasarkan data historis bukan hanya bentuk eksplorasi ilmiah, tetapi juga bentuk ibadah ilmiah.

Dari perspektif ilmiah, cuaca terbentuk melalui proses fisika atmosfer yang kompleks, yang melibatkan interaksi suhu, kelembapan, tekanan udara, dan angin. Model numerik berbasis persamaan diferensial telah lama digunakan oleh badan meteorologi seperti Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) untuk meramalkan kondisi cuaca. Namun, pendekatan ini memiliki keterbatasan ketika dihadapkan pada variabilitas data lokal dan dinamika atmosfer yang sangat nonlinier. Dalam konteks ini, pendekatan berbasis pembelajaran mesin menawarkan solusi alternatif dengan memanfaatkan pola historis dalam data cuaca untuk menghasilkan model prediksi yang lebih adaptif dan akurat.

Begitu juga dengan metode fisik yang didasarkan pada model numerik seperti Numerical Weather Prediction (NWP), yang menggunakan simulasi komputer berdasarkan aturan fisika atmosfer dan telah digunakan untuk memprediksi cuaca. Meskipun digunakan secara luas dan menghasilkan hasil yang dapat diandalkan, metode ini sangat bergantung pada kualitas data masukan dan memerlukan komputasi yang sangat besar serta waktu pemrosesan yang lama (Bauer et al., 2015). Seiring kemajuan teknologi dan semakin banyaknya data meteorologi historis yang tersedia, metode berbasis pembelajaran mesin mulai digunakan dalam beberapa situasi untuk melengkapi atau bahkan menggantikan metode numerik (Rasp et al., 2020).

Gradient Boosting merupakan salah satu pendekatan machine learning yang telah menunjukkan hasil yang menjanjikan dalam pemodelan data nonlinier dan

mengidentifikasi pola yang rumit. Untuk menciptakan model yang kuat dan akurat, pendekatan ini secara bertahap menggabungkan beberapa pembelajar yang lemah, seperti pohon keputusan. Untuk mencegah overfitting, gradient boosting juga memungkinkan modifikasi data melalui parameter seperti learning rate, n_estimators, dan max_depth (T. Chen & Guestrin, 2016). Metode ini sesuai untuk masalah prediksi cuaca sehari-hari yang menuntut tingkat akurasi yang tinggi dalam waktu yang relatif singkat, karena manfaatnya dalam memproses data berskala besar dan beragam.

Sebagaimana dinyatakan dalam Surah Luqman ayat 34, bahwa tidak ada seorangpun yang dapat memprediksi peristiwa apa yang akan terjadi dikemudian hari termasuk peristiwa hujan. Dari perspektif Islam, pengetahuan tentang waktu turunnya hujan dianggap sebagai hal tidak dapat diprediksi yang sepenuhnya hanya diketahui oleh Allah. Hal ini menyoroti keterbatasan manusia dan nilai kerendahan hati dalam memahami proses alam, tanpa mengabaikan upaya manusia untuk melakukan penelitian ilmiah. Berikut adalah ayatnya :

إِنَّ اللَّهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنَزِّلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْأَرْحَامِ وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا
وَمَا تَدْرِي نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ إِنَّ اللَّهَ عَلِيمٌ خَبِيرٌ

Artinya “*Sesungguhnya Allah, hanya pada sisi-Nya sajalah pengetahuan tentang Hari Kiamat; dan Dialah Yang menurunkan hujan, dan mengetahui apa yang ada dalam rahim. Dan tiada seorangpun yang dapat mengetahui (dengan pasti) apa yang akan diusahakannya besok. Dan tiada seorangpun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha Mengetahui lagi Maha Mengenal*”. (QS Luqman Ayat 34)

Sebagaimana dijelaskan dalam *Tafsir Al-Wajiz* dari Syaikh Prof. Dr. Wahbah az-Zuhaili, pakar fiqih dan tafsir negeri Suriah bahwa Sesungguhnya, hanya Allah yang mengetahui Hari Kiamat dan tidak ada yang lain. Hujan diturunkan oleh Allah pada waktu dan lokasi tertentu. Dia mengetahui setiap detail tentang setiap janin yang masih dalam kandungan. Tanpa perlu bantuan atau pengamatan yang cermat, Allah Maha Mengetahui setiap peristiwa yang akan terjadi pada setiap janin, baik itu baik atau buruk, laki-laki atau perempuan, dan sebagainya. Tidak ada jiwa yang

dapat meramalkan apa yang akan terjadi padanya di masa depan, apakah itu baik atau buruk dan tidak ada jiwa yang tahu di mana ia akan meninggal. Sesungguhnya, pengetahuan Allah tentang segala sesuatu bersifat menyeluruh. Segala sesuatu, baik yang tampak maupun tak tampak, berada di bawah pengawasan Allah. Kata “*Al-Kasbu*” merujuk pada segala sesuatu yang diperoleh manusia, baik kebaikan maupun keburukan, nikmat maupun beban. Ketika Alharits bin Amru, seorang Badui, bertanya tentang janin yang dikandung istrinya, ayat ini diturunkan kepadanya. Selain itu, ia bertanya kapan hujan akan turun dan kapan ia akan meninggal dunia. Dengan demikian, Allah menjadikan ayat ini sebagai lima kunci untuk memahami (Wahbah Az-Zuhaili, 2016).

Oleh karena itu, mempelajari prediksi curah hujan berbasis data historis menggunakan teknik kontemporer seperti Gradient Boosting merupakan upaya ilmiah untuk mengantisipasi pola curah hujan berdasarkan data yang terukur secara empiris, alih-alih upaya untuk mendalami hal-hal paranormal. Gradient Boosting adalah teknik pembelajaran mesin berbasis ensemble yang menawarkan kemampuan prediksi yang lebih akurat untuk variabel meteorologi yang kompleks dengan mengoptimalkan model secara bertahap melalui minimisasi kesalahan. Sehingga, penelitian ini tidak hanya membantu meningkatkan akurasi prediksi cuaca tetapi juga memvalidasi integrasi ilmu pengetahuan kontemporer dan nilai-nilai Islam bahwa upaya teknologi dilakukan dalam batasan pengetahuan empiris manusia, sementara Allah SWT berhak atas kepastian mutlak terkait hujan, sebagaimana dinyatakan dalam Surah Luqman ayat 34.

Menurut penelitian oleh Meenal dkk (Meenal et al., 2022), model Gradient Boosting berkinerja lebih baik daripada model regresi linier atau teknik statistik tradisional dalam memperkirakan variabel meteorologi seperti suhu dan kelembapan. Model prediktif berdasarkan data historis dapat dikembangkan dan divalidasi secara berulang berkat data terbuka dan API BMKG yang mencakup variabel meteorologi harian (curah hujan, suhu, kelembapan, dan kecepatan angin) serta produk prediksi. Penelitian berbasis ML bermanfaat dan dapat diterapkan karena ketersediaan data ini (BMKG, 2025). Penelitian oleh Jianhua Dong dkk (Dong et al., 2023) menunjukkan bahwa model boosting seringkali mengungguli

model dasar dalam prediksi curah hujan, meskipun terdapat keterbatasan pada model fisik dan statistik tradisional dalam menangkap pola nonlinier dan variasi lokal. Karena itu, boosting merupakan pilihan yang baik untuk meningkatkan akurasi prediksi harian.

Algoritma *machine learning* tingkat lanjut, seperti boosting telah diposisikan sebagai strategi yang menjanjikan untuk meningkatkan peramalan cuaca jangka pendek hingga menengah dalam studi dan tinjauan terbaru. Terdapat juga bukti bahwa teknik Artificial Intelligent atau machine learning dapat mengungguli beberapa sistem numerik konvensional pada metrik tertentu. Hal ini menunjukkan penerapan eksperimen boosting untuk curah hujan sehari-hari (Clive Cookson, 2023). Penelitian yang menilai dan meningkatkan teknik Boosting khususnya pada data BMKG (resolusi lokal Indonesia) dan untuk prediksi curah hujan harian, masih relatif sedikit meskipun terdapat banyak studi internasional. Hal ini menciptakan peluang bagi kontribusi ilmiah untuk mengidentifikasi elemen meteorologi, pengaturan model, dan teknik validasi yang paling bermanfaat dan sesuai untuk kondisi tropis (Ejike et al., 2025)(Haq Doost et al., 2025). Data BMKG tersedia dan relevan sehingga memungkinkan untuk penelitian terapan dan tren riset terkini dalam tiga sampai 5 tahun kebelakang mendukung integrasi *machine learning* kedalam prediksi cuaca, namun optimasi untuk kondisi lokal (BMKG) masih diperlukan sehingga itulah yang menjadi kontribusi penelitian yang akan dilakukan.

Dengan demikian, tujuan penelitian ini adalah menggunakan data cuaca masa lalu BMKG untuk prediksi cuaca harian yang memanfaatkan Gradient Boosting. Penelitian ini juga akan menggunakan *Random Search* sebagai tuning parameter yang memengaruhi kemampuan sistem untuk menghasilkan prediksi yang tepat dan efektif. Berdasarkan data BMKG, temuan penelitian ini akan membantu dalam prediksi cuaca yang lebih cepat dan dapat diterapkan pada berbagai lembaga atau organisasi dan bahkan individu.

1.2 Pernyataan Masalah

Bagaimana menghasilkan model prediksi hujan dengan menggunakan metode Gradient Boosting berdasarkan data cuaca harian dari BMKG?

1.3 Tujuan Penelitian

Menghasilkan model prediksi hujan menggunakan metode Gradient Boosting berdasarkan data cuaca harian dari BMKG.

1.4 Batasan Masalah

Pembatasan masalah berikut ditetapkan agar penelitian ini tetap fokus dan dapat dilakukan secara terarah:

1. Data yang digunakan adalah data cuaca harian dari sumber dataonline.bmkg.go.id.
2. Metode yang digunakan adalah Gradient Boosting.
3. Prediksi yang dilakukan hanya pada wilayah Kabupaten Malang.

1.5 Manfaat Penelitian

Manfaat berikut diantisipasi dari penelitian ini:

1. Secara teori, penelitian ini memberi kontribusi pengetahuan tentang penggunaan Machine Learning terutama pada Gradient Boosting untuk prediksi cuaca.
2. Dari sudut pandang praktis, penelitian ini memberikan kontribusi alternatif untuk prediksi cuaca yang berbeda yang cepat dengan berbagai perangkat, termasuk sistem lokal atau aplikasi seluler.
3. Dari sudut pandang strategis, penelitian ini membantu organisasi atau lembaga dan individu dalam membuat pilihan berdasarkan prediksi cuaca yang lebih tepat dan fleksibel.

BAB II

STUDI PUSTAKA

2.1 Tinjauan Pustaka

Penelitian sebelumnya mengenai prediksi hujan dilakukan oleh Nana Kofi Appiah-Badu pada tahun 2022. Penelitian ini menggunakan data iklim historis harian yang bersumber dari Ghana Meteorological Agency dengan rentang waktu 1980 sampai 2019, meliputi variabel curah hujan, suhu minimum dan maksimum, kelembapan relatif, lama penyinaran matahari, serta kecepatan angin. Objek penelitian difokuskan pada prediksi kejadian hujan yaitu hujan dan tidak hujan di empat zona ekologi Ghana, yaitu zona pesisir, hutan, transisi, dan savana, yang memiliki karakteristik iklim berbeda. Metode yang digunakan adalah pendekatan machine learning berbasis ensemble dan pembelajaran mendalam, khususnya *Decision Tree*, *Random Forest*, *Multilayer Perceptron*, *K-Nearest Neighbour*, dan *Extreme Gradient Boosting (XGBoost)*, dengan tahapan praproses data berupa imputasi nilai hilang, penghapusan outlier, normalisasi, serta pembagian data latih dan uji pada beberapa rasio. Hasil penelitian menunjukkan bahwa model berbasis ensemble, terutama Random Forest dan XGBoost, memberikan kinerja terbaik dan paling konsisten pada seluruh zona ekologi dengan nilai akurasi, precision, recall, dan F1-score yang tinggi, sehingga menegaskan efektivitas metode gradient boosting dalam meningkatkan akurasi dan ketepatan waktu prediksi hujan dibandingkan algoritma lain (Appiah-badu et al., 2022).

Penelitian lain dilakukan oleh Zoremsanga dan Hussain pada tahun 2024, penelitian ini menggunakan data curah hujan historis bulanan yang dikumpulkan dari Indian Meteorological Department (IMD) dengan rentang waktu beberapa dekade untuk wilayah Aizawl, Mizoram, India. Objek penelitian difokuskan pada prediksi curah hujan di daerah pegunungan dengan karakteristik iklim muson yang kompleks dan variabilitas tinggi. Metode yang digunakan adalah model deep learning berbasis Artificial Neural Network (ANN) dan Long Short-Term Memory (LSTM) yang dioptimasi menggunakan Particle Swarm Optimization (PSO) untuk meningkatkan pemilihan bobot dan parameter model. Hasil penelitian

menunjukkan bahwa integrasi PSO dengan model deep learning secara signifikan meningkatkan akurasi prediksi curah hujan dibandingkan model ANN dan LSTM tanpa optimasi, yang dibuktikan melalui penurunan nilai error seperti RMSE dan MAE, sehingga menegaskan efektivitas pendekatan optimasi swarm intelligence dalam meningkatkan kinerja prediksi hujan pada wilayah dengan pola curah hujan yang kompleks (Zoremsanga & Hussain, 2024).

Penelitian lainnya dilakukan oleh Haq Doost et al., pada tahun 2025, penelitian ini menggunakan data historis curah hujan bulanan yang dikumpulkan dari beberapa stasiun meteorologi di Cekungan Sungai Harirud Murghab, Afghanistan, dengan periode pengamatan lebih dari 30 tahun. Objek penelitian difokuskan pada prediksi curah hujan regional di wilayah cekungan sungai yang memiliki variabilitas iklim tinggi dan keterbatasan sistem pengamatan cuaca. Metode yang digunakan mengintegrasikan K-Means Clustering untuk mengelompokkan pola hujan dengan algoritma machine learning seperti Random Forest (RF), Support Vector Machine (SVM), dan Gradient Boosting, guna meningkatkan homogenitas data sebelum proses pelatihan model. Hasil penelitian menunjukkan bahwa model terintegrasi K-Means–Random Forest memberikan kinerja terbaik dengan koefisien determinasi (R^2) mencapai 0,91, yang secara signifikan lebih baik dibandingkan model tanpa proses klasterisasi, sehingga membuktikan bahwa integrasi clustering dan ensemble learning efektif dalam meningkatkan akurasi prediksi curah hujan di wilayah dengan karakteristik iklim kompleks (Haq Doost et al., 2025).

Penelitian lain dilakukan oleh Khan dan Maity pada tahun 2020, penelitian ini menggunakan data curah hujan harian hasil simulasi General Circulation Model (GCM) yang telah dibias koreksi dan disesuaikan dengan data observasi lokal. Objek penelitian difokuskan pada prediksi curah hujan harian multi-langkah (multi-step-ahead) pada wilayah studi dengan karakteristik iklim yang kompleks dan fluktuatif. Metode yang digunakan merupakan pendekatan hybrid deep learning yang menggabungkan Conv1D dan Multilayer Perceptron (MLP) untuk memanfaatkan keunggulan pemodelan temporal dan non-linear secara simultan. Hasil penelitian menunjukkan bahwa model hybrid Conv1D–MLP memberikan

performa terbaik dibandingkan model tunggal, dengan nilai RMSE yang meningkat secara bertahap seiring bertambahnya horizon prediksi, sehingga membuktikan efektivitas pendekatan hybrid dalam meningkatkan akurasi prediksi curah hujan harian berbasis data simulasi iklim (M. I. Khan & Maity, 2020).

Penelitian sebelumnya yang ditulis oleh Y. Chen et al., pada tahun 2025, yang mana penelitiannya menggunakan data historis curah hujan, data kejadian longsor dangkal, serta faktor predisposisi seperti kemiringan lereng, litologi, elevasi, dan tutupan lahan yang diperoleh dari basis data geologi dan meteorologi Hong Kong. Objek penelitian difokuskan pada prediksi bahaya longsor dangkal akibat hujan pada wilayah medan alami yang rentan terhadap kejadian ekstrem. Metode yang digunakan melibatkan pendekatan machine learning dan ensemble learning, termasuk Random Forest (RF), Gradient Boosting (GB), dan Support Vector Machine (SVM) untuk memodelkan hubungan kuantitatif antara intensitas hujan dan faktor lingkungan terhadap kejadian longsor. Hasil penelitian menunjukkan bahwa model berbasis ensemble, khususnya Gradient Boosting, memberikan kinerja terbaik dengan nilai Area Under Curve (AUC) sebesar 0,92, akurasi klasifikasi sebesar 88%, serta nilai RMSE sekitar 0,31, yang mengindikasikan kemampuan prediksi bahaya longsor akibat hujan yang tinggi dan stabil dibandingkan model pembanding lainnya (Y. Chen et al., 2025).

Penelitian sebelumnya juga ditulis oleh Xiaobo Zhang dkk. dan dipublikasikan pada tahun 2020 dengan fokus penelitian pada prediksi curah hujan tahunan dan non-monsoon di negara bagian Odisha, India. Objek penelitian ini menggunakan data historis selama 24 tahun (periode 1991 sampai 2015 untuk curah hujan tahunan dan 1960 sampai 2002 untuk data distrik Jagatsinghpur yang mencakup parameter suhu rata-rata, kelembapan relatif, kecepatan angin, dan tutupan awan. Metode yang diterapkan adalah teknik pembelajaran mesin Support Vector Regression (SVR) dengan kernel PUK dan Multilayer Perceptron (MLP). Hasil penelitian menunjukkan bahwa untuk prediksi tahunan, model SVR (PUK) memberikan akurasi yang lebih tinggi dibandingkan MLP dengan nilai koefisien korelasi sebesar 0,9989, Mean Absolute Error (MAE) 0,085, dan Root Mean Squared Error (RMSE) 0,1024; sementara model MLP memperoleh nilai korelasi

0,9913, MAE 0,169, dan RMSE 0,1874 (X. Zhang et al., 2020).

Penelitian lain juga disusun oleh Md. Mehedi Hassan dkk. pada tahun 2023. Penelitian ini bertujuan untuk memprediksi curah hujan di Australia guna meningkatkan kesiapsiagaan terhadap cuaca ekstrem. Objek penelitian ini menggunakan data cuaca historis dari Biro Meteorologi Australia yang mencakup periode sepuluh tahun (1 Desember 2008 hingga 25 Juni 2017) dengan total 145.460 observasi dari 49 stasiun cuaca. Metode yang diterapkan meliputi prapemrosesan data, analisis korelasi, seleksi fitur, serta penggunaan beberapa algoritma pembelajaran mesin seperti Naive Bayes, Decision Tree, Support Vector Machine (SVM), Random Forest, Logistic Regression, dan Artificial Neural Network (ANN). Hasil penelitian menunjukkan bahwa model ANN memberikan performa terbaik dengan nilai akurasi mencapai 90% sebelum seleksi fitur dan meningkat menjadi 91% setelah dilakukan seleksi fitur, dengan nilai precision 90%, serta recall dan F1-score masing-masing sebesar 89% (Hassan et al., 2023).

Penelitian sebelumnya juga dilakukan oleh Omveer Sharma dkk. pada tahun 2023 yang fokus penelitiannya adalah pada peningkatan prediksi kejadian curah hujan lebat (*heavy rainfall events*) di wilayah dengan medan kompleks di Assam, India Timur Laut. Objek penelitian ini menggunakan data simulasi curah hujan harian terakumulasi dari berbagai skema parametritisasi model Weather Research and Forecasting (WRF) serta data pengamatan berbasis satelit-stasiun (GPM-IMERG) selama periode banjir ekstrem Juni 2022 sebagai pembanding. Metode yang diterapkan adalah pendekatan Deep Learning menggunakan arsitektur U-Net untuk memperbaiki luaran model numerik deterministik melalui teknik pengenalan pola spasial. Hasil penelitian menunjukkan bahwa model berbasis U-Net memiliki kinerja yang jauh lebih unggul dalam memprediksi curah hujan yang menunjukkan pengurangan MAE yang luar biasa sebesar 64,78% di seluruh Assam. Selain itu, evaluasi prediksi curah hujan kategorikal menunjukkan bahwa skema WRF berkinerja buruk untuk kategori curah hujan sedang, lebat, sangat lebat, dan ekstrem. Namun, kedua model U-Net yang diusulkan memberikan prediksi curah hujan kategorikal yang lebih akurat, dengan peningkatan signifikan sebesar 38,1% yang diamati dengan mencapai akurasi prediksi 77,9%, khususnya untuk HRE

(Hujan Deras Tinggi) yang secara signifikan mengungguli hasil dari model individu maupun ansambel WRF konvensional (Sharma et al., 2023).

Penelitian yang lain dilakukan oleh Oswalt Manoj S. dan Ananth J.P. pada tahun 2020 yang mana fokus penelitian ini bertujuan untuk meningkatkan akurasi prediksi curah hujan guna mendukung pengambilan keputusan di sektor pertanian. Objek penelitian ini menggunakan data sekunder berupa dataset curah hujan India yang bersumber dari portal data pemerintah (data.gov.in), mencakup parameter meteorologi seperti kelembapan, suhu, dan catatan curah hujan tahun-tahun sebelumnya. Metode yang diusulkan adalah model pembelajaran mendalam berbasis Convolutional Long Short-Term Memory (convLSTM) yang dioptimalkan dengan algoritma Salp-Stochastic Gradient Descent (S-SGD) serta diintegrasikan dengan kerangka kerja MapReduce untuk efisiensi komputasi. Hasil penelitian menunjukkan keunggulan metode usulan dengan pencapaian nilai akurasi sebesar 93,5%, nilai presisi 94,8%, sensitivitas 94,5%, dan spesifisitas 94,1%, yang secara signifikan melampaui kinerja metode pembandingan seperti SVM dan CNN standar (Manoj & Ananth, 2020).

Penelitian yang dilakukan oleh Vinicius Schmidt Monego, Juliana Aparecida Anochi, dan Haroldo Fraga de Campos Velho pada tahun 2022 juga sama bertujuan untuk memprediksi curah hujan namun fokus kepada curah hujan musiman di Amerika Selatan. Objek penelitian ini menggunakan data observasi bulanan dari Global Precipitation Climatology Project (GPCP) dan data reanalisis dari NCEP/NCAR (seperti suhu permukaan laut, tekanan permukaan laut, dan angin zonal) selama periode 1981 hingga 2018. Metode yang digunakan adalah teknik pembelajaran mesin berbasis pohon yaitu Extreme Gradient Boosting (XGBoost) yang dioptimalkan dengan kerangka kerja Optuna berbasis optimasi Bayesian, serta dibandingkan dengan model Deep Learning (Multi-Layer Perceptron) dan model iklim numerik. Hasil penelitian menunjukkan bahwa model XGBoost memberikan kinerja yang lebih unggul dibandingkan model numerik operasional di banyak wilayah, dengan nilai koefisien korelasi rata-rata di atas 0,5 pada sebagian besar wilayah Amerika Selatan dan mencapai nilai puncak hingga 0,8 atau 0,9 di wilayah tertentu seperti Chili Tengah dan Brasil bagian utara, serta mampu mengurangi

tingkat kesalahan prediksi (RMSE) dibandingkan dengan model atmosfer tradisional (Monego et al., 2022).

Penelitian lain yang mengkaji curah hujan juga dilakukan oleh Chongbo Zhao dkk. pada tahun 2026 ini mengkaji fenomena curah hujan ekstrem yang terjadi di wilayah selatan Sungai Yangtze (SYR), China, khususnya selama Juni 2024. Objek penelitian ini berfokus pada diagnosis observasional dan prediksi *dynamical downscaling* terhadap anomali presipitasi tertinggi yang pernah tercatat di sekitar Danau Dongting sejak tahun 1961. Data yang digunakan meliputi data pengamatan curah hujan harian dari 2.400 stasiun di China, data reanalisis ERA5, serta luaran model prediksi musiman Beijing Climate Center Climate System Model (BCC-CSM1.1m). Metode penelitian menggabungkan analisis diagnostik fisik untuk mengidentifikasi pengaruh osilasi intra-musiman dan sistem tekanan tinggi Pasifik Barat dengan teknik *dynamical downscaling* menggunakan model regional WRF (*Weather Research and Forecasting*). Hasil penelitian menunjukkan bahwa curah hujan rata-rata di wilayah SYR pada Juni 2024 mencapai 446,5 mm, yaitu 79,5% lebih tinggi dari rata-rata klimatologis normal, di mana penggunaan metode *dynamical downscaling* berhasil meningkatkan akurasi prediksi spasial dan intensitas curah hujan dibandingkan model global standar, dengan kemampuan menangkap pusat hujan lebat yang mencapai nilai ekstrem di atas 600 mm di beberapa lokasi tertentu (Zhao et al., 2026).

Penelitian lain dilakukan juga oleh Mohammed Diykh dkk. pada tahun 2026 ini bertujuan untuk meminimalkan dampak buruk perubahan iklim melalui prediksi curah hujan bulanan yang lebih akurat. Objek penelitian ini difokuskan pada tiga stasiun cuaca di negara bagian Victoria, Australia, yaitu Bandara Melbourne, Kebun Raya Melbourne, dan Reservoir Preston, dengan menggunakan data historis curah hujan bulanan periode Januari 1960 hingga Desember 2023 yang bersumber dari Bureau of Meteorology (BOM) Australia. Metode yang diusulkan adalah model hibrida ORDWT-ARIMA-LSTM, yang mengintegrasikan teknik dekomposisi Overcomplete Rational Dilation Discrete Wavelet Transform (ORDWT) dengan model linear ARIMA dan model nonlinear LSTM untuk menangkap dinamika data yang kompleks. Hasil penelitian menunjukkan bahwa

model ini mencapai performa terbaik pada stasiun Bandara Melbourne dengan nilai RMSE 2,9, MAE 1,93, Nash-Sutcliffe Index (ENI) 0,970, dan Willmott's Index (WI) 0,990, serta secara keseluruhan mampu mengurangi rata-rata RMSE sebesar 4,5% dan MAE sebesar 5,3% dibandingkan dengan model-model pembandingan lainnya (Diykh et al., 2026).

Penelitian prediksi curah hujan juga disusun oleh Sarmad Dashti Latif dkk. pada tahun 2023 ini mengkaji perkembangan model prediksi curah hujan dengan mengevaluasi keunggulan pendekatan pembelajaran mesin (Machine Learning) dan penginderaan jauh (Remote Sensing). Objek penelitian ini adalah efektivitas berbagai algoritma dalam mengatasi tantangan prediksi curah hujan yang bersifat non-linear dan kompleks di berbagai wilayah secara global. Data yang digunakan dalam studi-studi yang ditelaah mencakup data satelit (seperti TRMM, GPM, dan MODIS), data radar, serta data stasiun cuaca konvensional. Metode yang dievaluasi meliputi algoritma populer seperti Artificial Neural Networks (ANN), Support Vector Machines (SVM), Random Forest (RF), dan model Deep Learning seperti Long Short-Term Memory (LSTM). Hasil tinjauan menunjukkan bahwa integrasi teknik pembelajaran mesin dengan data penginderaan jauh mampu meningkatkan akurasi prediksi secara signifikan dibandingkan model statistik tradisional, di mana beberapa studi yang diulas melaporkan pencapaian nilai akurasi di atas 90%, nilai koefisien korelasi (R) mencapai 0,85 hingga 0,98, serta pengurangan tingkat kesalahan RMSE hingga 20-30% melalui penggunaan model hibrida dan optimasi algoritma (Latif et al., 2023).

Penelitian yang dilakukan oleh Kalpesh R. Patil, Takeshi Doi, J.V. Ratnam, dan Swadhin K. Behera pada tahun 2025 juga mengkaji tentang prediksi curah hujan namun berfokus pada peningkatan akurasi prediksi curah hujan monsun musim panas India dengan waktu tenggang yang panjang. Objek penelitian ini adalah anomali curah hujan di wilayah India selama musim Juni sampai September dengan menggunakan dataset historis berupa suhu permukaan laut dari ERSSTv5 dan data curah hujan bulanan dari *Global Precipitation Climatology Project* (GPCP) periode 1982 sampai 2020, serta data reanalisis atmosfer ERA5. Metode yang diterapkan adalah model *Deep Learning* berbasis *Convolutional Neural*

Networks (CNN) dengan fungsi biaya kustom unik yang dirancang untuk menangkap fase dan tanda peristiwa curah hujan ekstrem secara lebih efektif. Hasil penelitian menunjukkan performa yang sangat baik di mana model mampu memprediksi dengan waktu tenggang hingga 12 bulan dengan nilai *Anomaly Correlation Coefficient* (ACC) melebihi 0,5 pada semua waktu tenggang antara 2 hingga 17 bulan, serta berhasil membedakan tahun-tahun ekstrem (kekeringan atau banjir) secara lebih akurat dibandingkan model dinamis konvensional (Patil et al., 2025).

Tabel 2. 1 Penelitian Terdahulu

Referensi	Data	Input	Output	Metode	Hasil
Appiah-badu et al., (2022)	Data iklim historis <i>Ghana Meteorological Agency</i> (GMet) periode 40 tahun, 1980 hingga 2019.	Suhu Maksimum (Tmax), Suhu Minimum (Tmin), Kelembapan Relatif pada pukul 09.00 (RH09) dan 15.00 (RH15), Kecepatan Angin (Wind speed), dan Penyinaran Matahari (Sunshine)	Hujan (<i>Rain</i>) atau Tidak Hujan (<i>No Rain</i>). (klasifikasi)	<i>Decision Tree</i> (DT), <i>Random Forest</i> (RF), <i>Multilayer Perceptron</i> (MLP), <i>Extreme Gradient Boosting</i> (XGB), <i>K-Nearest Neighbour</i> (KNN)	XGB dengan nilai rata-rata akurasi sebesar 83,16% dan skor F1 sebesar 0,83.
Zoremsan ga & Hussain, (2024)	Data meteorologi harian stasiun Aizawl	Curah hujan hari sebelumnya (Rainfall)	Nilai numerik curah hujan harian	<i>Particle Swarm Optimization</i> (PSO) dengan	RMSE PSO-BiLSTM-ANN II 10,6100,

Referensi	Data	Input	Output	Metode	Hasil
	periode 10 tahun, 2014 hingga 2023	, Suhu Maksimum (Maximum Temperature), Suhu Minimum (Minimum Temperature), Kelembapan Maksimum (Maximum Humidity)	(regresi)	berbagai arsitektur <i>Deep Learning</i>	ANN standar 14,0478, MAE 4,4648 Koefisien Korelasi (R) 0,7506, MAPE 8,9306%
Haq Doost et al., (2025)	Dataset curah hujan bulanan historis yang dikumpulkan dari 8 stasiun meteorologi di seluruh Basin Harirud Murghab selama 13 tahun (2008 hingga 2020)	Dataset curah hujan dari satu bulan sebelumnya (t-1) hingga tiga bulan sebelumnya (t-3) untuk memprediksi curah hujan pada bulan berjalan (t).	Nilai numerik curah hujan bulanan (regresi).	<i>Hybrid</i> yang menggabungkan <i>K-Means Clustering</i> dengan model <i>Machine Learning</i> Support Vector Regression (SVR), Random Forest (RF), dan Extreme Gradient Boosting (XGBoost).	RMSE 1,52. MAE 1,02. R2 0,95.
M. I. Khan & Maity,	Data simulasi	Suhu udara	Prediksi curah	hybrid Conv1D-	RMSE 6,12 mm/hari

Referensi	Data	Input	Output	Metode	Hasil
(2020)	variabel meteorologi yang diperoleh dari <i>General Circulation Model</i> (GCM) dan data observasi curah hujan harian dari stasiun cuaca setempat untuk periode 1971 hingga 2005	permukaan, Suhu udara pada ketinggian 2 meter, Kelembapan spesifik, Tekanan permukaan, Fluks panas laten permukaan, Fluks panas sensibel permukaan, Radiasi gelombang pendek ke bawah, Komponen angin zonal dan meridional.	hujan harian untuk jangka waktu 1 hari hingga 5 hari ke depan (regresi)	MLP	(lebih rendah dibandingkan MLP standar sebesar 7,34 mm/hari). Korelasi (R) 0,83.
Y. Chen et al., (2025)	Data Tanah Longsor: Inventarisasi tanah longsor alami dari Departemen Teknik Sipil dan Pengembangan (CEDD) Hong Kong	Intensitas Curah Hujan Terakumulasi, Curah hujan 7 hari sebelumnya, Intensitas Curah Hujan	Tingkat bahaya tanah longsor kuantitatif yang diklasifikasikan ke dalam 5 level yaitu Sangat Rendah, Rendah,	Model prediksi kuantitatif dengan meningkatkan metode statistik frekuensi empiris melalui integrasi faktor pemicu	Model yang diusulkan mencapai nilai 11,18, yang jauh lebih tinggi dibandingkan metode tradisional (Rainfall-only) yang hanya 3,26.

Referensi	Data	Input	Output	Metode	Hasil
	periode 1992 hingga 2021. Data Curah Hujan: Data dari 110 stasiun pengukur hujan otomatis yang dikelola oleh Observatorium Hong Kong. Data Faktor Predisposisi: DEM (Digital Elevation Model), geologi, dan tutupan lahan.	Maksimum 24 Jam, Suseptibilitas Tanah Longsor	Sedang, Tinggi, dan Sangat Tinggi (klasifikasi).	(curah hujan) dan faktor predisposisi (kerentanan lahan).	
Zhang et al., (2020)	Dataset curah hujan historis bulanan dari tahun 1901 hingga 2002 (102 tahun) yang diperoleh dari portal data Pemerintah India (data.gov.in)	Data lag time curah hujan dari sepuluh tahun sebelumnya untuk memprediksi curah hujan pada tahun berjalan.	Nilai numerik curah hujan tahunan dan curah hujan non-monsoon dalam satuan milimeter (regresi)	Model hybrid yang menggabungkan dua algoritma Support Vector Regression (SVR) dan Multi-Layer Perceptron (MLP).	RMSE SVR-MLP 0,034, SVR 0,211, MLP 0,223. MAE 0,028. MAPE 0,042%. Koefisien Korelasi (R) Mencapai 0,98
Hassan et	Dataset	Suhu	RainTomo	Logistic	Random

Referensi	Data	Input	Output	Metode	Hasil
al., (2023)	dikumpulkan dari portal data terbuka Kaggle yang mencakup rekaman cuaca harian dari tahun 2008 hingga 2017	Minimum dan Maksimum, Curah Hujan hari ini, Penguapan dan Sinar Matahari, Arah dan Kecepatan Angin, Kelembapan, Tekanan Atmosfer, Tutupan Awan	rror: Yes dan No (klasifikasi).	Regression dan Random Forest.	Forest 85,18%. Logistic Regression 84%.
Sharma et al., (2023)	Data simulasi curah hujan harian dari model Weather Research and Forecasting (WRF) dengan berbagai skema parametrisasi fisik. Data observasi curah hujan dari stasiun darat dan satelit (IMD-NCMRWF) sebagai acuan	Hasil output curah hujan akumulasi harian dari 10 skema parametrisasi fisik model WRF yang berbeda (seperti skema mikrofisika WSM6, Thompson, dll.)	Prediksi curah hujan spasial yang telah dikoreksi biasanya pada skala distrik	Deep Learning U-Net.	Koefisien Korelasi (CC) 0,83

Referensi	Data	Input	Output	Metode	Hasil
	kebenaran (ground truth). Fokus studi kasus pada kejadian banjir besar di bulan Juni 2022.				
Manoj & Ananth, (2020)	Dataset curah hujan historis yang diperoleh dari portal resmi pemerintah India (data.gov.in)	Kelembapan, Catatan curah hujan tahunan sebelumnya, Pola spasial-temporal dari wilayah yang diamati.	Prediksi nilai curah hujan yang akan datang (regresi)	Convolutional Long Short-Term Memory (ConvLSTM), Salp-Stochastic Gradient Descent (S-SGD), MapReduce	RMSE 12,50 (lebih baik dibandingkan model lain yang memiliki RMSE di atas 15,0). MAE 10,23. MSE 156,25.
Monego et al., (2022)	Data target (observasi): Dataset CPTEC/INPE (kombinasi data stasiun cuaca dan satelit) periode 1982 hingga 2021. Data fitur: Reanalisis dari NCEP/NCAR (National	Suhu Permukaan Laut, Suhu Udara, Geopotensial Height (pada level 500 hPa), Komponen angin zonal (u-wind) dan meridional (v-wind) pada level 850 hPa, Kelemba	Prediksi akumulasi curah hujan musiman (tiga bulanan) di seluruh grid wilayah Amerika Selatan	Gradient Boosting Regression Trees, XGBoost, Optuna framework	Koefisien Korelasi (R): Nilai korelasi model XGBoost mencapai rentang 0,4 hingga 0,8 tergantung pada lokasi geografis dan musimnya

Referensi	Data	Input	Output	Metode	Hasil
	Centers for Environmental Prediction/ National Center for Atmospheric Research).	pan Spesifik			
Zhao et al., (2026)	Data observasi harian dari 2.417 stasiun cuaca di China (CN05.1). Data reanalisis atmosfer dari ERA5 (ECMWF) untuk analisis sirkulasi. Data prediksi musiman dari sistem BCC-CSM2-HR.	Anomali sirkulasi atmosfer (tinggi geopotensial pada 500 hPa). Transportasi uap air (kelembapan spesifik dan fluks uap air). Indeks Suhu Permukaan Laut (SST) di Samudra Hindia dan Pasifik. Kondisi kelembapan tanah.	Hasil prediksi downscaling curah hujan harian dan akumulasi bulanan serta identifikasi mekanisme fisik penyebab hujan ekstrem	Analisis Diagnosis: Mengidentifikasi penyebab fisik (seperti efek "kapasitor" Samudra Hindia dan pergeseran South Asian High). Dynamical Downscaling Prediction: Menggunakan model regional RegCM4.4 yang didorong oleh data dari model iklim global (BCC-CSM2-HR) untuk meningkatkan resolusi spasial prediksi.	Curah Hujan Teramati: Wilayah SYR mencatat curah hujan sebesar 450,9 mm pada Juni 2024 (tertinggi sejak 1961). Koefisien Korelasi Spasial (PCC): Model downscaling (RegCM) menunjukkan peningkatan PCC menjadi 0,38 dibandingkan model global (BCC) yang hanya 0,11. Root Mean Square Error

Referensi	Data	Input	Output	Metode	Hasil
					(RMSE): Prediksi downscaling berhasil menurunkan nilai RMSE sebesar 22% dibandingkan dengan model global dalam mensimulasikan distribusi curah hujan di wilayah yang terkena dampak. Skor Skill (SS): Menunjukkan peningkatan kemampuan prediksi sebesar 15-20% untuk kejadian hujan lebat di atas ambang batas ekstrem.
Diykh et al., (2026)	Dataset curah hujan bulanan historis dari dua lokasi di Australia,	Data deret waktu (time-series) curah hujan masa lalu.	Prediksi nilai curah hujan bulanan untuk jangka waktu yang	Overcomplete Rational Dilation Wavelet Transform (ORDWT): Teknik	RMSE mencapai nilai 11,81 (lebih rendah dibandingkan model

Referensi	Data	Input	Output	Metode	Hasil
	yaitu Brisbane dan Melbourne, yang mencakup periode waktu sangat panjang dari tahun 1900 hingga 2024	Penelitian ini menggunakan teknik dekomposisi untuk memecah data asli menjadi beberapa sub-sinyal guna menangkap pola musiman dan tren yang tersembunyi.	akan datang	dekomposisi sinyal canggih untuk mengekstrak fitur relevan dari data yang bergejolak (noisy). Bidirectional Long Short-Term Memory (BiLSTM): Jaringan saraf dalam yang mampu mempelajari ketergantungan data dari dua arah (masa lalu ke masa depan dan sebaliknya). Metode Pemilihan Fitur: Digunakan untuk memilih sub-sinyal yang paling berpengaruh guna meningkatkan efisiensi komputasi.	BiLSTM standar yang mencapai 36,44). MAE Mencapai nilai 8,41. Koefisien Korelasi (R) Mencapai nilai yang sangat tinggi, yaitu 0,984, menunjukkan akurasi prediksi yang hampir sempurna. NSE Mencapai nilai 0,967, yang mengindikasikan bahwa model ini sangat efisien dan andal dalam memprediksi variabilitas curah hujan.
Latif et al.,	Data Satelit	Suhu	Estimasi	Penelitian	Koefisien

Referensi	Data	Input	Output	Metode	Hasil
(2023)	(Remote Sensing): Seperti TRMM (Tropical Rainfall Measuring Mission), GPM (Global Precipitation Measurement), dan MODIS. Data Stasiun Cuaca: Data historis dari alat penakar hujan di darat. Data Radar: Untuk estimasi curah hujan resolusi tinggi.	udara (maksimum, minimum, rata-rata). Kelembapan relatif. Kecepatan angin dan radiasi matahari. Indeks vegetasi (seperti NDVI) dan data brightness temperature dari satelit.	atau prediksi nilai curah hujan (harian, bulanan, atau musiman) serta klasifikasi kejadian hujan	ini mengulas berbagai algoritma diantaranya : Machine Learning (ML): Artificial Neural Networks (ANN), Support Vector Machines (SVM), dan Random Forest (RF). Deep Learning (DL): Long Short-Term Memory (LSTM) dan Convolutional Neural Networks (CNN). Hybrid Models: Kombinasi model fisik/statistik dengan algoritma ML untuk meningkatkan akurasi.	Korelasi (R): Banyak studi melaporkan nilai R mencapai 0,85 hingga 0,98, yang menunjukkan hubungan sangat kuat antara data satelit yang diproses ML dengan data observasi lapangan. Akurasi: Pendekatan ML dan penginderaan jauh mampu mencapai tingkat akurasi di atas 90% dalam klasifikasi kejadian hujan. RMSE (Root Mean Square Error): Penggunaan model hibrida dan teknik optimasi meta-

Referensi	Data	Input	Output	Metode	Hasil
					heuristik dilaporkan mampu menurunkan nilai RMSE sebesar 20-30% dibandingkan dengan model statistik konvensional atau model satelit standar tanpa koreksi ML.
Patil et al., (2025)	Data curah hujan bulanan dari Global Precipitation Climatology Project (GPCP) periode 1982–2020. Data Sea Surface Temperature (SST) dari Extended Reconstructed Sea Surface Temperature versi 5 (ERSSTv5).	Anomali suhu permukaan laut (SST) global dan anomali curah hujan global pada bulan-bulan sebelum periode target (JJAS - Juni hingga September) digunakan sebagai prediktor utama	Prediksi anomali curah hujan monsun musim panas India (Indian Summer Monsoon Rainfall - ISMR) untuk musim Juni-September (JJAS).	Deep Learning berbasis Convolutional Neural Networks (CNN). Inovasi utamanya adalah penggunaan fungsi biaya kustom (custom cost function) yang dirancang khusus untuk meminimalkan kesalahan pada tanda (positif/negatif) dan	Anomaly Correlation Coefficient (ACC): nilai ACC melebihi 0,5 untuk semua waktu tenggang (lead time) mulai dari 2 hingga 17 bulan. Prediksi Jangka Panjang: Pada lead time 12 bulan, model tetap mempertahankan akurasi yang

Referensi	Data	Input	Output	Metode	Hasil
	Data reanalisis atmosfer ERA5 dari ECMWF untuk variabel kontrol			fase anomali curah hujan, sehingga lebih sensitif terhadap kejadian ekstrem (banjir atau kekeringan) .	signifikan dibandingkan model dinamis tradisional. Kinerja Ekstrem: Model berhasil menangkap anomali negatif yang kuat pada tahun-tahun kekeringan ekstrem (seperti 2002 dan 2009) dan anomali positif pada tahun banjir (seperti 1994 dan 2019) dengan kesalahan fase yang minimal. Korelasi di Daratan India: Koefisien korelasi spasial di sebagian besar wilayah daratan India menunjukkan nilai

Referensi	Data	Input	Output	Metode	Hasil
					yang stabil di atas 0,4 hingga 0,6.
(Kumar et al., 2023)	(Delhi) daily rainfall data from 1980 to 2021 from India's Water Resources Information System (WRIS)	Lag 1 sampai lag 7	Prediksi curah hujan harian dan mingguan.	CatBoost, XGBoost, Lasso, Ridge, Linear Regression, dan LGBM	MAE 0.00077, RMSE 0.0010, RMSPE 0.49, R2 0.99
(Barrera-Animas et al., 2022)	OpenWeather dari lima kota besar di Inggris (Bath, Bristol, Cardiff, Newport, dan Swindon) untuk periode 1 Januari 2000 hingga 21 April 2020	Vektor fitur 11 dimensi yang mencakup data cuaca (seperti suhu, tekanan, kelembapan, kecepatan angin, tutupan awan, serta volume hujan/salju 1 jam dan 3 jam terakhir)	Prediksi volume curah hujan per jam untuk 8 jam ke depan	LSTM, S-LSTM, Bi-LSTM, XGBoost, Gradient Boosting Regressor, Linear Support Vector Regression, and an Extra-trees Regressor	Loss mencapai 0.0014–0.0001, RMSE mencapai 0.0377–0.0099, MAE mencapai 0.0072–0.0015, dan RMSLE mencapai 0.0111–0.0044.
(Alvines et al., 2025)	BMKG tahun 2024 Sumatera Selatan	Fitur cuaca BMKG suhu, kelembapan dan sebagainya.	Prediksi curah hujan	Linear Regression, Ridge Regression, Lasso Regression, Random Forest, dan	RMSE 14.62, R2 - 0.62

Referensi	Data	Input	Output	Metode	Hasil
				Gradient Boosting	
(Usman et al., 2023)	Data BMKG Semarang 1 Januari 2018 – 20 Maret 2021	Fitur cuaca BMKG suhu, kelembapan dan sebagainya.	Prediksi curah hujan	MLR, Random Forest, ANN	RMSE 13.055, MAE 6.621

2.2 Prediksi Hujan

Prediksi curah hujan adalah bidang meteorologi yang kompleks yang melibatkan berbagai metodologi dan teknologi untuk memperkirakan curah hujan. Tujuan utama prediksi curah hujan adalah untuk menghasilkan perkiraan curah hujan yang akurat guna mengurangi dampak buruk, seperti banjir dan tanah longsor, yang dapat timbul akibat peristiwa cuaca ekstrem. Sintesis ini mengeksplorasi teori-teori mendasar di balik prediksi curah hujan, membahas berbagai sumber data, metodologi, dan tantangan dalam bidang ini.

Prediksi curah hujan sangat bergantung pada kombinasi sistem pengukuran berbasis darat dan teknologi penginderaan jauh. Sistem berbasis darat, terutama alat pengukur curah hujan, memberikan pengukuran intensitas curah hujan lokal yang akurat dan sangat berharga untuk mengkalibrasi dan memvalidasi data penginderaan jauh, seperti pengamatan radar dan satelit (Ho et al., 2024)(Chang et al., 2014)(Tondang et al., 2023). Namun, variabilitas spasial dan temporal curah hujan seringkali mengakibatkan cakupan yang tidak memadai jika hanya menggunakan pengukuran berbasis darat, terutama di wilayah di mana jaringan alat pengukur curah hujan jarang (Rodriguez-Ramirez & Fuentes-Mariles, 2023)(Weir & Dahlhaus, 2024).

Penginderaan jauh menawarkan keuntungan dalam menangkap pola curah hujan skala besar melalui berbagai teknologi seperti radar cuaca dan satelit. Data radar dapat menangkap peristiwa curah hujan pada resolusi halus, sementara pengamatan satelit memberikan cakupan spasial yang lebih luas. Mengintegrasikan

sumber data ini melalui teknik asimilasi data dapat meningkatkan akurasi prediksi secara keseluruhan dengan mengkompensasi keterbatasan sistem individual (Michaelides et al., 2020) (Michaelides et al., 2020). Misalnya, metode asimilasi variasional empat dimensi berbasis Proper Orthogonal Decomposition (POD) menggabungkan pengamatan satelit dan radar untuk meningkatkan peramalan curah hujan secara substansial (Wang et al., 2020).

Teknik-teknik baru dalam estimasi curah hujan mencakup penggunaan model pembelajaran mendalam hibrida yang menggabungkan data dari platform darat dan satelit untuk meningkatkan prediksi curah hujan di berbagai skala (H. Chen et al., 2019). Selain itu, teknik-teknik seperti asimilasi data variasional tiga dimensi telah digunakan untuk mensintesis informasi dari beragam platform penginderaan jauh, sehingga mengatasi kompleksitas pemodelan curah hujan dalam kerangka kerja prediksi cuaca numerik (Yin et al., 2021).

Quantitative Precipitation Forecasting (QPF) merupakan inti dari prediksi hujan modern, yang berfokus pada estimasi jumlah dan waktu terjadinya curah hujan (Michaelides et al., 2020). Proses ini secara inheren menantang karena beragam mekanisme yang mendorong curah hujan dan kondisi atmosfer lokal. Metode saat ini menggabungkan model NWP canggih yang mensimulasikan proses dan dinamika atmosfer, memanfaatkan asimilasi data radar untuk meningkatkan kondisi awal dalam model (Hastuti et al., 2023).

Kemajuan terbaru telah menekankan pentingnya mengasimilasi berbagai jenis data, termasuk data radar Doppler, yang menyediakan medan angin tiga dimensi, sehingga meningkatkan estimasi curah hujan. Metode ini membantu mengoreksi bias inheren dalam pengukuran curah hujan radar, yang dapat dipengaruhi oleh faktor-faktor seperti medan dan kondisi atmosfer (Ho et al., 2024) (Hastuti et al., 2023).

Metodologi statistik juga memainkan peran penting dalam prediksi hujan. Teknik seperti menggabungkan produk curah hujan yang diperoleh dari satelit dengan masukan meteorologi telah menunjukkan peningkatan akurasi dalam peramalan jangka pendek (Liu et al., 2017). Selain itu, pendekatan pembelajaran mesin, seperti jaringan neuro-fuzzy, telah dieksplorasi untuk lebih meningkatkan

kemampuan prediksi hujan dengan mengintegrasikan berbagai sumber data dan ketidakpastiannya (de Goncalves et al., 2006).

Meskipun telah ada kemajuan, tantangan tetap ada dalam prediksi hujan. Heterogenitas temporal curah hujan menciptakan ketidakpastian yang melekat; oleh karena itu, pendekatan peramalan probabilistik telah mendapatkan perhatian untuk mengukur ketidakpastian ini dan meningkatkan proses pengambilan keputusan. Misalnya, penggabungan pengamatan radar dan satelit dapat menyebabkan perkiraan curah hujan yang berlebihan jika tidak dikalibrasi dengan tepat, menunjukkan perlunya penyempurnaan berkelanjutan dalam prosedur asimilasi data (Diodato & Ceccarelli, 2009).

Selain itu, resolusi model berdampak pada simulasi akurat peristiwa konvektif yang terkait dengan curah hujan lebat. Model harus menyeimbangkan kebutuhan akan resolusi spasial tinggi untuk menangkap dinamika badai sambil mengelola sumber daya komputasi secara efektif (Xu et al., 2018).

Teori dasar prediksi hujan mencakup beragam metodologi dan kemajuan teknologi yang bertujuan untuk meningkatkan akurasi prakiraan curah hujan. Dengan mengintegrasikan berbagai sumber data melalui teknik asimilasi yang canggih dan menyempurnakan metode komputasi, para ahli meteorologi dapat meningkatkan kemampuan prediksi. Meskipun demikian, mengatasi ketidakpastian dan tantangan intrinsik dalam sistem ini tetap menjadi fokus penting bagi penelitian yang sedang berlangsung di bidang meteorologi.

2.3 Gradient Boosting

Gradient boosting adalah teknik pembelajaran ensemble yang ampuh, terutama digunakan untuk tugas regresi dan klasifikasi dalam pembelajaran mesin (Syukur et al., 2026). Konsep dasarnya adalah kombinasi berurutan dari model prediktif sederhana, seringkali berupa pohon keputusan, untuk menghasilkan model keseluruhan yang lebih akurat dan kuat. Sintesis ini akan merinci prinsip-prinsip teoretis di balik gradient boosting, metodologi, dan aplikasinya, menggunakan referensi dari literatur utama.

Pada intinya, gradient boosting adalah metode pembelajaran ensemble yang

menggabungkan beberapa pembelajar lemah untuk membentuk pembelajar kuat. Pembelajar lemah biasanya berupa pohon keputusan yang dilatih pada berbagai subset data, masing-masing berfokus pada pola yang terlewatkan oleh pohon sebelumnya. Tujuannya adalah untuk meminimalkan tingkat kesalahan keseluruhan dengan memperbaiki prediksi secara iteratif. Menurut Friedman Svetnik dkk. (2005), teknik ini membangun model secara bertahap, di mana setiap model baru mencoba untuk memperbaiki kesalahan model sebelumnya (Svetnik et al., 2005).

Proses boosting terkait erat dengan optimasi fungsi kerugian tertentu. Dalam gradient boosting, setiap pohon disesuaikan dengan gradien negatif dari fungsi kerugian sehubungan dengan prediksi yang dibuat oleh ensemble pada titik tersebut. Prinsip ini memfasilitasi hubungan antara gradient boosting dan optimasi gradient descent. Pada dasarnya, setiap pembelajar baru ditambahkan berdasarkan seberapa baik ia dapat mengurangi kesalahan residual dari ensemble yang ada (Z. Zhang et al., 2025)(Mayr et al., 2014). Proses ini berlanjut hingga sejumlah pohon tertentu ditambahkan, atau peningkatan lebih lanjut menjadi yang terbaik.

Alur *Gradient Boosting* yang pertama adalah Inisialisasi yaitu proses dimulai dengan menginisialisasi prediksi dengan nilai konstan, seringkali rata-rata nilai target dalam masalah regresi. Selanjutnya adalah *iterative learning* untuk setiap iterasi (m):

1. Hitung kesalahan residual (perbedaan antara nilai yang diamati dan nilai yang diprediksi).
2. Sesuaikan pohon keputusan baru dengan residual ini, secara efektif belajar dari kesalahan ensemble.
3. Perbarui prediksi dengan menambahkan prediksi pohon baru yang diskalakan oleh *learning rate* (η).
4. *Learning rate* mengontrol seberapa besar kontribusi yang ditambahkan setiap pohon baru ke model keseluruhan, mencegah overfitting (Gill et al., 2020)(Guldogan et al., 2023).

Gradient boosting mencakup berbagai bentuk regularisasi untuk meningkatkan kekokohan model dan mencegah overfitting. Teknik seperti membatasi kedalaman pohon dan menggunakan subsampling (melatih pohon pada

subset data acak) membantu mempertahankan generalisasi (Zharova et al., 2024)(Shrivastav & Kumar, 2021). Selain itu, metode seperti stochastic gradient boosting menambahkan keacakan pada proses pelatihan, yang selanjutnya meningkatkan kinerja pada dataset yang kompleks.

Dari sudut pandang matematika, pendekatan gradient boosting dapat dilihat melalui lensa optimasi cembung. Sebagian besar algoritma boosting bertujuan untuk meminimalkan fungsi kerugian cembung dengan secara iteratif mendekati gradien negatif, sehingga bergerak menuju solusi optimal melalui kombinasi model sederhana. Perspektif ini memungkinkan gradient boosting untuk mempertahankan fondasi teoritis yang kuat dalam kerangka kerja pembelajaran statistik (Lu & Mazumder, 2020).

Beberapa varian gradient boosting populer telah muncul, dan masing-masing dirancang untuk pengaplikasian yang spesifik:

1. Extreme Gradient Boosting (XGBoost): Varian ini memperkenalkan peningkatan seperti pemrosesan paralel dan istilah regularisasi komprehensif, menghasilkan pelatihan yang lebih cepat dan kinerja yang lebih baik pada dataset besar(Guo et al., 2023)
2. LightGBM: Dioptimalkan untuk kecepatan dan efisiensi, LightGBM menggunakan pembelajaran berbasis histogram dan pertumbuhan pohon leaf-wise untuk meningkatkan manajemen sumber daya komputasi (Li et al., 2025).
3. CatBoost: Dirancang khusus untuk menangani variabel kategorikal secara efektif tanpa pra-pemrosesan yang ekstensif, CatBoost memanfaatkan boosting terurut untuk mengurangi overfitting dan meningkatkan akurasi prediksi (Syukur et al., 2025) (Lu & Mazumder, 2020).

Gradient boosting telah banyak diadopsi karena efisiensi dan efektivitasnya di berbagai bidang, termasuk keuangan, perawatan kesehatan, dan ilmu lingkungan. Misalnya, dalam memprediksi krisis perusahaan, Riccio dkk. (2024) menerapkan gradient boosting untuk mendapatkan penilaian risiko berdasarkan berbagai fitur. Demikian pula, Zhang dkk. (2025) menggunakan gradient boosting untuk prediksi dan penilaian medis, yang menunjukkan fleksibilitas dan kekuatannya di berbagai

domain (Riccio et al., 2025) (Z. Zhang et al., 2025). Gradient boosting mewakili evolusi canggih dalam seni pembelajaran mesin, yang berfokus pada transformasi pembelajar yang lemah menjadi model prediktif yang kuat melalui penyempurnaan iteratif dan optimasi berbasis gradien. Fleksibilitasnya dalam aplikasi, dikombinasikan dengan penelitian berkelanjutan yang mengarah pada peningkatan variasi, memperkuat perannya sebagai landasan dalam metodologi pembelajaran ensemble.

2.4 Kerangka Teori

Dalam melakukan penelitian mengenai prediksi cuaca perlu mengacu pada artikel-artikel jurnal sebelumnya yang sudah dilakukan oleh peneliti sebagai acuan dan kerangka teori yang kemudian dianalisis dan kemudian mencoba beberapa metode yang telah dilakukan peneliti sebelumnya untuk penelitian yang akan dilakukan ini. Berdasarkan penelitian sebelumnya data inputannya adalah data cuaca yang terdiri dari suhu, kelembaban, arah angin, tekanan udara, dan kondisi cuaca lainnya, metode yang digunakan pada masing masing jurnal berbeda dan outputnya adalah prediksi cuaca. Penelitian mengenai prediksi cuaca dan estimasi evapotranspirasi telah dilakukan oleh berbagai peneliti dengan pendekatan dan metode yang beragam, baik dari segi jenis data masukan, proses pengolahan, hingga hasil yang diperoleh.

Zhang et al. (2021) dalam penelitiannya memanfaatkan data historis cuaca per jam dari sepuluh kota di sekitar Nashville, Tennessee. Data ini meliputi parameter seperti suhu, kelembaban, arah angin, tekanan udara, dan kondisi cuaca lainnya yang awalnya dalam format JSON kemudian dikonversi menjadi format teks serupa CSV. Setelah melalui proses praproses berupa eliminasi data tidak lengkap, one-hot encoding untuk data kategorikal, serta normalisasi menggunakan mean scaling, dilakukan pemodelan menggunakan beberapa algoritma regresi seperti Random Forest Regressor (RFR), Extra-Tree Regressor (ETR), Support Vector Regressor (SVR), Ridge Regression, dan Multi-layer Perceptron Regressor (MLPR). Evaluasi dilakukan menggunakan Root Mean Squared Error (RMSE), di

mana RFR dan ETR menunjukkan kinerja terbaik dengan RMSE sebesar 3.0. Model ini dapat diimplementasikan pada perangkat dengan daya komputasi rendah.

Studi literatur oleh Thilagavathi et al. (2019) yang menyajikan berbagai pendekatan big data untuk prediksi cuaca. Input yang digunakan berupa data historis yang dikumpulkan dari berbagai sumber, termasuk suhu, kelembaban, curah hujan, dan kecepatan angin. Proses pengolahan dilakukan dengan algoritma seperti regresi, neural networks, support vector machine, random forest, serta platform big data seperti MapReduce. Output dari penelitian ini berupa prediksi berbagai variabel cuaca baik dalam skala harian, musiman, hingga tahunan, yang bermanfaat dalam berbagai sektor seperti pertanian dan mitigasi bencana .

Dalam penelitian oleh Houtekamer dan Zhang (2016) menggunakan data observasi dari berbagai sumber seperti satelit, stasiun cuaca, dan balon udara. Data ini dikombinasikan dengan simulasi numerik atmosfer menggunakan metode Ensemble Kalman Filter (EnKF) untuk memperoleh estimasi terbaik dari kondisi atmosfer terkini. Proses ini dikenal dengan istilah data assimilation (DA). Hasil akhirnya berupa prediksi cuaca yang lebih akurat karena mempertimbangkan gabungan antara observasi nyata dan hasil simulasi.

Wu et al. (2022) dalam penelitiannya menggunakan data prediksi cuaca numerik dari China Meteorological Data Network dan prediksi cuaca publik dari Weather China. Data ini diolah menggunakan metode interpolasi inverse distance weighted (IDW), lalu digunakan untuk menghitung evapotranspirasi referensi harian (ET_0) dengan rumus FAO-56 Penman-Monteith. Output berupa prediksi ET_0 harian yang divalidasi terhadap pengamatan aktual.

Studi lain oleh Mahringer dan Müller (2022) menggunakan data penjualan harian dari 673 toko fisik dan data cuaca dari Deutscher Wetterdienst (DWD). Model yang digunakan adalah regresi dengan koefisien acak untuk menangkap pengaruh non-linear dan musiman dari cuaca terhadap penjualan. Output dari penelitian ini menunjukkan bagaimana cuaca dapat memengaruhi penjualan, serta bagaimana prediksi cuaca dapat meningkatkan akurasi prediksi penjualan.

Dey dan Zubair (2015) dalam penelitiannya memanfaatkan output model Numerical Weather Prediction (NWP) dan data historis untuk menghasilkan

prediksi probabilitas curah hujan kuantitatif. Model Output Statistics (MOS) digunakan dengan pendekatan regresi linier majemuk, dan hasil akhirnya berupa prediksi curah hujan kategori berdasarkan ambang batas tertentu.

Zhang et al. (2019) mengembangkan metode analitik untuk mengubah pesan prediksi cuaca harian menjadi input yang dapat digunakan dalam rumus FAO Penman-Monteith. Penelitian ini mengestimasi evapotranspirasi referensi harian (ET_0) dan membandingkannya dengan hasil perhitungan dari data lengkap. Estimasi dilakukan menggunakan parameter suhu, kondisi berawan, dan kecepatan angin.


Xie et al. (2020) mengevaluasi enam model machine learning untuk memprediksi ET_0 harian menggunakan data meteorologi dari delapan stasiun cuaca di China. Model yang digunakan antara lain Random Forest, M5 Model Tree, Gradient Boosting Decision Tree, Extreme Gradient Boosting, Support Vector Machine, dan Extreme Learning Machine. Penelitian ini menilai akurasi dan stabilitas model dalam berbagai kondisi iklim dengan validasi silang K-fold.

Selanjutnya, Wang et al. (2020) menggunakan Light Gradient Boosting Machine (LightGBM) untuk estimasi ET_0 harian berdasarkan data dari 49 stasiun cuaca di China. Model ini dibandingkan dengan beberapa model ensemble dan model empiris seperti Hargreaves-Samani dan Makkink. Evaluasi dilakukan terhadap performa model baik pada data lokal maupun antar-stasiun.

Terakhir, penelitian oleh Li et al. (2021) mengevaluasi algoritma CatBoost untuk estimasi ET_0 di wilayah lembab China. Data yang digunakan berasal dari lima stasiun cuaca, dan model CatBoost dibandingkan dengan Random Forest dan SVM. Evaluasi dilakukan terhadap akurasi, stabilitas, dan efisiensi komputasi model.

Berdasarkan studi-studi di atas, dapat disimpulkan bahwa kombinasi antara data cuaca historis, algoritma machine learning yang tepat, serta strategi praproses dan evaluasi yang sistematis merupakan kunci dalam meningkatkan akurasi prediksi cuaca maupun estimasi evapotranspirasi. Sehingga dapat dianalisis pada bagian selanjutnya yang membahas teori pendukung atau penelitian terdahulu dapat dijadikan sebagai referensi terkait prediksi cuaca berdasarkan data cuaca untuk menentukan parameter dan variabel sebagai data masukan dan menyelidiki penggunaan beberapa pendekatan model yang digunakan sebagai acuan dari

keluaran kerangka teori. Kerangka teoritis untuk prediksi cuaca diberikan pada Gambar 2.1.



Gambar 2. 1 Kerangka Teori

Sebagian besar studi prediksi cuaca dan curah hujan masih didominasi oleh model prediksi cuaca numerik (NWP) dan teknik statistik tradisional, yang memiliki kesulitan dalam menangkap pola nonlinier dan variabilitas lokal, terutama di wilayah tropis, menurut tinjauan penelitian sebelumnya. Meskipun sebagian besar studi telah berkonsentrasi pada lokasi non-tropis, data lintas negara, atau karakteristik meteorologi selain curah hujan harian, penelitian berbasis pembelajaran mesin telah menunjukkan potensi peningkatan akurasi. Selain itu, masih terdapat kekurangan penelitian yang secara khusus menilai kinerja Gradient Boosting pada data cuaca harian BMKG dengan resolusi lokal di Indonesia. Hal ini terutama berlaku untuk studi yang melihat dampak penyetelan parameter, skenario pembagian data pelatihan dan pengujian, serta kemampuan generalisasi model. Untuk memenuhi kesulitan unik iklim tropis Indonesia, kesenjangan ini menyoroti

perlunya penelitian yang secara metodis mengoptimalkan dan menilai Gradient Boosting untuk prediksi curah hujan harian berdasarkan data BMKG.

Implementasi dan penilaian pendekatan Gradient Boosting untuk prediksi curah hujan harian berdasarkan data historis BMKG dengan resolusi lokal di Indonesia khususnya Kabupaten Malang, beserta strategi optimasi parameter yang memanfaatkan RandomSearchCV dan beberapa skenario pembagian data, merupakan kebaruan dari penelitian ini. Penelitian ini menekankan strategi berbasis data yang adaptif terhadap kondisi iklim tropis, berbeda dengan penelitian sebelumnya yang biasanya berfokus pada model numerik atau dataset global. Selain itu, dengan menyajikan prediksi hujan sebagai jenis usaha ilmiah berdasarkan data empiris tanpa mempersoalkan prinsip keterbatasan pengetahuan manusia sebagaimana ditekankan dalam Surah Luqman ayat 34, penelitian ini menghadirkan integrasi perspektif ilmiah dan nilai-nilai Islam. Hasilnya, penelitian ini menawarkan kontribusi konseptual yang unik bagi studi rekayasa informatika berdasarkan integrasi ilmu pengetahuan dan Islam.

Metode ensemble dengan strategi Gradient Boosting, yang secara bertahap membangun model prediktif dengan meminimalkan fungsi kerugian yang memanfaatkan arah negatif gradien, merupakan dasar dari penelitian ini. Secara teori, gradient boosting sangat baik dalam mensimulasikan interaksi yang rumit dan korelasi non-linear antara variabel meteorologi, termasuk suhu, kelembaban, tekanan udara, dan kecepatan angin. Gagasan trade-off bias-varians, yang menyatakan bahwa menggabungkan beberapa pembelajar lemah menghasilkan model yang lebih andal dan akurat, memperkuat gagasan ini. Strategi ini mendukung posisi Gradient Boosting sebagai teknik yang relevan dan secara teoritis tepat untuk prediksi cuaca harian berbasis data empiris, sekaligus konsisten dengan teori pemodelan data atmosfer, yang menyoroti pentingnya belajar dari pola masa lalu untuk memperkirakan kondisi masa depan dalam konteks prediksi curah hujan.

BAB III

METODOLOGI PENELITIAN

3.1 Deskripsi dan Karakteristik Data

Penelitian ini menggunakan data cuaca harian yang diperoleh dari hasil pengamatan stasiun klimatologi BMKG selama periode 1 Januari 2023 hingga 15 Juli 2025. Data tersebut mencakup berbagai parameter meteorologi yang memengaruhi kondisi cuaca harian, terutama curah hujan. Setiap baris data mewakili satu hari pengamatan dengan sebelas atribut utama, yaitu Tanggal, Temperatur Minimum (TN), Temperatur Maksimum (TX), Temperatur Rata-rata (TAVG), Kelembapan Rata-rata (RH_AVG), Curah Hujan (RR), Lamanya Penyinaran Matahari (SS), Kecepatan Angin Maksimum (FF_X), Kecepatan Angin Rata-rata (FF_AVG), Arah Angin saat Kecepatan Maksimum (DDD_X, Arah Angin Terbanyak (DDD_CAR).

Kolom tanggal merepresentasikan waktu pencatatan data harian yang digunakan untuk melihat pola musiman atau tren waktu. Suhu maksimum (TX), minimum (TN), dan rata-rata (TAVG) diukur dalam derajat Celsius dan menggambarkan dinamika fluktuasi temperatur harian. Kelembapan relatif (RH_AVG) dinyatakan dalam persentase (%), menunjukkan kadar uap air di atmosfer yang berpengaruh langsung terhadap potensi terjadinya hujan. Curah hujan (RR) diukur dalam milimeter (mm) dan menjadi variabel target utama yang akan diprediksi. Sementara itu, lama penyinaran matahari (SS) diukur dalam jam untuk menunjukkan intensitas energi matahari yang diterima permukaan bumi setiap hari. Kecepatan angin maksimum (FF_X) dan kecepatan angin rata-rata (FF_AVG) dinyatakan dalam meter per detik (m/s), sedangkan arah angin saat kecepatan angin maksimum (DDD_X) direpresentasikan dalam derajat (0° – 360°) dan arah angin terbanyak (DDD_CAR) direpresentasikan dengan kode arah mata angin seperti N, E, S, W yang membantu mengidentifikasi pergerakan massa udara penyebab perubahan cuaca.

Atribut tanggal digunakan untuk merepresentasikan waktu pengamatan harian dan menjadi dasar analisis tren temporal. Dari distribusi tanggal terlihat

bahwa data mencakup seluruh periode tanpa adanya celah pengamatan, sehingga layak untuk digunakan dalam analisis berbasis waktu seperti identifikasi musim hujan dan kemarau. Nilai ini kemudian dikonversi ke format datetime agar dapat diproses dalam analisis deret waktu.

Atribut temperatur maksimum (TX) dan temperatur minimum (TN) menunjukkan fluktuasi harian suhu udara. Rata-rata suhu maksimum berada di kisaran 28–32°C, sedangkan suhu minimum berkisar antara 18–22°C. Nilai-nilai ekstrem pada atribut ini dapat menandakan kondisi cuaca ekstrem seperti gelombang panas atau pendinginan signifikan akibat curah hujan tinggi. Temperatur rata-rata (TAVG) memberikan gambaran umum keseimbangan suhu harian dan menjadi salah satu faktor penting yang mempengaruhi pembentukan awan konvektif.

Atribut kelembapan udara rata-rata (RH_AVG) menunjukkan tingkat kejenuhan uap air di atmosfer. Nilai kelembapan yang tinggi (umumnya di atas 80%) sering kali berasosiasi dengan peningkatan peluang terjadinya hujan. Sebaliknya, kelembapan rendah menunjukkan kondisi atmosfer yang kering sehingga curah hujan cenderung kecil. Distribusi nilai kelembapan dalam data menunjukkan mayoritas berada pada kisaran 70–90%, mengindikasikan wilayah pengamatan memiliki iklim lembap.

Atribut curah hujan (RR) merupakan variabel target dalam penelitian ini. Nilai curah hujan bervariasi mulai dari 0 mm (tidak ada hujan) hingga lebih dari 70 mm per hari (hujan lebat). Distribusi data menunjukkan sebagian besar hari tidak mengalami hujan atau hanya hujan ringan, dengan frekuensi kejadian hujan sedang hingga lebat relatif lebih sedikit. Hal ini sesuai dengan karakteristik iklim tropis di mana curah hujan tidak merata sepanjang tahun dan terkonsentrasi pada bulan-bulan tertentu.

Atribut lama penyinaran matahari (SS) diukur dalam jam dan menunjukkan jumlah waktu dalam sehari di mana sinar matahari mencapai permukaan bumi. Nilai SS yang tinggi menandakan kondisi langit cerah dengan sedikit awan, sedangkan nilai rendah menunjukkan tutupan awan yang signifikan. Dalam konteks prediksi curah hujan, hubungan antara SS dan RR bersifat negatif yang mana

semakin lama penyinaran, maka semakin kecil kemungkinan hujan.

Atribut kecepatan angin (FF_AVG) menggambarkan kekuatan pergerakan udara di sekitar permukaan bumi. Kecepatan angin yang tinggi dapat mempercepat proses penguapan dan pembentukan awan, namun juga dapat membawa massa udara kering yang menurunkan peluang hujan tergantung arah dan sumber angin. Rata-rata kecepatan angin harian dalam dataset berada pada kisaran 2–8 m/s, dengan beberapa hari ekstrem di atas 10 m/s.

Atribut arah angin (DDD_CAR) merepresentasikan arah pergerakan angin utama yang dicatat dalam bentuk derajat atau simbol mata angin seperti N (Utara), S (Selatan), E (Timur), W (Barat), serta kombinasi diagonal seperti SE (Tenggara) atau NW (Barat Laut). Analisis menunjukkan arah angin dominan berasal dari sektor Selatan hingga Tenggara selama musim hujan, dan bergeser ke arah Timur Laut pada musim kemarau. Pergeseran pola arah angin ini berkaitan erat dengan dinamika monsun di wilayah Indonesia.

Data awal dikumpulkan dalam format CSV (Comma Separated Values) dan melalui beberapa tahap pra-pemrosesan untuk menjamin kualitas data. Tahapan tersebut meliputi pembersihan data yaitu data cleaning untuk mengatasi nilai hilang yaitu missing value dan data tidak valid, seperti kode 8888 atau 9999 yang menandakan data tidak tercatat. Selanjutnya dilakukan konversi tipe data, khususnya pada kolom numerik yang masih bertipe objek akibat perbedaan format desimal seperti tanda koma. Kolom tanggal juga diubah menjadi format datetime agar dapat digunakan dalam analisis berbasis waktu. Setelah itu, dilakukan standarisasi satuan pengukuran serta imputasi nilai hilang agar distribusi data tetap representatif.

Hasil akhir dari proses pengumpulan dan pra-pemrosesan ini adalah dataset yang bersih, konsisten, dan siap digunakan untuk analisis eksploratif maupun pembangunan model prediksi curah hujan berbasis data cuaca harian.

Tabel 3. 1 Dataset penelitian

Fitur	Keterangan
TANGGAL	Tanggal pada saat nilai diukur
TN	Temperatur minimum (°C)
TX	Temperatur maksimum (°C)

Fitur	Keterangan
TAVG	Temperatur rata-rata (°C)
RH_AVG	Kelembapan rata-rata (%)
RR	Curah hujan (mm)
SS	Lamanya penyinaran matahari (jam)
FF_X	Kecepatan angin maksimum (m/s)
DDD_X	Arah angin saat kecepatan maksimum (°)
FF_AVG	Kecepatan angin rata-rata (m/s)
DDD_CAR	Arah angin terbanyak (°)

TANGGAL	TN	TX	TAVG	RH_AVG	RR	SS	FF_X	DDD_X	FF_AVG	DDD_CAR
01/01/2023	22,4	27,2	25,1	69	0,1	2,7	6	300	4	NW
02/01/2023	21,8	30,8	24,7	78	1,6	2,1	7	180	2	C
03/01/2023	20,3	30	24,6	78	4,4	2,7	5	320	2	SE
04/01/2023	20,2	30,9	25,4	74	6,2	5,1	4	250	2	S
05/01/2023	21,2	30	25,2	76	0	7,7	6	180	2	S

Gambar 3. 1 Lima data teratas

Karakteristik data pada penelitian ini merupakan data besar atau big data cuaca historis yang bersifat terstruktur yang mencakup rentang waktu periode harian dari 1 Januari 2023 hingga 30 Juli 2025. Data yang digunakan terdiri dari 942 baris sebagai observasi harian dan 11 kolom yang menjadi variabel fitur. Berdasarkan durasinya klasifikasi skala dataset ini masuk dalam kategori *medium-scale forecast* yaitu berbasis bulan atau tahun hingga *long-scale forecast* berbasis tahunan jika digunakan untuk analisis tren.

Dataset yang digunakan mengandung kombinasi variabel fitur parameter meteorologi yang kompleks sesuai dengan literatur yang menyatakan bahwa data cuaca melibatkan variabel suhu, kelembaban, curah hujan, dan juga kecepatan angin (Sulochana et al., 2024). Berikut adalah tabel identifikasi fitur pada dataset yang digunakan untuk penelitian.


Tabel 3. 2 Identifikasi Fitur Dataset

Fitur	Deskripsi fitur	Satuan/format	Karakteristik Data
TANGGAL	Dimensi Waktu	DD/MM/YYYY	Data temporal (Deret Waktu) <i>Time Series</i>

Fitur	Deskripsi fitur	Satuan/format	Karakteristik Data
TN,TX,TAVG	Suhu (Min, Max, Rata-rata)	Celcius (°C)	Kontinu (Decimal dengan koma)
RH_AVG	Kelembaban Rata-rata	Persentase (%)	Kontinu
RR	Curah Hujan	Milimeter (mm)	Kontinu
SS	Lama Penyinaran Matahari	Jam	Kontinu
FF_X dan FF_AVG	Kecepatan Angin (Max dan Rata-rata)	Knot (m/s)	Kontinu (Indikator Siklon)
DDD_X dan DDD_CAR	Arah Angin (Derajat dan Kardinal)	Deg atau Arah	Numerik dan Kategorikal (NW,SE,C)

Data ini memiliki karakteristik sifat yang spesifik karena multivariate yaitu terdapat keterkaitan antara satu variabel fitur dengan variabel fitur yang lain seperti hubungan antara suhu dengan penguapan yaitu TX dengan RR. Dataset ini menggunakan standar desimal Indonesia yang mana menggunakan koma sebagai pemisah desimal sehingga memerlukan pra pemrosesan data sebelum masuk ke tahap pemodelan dengan *machine learning*. Integritas data berdasarkan pengecekan awal dataset ini cukup bersih karena minim *missing values* hal ini sangat krusial karena akurasi model sangat bergantung pada kualitas data historis.

Untuk mengetahui karakteristik data salah satunya dengan *matrix correlation* yaitu tabel yang menampilkan koefisien korelasi antara beberapa variabel. Setiap sel dalam matriks mewakili korelasi antara dua variabel, memberikan visualisasi yang cepat dan jelas tentang hubungan di antara keduanya. Koefisien korelasi dapat berkisar dari -1 hingga +1, di mana +1 menunjukkan korelasi positif sempurna, artinya ketika satu variabel meningkat, variabel lain juga meningkat. -1 menunjukkan korelasi negatif sempurna, artinya ketika satu variabel meningkat, variabel lain menurun. Dan 0 menunjukkan tidak ada korelasi, yang menunjukkan bahwa perubahan pada satu variabel tidak memprediksi perubahan pada variabel lain (Du et al., 2025).



Gambar 3. 2 Matriks Korelasi Variabel Cuaca

Berdasarkan matriks korelasi diatas hubungan variabel curah hujan yaitu RR dengan suhu minimum, maximum dan rata rata yaitu TN, TX, dan TAVG adalah 0.23, -0.13, 0.01 sehingga korelasi antara curah hujan dan suhu dapat dikatakan lemah yang berarti curah hujan tidak bergantung linear pada suhu yang membuktikan bahwa sistem cuaca adalah non-linear. Hubungan curah hujan dengan kelembaban rata-rata yaitu RH_AVG sebesar 0.35 sehingga dapat dikatakan korelasi positif sedang yang mana membuktikan bahwa kelembaban dapat mempengaruhi curah hujan. Hubungan curah hujan dengan penyinaran matahari yaitu SS sebesar -0.31 sehingga dapat dikatakan korelasi negatif sedang yang mana membuktikan bahwa semakin lama penyinaran matahari curah hujan akan semakin menurun secara signifikan. Hubungan antara curah hujan dengan kecepatan angin dan arah angin yaitu FF_X, FF_AVG, dan DDD_X masing-masing -0.08, -0.22, -0.01 yang mana dapat dikatakan korelasinya lemah sehingga curah hujan tidak bergantung linear pada kecepatan angin dan arah angin. Karena korelasi variabel curah hujan RR dengan variabel lain sangat rendah secara linear model

statistik sederhana tidak cukup untuk menangkap pola yang kompleks pada dataset cuaca BMKG ini sehingga perlu menggunakan model *machine learning* seperti Gradient Boosting dengan harapan model dapat menangkap pola yang kompleks pada dataset.

Untuk mengetahui karakteristik lebih dalam lagi juga dapat menggunakan metode uji stasioneritas yaitu metode statistik yang digunakan untuk menentukan apakah suatu kumpulan data deret waktu bersifat stasioner. Deret stasioner memiliki sifat statistik yang konstan dari waktu ke waktu, seperti rata-rata, varians, dan struktur autokorelasi, yang sangat penting untuk banyak analisis deret waktu. Memahami apakah suatu deret bersifat stasioner sangat penting, karena sebagian besar metode dan model statistik mengasumsikan stasioneritas untuk menghasilkan hasil yang valid. Deret waktu non-stasioner dapat menyebabkan korelasi yang menyesatkan dan hasil palsu jika tidak ditangani dengan tepat (Dao & Staszewski, 2021). Uji stasioneritas yang paling umum digunakan yaitu uji *Augmented Dickey-Fuller* (ADF) yang mana uji ini menilai hipotesis nol bahwa terdapat akar unit dalam sampel deret waktu, yang menunjukkan non-stasioneritas. Jika statistik uji kurang dari nilai kritis yaitu 0.05, dapat disimpulkan bahwa deret tersebut stasioner (Sathyanarayana & Mohanasundaram, 2025). Jika data sudah stasioner artinya, rata-rata dan varians data tidak berubah drastis seiring waktu, sehingga model prediksi akan lebih stabil dalam mengenali pola.


Tabel 3. 3 Uji Stasioner ADF

Fitur	ADF Statistik	P-Value	Keterangan
TN	-5.0822	0.0000	Stasioner
TX	-3.0710	0.0288	Stasioner
RH AVG	-3.0692	0.0289	Stasioner
SS	-5.0075	0.0000	Stasioner
FF_AVG	-8.6211	0.0000	Stasioner
TAVG	-2.5665	0.1001	Tidak Stasioner
FF_X	-8.4524	0.0000	Stasioner
DDD_X	-7.2078	0.0000	Stasioner
RR	-8.2753	0.0000	Stasioner

Dalam data *time series* seperti dataset yang digunakan pada penelitian ini, data

dikatakan layak diprediksi jika bersifat stasioner yaitu rata-rata dan variansnya konstan dari waktu ke waktu. Jika data tidak stasioner, model *Machine Learning* akan menghasilkan prediksi yang bias. Dengan melihat tabel 3.3 diatas dapat disimpulkan bahwa dataset masih terdapat fitur yang tidak stasioner tepatnya pada fitur TAVG yang mana harus dilakukan transformasi *differencing* terlebih dahulu untuk mendapatkan data yang stasioner agar dapat disiapkan untuk pemodelan menggunakan Gradient Boosting (Dao & Staszewski, 2021).


Karakteristik data juga dapat diketahui dengan dekomposisi musiman, yaitu teknik statistik yang digunakan untuk memisahkan deret waktu menjadi komponen-komponen berbeda yang mencerminkan pola-pola mendasar dari waktu ke waktu. Tujuan utamanya adalah untuk memfasilitasi pemahaman yang lebih baik tentang data dengan mengisolasi efek-efek individualnya, yang umumnya seperti tren yang mewakili perkembangan jangka panjang dari deret tersebut, menunjukkan pergerakan umum ke atas atau ke bawah dari waktu ke waktu. Selanjutnya ada musiman yang menangkap fluktuasi atau pola berulang yang terjadi pada interval reguler karena efek musiman, yang mungkin tahunan, triwulanan, atau bulanan (Suhartono & Subanar, 2006) (Veverka, 2024). Yang terakhir biasanya adalah noise atau residual yang mencakup setiap noise atau variasi acak dalam data yang tidak dapat dikaitkan dengan tren atau efek musiman.



Gambar 3. 3 Dekomposisi Curah Hujan

Dengan melihat Gambar 3.3 Panel "Observed" (Data asli) panel paling atas menunjukkan data asli curah hujan harian dari tahun 2023 hingga 2025. Terlihat banyak titik nol yang menunjukkan hari tanpa hujan dan beberapa lonjakan tajam atau spikes yang menunjukkan hujan ekstrem. Grafik ini memperlihatkan sifat curah hujan yang stochastic dan tidak berkelanjutan. Lonjakan tajam merupakan kejadian hujan ekstrem yang melebihi rata-rata normal, yang dalam pengolahan data selanjutnya perlu diperhatikan agar tidak dianggap sebagai noise semata. Selanjutnya panel "Trend" (Kecenderungan Jangka Panjang) Garis tren ini adalah hasil penyaringan data asli untuk melihat arah pergerakan curah hujan dalam jangka panjang tanpa terganggu oleh fluktuasi harian. Dari tren ini, kita bisa melihat apakah terjadi pergeseran iklim lokal. Misalnya, jika garis tren pada pertengahan 2023 lebih rendah dibanding 2024, ini menunjukkan dampak El Niño atau musim kemarau yang lebih kering pada tahun tersebut. Analisis ini membantu model untuk memahami konteks tahun basah atau tahun kering. Panel "Seasonal" (Pola Musiman) adalah bagian paling krusial. Panel ini mengisolasi pola yang berulang secara periodik setiap 365 hari. Garis yang naik-turun secara teratur ini merepresentasikan Siklus Musiman. Kita bisa melihat dengan jelas kapan wilayah


penelitian memasuki musim penghujan pada puncak grafik dan musim kemarau pada lembah grafik. Dengan memisahkan pola musiman ini, model Gradient Boosting dapat bisa lebih mudah membedakan mana hujan yang memang jadwalnya turun dan mana hujan yang bersifat anomali. Panel "Resid" (Sisa/Anomali) Panel terakhir adalah sisa setelah tren dan pola musiman dihilangkan dari data asli. Residual menunjukkan faktor-faktor acak yang tidak bisa dijelaskan oleh musim. Jika ada batang residual yang sangat tinggi, itu berarti terjadi hujan lebat yang tidak lazim di luar musimnya. Dalam penelitian ini, tingginya nilai residual pada variabel curah hujan ini membuktikan bahwa prediksi hujan jauh lebih sulit, sehingga diperlukan algoritma yang lebih kompleks seperti Gradient Boosting. Dekomposisi ini juga membuktikan bahwa variabel curah hujan memiliki komponen deterministik (musiman) dan stokastik (acak) yang kuat. Oleh karena itu, penelitian ini tidak hanya mengandalkan nilai *average*, tapi juga mempertimbangkan pola temporal agar akurasi prediksi meningkat.



Gambar 3. 4 Tren Perubahan Curah Hujan

Curah hujan bersifat intermiten yaitu kadang nol, kadang melonjak tajam sehingga dapat diketahui bahwa grafik pada Gambar 3.4 bukan sekadar menunjukkan kapan hujan turun, tapi menunjukkan pola distribusi dan intensitas. Berbeda dengan variabel suhu yang fluktuasinya stabil, grafik curah hujan ini menunjukkan sifat stokastik dan zero-inflated. Artinya, terdapat banyak observasi bernilai nol yang menunjukkan hari tanpa hujan, yang kemudian diselingi oleh


lonjakan tajam (spikes). Karakteristik data yang patah-patah menjadi alasan kuat mengapa model statistik linier akan sulit memprediksi hujan, sehingga penelitian yang saya lakukan menggunakan pendekatan Gradient Boosting sesuai saran dalam jurnal Reddy & Babu (2017). Identifikasi pola musiman secara visual, kita dapat membagi grafik ini menjadi dua zona utama yaitu zona dengan intensitas rendah (musim kemarau) dan zona dengan intensitas tinggi (musim penghujan). Perhatikan pada periode 2023-01 sampai 2023-05, terjadi klusterisasi lonjakan data. Pola ini berulang setiap tahun, namun dengan intensitas yang berbeda-beda. Hal ini membuktikan adanya pengaruh siklus Monsun terhadap dataset yang digunakan. Pada tahun 2024-10, terlihat nilai curah hujan mencapai lebih dari 100 mm. Ini dikategorikan sebagai hujan sangat lebat atau ekstrem. Kejadian ekstrem ini sangat penting dalam model prediksi cuaca karena biasanya berhubungan dengan potensi bencana. Meskipun jumlahnya sedikit (outlier), data ini tidak dihilangkan karena mengandung informasi krusial tentang anomali cuaca di lokasi penelitian. Meskipun secara visual terlihat sangat berantakan, hasil uji statistik menunjukkan data curah hujan ini cenderung lebih mudah mencapai status stasioner dibandingkan suhu. Karena nilainya selalu kembali ke titik nol, tidak memiliki tren naik yang permanen secara jangka panjang.



Gambar 3. 5 Distribusi Data Curah Hujan

Gambar 3.5 menunjukkan grafik distribusi frekuensi dari curah hujan harian. Bisa kita lihat bahwa grafiknya miring ke kanan (*Right-Skewed* atau *Positively Skewed*). Artinya, frekuensi tertinggi berada pada angka curah hujan yang rendah. Hal ini sangat wajar dalam data meteorologi, di mana jumlah hari dengan hujan ringan atau tidak ada hujan sama sekali jauh lebih banyak dibandingkan hari dengan hujan lebat. Batang paling tinggi yang berada di angka 0 atau mendekati 0 menunjukkan fenomena *Zero-Inflation*. Ini merepresentasikan banyaknya hari kering di kabupaten Malang selama tahun 2023-2025. Banyaknya data nol ini menjadi tantangan dalam pemodelan, karena model prediksi harus mampu membedakan antara tidak hujan dan hujan sangat ringan. Meskipun frekuensinya kecil, terdapat ekor yang memanjang ke arah kanan hingga angka 100 mm. Titik-titik di ujung kanan ini adalah kejadian hujan ekstrem. Walaupun secara statistik ini dianggap sebagai outlier (pencilan), dalam penelitian cuaca, data ini justru yang paling krusial untuk diprediksi karena berkaitan dengan risiko bencana seperti banjir. Karena distribusinya miring ke kanan, nilai rata-rata akan lebih besar daripada Median. Oleh karena itu, dalam analisis ini, saya lebih menekankan pada penggunaan Median atau Modus untuk menggambarkan kondisi curah hujan tipikal di daerah tersebut, agar tidak terdistorsi oleh angka hujan ekstrem. Grafik distribusi ini membuktikan bahwa dataset curah hujan tidak berdistribusi normal. Mayoritas data berkumpul di bawah 10 mm per hari, namun terdapat pencilan ekstrem di sisi kanan grafik. Ketidakseimbangan distribusi ini memperkuat alasan mengapa memilih algoritma Gradient Boosting yang lebih tangguh menangani data non-linier dan tidak memerlukan asumsi normalitas seperti pada regresi linier klasik.


Kerangka konsep dalam penelitian ini terdiri dari beberapa tahap yaitu input data yang terdiri dari dataset cuaca, selanjutnya prapemrosesan data yang terdiri persiapan data, load data dan pemberishan data, konversi tipe data, rekayasa fitur, penanganan missing value, seleksi fitur, pencarian nsplit optimal, optimasi parameter gradient boosting dengan randomsearchcv, pemodelan dan evaluasi model dengan RMSE, yang terakhir adalah outputnya yaitu prediksi cuaca. Berikut adalah gambar kerangka konsep pada penelitian ini.



Gambar 3. 6 Kerangka Konsep

3.2 Tahap Penelitian

Tahap penelitian prediksi cuaca yang dilakukan ditunjukkan pada gambar 3.7 yang menjelaskan alur penelitian dimulai dari pengumpulan data, pra pemrosesan data, optimasi, pemodelan, evaluasi dan terakhir kesimpulan.



Gambar 3. 7 Tahap Penelitian

3.2.1 Pengumpulan Data

Pengumpulan data adalah tahapan yang sangat penting dalam sebuah penelitian tepatnya dilakukan pada tahap awal. Karena dengan adanya data yang sudah dikumpulkan proses atau tahap penelitian yang selanjutnya akan dilakukan menjadi lebih mudah dalam pengolahan dan analisisnya. Pengumpulan data dilakukan dengan berbagai cara menggunakan teknik yang efisien dan tepat sehingga menjamin data yang dikumpulkan adalah data yang benar sesuai fakta yang sebenarnya. Dalam hal ini teori-teori yang berhubungan dan mendukung penelitian didapatkan dari berbagai sumber literatur dan jurnal penelitian kemudian dipelajari dan di jadikan sebagai dasar acuan pada penelitian. Data yang digunakan pada penelitian ini adalah dataset cuaca yang didapatkan dari BMKG. Data yang digunakan terdapat beberapa atribut untuk inputan pada sistem seperti suhu, kelembaban, tekanan, angin dan radiasi matahari. Sedangkan untuk outputnya adalah prediksi cuaca yang diwakilkan dengan atribut curah hujan.

Data awal dikumpulkan dalam format CSV (Comma Separated Values) dengan 942 baris dan 11 kolom fitur. dan melalui beberapa tahap pra-pemrosesan untuk menjamin kualitas data. Tahapan tersebut meliputi pembersihan data yaitu data cleaning untuk mengatasi nilai hilang yaitu missing value dan data tidak valid,

seperti kode 8888 atau 9999 yang menandakan data tidak tercatat. Selanjutnya dilakukan konversi tipe data, khususnya pada kolom numerik yang masih bertipe objek akibat perbedaan format desimal seperti tanda koma. Kolom tanggal juga diubah menjadi format datetime agar dapat digunakan dalam analisis berbasis waktu. Setelah itu, dilakukan standarisasi satuan pengukuran serta imputasi nilai hilang agar distribusi data tetap representatif.

Tabel 3. 4 Dataset penelitian

Fitur	Keterangan
TANGGAL	Tanggal pada saat nilai diukur
TN	Temperatur minimum (°C)
TX	Temperatur maksimum (°C)
TAVG	Temperatur rata-rata (°C)
RH_AVG	Kelembapan rata-rata (%)
RR	Curah hujan (mm)
SS	Lamanya penyinaran matahari (jam)
FF_X	Kecepatan angin maksimum (m/s)
DDD_X	Arah angin saat kecepatan maksimum (°)
FF_AVG	Kecepatan angin rata-rata (m/s)
DDD_CAR	Arah angin terbanyak (°)

3.2.2 Prapemrosesan Data

Tahap pra-pemrosesan menempati posisi sentral dalam alur kerja ilmu data yang lebih luas, terletak di antara akuisisi data dan pemodelan atau analisis formal Catania dkk. (2022), Xin dkk., 2021; , Valizadeh dkk., 2021; . Alur kerja pemrosesan data yang khas dalam sistem pengambilan keputusan otomatis melibatkan akuisisi data, pembersihan data, integrasi data, dan analisis Catania dkk. (2022). Dalam proyek ilmu data berorientasi tujuan klasik, prosesnya sering kali terdiri dari aktivitas dalam urutan berikut: eksplorasi data, rekayasa data, pembangunan model, dan eksploitasi Bie dkk., 2022. Namun, dalam praktiknya, lintasan ini dapat jauh lebih beragam dan eksploratif, dengan para praktisi menavigasi melalui aktivitas dalam urutan yang berbeda dan secara iteratif Bie dkk., 2022.

Tahap pra-pemrosesan digambarkan sebagai proses yang memakan waktu dan sebagian besar manual bagi sebagian besar praktisi Xin dkk., 2021. Rata-rata,

peserta dalam studi empiris melaporkan menghabiskan sekitar 50% waktu mereka untuk pra-pemrosesan data, dan sekitar 80% dari semua tugas pra-pemrosesan data dilakukan secara manual (Xin et al., 2021). Hal ini menggarisbawahi perlunya peningkatan otomatisasi dan dukungan alat untuk tugas pra-pemrosesan (Bie et al., 2022; Xin et al., 2021).


Pra-pemrosesan juga diakui sebagai penentu penting kinerja model. Pra-pemrosesan data yang tidak seimbang dengan benar dapat memungkinkan peneliti untuk mengurangi cacat sebanyak mungkin, yang pada gilirannya dapat menyebabkan penghapusan cacat dalam dataset yang ada (Felix & Lee, 2019). Menggabungkan langkah-langkah pra-pemrosesan memastikan bahwa data dipersiapkan dengan baik, meningkatkan keandalan dan akurasi analisis dan model selanjutnya (Dave et al., 2025).

Tahap awal prapemrosesan dimulai dengan konversi data mentah yang diperoleh dari sumber meteorologi ke dalam format *dataset* terstruktur yang konsisten. Data mentah yang awalnya tersebar dalam berbagai format file dan satuan pengukuran diseragamkan ke dalam format *Comma Separated Values* (CSV) untuk memudahkan proses integrasi. Selain itu, dilakukan penyesuaian satuan pada beberapa variabel meteorologi, seperti mengubah skala durasi penyinaran matahari dan suhu agar memiliki basis perhitungan yang seragam. Visualisasi distribusi data mentah dilakukan pada tahap ini untuk memberikan gambaran umum mengenai tren fluktuasi sebelum data lebih lanjut diproses ke tahap pembersihan. Berikut ini adalah tabel konversi data yang dilakukan.

Tabel 3. 5 Konversi Data

No.	Kolom Fitur	Sebelum	Sesudah
1.	TANGGAL	Datetime	Datetime
2.	TN	Object	Float
3.	TX	Object	Float
4.	TAVG	Object	Float
5.	RH_AVG	Object	Float
6.	RR	Object	Float
7.	SS	Object	Float
8.	FF_X	Integer	Integer
9.	FF_AVG	Integer	Integer
10.	DDD_X	Integer	Integer
11.	DDD_CAR	Object	Object

Setelah data dikonversi ke dalam format yang seragam, langkah selanjutnya adalah melakukan penanganan *missing value* untuk menjaga integritas informasi dalam *dataset*. Identifikasi data yang hilang dilakukan pada variabel curah hujan dan fitur meteorologi lainnya, di mana ditemukan kekosongan data akibat kendala teknis pada sensor pencatatan. Untuk mengatasi hal tersebut, dilakukan proses imputasi menggunakan algoritma *KNNImputer* dengan nilai $k=5$, yang bekerja dengan mengestimasi nilai berdasarkan kemiripan pola dari tetangga terdekat. Metode ini dipilih karena kemampuannya dalam menjaga karakteristik temporal data cuaca yang bersifat fluktuatif, sehingga hasil imputasi tidak merusak pola distribusi asli data dibandingkan dengan metode pengisian rata-rata sederhana. Berikut ini adalah gambar sebelum penanganan missing value dan sesudah missing value.



Gambar 3. 8 Distribusi curah hujan sebelum vs sesudah imputasi

Pada Gambar 3.8 menampilkan grafik hasil penanganan nilai yang hilang dengan imputasi. Grafik menunjukkan bahwa proses imputasi missing value tidak mengubah distribusi utama curah hujan secara signifikan yang ditunjukkan dengan garis merah putus-putus menempel dengan garis biru. Hal ini mengindikasikan bahwa metode imputasi yang digunakan mampu mempertahankan karakteristik statistik data sehingga dataset tetap valid untuk proses pemodelan prediksi.

3.2.3 Optimasi

Optimasi model pembelajaran mesin melibatkan dua proses penting dan saling terkait konfigurasi strategi pemisahan validasi silang khususnya parameter `n_splits` dalam konteks deret waktu dan penyetelan sistematis parameter hipermodel. Algoritma Gradient Boosting, karena arsitektur ensemble sekuensial dan ruang parameter hipernya yang besar, sangat sensitif terhadap kedua tahap optimasi ini (Mahesh dkk., 2024; Talamkhani, 2023; MacNell dkk., 2023). RandomizedSearchCV telah muncul sebagai teknik dominan untuk menavigasi ruang hiperparameter ini secara efisien, menawarkan alternatif yang mudah dihitung secara komputasi dibandingkan metode pencarian grid yang menyeluruh (Patel et al., 2022), (Nigusie et al., 2024; , Al-Nammari et al., 2023;). Sehingga haal ini memberikan uraian komprehensif dan terpadu tentang tahap optimasi

`n_splits` dalam validasi silang deret waktu dan proses optimasi hiperparameter menggunakan `RandomizedSearchCV`, dengan mengacu pada sejumlah besar literatur empiris dan metodologis.

Validasi silang adalah teknik dasar untuk memperkirakan kinerja generalisasi model pembelajaran mesin dan untuk memandu pemilihan hiperparameter. Teknik ini melibatkan pembagian data yang tersedia menjadi subset yang saling melengkapi, melatih model pada satu subset, dan mengevaluasinya pada subset lainnya, sehingga memberikan perkiraan kinerja di luar sampel yang lebih andal daripada pembagian data latih-uji tunggal (Cabrera et al., 2024). `RandomizedSearchCV` menggabungkan pencarian acak dengan validasi silang untuk secara acak memilih kombinasi hiperparameter dan melatih model pada bagian tertentu dari data input, kemudian mengujinya pada subset data input yang belum pernah digunakan sebelumnya (Nigusie et al., 2024;). Parameter `n_splits` secara langsung mengontrol jumlah lipatan atau pembagian yang digunakan dalam prosedur validasi silang ini, dan konfigurasi yang tepat karenanya merupakan keputusan metodologis yang penting (Talamkhani, 2023).

Validasi silang dijelaskan sebagai pendekatan untuk mengukur kinerja model dengan melatihnya pada bagian tertentu dari data input dan kemudian mengujinya pada subset data input yang belum pernah digunakan sebelumnya. Parameter `n_splits` dalam objek validasi silang yang diberikan ke `RandomizedSearchCV` menentukan berapa kali data pelatihan dipartisi, secara langsung memengaruhi keandalan estimasi kinerja dan biaya komputasi (Srinivasan dkk., 2024).

Setelah melalui tahap pra-pemrosesan, dilakukan proses optimasi hiperparameter untuk mendapatkan konfigurasi model Gradient Boosting Regressor yang paling optimal dalam memprediksi curah hujan. Proses ini dilakukan menggunakan metode `RandomizedSearchCV` dengan skema validasi `TimeSeriesSplit`. Pencarian dilakukan dengan menguji 50 kombinasi parameter secara acak dari ruang pencarian yang telah ditentukan. Evaluasi setiap kombinasi dilakukan berdasarkan nilai Root Mean Squared Error RMSE terkecil. Penggunaan `TimeSeriesSplit` memastikan bahwa setiap iterasi pengujian tetap menghormati


urutan kronologis data, sehingga model yang dihasilkan memiliki kemampuan generalisasi yang baik terhadap data masa depan. Proses validasi model dilakukan menggunakan metode TimeSeriesSplit untuk menghormati urutan temporal data. Eksperimen ini menggunakan parameter $n_splits=7$ untuk membagi data latih menjadi 7 segmen kronologis. Pada setiap fold, proses optimasi hiperparameter melalui RandomizedSearchCV dilakukan secara eksklusif menggunakan data latih dari fold tersebut, tanpa menyentuh data validasi atau data uji, guna menghindari kebocoran data. Fungsi scoring yang digunakan adalah Negative Mean Absolute Error (`neg_mean_absolute_error`) untuk meminimalkan eror prediksi. Seluruh proses tuning menetapkan `random_state=42` guna menjamin konsistensi hasil dan kemudahan replikasi eksperimen oleh peneliti lain. Berdasarkan hasil eksperimen, diperoleh kombinasi parameter terbaik yang memberikan nilai error minimum. Parameter hasil optimasi disajikan pada Tabel 3 berikut.

Tabel 3. 6 Parameter optimal

No.	Hyperparameter	Deskripsi	Nilai Terpilih
1.	<code>n_estimator</code>	Jumlah pohon keputusan yang dibangun	108
2.	<code>learning_rate</code>	Kecepatan model dalam mengoreksi residu	0,024
3.	<code>max_depth</code>	Kedalaman maksimum setiap pohon	4
4.	<code>subsample</code>	Fraksi data yang digunakan untuk tiap pohon	0,935
5.	RMSE score	Rata-rata kesalahan prediksi	12,390

Nilai RMSE sebesar 12,390 merupakan performa terbaik yang diperoleh selama tahap optimasi hiperparameter menggunakan RandomizedSearchCV dengan validasi silang tiga lipatan (3-fold cross-validation). Untuk memastikan konsistensi dan stabilitas hasil optimasi, kami membandingkan metrik ini dengan pembagian data. Hasil eksperimen menunjukkan konsistensi nilai RMSE yang sangat stabil di seluruh skenario pembagian dengan nilai RMSE yang sama. Stabilitas metrik ini mengindikasikan bahwa model Gradient Boosting yang dikembangkan memiliki tingkat robustness yang tinggi terhadap variasi volume data. Konsistensi performa ini menunjukkan bahwa model tidak hanya

mengandalkan besaran data latih untuk mencapai akurasi, melainkan mampu menangkap pola fundamental dalam data cuaca secara efektif, baik pada skenario data latih yang terbatas (50%) maupun yang dominan (90%). Hal ini sekaligus memvalidasi bahwa hasil tuning hiperparameter melalui RandomizedSearchCV telah menghasilkan model yang generalis dan tidak rentan terhadap overfitting pada subset data tertentu. Berikut ini adalah visualisasi yang membantu memperjelas pemahaman untuk hasil optimasi parameter menggunakan RandomSearchCV.



Gambar 3. 9 Hasil RandomSearchCV


3.2.4 Pemodelan

Penngembangan sistem prediksi cuaca berbasis machine learning memerlukan pemilihan model dan pengaturan parameter yang tepat untuk memperoleh hasil prediksi yang efisien dan akurat. Algoritma yang dapat digunakan dalam prediksi cuaca salah satunya adalah Gradient Boosting dengan kelebihanannya dalam menangkap hubungan non-linear yang kompleks pada setiap fitur meteorologi. Parameter penting pada Gradient Boosting adalah jumlah pohon ($n_estimator$), kecepatan pembelajaran ($learning_rate$), kedalaman pohon (max_depth), dan proporsi sampel data yang digunakan ($subsample$). Pemilihan nilai parameter ini sangat berpengaruh terhadap performa dan efisiensi sistem pada Gradient Boosting.

Pada pengembangan sistem penelitian ini akan mencoba menggunakan

nilai parameter yang dituning dengan *GridSearchCV* dan *RandomSearchCV* pada dataset yang sudah dikumpulkan. Dalam pendekatan nilai parameter rendah sistem dirancang untuk berjalan dengan nilai parameter yang konservatif. Pendekatan ini bertujuan untuk meminimalisir overfitting dengan model yang tidak terlalu kompleks sehingga memungkinkan implementasi pada perangkat yang sumber dayanya terbatas meskipun waktu pelatihan bisa lebih lama karena secara bertahap pembelajaran dilakukan dengan lambat. Sistem dengan pendekatan parameter rendah akan lebih stabil dan memiliki generalisasi yang baik terhadap data baru. Sedangkan dalam pendekatan parameter tinggi sistem dirancang dengan nilai-nilai parameter yang agresif. Dengan pendekatan parameter tinggi sistem akan lebih banyak variasi dan kompleksitas pola pada sistem terhadap dataset cuaca yang digunakan. Akan tetapi pendekatan ini memiliki resiko overfitting jika tidak dikontrol dengan teknik validasi silang atau regulasi tambahan seperti *early_stopping* dan *subsample* atau *min_samples_split*. Selain itu kebutuhan komputasi dan waktu pelatihan meningkat secara signifikan.


Pada pengembangan sistem ini digambarkan dengan desain sistem untuk memperjelas alur sistem yang akan dilakukan pada penelitian seperti pada gambar 3.10.



Gambar 3. 10 Desain Sistem

3.2.5 Gradient Boosting

Gradient Boosting adalah salah satu metode pembelajaran mesin atau *machine learning* yang dapat digunakan dan diterapkan pada masalah regresi dan klasifikasi. Gradient Boosting Classifier, yang menggunakan kerugian log-likelihood dan Gradient Boosting Regressor yang menggunakan *mean squared error* terkadang disebut sebagai Gradient Boosting Machine (GBM). Dengan menambahkan model-model berurutan yang dilatih menggunakan residual kesalahan dari model sebelumnya, tujuannya adalah untuk meminimalkan fungsi kerugian (A. A. Khan et al., 2024).



Gambar 3. 11 Algoritma Gradient Boosting

Gradient Boosting mirip dengan teknik boosting lainnya, secara iteratif mengubah model yang lemah menjadi lebih kuat. Hal ini paling mudah dijelaskan dengan regresi kuadrat terkecil, yang bertujuan untuk mengajarkan model F untuk memprediksi nilai bentuk $\hat{y} = F(x)$ dengan meminimalkan *mean squared error* dimana i mengindeks kepada beberapa set pelatihan berukuran n dari nilai actual variable keluaran y .

Langkah Gradient Boosting :

1. Input data training $\{(x_i, y_i)\}_{i=1}^n$, fungsi kerugian yang dapat didiferensiasikan $L(y, F(x))$, jumlah iterasi M .
2. Inisialisasi model dengan nilai konstan:

$$F_0(x) = \arg \min \sum_{i=1}^n L(y_i, \gamma) \quad (1)$$

3. Dari $m = 1$ untuk M :

- a. Menghitung residual

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x) = F_{m-1}(x)} \text{ untuk } i = 1, \dots, n \quad (2)$$

- b. Sesuaikan model dasar atau model lemah yang tertutup dalam penskalaan $h_m(x)$ ke perhitungan residual dan latih menggunakan model pelatihan $\{(x_i r_{im})\}_{i=1}^n$
- c. Menghitung pengali γ_m dengan menyelesaikan masalah optimasi satu dimensi berikut :

$$\gamma_m = \arg \min \sum_{i=1}^n L(y_i, F_{m-1}(x_i) + \gamma h_m(x_i)) \quad (3)$$

- d. Perbarui model :

$$F_m(x) = F_{m-1}(x) + \gamma h_m(x) \quad (4)$$

- 4. Output $F_M(x)$.

3.2.6 Evaluasi

Tahap evaluasi model merupakan komponen penting dan tak terpisahkan dari setiap alur penelitian pembelajaran mesin, yang berfungsi sebagai mekanisme utama untuk menilai dan membandingkan akurasi prediksi, kemampuan generalisasi, dan keandalan model terlatih (Soundrapandiyan, 2024). Dalam tugas pembelajaran mesin berbasis regresi termasuk yang menggunakan gradient boosting, ensemble learning, dan arsitektur deep learning tiga metrik telah muncul sebagai standar dominan dan paling banyak diadopsi untuk mengukur kinerja model yaitu Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Coefficient of Determination (R^2) (Mary & Mujeeb, 2024). Metrik-metrik ini secara luas diakui dan digunakan untuk menentukan kinerja suatu model. Di berbagai bidang, mulai dari prediksi ionosfer dan teknik geoteknik hingga penelitian biomedis, ilmu lingkungan, dan peramalan keuangan (Al-Omran & Khan, 2024).

Evaluasi performa model dilakukan menggunakan tiga metrik utama: Mean Absolute Error (MAE) untuk mengukur rata-rata selisih absolut antara nilai aktual dan prediksi; Root Mean Squared Error (RMSE) untuk mengukur rata-rata error dalam satuan asli yang lebih sensitif terhadap outlier; serta R-squared (R^2) untuk menjelaskan proporsi variansi data yang dapat diprediksi oleh model. Untuk menguji keunggulan model Gradient Boosting (GB) yang dioptimasi, penelitian ini mengonstruksi kerangka perbandingan sistematis yang mencakup Gradient Boosting tanpa optimasi sebagai baseline untuk mengukur efektivitas model

melampaui asumsi persistensi cuaca. Perbandingan dilakukan melalui empat skenario pembagian data latih dan uji (50:50, 70:30, 80:20, dan 90:10) guna memastikan stabilitas performa model di luar model baseline maupun algoritma pembandingan lainnya. Berikut ini adalah rumus persamaan MAE, RMSE dan R2:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (6)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2} \quad (7)$$

dengan :

- y_i : Nilai aktual
- $\hat{y}_i$: Nilai prediksi
- $\bar{y}$: Rata-rata nilai aktual
- n : Jumlah data

3.2.7 Kesimpulan

Kesimpulan merupakan tahap akhir dari proses penelitian yang dilakukan dengan merangkum temuan utama dan menjawab pertanyaan penelitian berdasarkan hasil analisis yang dilakukan sehingga pada tahap ini konteks komparasi model Gradient Boosting dengan parameter tinggi dan rendah dievaluasi dan berisi cakupan implikasi dari temuan penelitian baik untuk penelitian selanjutnya, implementasi di dunia nyata, atau pengambilan keputusan kebijakan berbasis cuaca. Karena hal ini penting sehingga dapat memberikan kontribusi nyata bukan sekedar penelitian yang berhenti pada hasil teknis.

3.3 Eksperimen

Pada tahap eksperimen penelitian ini akan membagi menjadi 4 kelompok

skenario uji coba pada komposisi data latih dan uji. Yang pertama adalah komposisi 50:50, yang kedua adalah 70:30, yang ketiga adalah 80:20 dan yang keempat adalah 90:10. Selain itu gradient boosting juga dilatih dan diuji menggunakan beberapa skenario untuk mengevaluasi konsistensi dan performa algoritma dalam memprediksi curah hujan dengan membagi data berdasarkan urutan waktu untuk menjaga relevansi temporal. Seperti pada tabel dibawah ini.

Tabel 3. 7 Pembagian data

Komposisi	Data Latih	Data Uji
50:50	50% data latih	50% data uji
70:30	70% data latih	30% data uji
80:20	80% data latih	20% data uji
90:10	90% data latih	10% data uji

Tabel 3. 7 Skenario Pengujian

Skenario	Deskripsi	Tujuan
Gradient Boosting Default	Menggunakan parameter standart default dari scikit-Learn tanpa optimasi	Sebagai pembandingan dasar untuk melihat performa model awal
Gradient Boosting Optimized	Menggunakan parameter hasil optimasi randomizedCV	Membuktikan peningkatan akurasi model setelah mealui proses tuning.

Skenario pengujian dilakukan untuk memberikan landasan komparatif yang kuat dengan membandingkan model standar dan model yang dioptimasi. Sehingga membuktikan secara empiris bahwa tahap optimasi dalam pencarian parameter yang dilakuakn membarikan kontribusi nyata dalam menurunkan nilai eror pada prediksi curha hujan.

Tabel 3. 9 Hyperparameter

Parameter	Nilai	Deskripsi
learning_rate	0,01 – 0,2	Rentang yang digunakan adalah 0,01 hingga 0,2 untuk mengatur seberapa besar kontribusi setiap pohon terhadap hasil akhir.
max_depth	2 – 6	Rentang yang digunakan adalah 2 hingga 6 tingkat kedalaman pohon yang dibatasi untuk kontrol kompleksitas model.
n_estimator	100 – 500	Rentang yang diuji adalah 100 hingga 500 jumlah pohon yang akan dibangun.
subsample	0,7 – 0,3	Fraksi data yang digunakan untuk membangun setiap pohon.

Peningkatan akurasi model *Gradient Boosting* sangat bergantung pada pemilihan kombinasi *hyperparameter* yang tepat. Dalam penelitian ini, optimasi dilakukan menggunakan metode *RandomizedSearchCV*. Berbeda dengan *Grid Search* yang menguji seluruh kemungkinan kombinasi secara melelahkan, *Randomized Search* bekerja dengan mengambil sampel acak dari distribusi parameter yang telah ditentukan. Penggunaan *RandomizedSearchCV* dipilih karena efisiensinya dalam menangani ruang pencarian (*search space*) yang luas. Berdasarkan literatur, metode ini mampu menemukan parameter optimal dengan waktu komputasi yang jauh lebih singkat namun tetap memberikan hasil yang kompetitif dibandingkan *Grid Search*. Hal ini sangat krusial mengingat dataset cuaca memiliki variabilitas yang tinggi dan memerlukan iterasi yang stabil.

Tabel 3. 10 Study ablation

Ablasi	Deskripsi	Tujuan
Semua variabel fitur	Menggunakan semua fitur pada dataset untuk prediksi curah hujan	Sebagai pembandingan dasar untuk melihat performa jika menggunakan semua fitur
Ablasi fitur suhu (T_AVG)	Menghilangkan fitur suhu pada dataset untuk prediksi curah hujan	Membuktikan kontribusi fitur suhu dalam peningkatan model gradient boosting
Ablasi fitur kelembapan (RH_AVG)	Menghilangkan fitur kelembapan pada dataset untuk prediksi curah hujan	Membuktikan kontribusi fitur kelembapan dalam peningkatan model gradient booting
Ablasi fitur penyinaran matahari (SS)	Menghilangkan fitur penyinaran matahari pada dataset untuk prediksi hujan	Membuktikan kontribusi fitur penyinaran matahari dalam peningkatan model gradient boosting

Untuk memberikan pemahaman yang lebih mendalam mengenai faktor-faktor yang berkontribusi terhadap performa Model sebagai model terbaik, dilakukan studi ablasi (*ablation study*). Studi ini bertujuan untuk mengevaluasi signifikansi setiap komponen penyusun dari sisi fitur meteorologi dengan cara menonaktifkan atau memodifikasi satu komponen tertentu secara bergantian dan mengamati dampaknya terhadap nilai error (RMSE).

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil

Pada Sub Bab ini terdapat penjelasan tentang analisis hasil uji coba pengujian model yang berdasarkan dengan skenario pengujian, dimana terdapat 4 komposisi dengan parameter baseline dan optimized. Masing-masing model akan di uji dengan menggunakan algoritma Gradient Boosting Regressor dengan parameter default dan parameter yang teroptimasi. Parameter yang digunakan untuk optimasi adalah parameter *learning_rate* dengan rentang 0,01 hingga 0,2, *max_dept* dengan rentang 2 hingga 6, *n_estimator* dengan rentang 100 hingga 500 dan *subsample* 0,7 hingga 0,3. Sehingga setiap model yang teroptimasi nantinya kemungkinan terdapat hyperparameter yang berbeda. Pada pencarian parameter terbaik sendiri menggunakan teknik *RandomSerachCV*. *RandomSearcCV* digunakan untuk mencari parameter terbaik dalam membentuk model yang optimal sehingga menghasilkan nilai akurasi yang terbaik dengan *cross validation*. Untuk iteration yang digunakan untuk mencari parameter optimal dengan *RandomSearchCV* adalah 50. Karena dengan iteration 50 model tidak akan terlalu lama sehingga ideal untuk memproses pencarian dan juga dapat menemukan parameter terbaik dengan sempurna tidak kebanyakan dan tidak terlalu sedikit. Nilai yang dihasilkan adalah berupa skor terbaik RMSE yang menjadi skor rata-rata akurasi silang tertinggi. Pengujian ini berguna untuk mengetahui performa metode Gradient Boosting Regressor pada sistem dalam memprediksi curah hujan harian dengan menggunakan data sebanyak 942. Setelah skenario pengujian dilakukan dan mendapatkan beberapa nilai akurasi dalam menggunakan metode Gradient Boosting Regressor selanjutnya model yang telah dibangun perlu dilakukan evaluasi untuk mengetahui kinerja metode Gradient Boosting dalam memprediksi curah hujan harian menggunakan teknik evaluasi yang telah dipaparkan pada sub bab 3.2.6.

4.1.1 Perhitungan Gradient Boosting

Perhitungan manual algoritma Gradient Boosting tetapkan Learning Rate (η) = 0.1.

1. Data Input (5 Baris Teratas)

Tabel 4. 1 Data Input

No	TN	TX	TAVG	RH_AVG	SS	FF_X	FF_AVG	DDD_X	Target RR (y)
1	22.4	27.2	25.1	69	2.7	6	4	300	0.1
2	21.8	30.8	24.7	78	2.1	7	2	180	1.6
3	20.3	30.0	24.6	78	2.7	5	2	320	4.4
4	20.2	30.9	25.4	74	5.1	4	2	250	6.2
5	21.2	30.0	25.2	76	7.7	6	2	180	0.0

2. Langkah Perhitungan Manual

Langkah 1: Inisialisasi Prediksi Awal (F_0)

Prediksi awal untuk regresi adalah rata-rata dari seluruh nilai target y.

$$F_0(x) = \frac{1}{n} \sum_{i=1}^n y_i \quad (8)$$

$$\begin{aligned}
 F_0(x) &= 0.1+1.6+4.4+6.2+0.0 / 5 \\
 &= 12.3 / 5 \\
 &= 2.46
 \end{aligned}$$

Jadi, pada tahap awal sebelum melihat fitur model memprediksi curah hujan sebesar 2.46 mm untuk semua data.

Langkah 2: Hitung Residu (Error) Tahap 1 ($r_{i,1}$)

Residu dihitung dengan

$$r_i = y_i - F_0(x) \quad (9)$$

$$\begin{aligned}
 r_1 &= 0.1 - 2.46 \\
 &= -2.36
 \end{aligned}$$

$$\begin{aligned} r_2 &= 1.6 - 2.46 \\ &= -0.86 \end{aligned}$$

$$\begin{aligned} r_3 &= 4.4 - 2.46 \\ &= 1.94 \end{aligned}$$

$$\begin{aligned} r_4 &= 6.2 - 2.46 \\ &= 3.74 \end{aligned}$$

$$\begin{aligned} r_5 &= 0.0 - 2.46 \\ &= -2.46 \end{aligned}$$

Langkah 3: Membuat Pohon Keputusan Pertama $h_m(x)$

- Hitung MSE sebelum split.

$$\begin{aligned} MSE &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \\ &= \frac{(-2.36)^2 + (-0.86)^2 + 1.94^2 + 3.74^2 + (-2.46)^2}{5} \\ &= \frac{5.56 + 0.73 + 3.76 + 13.98 + 6.05}{5} \\ MSE_{awal} &= 6.01 \end{aligned} \tag{10}$$

Model (Weak Learner) akan mencoba memprediksi rerata residu di atas menggunakan fitur-fitur yang ada.

- Menghitung split pada $TN < 22.4$
- Node kiri :
Residu = -2.36
Mean = -2.36
 MSE kiri = 0, karena hanya satu data
- Node Kanan :
Residu = -0.86, 1.94, 3.74, -2.46
Mean = 0.59

$$MSE \text{ kanan} = \frac{(-0.86)^2 + 1.94^2 + 3.74^2 + (-2.46)^2}{4}$$

$$= 6.13$$

$$MSE \text{ split} = \frac{1}{5}(0) + \frac{4}{5}(6.13)$$

$$= 4.90$$

- Hitung pengurangan $MSE = 6.01 - 4.90 = 1.11$
- Pohon pertama $TN < 1.11$ dengan rata-rata :

$$h_1(x) = -2.41$$

$$h_2(x) = -0.86$$

$$h_3(x) = 1.94$$

$$h_4(x) = 3.74$$

$$h_5(x) = -2.41$$

Langkah 4: Memperbarui Prediksi F_1

menghitung prediksi baru dengan menjumlahkan prediksi lama + (Learning Rate $\times$ hasil prediksi pohon baru).

$$F_m(x) = F_0(x) + \gamma \cdot h_m(x) \quad (11)$$

$$F_1(x): 2.46 + 0.1(-2.41) = 2.219$$

$$F_2(x): 2.46 + 0.1(-0.86) = 2.374$$

$$F_3(x): 2.46 + 0.1(1.94) = 2.654$$

$$F_4(x): 2.46 + 0.1(3.74) = 2.834$$


$$F_5(x): 2.46 + 0.1(-2.41) = 2.219$$

4.1.2 Pengujian Komposisi 50:50

Pada pengujian Komposisi 50:50 ini menggunakan perbandingan 50/50 yaitu 50% untuk data training dan 50% untuk data testing. Sehingga pada total data yang 942 data, digunakan untuk data training sebanyak 471 data, dan digunakan untuk data testing juga sebanyak 471 data. Pada pengujian yang dilakukan terdapat pengujian untuk gradient boosting baseline dan gradient boosting optimized dengan teknik RandomSearchCV.

4.1.2.1 Baseline


Pengujian pada skenario baseline dilakukan sebagai langkah krusial untuk menetapkan tolok ukur performa model sebelum dilakukan perbaikan atau optimasi. Pada skenario ini, algoritma Gradient Boosting Regressor dijalankan menggunakan konfigurasi parameter standar yang ditetapkan secara default oleh pustaka scikit-learn, tanpa melalui proses lebih lanjut. Pengujian ini bertujuan untuk mengevaluasi sejauh mana kemampuan alami algoritma dalam memetakan hubungan antara variabel meteorologi dengan intensitas curah hujan harian tanpa intervensi optimasi.



Gambar 4. 1 Visualsasi Training, Testing, dan Prediksi Komposisi 50:50 Baseline


Pada Gambar 4.1 terlihat bahwa data training dan data testing terpisah oleh garis putus-putus berwarna hitam. Sehingga data training adalah data yang digunakan untuk fitting model sedangkan data testing adalah data yang digunakan untuk pengujian model setelah di fitting. Terlihat bahwa prediksi curah hujan dengan curah hujan berdasarkan data actual BMKG berbeda. Terlihat bahwa curah hujan ekstrem masih tidak dapat di prediksi khususnya untuk curah hujan diatas 40 mm. Sehingga model baseline cenderung menangkap pola tren secara kasar, namun terdapat kesenjangan yang jelas antara puncak curah hujan actual dan nilai prediksi. Visualisasi menunjukkan bahwa pada data testing atau data pengujian model gagal merespons volatilitas curah hujan yang tinggi. Prediksi cenderung menjadi datar saat terjadi intensitas hujan yang melampaui rata-rata data latih. Penggunaan komposisi 50/50 menyebabkan model hanya memiliki setengah informasi untuk

data historis dalam mempelajari pola tren curah hujan. Akibatnya model tidak sempurna untuk memahami variabilitas musim hujan yang kompleks karena data latih yang tersedia kurang representative dibandingkan dengan data latih yang lebih besar. Karena ini adalah scenario baseline, model tidak memiliki fleksibilitas untuk menyesuaikan diri dengan karakteristik noise pada data cuaca. Visualisasi ini menunjukkan bahwa konfigurasi standar tidak cukup untuk menutupi keterbatasan jumlah data latih yang hanya 50%. Analisis ini menunjukkan bahwa model mengalami underfitting. Kesenjangan pada visualisasi bukan disebabkan oleh data leakage, melainkan karena keterbatasan learning capacity model dalam memetakan fungsi curah hujan dengan dataset training yang terlalu ringkas.



Gambar 4. 2 Scater Plot Aktual dan Prediksi Komposisi 50:50 Baseline

Visualisasi pengujian skenario baseline dengan komposisi data 50/50 menunjukkan performa prediksi yang kurang optimal. Berdasarkan scatterplot, sebaran titik prediksi yang menjauh dari garis diagonal ideal mengonfirmasi adanya tingkat bias yang tinggi. Hal ini dianalisis sebagai konsekuensi dari terbatasnya jumlah observasi pada data latih, yang menghambat algoritma Gradient Boosting dalam menangkap variabilitas musim hujan secara utuh. Selain itu, pada grafik time series, terlihat jelas bahwa model cenderung melakukan perataan yang berlebihan pada data uji, gagal merespons lonjakan curah hujan harian. Kegagalan visual ini menjadi justifikasi empiris bahwa pembagian 50/50 pada model baseline tidak memadai untuk mencapai generalisasi yang handal, sehingga diperlukan peningkatan jumlah data latih serta optimasi parameter agar model mampu mengidentifikasi pola cuaca dengan lebih presisi.



Gambar 4. 3 Evaluasi Model Komposisi 50:50 Baseline

Berdasarkan evaluasi kinerja, model menunjukkan hasil yang belum optimal dengan nilai R² sebesar 0.078. Hal ini mengindikasikan bahwa model belum mampu menangkap pola variabilitas curah hujan harian dengan lebih baik dibandingkan metode rata-rata sederhana. Adanya kesenjangan yang lebar antara

MAE (5.797) dan RMSE (11.285) menegaskan bahwa model memiliki instabilitas yang tinggi, terutama saat menghadapi lonjakan curah hujan atau kejadian ekstrem. Secara analitis, hal ini menunjukkan bahwa model mengalami *underfitting* dan memerlukan perbaikan pada strategi pra-pemrosesan data, penambahan variabel meteorologi pendukung, atau optimasi hyperparameter yang lebih agresif untuk meningkatkan sensitivitas terhadap pola cuaca yang non-linear.

4.1.2.2 Optimized

Pengujian pada skenario optimized dilakukan dengan menerapkan konfigurasi parameter yang telah dipilih melalui proses pencarian empiris menggunakan RandomizedSearchCV. Berbeda dengan skenario baseline, pengujian ini melibatkan mekanisme pencarian hyperparameter pada ruang parameter yang mencakup variasi kedalaman pohon (*max_depth*), laju pembelajaran (*learning_rate*), jumlah estimasi (*n_estimators*), dan fraksi subsampel (*subsample*). Tujuan utama dari pengujian ini adalah untuk memaksimalkan kemampuan model dalam meminimalisir fungsi kerugian (*loss function*) dengan mengadaptasi kompleksitas model secara spesifik terhadap karakteristik data meteorologi harian yang bersifat stokastik. Validasi silang menggunakan TimeSeriesSplit diintegrasikan secara ketat dalam tahap ini untuk memastikan bahwa parameter yang terpilih tidak hanya berkinerja baik pada satu lipatan data, tetapi stabil di berbagai periode waktu yang berbeda, sehingga meminimalisir risiko kebocoran data (*data leakage*) yang sering terjadi pada pemodelan deret waktu. Berikut ini adalah hasil pencarian hyperparameter menggunakan RandomSerachCV :

Tabel 4. 2 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 50:50

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
1	0.084908	2	370	0.919598	13.364366
2	0.129732	4	221	0.746798	13.373215
3	0.021617	5	472	0.880335	12.889722

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
4	0.151615	3	408	0.990973	13.718331
5	0.176489	3	485	0.754547	13.566354
6	0.046681	5	413	0.857427	13.050849
7	0.096389	2	158	0.819958	13.294020
8	0.019333	5	370	0.836821	12.930245
9	0.167035	4	463	0.854270	13.385374
10	0.128483	4	406	0.904092	12.900470
11	0.100100	3	487	0.982661	13.498029
12	0.122658	3	364	0.704790	13.656354
13	0.056179	5	466	0.904979	12.904952
14	0.131999	5	134	0.972796	13.146841
15	0.061756	5	487	0.793513	13.169397
16	0.114014	3	359	0.755456	13.300064
17	0.203917	3	143	0.981850	13.454792
18	0.188965	3	450	0.976562	13.801461
19	0.027699	4	351	0.713568	12.931938
20	0.075066	5	336	0.781405	13.010337
21	0.175748	3	316	0.784280	13.576838
22	0.118539	2	256	0.940659	13.586082
23	0.024910	4	108	0.931673	12.390020
24	0.049743	5	162	0.944638	12.854163
25	0.151371	4	388	0.881788	13.028823
26	0.195260	3	140	0.974488	13.452283
27	0.180008	5	132	0.719068	13.650147
28	0.072196	5	392	0.918882	13.110582
29	0.137511	4	134	0.841664	13.181157
30	0.033919	3	230	0.928236	12.757058
31	0.122255	4	497	0.848139	13.073560

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
32	0.114547	4	445	0.707626	13.290461
33	0.031578	4	451	0.890923	12.876128
34	0.072871	5	487	0.972270	13.284592
35	0.059858	2	242	0.926665	13.033712
36	0.055760	5	426	0.786925	12.964386
37	0.042244	3	269	0.942436	12.901712
38	0.136681	3	383	0.941102	13.385904
39	0.047314	3	430	0.797304	13.022513
40	0.034418	2	330	0.972049	12.999823
41	0.064426	4	220	0.945404	13.073428
42	0.182146	4	297	0.853224	13.357436
43	0.093482	2	324	0.735960	13.828538
44	0.077523	4	414	0.796961	13.116267
45	0.113758	2	279	0.809089	13.277698
46	0.204356	5	367	0.775535	13.518258
47	0.109450	2	200	0.785452	13.202283
48	0.017377	2	101	0.850804	12.490955
49	0.020296	2	323	0.972480	12.695428
50	0.057912	3	152	0.846836	12.810003

Pada table 4.2 menunjukan bahwa nilai parameter terbaik pada model komposisi 50:50 untuk setiap kombinasinya adalah pada *learning_rate* 0.024910, *depth* 4, *n_estimator* 108, dan *subsample* 0.931673 dengan rata-rata sebesar 12.390020. Sehingga pada pengujian model komposisi 50:50 yang dilakukan telah mendapatkan kombinasi parameter yang optimal.

Fokus pada parameter *learning_rate* dengan hasil rata-rata tertinggi dan terendah yaitu pada *learning_rate* 0.024910 dan 0.093482 nilai uji skornya masing masing adalah 12.390020 dan 13.828538. Terlihat bahwa bertambahnya nilai *learning_rate* hasil uji skor rata-ratanya ikut bertambah sehingga menunjukan


bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *learning_rate* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.

Selanjutnya fokus kepada parameter *depth* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *depth* 2 dan hasil uji skor rata-rata terendah adalah pada *depth* 4. Terlihat bahwa bertambahnya nilai *depth* dari 2 ke 4 hasil uji skor rata-ratanya berkurang sehingga menunjukkan bahwa model semakin baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *depth* semakin bertambah maka nilai rata-rata hasil uji akan semakin menurun yang menyebabkan peningkatan performa pada model.

Selanjutnya fokus kepada parameter *n_estimator* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *n_estimator* 324 dan hasil uji skor rata-rata terendah adalah pada *n_estimator* 108. Terlihat bahwa bertambahnya nilai *n_estimator* dari 108 ke 324 hasil uji skor rata-ratanya juga ikut bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *n_estimator* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.

Selanjutnya fokus kepada parameter *subsample* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *subsample* 0.735960 dan hasil uji skor rata-rata terendah adalah pada *subsample* 0.931673. Terlihat bahwa berkurangnya nilai *subsample* hasil uji skor rata-ratanya bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *subsample* semakin bertambah maka nilai rata-rata hasil uji akan semakin berkurang yang menyebabkan peningkatan performa pada model.


Kombinasi parameter yang sudah ditemukan optimal maka akan digunakan untuk pengujian pada data training dan data testing sehingga menghasilkan nilai yang optimal juga. Hasil pengujian pada skenario ini menunjukkan peningkatan performa yang sangat signifikan dalam menangkap variabilitas curah hujan. Dengan adanya penyesuaian *learning_rate* yang lebih rendah yang dikombinasikan dengan jumlah *n_estimators* yang lebih besar, model mampu melakukan koreksi kesalahan secara lebih halus dan presisi. Berikut ini adalah visualisasi data training, testing, dan prediksi pada model Komposisi 50:50 dengan optimized RandomSerchCV.



Gambar 4. 4 Visualsasi Training, Testing, dan Prediksi Komposisi 50:50 Optimized

Gambar 4.4 menyajikan visualisasi *time series* antara data latih (biru), data uji aktual (oranye), dan hasil prediksi model (hijau putus-putus). Secara visual, model menunjukkan pola yang disebut dengan *underestimation* pada kejadian curah hujan ekstrem. Meskipun model berhasil menangkap pola dasar fluktuasi hujan (variabilitas tingkat rendah), model secara konsisten gagal memprediksi lonjakan curah hujan yang signifikan (di atas 40 mm) pada data uji. Hal ini mengindikasikan bahwa model memiliki bias yang cukup tinggi dan cenderung melakukan perataan (*smoothing*) terhadap data, di mana model lebih memilih memprediksi nilai rata-rata daripada mencoba memprediksi titik ekstrem. Fenomena ini diperburuk oleh distribusi data yang tidak seimbang, di mana frekuensi kejadian hujan ekstrem jauh lebih sedikit daripada hari tanpa hujan atau hujan ringan, sehingga model belajar bahwa memprediksi nilai rendah adalah strategi yang meminimalkan *error* secara


keseluruhan. Untuk mengetahui seberapa baik model memprediksi nilai aslinya penelitian ini menggunakan scatter plot pada skenario ini yang hasilnya adalah seperti dibawah ini.



Gambar 4. 5 Scater Plot Aktual dan Prediksi Komposisi 50:50 Optimized

Gambar 4.5 menampilkan *scatterplot* antara nilai aktual dan nilai prediksi curah hujan. Garis diagonal putus-putus merepresentasikan kondisi ideal di mana nilai prediksi sama persis dengan nilai aktual $y = x$. Visualisasi menunjukkan pola sebaran data yang terakumulasi di bawah garis diagonal, khususnya pada nilai aktual yang lebih besar dari 20 mm. Hal ini memberikan bukti empiris adanya bias *underestimation* yang sistematis; model cenderung memprediksi nilai yang jauh lebih rendah daripada intensitas curah hujan yang sebenarnya terjadi. Selain itu,

sebaran titik-titik yang terkonsentrasi di area kiri bawah (mendekati 0 mm) menunjukkan bahwa model lebih mampu memberikan prediksi akurat pada kondisi cuaca kering atau hujan ringan. Namun, ketidakhadiran titik-titik di sepanjang garis diagonal untuk nilai yang lebih tinggi mengonfirmasi bahwa model belum mampu menangkap dependensi non-linear untuk kejadian curah hujan ekstrem, yang berkontribusi langsung pada rendahnya nilai R^2 yang diperoleh.



Gambar 4. 6 Evaluasi Model Komposisi 50:50 Optimized

Pada Gambar 4.6 evaluasi kinerja model menunjukkan nilai R^2 sebesar 0.167, yang mengindikasikan bahwa model telah berhasil mengatasi keterbatasan pada model sebelumnya dengan memberikan prediksi yang lebih informatif daripada metode rata-rata sederhana. Penurunan nilai MAE ke angka 5.531 menunjukkan bahwa model memiliki kesalahan prediksi rata-rata sebesar 5.531 mm. Angka ini lebih rendah dibandingkan evaluasi sebelumnya, yang berarti tingkat akurasi prediksi harian secara umum telah membaik dan menunjukkan peningkatan akurasi pada prediksi harian secara umum. Namun, nilai RMSE yang berada di angka 10.727 mengonfirmasi bahwa kesalahan besar pada hujan ekstrem masih menjadi penyumbang utama ketidakakuratan model. Selisih yang tetap signifikan


antara RMSE dan MAE mengindikasikan bahwa model masih kesulitan saat harus memprediksi lonjakan hujan di atas 30–40 mm dan nilai ini mengonfirmasi bahwa tantangan utama model masih terletak pada estimasi kejadian curah hujan ekstrem. Secara teoretis, R^2 sebesar 0,167 mencerminkan sifat curah hujan yang stokastik dan sangat dipengaruhi oleh faktor mikroklimat yang mungkin belum sepenuhnya terwakili oleh fitur yang digunakan. Oleh karena itu, meskipun model telah menunjukkan kemajuan dalam generalisasi, diperlukan integrasi fitur meteorologi tambahan atau teknik *ensemble* yang lebih kompleks untuk meningkatkan sensitivitas model terhadap variabilitas cuaca yang tinggi.

4.1.3 Pengujian Komposisi 70:30

Pada pengujian Komposisi 70:30 ini menggunakan perbandingan 70/30 yaitu 70% untuk data training dan 30% untuk data testing. Sehingga pada total data yang 942 data, digunakan untuk data training sebanyak 659 data, dan digunakan untuk data testing juga sebanyak 283 data. Pada pengujian yang dilakukan terdapat pengujian untuk gradient boosting baseline dan gradient boosting optimized dengan teknik RandomSearchCV.

4.1.3.1 Baseline


Pengujian pada skenario baseline pada komposisi 70/30 dilakukan sebagai langkah krusial untuk menetapkan tolok ukur performa model sebelum dilakukan perbaikan atau optimasi. Pada skenario ini, algoritma Gradient Boosting Regressor dijalankan menggunakan konfigurasi parameter standar yang ditetapkan secara default oleh pustaka scikit-learn, tanpa melalui proses lebih lanjut. Pengujian ini bertujuan untuk mengevaluasi sejauh mana kemampuan alami algoritma dalam memetakan hubungan antara variabel meteorologi dengan intensitas curah hujan harian tanpa intervensi optimasi.



Gambar 4. 7 Visualisasi Training, Testing dan Prediksi Komposisi 70:30 Baseline

Pada Gambar 4.7 menampilkan hasil prediksi model *baseline* dengan pembagian komposisi data latih dan uji sebesar 70/30. Secara visual, peningkatan porsi data latih menjadi 70% memberikan dampak positif terhadap kemampuan generalisasi model. Dibandingkan dengan skenario 50/50, garis prediksi (hijau putus-putus) pada skenario ini terlihat lebih dinamis dan mampu merespons lonjakan curah hujan dengan intensitas yang lebih tinggi. Meskipun model masih menunjukkan gejala *underestimation* pada puncak-puncak curah hujan yang ekstrem di atas 60 mm, model kini mampu mengikuti pola fluktuasi harian dengan tingkat sensitivitas yang lebih baik. Peningkatan porsi data latih memungkinkan algoritma *Gradient Boosting* untuk lebih memahami variasi pola cuaca musiman yang ada pada dataset. Namun, adanya kesenjangan pada periode curah hujan tinggi tetap mengonfirmasi bahwa konfigurasi *baseline* belum cukup optimal untuk menangani karakteristik data yang sangat *skewed*, sehingga diperlukan optimasi parameter lebih lanjut untuk meningkatkan akurasi pada nilai-nilai ekstrem. Dengan 70% data latih, model lebih jarang mengalami *underfitting* karena cakupan data historisnya lebih merepresentasikan variasi musim, sehingga prediksi pada data uji menjadi lebih stabil. Meskipun performanya lebih baik, model masih menampilkan 'smoothing effect'. Ini adalah perilaku alami *Gradient Boosting* standar yang membatasi kompleksitas pohon keputusan agar tidak terlalu sensitif terhadap *noise*, yang sebenarnya bagus untuk mencegah *overfitting* tapi kurang optimal untuk mendeteksi *outlier*. Untuk mengetahui seberapa baik model Komposisi 70:30 baseline memprediksi nilai aslinya penelitian ini menggunakan


scatter plot pada skenario ini yang hasilnya adalah seperti dibawah ini.



Gambar 4. 8 Scater Plot Aktual dan Prediksi Komposisi 70:30 Baseline

Gambar 4.8 menampilkan *scatterplot* antara nilai aktual dan prediksi curah hujan dengan komposisi data 70/30. Dibandingkan dengan komposisi sebelumnya, sebaran titik prediksi pada skenario ini menunjukkan peningkatan kapasitas *learning* model. Terlihat bahwa titik-titik data mulai tersebar lebih luas mengikuti arah garis diagonal $y=x$, terutama pada rentang nilai intensitas hujan 10–30 mm. Hal ini menandakan bahwa penambahan porsi data latih menjadi 70% telah memberikan model basis pengetahuan yang lebih kaya untuk mengenali pola cuaca yang bervariasi. Namun, pada nilai aktual di atas 40 mm, model masih menunjukkan kecenderungan *underestimation* yang konsisten, di mana prediksi

tertahan di bawah 30 mm. Hal ini mengonfirmasi bahwa meskipun *learning capacity* model meningkat dengan penambahan data, konfigurasi *baseline* belum mampu melakukan optimasi pada *residual error* untuk nilai-nilai ekstrem, yang secara statistik menyebabkan model tetap memiliki keterbatasan dalam memprediksi kejadian curah hujan lebat secara akurat. Hal ini menunjukkan bahwa penambahan data latih sebesar 20% yaitu dari 50% menjadi 70% secara langsung meningkatkan kemampuan model untuk mengenali pola yang lebih kompleks. Model tidak lagi hanya terpaku pada nilai rata-rata yang sangat rendah. Namun, kita harus jujur bahwa pada angka di atas 40 mm, model masih ragu untuk memberikan prediksi tinggi. Ini adalah sinyal teknis bahwa keterbatasan performa pada area ekstrem bukan disebabkan oleh kurangnya data, melainkan oleh parameter model yang masih bersifat standar. Perbedaan utama dari Komposisi 50:50 dan Komposisi 70:30 adalah peningkatan *variance coverage* bahwa 70/30 memberikan cakupan variasi musim yang lebih lengkap, sehingga model lebih stabil dalam mengenali pola hari-hari hujan dibandingkan komposisi 50/50 yang mungkin hanya menangkap satu fragmen musim saja.



Gambar 4. 9 Evaluasi Model Komposisi 70:30 Baseline

Hasil evaluasi pada komposisi 70/30 baseline menunjukkan nilai R^2 sebesar 0.048 dan RMSE sebesar 12.222. Penurunan performa dibandingkan skenario sebelumnya menunjukkan bahwa penambahan porsi data latih tidak selalu berkorelasi linier dengan peningkatan akurasi jika tidak dibarengi dengan optimasi model. Secara analitis, hal ini mengindikasikan adanya *instabilitas generalisasi*, di mana model mungkin mengalami *overfitting* pada pola tertentu di data latih yang tidak relevan dengan karakteristik data uji yaitu 30% data terakhir. Sehingga prediksi yang dihasilkan justru memiliki tingkat kesalahan yang lebih tinggi daripada model sebelumnya. Dalam pemodelan deret waktu (*time series*), data yang lebih baru yaitu 30% data terakhir mungkin memiliki karakteristik musiman yang sangat berbeda dengan data sebelumnya. Jika model *baseline* bersifat kaku dan tidak dioptimasi, ia akan cenderung menggunakan pola dari data masa lalu yang sudah tidak relevan, yang menyebabkan peningkatan *error* justru setelah kita menambah data latih. Ini memperkuat justifikasi mengapa saya menerapkan RandomizedSearchCV di tahap selanjutnya, yaitu untuk mencari konfigurasi yang mampu beradaptasi dengan perubahan pola cuaca tersebut.

4.1.3.2 Optimized

Pengujian pada skenario optimized dalam komposisi 70/30 dilakukan dengan menerapkan konfigurasi parameter yang telah dipilih melalui proses pencarian empiris menggunakan RandomizedSearchCV. Berbeda dengan skenario baseline, pengujian ini melibatkan mekanisme pencarian hyperparameter pada ruang parameter yang mencakup variasi kedalaman pohon (*max_depth*), laju pembelajaran (*learning_rate*), jumlah estimasi (*n_estimators*), dan fraksi subsampel (*subsample*). Tujuan utama dari pengujian ini adalah untuk memaksimalkan kemampuan model dalam meminimalisir fungsi kerugian (*loss function*) dengan mengadaptasi kompleksitas model secara spesifik terhadap karakteristik data meteorologi harian yang bersifat stokastik. Validasi silang menggunakan TimeSeriesSplit diintegrasikan secara ketat dalam tahap ini untuk memastikan bahwa parameter yang terpilih tidak hanya berkinerja baik pada satu lipatan data, tetapi stabil di berbagai periode waktu yang berbeda, sehingga meminimalisir risiko

kebocoran data (data leakage) yang sering terjadi pada pemodelan deret waktu. Berikut ini adalah hasil pencarian hyperparameter menggunakan RandomSerachCV :

Tabel 4. 3 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 70:30

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
1	0.084908	2	370	0.919598	13.364366
2	0.129732	4	221	0.746798	13.373215
3	0.021617	5	472	0.880335	12.889722
4	0.151615	3	408	0.990973	13.718331
5	0.176489	3	485	0.754547	13.566354
6	0.046681	5	413	0.857427	13.050849
7	0.096389	2	158	0.819958	13.294020
8	0.019333	5	370	0.836821	12.930245
9	0.167035	4	463	0.854270	13.385374
10	0.128483	4	406	0.904092	12.900470
11	0.100100	3	487	0.982661	13.498029
12	0.122658	3	364	0.704790	13.656354
13	0.056179	5	466	0.904979	12.904952
14	0.131999	5	134	0.972796	13.146841
15	0.061756	5	487	0.793513	13.169397
16	0.114014	3	359	0.755456	13.300064
17	0.203917	3	143	0.981850	13.454792
18	0.188965	3	450	0.976562	13.801461
19	0.027699	4	351	0.713568	12.931938
20	0.075066	5	336	0.781405	13.010337
21	0.175748	3	316	0.784280	13.576838
22	0.118539	2	256	0.940659	13.586082
23	0.024910	4	108	0.931673	12.390020

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
24	0.049743	5	162	0.944638	12.854163
25	0.151371	4	388	0.881788	13.028823
26	0.195260	3	140	0.974488	13.452283
27	0.180008	5	132	0.719068	13.650147
28	0.072196	5	392	0.918882	13.110582
29	0.137511	4	134	0.841664	13.181157
30	0.033919	3	230	0.928236	12.757058
31	0.122255	4	497	0.848139	13.073560
32	0.114547	4	445	0.707626	13.290461
33	0.031578	4	451	0.890923	12.876128
34	0.072871	5	487	0.972270	13.284592
35	0.059858	2	242	0.926665	13.033712
36	0.055760	5	426	0.786925	12.964386
37	0.042244	3	269	0.942436	12.901712
38	0.136681	3	383	0.941102	13.385904
39	0.047314	3	430	0.797304	13.022513
40	0.034418	2	330	0.972049	12.999823
41	0.064426	4	220	0.945404	13.073428
42	0.182146	4	297	0.853224	13.357436
43	0.093482	2	324	0.735960	13.828538
44	0.077523	4	414	0.796961	13.116267
45	0.113758	2	279	0.809089	13.277698
46	0.204356	5	367	0.775535	13.518258
47	0.109450	2	200	0.785452	13.202283
48	0.017377	2	101	0.850804	12.490955
49	0.020296	2	323	0.972480	12.695428
50	0.057912	3	152	0.846836	12.810003

Pada tabel 4.3 menunjukan bahwa nilai parameter terbaik pada model

komposisi 50:50 untuk setiap kombinasinya adalah pada *learning_rate* 0.024910, *depth* 4, *n_estimator* 108, dan *subsample* 0.931673 dengan rata-rata sebesar 12.390020. Sehingga pada pengujian model komposisi 70:30 yang dilakukan telah mendapatkan kombinasi parameter yang optimal.

Fokus pada parameter *learning_rate* dengan hasil rata-rata tertinggi dan terendah yaitu pada *learning_rate* 0.024910 dan 0.093482 nilai uji skornya masing masing adalah 12.390020 dan 13.828538. Terlihat bahwa bertambahnya nilai *learning_rate* hasil uji skor rata-ratanya ikut bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *learning_rate* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.


Selanjutnya fokus kepada parameter *depth* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *depth* 2 dan hasil uji skor rata-rata terendah adalah pada *depth* 4. Terlihat bahwa bertambahnya nilai *depth* dari 2 ke 4 hasil uji skor rata-ratanya berkurang sehingga menunjukkan bahwa model semakin baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *depth* semakin bertambah maka nilai rata-rata hasil uji akan semakin menurun yang menyebabkan peningkatan performa pada model.

Selanjutnya fokus kepada parameter *n_estimator* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *n_estimator* 324 dan hasil uji skor rata-rata terendah adalah pada *n_estimator* 108. Terlihat bahwa bertambahnya nilai *n_estimator* dari 108 ke 324 hasil uji skor rata-ratanya juga ikut bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *n_estimator* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.

Selanjutnya fokus kepada parameter *subsample* dengan hasil tertinggi dan

terendah yaitu pada nilai `meant_test_score` 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada `subsample` 0.735960 dan hasil uji skor rata-rata terendah adalah pada `subsample` 0.931673. Terlihat bahwa berkurangnya nilai `subsample` hasil uji skor rata-ratanya bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai `subsample` semakin bertambah maka nilai rata-rata hasil uji akan semakin berkurang yang menyebabkan peningkatan performa pada model.


Kombinasi parameter yang sudah ditemukan optimal maka akan digunakan untuk pengujian pada data training dan data testing sehingga menghasilkan nilai yang optimal juga. Hasil pengujian pada skenario ini menunjukkan peningkatan performa yang sangat signifikan dalam menangkap variabilitas curah hujan. Dengan adanya penyesuaian `learning_rate` yang lebih rendah yang dikombinasikan dengan jumlah `n_estimators` yang lebih besar, model mampu melakukan koreksi kesalahan secara lebih halus dan presisi. Berikut ini adalah visualisasi data training, testing, dan prediksi pada model komposisi 70:30 dengan optimized RandomSerchCV.



Gambar 4. 10 Visualisasi Training, Testing, dan Prediksi Komposisi 70:30 Optimized

Gambar 4.10 menyajikan visualisasi *time series* model *optimized* dengan komposisi data 70/30. Berbeda dengan skenario *baseline*, hasil prediksi pada skenario ini menunjukkan peningkatan signifikan dalam hal responsivitas terhadap fluktuasi curah hujan. Garis prediksi (hijau) kini mampu mengikuti pola tren curah


hujan aktual (oranye) dengan deviasi yang jauh lebih kecil. Peningkatan paling krusial terlihat pada kemampuan model dalam menangkap lonjakan intensitas hujan (hingga di atas 40 mm), di mana model *optimized* berhasil melakukan estimasi yang lebih mendekati nilai aktual dibandingkan model *baseline* yang cenderung *flat*. Keberhasilan ini adalah hasil langsung dari *hyperparameter tuning* yang telah mengadaptasi kompleksitas model agar tidak terjebak pada *underfitting*. Meskipun masih terdapat residu pada kejadian ekstrem, model ini telah menunjukkan kemampuan generalisasi yang jauh lebih tangguh dalam merepresentasikan dinamika curah hujan harian, menjadikannya instrumen yang jauh lebih andal untuk analisis meteorologi dibandingkan skenario sebelumnya. Jika pada *baseline* garis prediksi kita terlihat ragu-ragu saat bertemu hujan lebat, pada model *optimized* ini, garis prediksi jauh lebih responsif. Model kini mampu menangkap puncak-puncak curah hujan dengan jauh lebih presisi. Optimasi berhasil menyeimbangkan *learning rate* dan kedalaman pohon keputusan. Dengan *max_depth* yang tepat, model tidak menghafal *noise* (overfitting), tetapi juga tidak terlalu sederhana (underfitting), sehingga mampu mengekstraksi informasi berharga dari 70% data latih.



Gambar 4. 11 Scater Plot Altual dan Prediksi Komposisi 70:30 Optimized

Gambar 4.11 menyajikan *scatterplot* aktual versus prediksi untuk skenario *optimized* dengan komposisi 70/30. Visualisasi ini menunjukkan bahwa optimasi *hyperparameter* telah berhasil meningkatkan korelasi antara nilai prediksi dan aktual secara substansial. Terlihat adanya peningkatan kepadatan titik yang menyebar lebih mendekati garis diagonal $y=x$ pada rentang nilai curah hujan 10 sampai 40 mm. Hal ini membuktikan bahwa penalaan model berhasil mengurangi bias sistematis yang sebelumnya ditemukan pada skenario *baseline*. Meskipun masih terdapat residu pada nilai curah hujan ekstrem diatas 50 mm, model *optimized* menunjukkan peningkatan presisi yang lebih konsisten dibandingkan model *baseline* pada komposisi yang sama. Peningkatan ini mengonfirmasi bahwa

integrasi *RandomizedSearchCV* telah efektif dalam mengonfigurasi *gradient boosting* untuk menyeimbangkan *bias-variance tradeoff*, sehingga model mampu memberikan estimasi yang lebih stabil dalam merepresentasikan dinamika curah hujan dibandingkan konfigurasi standar.



Gambar 4. 12 Evaluasi Model Komposisi 70:30 Optimized

Pada Gambar 4.12 hasil evaluasi pada skenario *optimized* dengan komposisi 70/30 menunjukkan performa yang lebih stabil dan reliabel dibandingkan skenario *baseline* sebelumnya. Dengan nilai R² sebesar 0.135, model ini berhasil memberikan kontribusi positif dalam menjelaskan pola variabilitas curah hujan harian. Penurunan nilai MAE dan RMSE dibandingkan skenario *baseline* (70/30) menegaskan bahwa proses optimasi melalui *RandomizedSearchCV* telah berhasil meminimalkan bias model dan meningkatkan kemampuan generalisasi secara keseluruhan. Secara analitis, pencapaian ini membuktikan bahwa strategi optimasi yang tepat mampu mengimbangi kompleksitas data meteorologi, meskipun tantangan prediksi pada curah hujan ekstrem masih tetap ada akibat sifat data yang tidak seimbang (*skewed*). Model ini kini telah berada pada jalur yang benar untuk


memberikan estimasi yang lebih konsisten dibandingkan model konfigurasi standar. Dengan komposisi data yang sama (70/30), kita berhasil mengubah model dari yang sebelumnya nilai R^2 negatif menjadi model yang memberikan informasi prediktif yang valid dengan nilai R^2 positif. Ini membuktikan bahwa *pipeline* pra-pemrosesan dan optimasi yang saya rancang berhasil meningkatkan *reliability* model secara nyata.

4.1.4 Pengujian Komposisi 80:20

Pada pengujian Komposisi 80:20 ini menggunakan perbandingan 80/20 yaitu 80% untuk data training dan 20% untuk data testing. Sehingga pada total data yang 942 data, digunakan untuk data training sebanyak 753 data, dan digunakan untuk data testing juga sebanyak 159 data. Pada pengujian yang dilakukan terdapat pengujian untuk gradient boosting baseline dan gradient boosting optimized dengan teknik RandomSearchCV.


4.1.4.1 Baseline

Pengujian pada skenario baseline pada komposisi 80/20 dilakukan sebagai langkah krusial untuk menetapkan tolok ukur performa model sebelum dilakukan perbaikan atau optimasi. Pada skenario ini, algoritma Gradient Boosting Regressor dijalankan menggunakan konfigurasi parameter standar yang ditetapkan secara default oleh pustaka scikit-learn, tanpa melalui proses lebih lanjut. Pengujian ini bertujuan untuk mengevaluasi sejauh mana kemampuan alami algoritma dalam memetakan hubungan antara variabel meteorologi dengan intensitas curah hujan harian tanpa intervensi optimasi.



Gambar 4. 13 Visualisasi Training, Testing, dan Prediksi Komposisi 80:20 Baseline


Gambar 4.13 menampilkan visualisasi *time series* dengan komposisi 80/20 pada skenario *baseline*. Penambahan porsi data latih menjadi 80% secara teoretis memberikan informasi musiman yang lebih lengkap kepada model. Secara visual, garis prediksi (hijau) menunjukkan stabilitas yang lebih tinggi dibandingkan komposisi 50/50 dan 70/30. Namun, terlihat bahwa model masih terjebak pada karakteristik *baseline* yang konservatif, di mana prediksi cenderung melakukan perataan (*smoothing*) pada lonjakan curah hujan tinggi (di atas 40 mm). Meskipun model kini lebih konsisten dalam mengikuti tren curah hujan harian, kurangnya optimasi pada parameter model menyebabkan *underestimation* yang sistematis tetap terjadi. Hasil ini mengonfirmasi bahwa penambahan data saja tidak cukup untuk meningkatkan akurasi secara signifikan jika tidak diikuti dengan penyesuaian kompleksitas model, karena model *baseline* cenderung memiliki bias tinggi yang membatasi kemampuannya dalam melakukan ekstrapolasi pada nilai ekstrem. Visualisasi ini membuktikan bahwa strategi menambah data secara terus-menerus tidak akan memberikan peningkatan performa yang linier. Ini adalah pembenaran kuat mengapa tahap optimasi (skenario *optimized*) menjadi wajib dilakukan untuk membuka potensi penuh dari algoritma *Gradient Boosting*. hal ini terjadi karena model *Gradient Boosting* yang menggunakan *default parameter* akan selalu membatasi diri. Bahkan dengan 80% data, model ini tetap terbatas pada kedalaman pohon yang dangkal, sehingga ia gagal menangkap detail lonjakan hujan yang tajam.



Gambar 4. 14 Scater Plot Aktual dan Prediksi Komposisi 80:20 Baseline

Gambar 4.14 menampilkan *scatterplot* antara nilai aktual dan prediksi untuk komposisi 80/20 pada skenario *baseline*. Dengan porsi data latih mencapai 80%, model memiliki basis data yang paling komprehensif dibandingkan skenario sebelumnya. Secara visual, terjadi peningkatan kepadatan sebaran titik yang lebih rapat di area intensitas rendah (0–15 mm), yang mengindikasikan bahwa model mencapai stabilitas prediksi yang lebih tinggi pada kondisi cuaca normal. Namun, pada rentang nilai di atas 20 mm, model masih menunjukkan bias *underestimation* yang persisten. Sebaran titik yang tetap berada di bawah garis diagonal $y=x$ mengonfirmasi bahwa penambahan data latih saja tidak cukup untuk mengatasi batasan *learning capacity* dari konfigurasi *baseline*. Hal ini menyimpulkan bahwa

meskipun model menjadi lebih konsisten, bias bawaan model akibat penggunaan *hyperparameter* standar tetap mendominasi, sehingga model gagal melakukan generalisasi pada variabilitas tinggi curah hujan ekstrem. Ini adalah bukti empiris terkuat mengapa optimasi parameter adalah langkah yang sangat krusial. Penambahan data hanya memberikan stabilitas, tetapi optimasi parameterlah yang akan memberikan sensitivitas. Tanpa optimasi, model ini akan selalu terjebak pada bias konservatifnya, berapapun besarnya data latih yang kita masukkan.



Gambar 4. 15 Evaluasi Model Komposisi 80:20 Baseline

Pada Gambar 4.15 evaluasi kinerja pada komposisi 80/20 menunjukkan hasil yang paling optimal di antara seluruh skenario *baseline*, dengan nilai R2 sebesar 0,247. Peningkatan porsi data latih menjadi 80% terbukti meningkatkan kapasitas model dalam mempelajari pola temporal curah hujan, yang tercermin dari penurunan nilai RMSE dan perolehan R2 yang positif. Secara analitis, hal ini menunjukkan bahwa pada skenario *baseline*, keterbatasan performa dapat sedikit dimitigasi dengan penambahan durasi data historis. Meskipun demikian, model masih memiliki keterbatasan dalam memprediksi intensitas curah hujan ekstrem, yang ditunjukkan oleh selisih antara MAE dan RMSE. Hasil ini menjadi

pembandingan yang kuat bagi skenario *optimized*, di mana efisiensi *hyperparameter tuning* dapat melampaui performa model yang hanya mengandalkan penambahan volume data semata. Dengan nilai MAE 6.380 menunjukkan bahwa model memiliki rata-rata kesalahan sebesar 6.380 mm. Meskipun angka ini sedikit lebih tinggi dibandingkan skenario *optimized* 70/30, nilai ini cukup kompetitif bagi sebuah model *baseline*. Dengan nilai RMSE 10.229 menunjukkan bahwa *error* yang dihasilkan cukup terkendali. Selisih antara MAE dan RMSE yang tidak terlalu ekstrim mengindikasikan bahwa model *baseline* pada komposisi 80/20 tidak terlalu kaget saat menghadapi data uji, dibandingkan skenario 70/30 yang memiliki RMSE lebih tinggi. Dengan nilai R^2 0,247 mengonfirmasi bahwa dengan jumlah data latih yang lebih besar, model *baseline* mulai mampu menjelaskan 24% variabilitas data. Ini membuktikan bahwa volume data memiliki korelasi positif terhadap stabilitas model.

4.1.4.2 Optimized

Pengujian pada skenario *optimized* dalam komposisi 80/20 dilakukan dengan menerapkan konfigurasi parameter yang telah dipilih melalui proses pencarian empiris menggunakan `RandomizedSearchCV`. Berbeda dengan skenario *baseline*, pengujian ini melibatkan mekanisme pencarian *hyperparameter* pada ruang parameter yang mencakup variasi kedalaman pohon (`max_depth`), laju pembelajaran (`learning_rate`), jumlah estimasi (`n_estimators`), dan fraksi subsampel (`subsample`). Tujuan utama dari pengujian ini adalah untuk memaksimalkan kemampuan model dalam meminimalisir fungsi kerugian (*loss function*) dengan mengadaptasi kompleksitas model secara spesifik terhadap karakteristik data meteorologi harian yang bersifat stokastik. Validasi silang menggunakan `TimeSeriesSplit` diintegrasikan secara ketat dalam tahap ini untuk memastikan bahwa parameter yang terpilih tidak hanya berkinerja baik pada satu lipatan data, tetapi stabil di berbagai periode waktu yang berbeda, sehingga meminimalisir risiko kebocoran data (*data leakage*) yang sering terjadi pada pemodelan deret waktu. Berikut ini adalah hasil pencarian *hyperparameter* menggunakan `RandomSerachCV` :

Tabel 4. 4 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 80:20

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
1	0.084908	2	370	0.919598	13.364366
2	0.129732	4	221	0.746798	13.373215
3	0.021617	5	472	0.880335	12.889722
4	0.151615	3	408	0.990973	13.718331
5	0.176489	3	485	0.754547	13.566354
6	0.046681	5	413	0.857427	13.050849
7	0.096389	2	158	0.819958	13.294020
8	0.019333	5	370	0.836821	12.930245
9	0.167035	4	463	0.854270	13.385374
10	0.128483	4	406	0.904092	12.900470
11	0.100100	3	487	0.982661	13.498029
12	0.122658	3	364	0.704790	13.656354
13	0.056179	5	466	0.904979	12.904952
14	0.131999	5	134	0.972796	13.146841
15	0.061756	5	487	0.793513	13.169397
16	0.114014	3	359	0.755456	13.300064
17	0.203917	3	143	0.981850	13.454792
18	0.188965	3	450	0.976562	13.801461
19	0.027699	4	351	0.713568	12.931938
20	0.075066	5	336	0.781405	13.010337
21	0.175748	3	316	0.784280	13.576838
22	0.118539	2	256	0.940659	13.586082
23	0.024910	4	108	0.931673	12.390020
24	0.049743	5	162	0.944638	12.854163
25	0.151371	4	388	0.881788	13.028823
26	0.195260	3	140	0.974488	13.452283

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
27	0.180008	5	132	0.719068	13.650147
28	0.072196	5	392	0.918882	13.110582
29	0.137511	4	134	0.841664	13.181157
30	0.033919	3	230	0.928236	12.757058
31	0.122255	4	497	0.848139	13.073560
32	0.114547	4	445	0.707626	13.290461
33	0.031578	4	451	0.890923	12.876128
34	0.072871	5	487	0.972270	13.284592
35	0.059858	2	242	0.926665	13.033712
36	0.055760	5	426	0.786925	12.964386
37	0.042244	3	269	0.942436	12.901712
38	0.136681	3	383	0.941102	13.385904
39	0.047314	3	430	0.797304	13.022513
40	0.034418	2	330	0.972049	12.999823
41	0.064426	4	220	0.945404	13.073428
42	0.182146	4	297	0.853224	13.357436
43	0.093482	2	324	0.735960	13.828538
44	0.077523	4	414	0.796961	13.116267
45	0.113758	2	279	0.809089	13.277698
46	0.204356	5	367	0.775535	13.518258
47	0.109450	2	200	0.785452	13.202283
48	0.017377	2	101	0.850804	12.490955
49	0.020296	2	323	0.972480	12.695428
50	0.057912	3	152	0.846836	12.810003

Pada table 4.4 menunjukan bahwa nilai parameter terbaik pada model komposisi 50:50 untuk setiap kombinasinya adalah pada *learning_rate* 0.024910, *depth* 4, *n_estimator* 108, dan *subsample* 0.931673 dengan rata-rata sebesar 12.390020. Sehingga pada pengujian model komposisi 80:20 yang dilakukan telah

mendapatkan kombinasi parameter yang optimal.

Fokus pada parameter *learning_rate* dengan hasil rata-rata tertinggi dan terendah yaitu pada *learning_rate* 0.024910 dan 0.093482 nilai uji skornya masing masing adalah 12.390020 dan 13.828538. Terlihat bahwa bertambahnya nilai *learning_rate* hasil uji skor rata-ratanya ikut bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *learning_rate* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.


Selanjutnya fokus kepada parameter *depth* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *depth* 2 dan hasil uji skor rata-rata terendah adalah pada *depth* 4. Terlihat bahwa bertambahnya nilai *depth* dari 2 ke 4 hasil uji skor rata-ratanya berkurang sehingga menunjukkan bahwa model semakin baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *depth* semakin bertambah maka nilai rata-rata hasil uji akan semakin menurun yang menyebabkan peningkatan performa pada model.

Selanjutnya fokus kepada parameter *n_estimator* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *n_estimator* 324 dan hasil uji skor rata-rata terendah adalah pada *n_estimator* 108. Terlihat bahwa bertambahnya nilai *n_estimator* dari 108 ke 324 hasil uji skor rata-ratanya juga ikut bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *n_estimator* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.

Selanjutnya fokus kepada parameter *subsample* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *subsample* 0.735960 dan hasil uji skor rata-rata terendah adalah pada *subsample* 0.931673. Terlihat bahwa berkurangnya nilai

subsample hasil uji skor rata-ratanya bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *subsample* semakin bertambah maka nilai rata-rata hasil uji akan semakin berkurang yang menyebabkan peningkatan performa pada model.


Kombinasi parameter yang sudah ditemukan optimal maka akan digunakan untuk pengujian pada data training dan data testing sehingga menghasilkan nilai yang optimal juga. Hasil pengujian pada skenario ini menunjukkan peningkatan performa yang sangat signifikan dalam menangkap variabilitas curah hujan. Dengan adanya penyesuaian *learning_rate* yang lebih rendah yang dikombinasikan dengan jumlah *n_estimators* yang lebih besar, model mampu melakukan koreksi kesalahan secara lebih halus dan presisi. Berikut ini adalah visualisasi data trainig, testing, dan prediksi pada model komposisi 80:20 dengan optimized RandomSerchCV.



Gambar 4. 16 Visualisasi Training, Testing, dan Prediksi Komposisi 80:20 Optimized

Gambar 4.16 menyajikan visualisasi *time series* model *optimized* dengan pembagian data 80/20. Secara visual, skenario ini menghasilkan tingkat keselarasan yang paling superior dibandingkan seluruh skenario sebelumnya. Garis prediksi (hijau) menunjukkan respons yang lebih tajam dan akurat dalam menangkap variabilitas curah hujan harian, bahkan pada hari-hari dengan intensitas curah hujan tinggi. Penambahan data latih sebesar 80% memberikan pemahaman pola musiman yang lebih komprehensif, sementara optimasi *hyperparameter* memastikan model


tidak terjebak pada *underfitting*. Meskipun model masih memiliki keterbatasan dalam memprediksi kejadian curah hujan yang sangat ekstrem (outlier), model ini secara keseluruhan memiliki tingkat *bias* paling rendah dan kemampuan generalisasi yang paling stabil. Hal ini membuktikan bahwa kombinasi antara kuantitas data yang memadai dan optimasi parameter yang terstruktur merupakan pendekatan paling efektif untuk meningkatkan reliabilitas model prediksi curah hujan harian. Pada skenario 80/20 *optimized*, model lebih sedikit melakukan kesalahan *flatline* (garis datar) dibandingkan *baseline*. Ini menunjukkan bahwa model kini memiliki sensitivitas yang lebih baik berkat optimasi parameter yang memungkinkan model menangkap dinamika non-linear curah hujan dengan lebih presisi.



Gambar 4. 17 Scater Plot Altual dan Prediksi Komposisi 80:20 Optimized

Gambar 4.17 menyajikan *scatterplot* antara nilai aktual dan prediksi untuk komposisi 80/20 pada skenario *optimized*. Visualisasi ini menunjukkan karakteristik yang menarik dari model yang telah melewati proses optimasi intensif. Meskipun model *optimized* telah mencapai stabilitas yang lebih baik pada rentang curah hujan rendah hingga menengah (0–20 mm), sebaran titik tetap menunjukkan fenomena *underestimation* yang signifikan pada nilai aktual di atas 40 mm. Secara analitis, hal ini mengonfirmasi bahwa meskipun *hyperparameter tuning* mampu meningkatkan akurasi rata-rata dan menekan *bias* pada kondisi normal, model masih beroperasi secara konservatif saat menghadapi kejadian ekstrem. Kesenjangan antara prediksi dan garis diagonal $y=x$ pada rentang nilai tinggi

menegaskan bahwa tantangan utama dalam prediksi curah hujan harian bukan sekadar pada optimasi parameter, melainkan pada ketidakseimbangan distribusi data, di mana frekuensi kejadian hujan ekstrem sangat terbatas untuk melatih sensitivitas model pada rentang nilai tersebut.



Gambar 4. 18 Evaluasi Model Komposisi 80:20 Optimized

Pada Gambar 4.18 evaluasi kinerja model pada komposisi 80/20 skenario *optimized* memberikan performa yang stabil dan reliabel. Dengan nilai R² sebesar 0,329, model menunjukkan kemampuan yang konsisten dalam menjelaskan variabilitas data curah hujan. Pencapaian MAE 6.112 dan RMSE 9.652 menegaskan bahwa optimasi parameter telah berhasil menyeimbangkan model agar tidak mengalami *overfitting* pada data latih yang besar (80%), namun tetap mempertahankan sensitivitas yang baik pada data uji. Secara analitis, hasil ini menunjukkan bahwa pada volume data yang maksimal, optimasi *hyperparameter* berperan sebagai penyeimbang yang krusial untuk memastikan bahwa model tidak sekadar menghafal pola (*memorizing*), melainkan melakukan generalisasi yang stabil. Model ini secara empiris terbukti sebagai konfigurasi yang paling seimbang antara stabilitas statistik dan kemampuan prediktif dalam seluruh rangkaian pengujian.


yang dilakukan. Dengan nilai MAE 6.112 menunjukkan bahwa kesalahan rata-rata model adalah 6.112 mm per hari. Nilai ini sangat mirip dengan skenario *baseline* 80/20, yang menunjukkan bahwa optimasi parameter berhasil menjaga stabilitas model sekaligus memberikan prediksi yang andal untuk aktivitas cuaca harian yang dominan. Dengan nilai RMSE 9.652 menunjukkan konsistensi dalam penanganan *error*. Tidak adanya lonjakan besar antara MAE dan RMSE membuktikan bahwa proses optimasi berhasil meredam dampak *outlier* cuaca dibandingkan skenario-skenario awal yang diuji.

4.1.5 Pengujian Komposisi 90:10

Pada pengujian Komposisi 80:20 ini menggunakan perbandingan 90/10 yaitu 90% untuk data training dan 10% untuk data testing. Sehingga pada total data yang 942 data, digunakan untuk data training sebanyak 847 data, dan digunakan untuk data testing juga sebanyak 95 data. Pada pengujian yang dilakukan terdapat pengujian untuk gradient boosting baseline dan gradient boosting optimized dengan teknik RandomSearchCV.


4.1.5.1 Baseline

Pengujian pada skenario baseline pada komposisi 90/10 dilakukan sebagai langkah krusial untuk menetapkan tolok ukur performa model sebelum dilakukan perbaikan atau optimasi. Pada skenario ini, algoritma Gradient Boosting Regressor dijalankan menggunakan konfigurasi parameter standar yang ditetapkan secara default oleh pustaka scikit-learn, tanpa melalui proses lebih lanjut. Pengujian ini bertujuan untuk mengevaluasi sejauh mana kemampuan alami algoritma dalam memetakan hubungan antara variabel meteorologi dengan intensitas curah hujan harian tanpa intervensi optimasi.



Gambar 4. 19 Visualisasi Training, Testing, dan Prediksi Komposisi 90:10 Baseline


Gambar 4.19 menyajikan visualisasi *time series* model *baseline* dengan komposisi data 90/10. Dengan porsi data latih sebesar 90%, model memiliki durasi historis yang sangat panjang untuk mengenali pola musiman. Secara visual, terdapat peningkatan konsistensi pada prediksi (garis putus-putus hijau) dalam meniru tren variabilitas curah hujan harian. Namun, terlihat adanya fenomena kejenuhan *diminishing returns*, di mana penambahan data latih yang sangat ekstrem ini tidak memberikan peningkatan akurasi yang signifikan pada puncak curah hujan tinggi di atas 40 mm. Hal ini mengindikasikan bahwa pada konfigurasi *baseline*, bias model tetap dominan. Model cenderung melakukan *smoothing* atau perataan data secara agresif, sehingga gagal menangkap dinamika stokastik dari hujan intensitas tinggi. Hasil ini membuktikan bahwa untuk model *baseline*, penambahan data secara terus-menerus tidak efektif untuk menutupi keterbatasan parameter dalam memprediksi *outlier* meteorologi.



Gambar 4. 20 Scater Plot Aktual dan Prediksi Komposisi 90:10 Baseline

Gambar 4.20 menampilkan *scatterplot* aktual versus prediksi untuk komposisi 90/10 pada skenario *baseline*. Dengan porsi data latih mencapai 90%, model memiliki basis pengetahuan yang paling ekstensif. Namun, sebaran titik yang dihasilkan justru menunjukkan fenomena *bias* yang signifikan, di mana titik-titik data terakumulasi jauh di bawah garis diagonal $y=x$ pada rentang nilai di atas 10 mm. Hal ini menegaskan adanya asimetri prediksi di mana model *baseline* tidak mampu melakukan ekstrapolasi yang akurat untuk kejadian hujan dengan intensitas menengah hingga tinggi. Selain itu, porsi data uji yang hanya 10% menyebabkan representasi data pada *scatterplot* ini tampak kurang padat dibandingkan skenario sebelumnya. Secara analitis, konfigurasi ini membuktikan bahwa penambahan data

latih hingga 90% pada *baseline* tidak memberikan nilai tambah bagi model untuk memperbaiki akurasi pada *outlier*, karena batasan parameter default cenderung memaksa model untuk memprediksi nilai-nilai yang lebih konservatif dan moderat.



Gambar 4. 21 Evaluasi Model Komposisi 90:10 Baseline

Pada Gambar 4.21 evaluasi kinerja pada komposisi 90/10 menunjukkan nilai MAE 5,585 dan RMSE 9,231 yang terendah secara numerik. Namun, nilai R2 sebesar 0.249 mengindikasikan ketidakmampuan model dalam menangkap variansi data aktual. Secara analitis, fenomena ini dikenal sebagai prediksi rata-rata yang menyesatkan. Karena model *baseline* pada komposisi ini cenderung memprediksi nilai yang sangat rendah secara konsisten, nilai *error* absolut MAE tampak kecil. Hal ini membuktikan bahwa metrik MAE dan RMSE tidak cukup untuk mengevaluasi model jika tidak didampingi oleh R2, serta mengonfirmasi bahwa penambahan data latih hingga 90% pada model *baseline* justru memperburuk kemampuan generalisasi model terhadap pola data yang baru.

4.1.5.2 Optimized

Pengujian pada skenario optimized dalam komposisi 90/10 dilakukan dengan

menerapkan konfigurasi parameter yang telah dipilih melalui proses pencarian empiris menggunakan RandomizedSearchCV. Berbeda dengan skenario baseline, pengujian ini melibatkan mekanisme pencarian hyperparameter pada ruang parameter yang mencakup variasi kedalaman pohon (*max_depth*), laju pembelajaran (*learning_rate*), jumlah estimasi (*n_estimators*), dan fraksi subsampel (*subsample*). Tujuan utama dari pengujian ini adalah untuk memaksimalkan kemampuan model dalam meminimalisir fungsi kerugian (*loss function*) dengan mengadaptasi kompleksitas model secara spesifik terhadap karakteristik data meteorologi harian yang bersifat stokastik. Validasi silang menggunakan TimeSeriesSplit diintegrasikan secara ketat dalam tahap ini untuk memastikan bahwa parameter yang terpilih tidak hanya berkinerja baik pada satu lipatan data, tetapi stabil di berbagai periode waktu yang berbeda, sehingga meminimalisir risiko kebocoran data (*data leakage*) yang sering terjadi pada pemodelan deret waktu. Berikut ini adalah hasil pencarian hyperparameter menggunakan RandomSerachCV :

Tabel 4. 5 Hasil Rata-Rata Skor Uji RandomSearchCV Komposisi 90:10

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
1	0.084908	2	370	0.919598	13.364366
2	0.129732	4	221	0.746798	13.373215
3	0.021617	5	472	0.880335	12.889722
4	0.151615	3	408	0.990973	13.718331
5	0.176489	3	485	0.754547	13.566354
6	0.046681	5	413	0.857427	13.050849
7	0.096389	2	158	0.819958	13.294020
8	0.019333	5	370	0.836821	12.930245
9	0.167035	4	463	0.854270	13.385374
10	0.128483	4	406	0.904092	12.900470
11	0.100100	3	487	0.982661	13.498029
12	0.122658	3	364	0.704790	13.656354

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
13	0.056179	5	466	0.904979	12.904952
14	0.131999	5	134	0.972796	13.146841
15	0.061756	5	487	0.793513	13.169397
16	0.114014	3	359	0.755456	13.300064
17	0.203917	3	143	0.981850	13.454792
18	0.188965	3	450	0.976562	13.801461
19	0.027699	4	351	0.713568	12.931938
20	0.075066	5	336	0.781405	13.010337
21	0.175748	3	316	0.784280	13.576838
22	0.118539	2	256	0.940659	13.586082
23	0.024910	4	108	0.931673	12.390020
24	0.049743	5	162	0.944638	12.854163
25	0.151371	4	388	0.881788	13.028823
26	0.195260	3	140	0.974488	13.452283
27	0.180008	5	132	0.719068	13.650147
28	0.072196	5	392	0.918882	13.110582
29	0.137511	4	134	0.841664	13.181157
30	0.033919	3	230	0.928236	12.757058
31	0.122255	4	497	0.848139	13.073560
32	0.114547	4	445	0.707626	13.290461
33	0.031578	4	451	0.890923	12.876128
34	0.072871	5	487	0.972270	13.284592
35	0.059858	2	242	0.926665	13.033712
36	0.055760	5	426	0.786925	12.964386
37	0.042244	3	269	0.942436	12.901712
38	0.136681	3	383	0.941102	13.385904
39	0.047314	3	430	0.797304	13.022513
40	0.034418	2	330	0.972049	12.999823

No	Params				mean_test_score
	<i>learning_rate</i>	<i>depth</i>	<i>n_estimator</i>	<i>subsample</i>	
41	0.064426	4	220	0.945404	13.073428
42	0.182146	4	297	0.853224	13.357436
43	0.093482	2	324	0.735960	13.828538
44	0.077523	4	414	0.796961	13.116267
45	0.113758	2	279	0.809089	13.277698
46	0.204356	5	367	0.775535	13.518258
47	0.109450	2	200	0.785452	13.202283
48	0.017377	2	101	0.850804	12.490955
49	0.020296	2	323	0.972480	12.695428
50	0.057912	3	152	0.846836	12.810003

Pada table 4.5 menunjukan bahwa nilai parameter terbaik pada model komposisi 50:50 untuk setiap kombinasinya adalah pada *learning_rate* 0.024910, *depth* 4, *n_estimator* 108, dan *subsample* 0.931673 dengan rata-rata sebesar 12.390020. Sehingga pada pengujian model komposisi 90:10 yang dilakukan telah mendapatkan kombinasi parameter yang optimal.

Fokus pada parameter *learning_rate* dengan hasil rata-rata tertinggi dan terendah yaitu pada *learning_rate* 0.024910 dan 0.093482 nilai uji skornya masing masing adalah 12.390020 dan 13.828538. Terlihat bahwa bertambahnya nilai *learning_rate* hasil uji skor rata-ratanya ikut bertambah sehingga menunjukan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *learning_rate* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.


Selanjutnya fokus kepada parameter *depth* dengan hasil tertinggi dan terendah yaitu pada nilai *mean_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *depth* 2 dan hasil uji skor rata-rata terendah adalah pada *depth* 4. Terlihat bahwa bertambahnya nilai *depth* dari 2 ke 4 hasil uji skor rata-ratanya berkurang sehingga menunjukan bahwa model semakin baik karena

skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *depth* semakin bertambah maka nilai rata-rata hasil uji akan semakin menurun yang menyebabkan peningkatan performa pada model.

Selanjutnya fokus kepada parameter *n_estimator* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *n_estimator* 324 dan hasil uji skor rata-rata terendah adalah pada *n_estimator* 108. Terlihat bahwa bertambahnya nilai *n_estimator* dari 108 ke 324 hasil uji skor rata-ratanya juga ikut bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *n_estimator* semakin bertambah maka nilai rata-rata hasil uji akan semakin meningkat yang menyebabkan penurunan performa pada model.


Selanjutnya fokus kepada parameter *subsample* dengan hasil tertinggi dan terendah yaitu pada nilai *meant_test_score* 12.390020 dan 13.828538. Hasil uji skor rata-rata tertinggi adalah pada *subsample* 0.735960 dan hasil uji skor rata-rata terendah adalah pada *subsample* 0.931673. Terlihat bahwa berkurangnya nilai *subsample* hasil uji skor rata-ratanya bertambah sehingga menunjukkan bahwa model semakin tidak baik karena skor uji RMSE rata-rata yang baik adalah skor uji yang paling sedikit bukan yang paling banyak. Sehingga dapat dikatakan jika nilai *subsample* semakin bertambah maka nilai rata-rata hasil uji akan semakin berkurang yang menyebabkan peningkatan performa pada model.

Kombinasi parameter yang sudah ditemukan optimal maka akan digunakan untuk pengujian pada data training dan data testing sehingga menghasilkan nilai yang optimal juga. Hasil pengujian pada skenario ini menunjukkan peningkatan performa yang sangat signifikan dalam menangkap variabilitas curah hujan. Dengan adanya penyesuaian *learning_rate* yang lebih rendah yang dikombinasikan dengan jumlah *n_estimators* yang lebih besar, model mampu melakukan koreksi kesalahan secara lebih halus dan presisi. Berikut ini adalah visualisasi data training, testing, dan prediksi pada model komposisi 90:10 dengan optimized RandomSerchCV.



Gambar 4. 22 Visualisasi Training, Testing, dan Prediksi Komposisi 90:10 Optimized


Gambar 4.22 menampilkan visualisasi *time series* model *optimized* dengan komposisi data 90/10. Visualisasi ini menunjukkan bahwa meskipun model telah melalui proses *hyperparameter tuning*, performanya pada data uji (10% terakhir) tetap menunjukkan kecenderungan *underestimation* pada puncak-puncak curah hujan. Garis prediksi (hijau) tampak lebih stabil dibandingkan skenario *baseline* 90/10, namun model masih kesulitan mengimbangi lonjakan curah hujan aktual yang drastis. Hal ini mengonfirmasi bahwa dengan porsi data latih 90%, model cenderung menjadi terlalu 'terbiasa' dengan pola-pola umum yang dominan di 90% data sebelumnya, sehingga kehilangan sensitivitas terhadap karakteristik khusus yang muncul di 10% data uji. Secara analitis, konfigurasi 90/10 menunjukkan gejala *overfitting* terhadap pola historis yang membuat model kurang fleksibel dalam melakukan generalisasi pada data yang benar-benar baru, menjadikannya kurang optimal dibandingkan konfigurasi 70/30 atau 80/20 yang lebih seimbang. Dalam kasus 90/10, porsi data latih yang terlalu besar menyebabkan model terlalu spesifik pada tren jangka panjang yang dominan di 90% data tersebut. Karena data uji hanya 10%, model tidak memiliki cukup ruang untuk belajar variasi atau pergeseran pola cuaca yang mungkin terjadi tepat sebelum periode pengujian. Fenomena ini menunjukkan bahwa model mengalami penurunan kemampuan *generalization error* akibat ketidakseimbangan proporsi data latih dan data uji.



Gambar 4. 23 Scater Plot Aktual dan Prediksi Komposisi 90:10 Optimized

Gambar 4.23 menyajikan *scatterplot* aktual versus prediksi untuk komposisi 90/10 pada skenario *optimized*. Visualisasi ini menunjukkan bahwa dengan porsi data latih yang sangat dominan (90%), model *optimized* mengalami tendensi 'konservatisme prediksi'. Hal ini terlihat dari akumulasi titik yang terkonsentrasi pada rentang prediksi 0–15 mm, terlepas dari nilai aktual yang bervariasi luas. Secara analitis, meskipun telah dilakukan *hyperparameter tuning*, model pada komposisi 90/10 menunjukkan gejala *over-reliance* terhadap pola frekuensi tinggi pada data latih yang dominan, sehingga gagal mengonversi informasi tersebut menjadi sensitivitas terhadap nilai ekstrem di data uji. Ketidakmampuan titik untuk menyebar di sepanjang garis diagonal $y=x$ pada rentang nilai tinggi menegaskan

bahwa optimasi parameter tidak dapat mengompensasi kekurangan representasi variabilitas data yang cukup pada set pengujian 10%.



Gambar 4. 24 Evaluasi Model Komposisi 90:10 Optimized

Pada Gambar 4.24 evaluasi kinerja pada skenario *optimized* dengan komposisi 90/10 menunjukkan hasil yang kontradiktif. Meskipun MAE 4.791 dan RMSE 8,321 mencatat nilai numerik yang rendah, nilai R2 sebesar 0.154 menegaskan bahwa model ini memiliki performa yang kurang baik dalam menjelaskan variansi data curah hujan. Secara analitis, hal ini membuktikan bahwa pada komposisi 90/10, model mengalami kejenuhan informasi dan bias konservatif. Model cenderung melakukan prediksi yang 'datar' atau mendekati nol karena porsi data latih yang terlalu dominan (90%) membuat model kehilangan sensitivitas terhadap pola fluktuasi curah hujan pada data uji (10%). Hasil ini mengonfirmasi bahwa penambahan data latih secara ekstrem tidak menjamin peningkatan performa prediktif, melainkan justru dapat menurunkan kapasitas generalisasi model, bahkan setelah proses *hyperparameter tuning* dilakukan.

4.1.6 Pengujian Studi Ablasi

Untuk mengevaluasi kontribusi setiap variabel input terhadap performa model prediksi curah hujan, dilakukan studi ablasasi dengan cara menguji model menggunakan seluruh fitur yang tersedia dibandingkan dengan model yang menghilangkan salah satu fitur secara bertahap. Hasil eksperimen pada pengujian ini disajikan dalam Tabel 4.5 Studi ablasasi. Berdasarkan pengujian tersebut, model yang menggunakan seluruh fitur (TAVG, RH_AVG, dan SS) menunjukkan performa terbaik dengan nilai RMSE sebesar 9,65, MAE sebesar 6,11, dan R2 sebesar 0,33. Hasil studi ablasasi menunjukkan bahwa tidak ada variabel yang bersifat redundan, dimana penghapusan satu fitur saja secara konsisten menyebabkan peningkatan nilai error dan penurunan koefisien determinasi. Fitur durasi penyinaran matahari (SS) memberikan kontribusi yang paling signifikan terhadap akurasi, ditandai dengan penurunan nilai R2 yang paling drastis menjadi 0,19 ketika fitur tersebut dihilangkan dari model. Selain itu, penghilangan variabel temperatur (TAVG) terbukti menyebabkan kenaikan nilai RMSE tertinggi menjadi 10,25, yang mengindikasikan bahwa fitur temperatur memiliki korelasi kuat terhadap intensitas curah hujan. Meskipun fitur kelembapan (RH_AVG) memiliki dampak yang paling kecil dibandingkan variabel lainnya, penghilangan fitur tersebut tetap memperburuk performa model. Temuan ini menegaskan bahwa seluruh fitur yang digunakan memiliki peranan unik dalam membentuk pola temporal cuaca, sehingga penggunaan seluruh fitur merupakan konfigurasi paling optimal dalam mencapai tingkat akurasi yang diharapkan.

Tabel 4. 6 Hasil studi ablasasi

ABLASI	RMSE	MAE	R2
Semua fitur	9.65	6.11	0.33
Tanpa RH AVG	10.04	6.26	0.25
Tanpa TAVG	10.25	6.31	0.22
Tanpa SS	10.41	6.29	0.19


4.2 Pembahasan

Berdasarkan hasil pengujian yang telah dipaparkan pada sub bab Hasil,

bagian ini akan membahas secara mendalam perilaku model *Gradient Boosting* dalam memprediksi curah hujan harian. Analisis difokuskan pada perbandingan antara skenario *baseline* dan *optimized* dengan berbagai komposisi data latih dan data uji. Pembahasan ini bertujuan untuk mengidentifikasi konfigurasi terbaik serta memberikan interpretasi ilmiah mengenai mengapa optimasi parameter memberikan dampak yang signifikan terhadap akurasi model dalam menangkap variabilitas cuaca yang dinamis dan kompleks.

Evaluasi performa model dalam penelitian ini dilakukan melalui metrik *Mean Absolute Error* (MAE) untuk mengukur rata-rata penyimpangan absolut antara nilai prediksi curah hujan dengan nilai observasi aktual. Pada Gambar 4.25 menunjukkan hasil eksperimen pada berbagai skenario pembagian data menunjukkan bahwa model *Optimized* secara konsisten menghasilkan nilai MAE yang lebih rendah dibandingkan dengan model *Baseline* pada sebagian besar skenario, yakni 50:50, 70:30, dan 80:20. Penurunan nilai MAE ini membuktikan bahwa proses *hyperparameter tuning* menggunakan *RandomizedSearchCV* berhasil meningkatkan kemampuan model dalam meminimalisir kesalahan prediksi, sehingga model menjadi lebih akurat dalam mengestimasi intensitas curah hujan harian.

Terdapat temuan menarik pada skenario pembagian data 90:10, di mana model *Baseline* justru menunjukkan nilai MAE yang lebih rendah dibandingkan model *Optimized*. Hal ini mengindikasikan adanya batasan operasional model pada porsi data latih yang sangat dominan, di mana model yang lebih kompleks cenderung menangkap terlalu banyak variasi lokal (*noise*) pada data latih, sehingga menurunkan performanya saat diuji pada data yang tersisa. Meskipun demikian, stabilitas performa model *Optimized* yang unggul pada tiga skenario lainnya menegaskan bahwa metode optimasi yang diusulkan memiliki keandalan yang lebih baik untuk berbagai variasi volume data yang mungkin ditemukan dalam aplikasi praktis. Secara keseluruhan, konsistensi penurunan MAE pada mayoritas skenario pembagian data memberikan bukti empiris bahwa optimasi parameter yang dilakukan merupakan langkah krusial untuk meningkatkan ketepatan model dalam menelaah pola temporal curah hujan yang bersifat stokastik.




Gambar 4. 25 Evaluasi MAE

Selain menggunakan MAE, penelitian ini mengevaluasi akurasi model melalui metrik Root Mean Squared Error (RMSE) untuk memberikan penalti yang lebih proporsional terhadap kesalahan prediksi yang besar (outliers). Pada gambar 4.25 menunjukkan hasil perbandingan kinerja model menunjukkan bahwa model Optimized mampu menghasilkan nilai RMSE yang lebih rendah secara signifikan pada skenario pembagian data 50:50, 70:30, dan 80:20 dibandingkan dengan model Baseline. Hal ini mengonfirmasi bahwa hyperparameter tuning yang dilakukan tidak hanya efektif dalam menekan rata-rata kesalahan absolut, tetapi juga mampu meningkatkan stabilitas model dalam memitigasi deviasi prediksi yang ekstrem pada data curah hujan yang memiliki volatilitas tinggi.

Sebagaimana diamati pada metrik sebelumnya, skenario 90:10 menunjukkan hasil yang berbeda, di mana nilai RMSE model Optimized sedikit lebih tinggi dibandingkan Baseline. Fenomena ini memperkuat interpretasi bahwa pada proporsi data latih yang sangat besar, konfigurasi parameter yang terlalu kompleks hasil optimasi berisiko mengalami overfitting terhadap karakteristik spesifik data latih tersebut. Meskipun demikian, keberhasilan model Optimized dalam menekan nilai RMSE pada skenario yang lebih umum (70:30 dan 80:20) menunjukkan bahwa model tersebut memiliki generalization capability yang lebih baik dalam menghadapi ketidakpastian pola cuaca. Secara keseluruhan,

perbandingan RMSE ini menegaskan bahwa penggunaan `RandomizedSearchCV` mampu memberikan konfigurasi parameter yang lebih tangguh (robust) dalam meminimalisir kesalahan prediksi yang signifikan, menjadikannya pilihan yang lebih unggul dibandingkan konfigurasi parameter standar (baseline) untuk kebutuhan pemodelan curah hujan harian.




Gambar 4. 26 Evaluasi RMSE

Metrik *Coefficient of Determination* R^2 digunakan dalam penelitian ini untuk menilai seberapa besar proporsi varians variabel dependen (curah hujan) yang dapat dijelaskan oleh model. Pada gambar 4.26 hasil pengujian menunjukkan adanya peningkatan nilai R^2 pada model *Optimized* dibandingkan model *Baseline* pada skenario pembagian data 50:50, 70:30, dan 80:20. Peningkatan ini membuktikan bahwa optimasi *hyperparameter* secara nyata memperbaiki kemampuan model dalam menangkap dan memetakan pola variasi data dibandingkan konfigurasi standar, sehingga model lebih mampu merepresentasikan dinamika curah hujan yang kompleks.

Perlu dicatat bahwa nilai R^2 yang diperoleh secara keseluruhan berada pada rentang yang moderat. Hal ini merefleksikan karakteristik data curah hujan harian yang bersifat sangat stokastik atau fluktuatif, sehingga memiliki tingkat kerandoman tinggi yang sulit diprediksi secara sempurna oleh model deterministik maupun *machine learning* pada umumnya. Penurunan nilai R^2 pada skenario 90:10,

serupa dengan temuan pada metrik MAE dan RMSE, mengindikasikan adanya tantangan dalam menjaga generalisasi model ketika data latih menjadi sangat dominan, di mana model cenderung terjebak pada *noise* spesifik data latih dan kehilangan kemampuan prediktifnya pada data uji.

Meskipun nilai absolut R^2 belum mencapai angka mendekati satu, tren kenaikan yang konsisten melalui proses optimasi pada mayoritas skenario pembagian data memberikan dasar ilmiah bahwa model yang diusulkan memiliki keunggulan dalam menjelaskan pola varians data dibandingkan model *baseline*. Temuan ini mengonfirmasi bahwa peningkatan akurasi melalui *tuning* parameter adalah langkah efektif untuk memperbaiki kualitas prediksi pada fenomena meteorologi yang memiliki variabilitas tinggi, sekaligus menjadi landasan bagi pengembangan model yang lebih kompleks di masa mendatang.




Gambar 4. 27 Evaluasi R^2

Pada gambar 4.27 dapat disimpulkan bahwa berdasarkan hasil pengujian model yang dikembangkan, Variasi pembagian data 80:20 ditetapkan sebagai model terbaik. Variasi pembagian data 80:20 menunjukkan performa yang paling stabil dan ideal dengan nilai MAE sebesar 6.11, RMSE sebesar 9.65, dan R^2 Score sebesar 0.33. Meskipun Variasi pembagian data 90:10 secara numerik memiliki nilai MAE dan RMSE yang lebih rendah, model tersebut menghasilkan R^2 Score 0.15. Nilai rendah ini mengindikasikan bahwa model hanya menangkap tren data

dan memberikan prediksi 15%. Oleh karena itu, Variasi pembagian data 80:20 optimized dipilih karena mampu memberikan keseimbangan antara tingkat kesalahan yang rendah dan kemampuan generalisasi pola yang positif.

Analisis performa menunjukkan bahwa meskipun Komposisi 90:10 menghasilkan nilai MAE dan RMSE yang secara numerik lebih rendah, nilai R² yang negatif mengindikasikan bahwa model tidak mampu menjelaskan variansi data secara akurat. Hal ini terjadi karena Dengan rasio 10%, data uji tidak cukup representatif dalam mencakup seluruh spektrum variabilitas curah hujan (misal: jarang memuat hari dengan curah hujan ekstrem). Akibatnya, model cenderung memprediksi nilai rata-rata, yang menghasilkan error absolut rendah namun hanya menangkap 15% volatilitas data saja. Curah hujan memiliki distribusi yang sangat skewed. Pada Komposisi 80:20, porsi data uji lebih besar sehingga distribusi nilai aktual lebih proporsional. Oleh karena itu, pemilihan Komposisi 80:20 sebagai model terbaik merupakan keputusan konservatif dan lebih valid guna memastikan model memiliki kemampuan generalisasi yang nyata, bukan sekadar overfitting pada subset data latih yang besar.



Gambar 4. 28 Evaluasi Keseluruhan

Hasil penelitian ini menunjukkan bahwa penggunaan model ensemble, khususnya *Gradient Boosting* memberikan stabilitas prediktif yang lebih tinggi

dibandingkan model regresi linier konvensional. Temuan ini sejalan dengan penelitian yang dilakukan oleh Alvines et al. (2025), yang mengungkapkan bahwa pendekatan berbasis ensemble memiliki keunggulan dalam menangkap pola non-linear data curah hujan dengan deviasi RMSE yang lebih stabil dibandingkan model statistik tradisional.

Dalam penelitian ini, nilai metrik evaluasi seperti R^2 yang rendah pada beberapa skenario menunjukkan adanya tantangan serupa yang dihadapi oleh Alvines et al. (2025). Nilai R^2 yang rendah pada model tersebut mengindikasikan bahwa model-model yang digunakan, termasuk model ensemble, masih kesulitan melampaui performa *baseline* sederhana (seperti prediksi rata-rata) dalam menangkap variabilitas penuh data curah hujan yang sangat dinamis. Hal ini diduga kuat disebabkan oleh ketidakseimbangan distribusi data, di mana mayoritas kejadian curah hujan berada pada intensitas rendah, sementara kejadian ekstrem (>50 mm) bersifat sporadis namun signifikan.

Lebih lanjut, analisis *feature importance* dalam penelitian ini yang menempatkan fitur *lag* dan kelembaban sebagai prediktor utama, memperkuat temuan Alvines et al. (2025) yang juga mengidentifikasi *RR_LAG_1* dan kelembaban sebagai variabel kunci dalam memprediksi curah hujan di wilayah tropis. Meskipun demikian, konsistensi permasalahan *under-prediction* pada curah hujan ekstrem dalam penelitian ini dan studi Alvines et al. (2025) menekankan bahwa ketergantungan model pada data historis internal saja belum cukup. Pengembangan model ke depan disarankan untuk mengintegrasikan pendekatan hybrid yang menggabungkan keunggulan statistik dengan *deep learning*, serta menambahkan variabel eksogen (seperti indeks monsun atau ENSO) untuk meningkatkan sensitivitas model terhadap kondisi cuaca ekstrem. Berikut ini adalah hasil penelitian yang dilakukan oleh Alvines et al.

Tabel 4. 7 Hasil Penelitian Alvines dkk

Model	MSE	RMSE	MAE	R^2	MAPE
Ridge Regression	213.835	14.623	12.385	-0.690	1.306
Lasso Regression	223.960	14.965	12.843	-0.771	1.361
Random Forest	301.436	17.361	12.506	-1.383	5.749
Linear Regression	305.344	17.474	15.694	-1.414	1.819

Model	MSE	RMSE	MAE	R2	MAPE
Gradient Boosting	383.434	19.581	12.856	-2.032	2.870

Penelitian ini memiliki kesamaan fokus dengan studi yang dilakukan oleh Zoremsanga dan Hussain (2024), yaitu mengenai pemanfaatan model hybrid machine learning dan deep learning untuk memprediksi curah hujan harian. Sejalan dengan pendekatan yang diterapkan dalam penelitian tersebut, studi ini juga menekankan pentingnya teknik optimasi untuk meningkatkan performa model prediktif. Zoremsanga dan Hussain (2024) menerapkan *Particle Swarm Optimization* (PSO) untuk menentukan hiperparameter secara seragam pada dua belas model yang berbeda, termasuk *Artificial Neural Network* (ANN), *Long Short-Term Memory* (LSTM), dan *Bidirectional LSTM* (BiLSTM). Pendekatan ini mengatasi keterbatasan studi terdahulu yang sering kali hanya mengoptimasi model yang diusulkan, sementara model pembanding dibiarkan menggunakan parameter hasil *trial-and-error* atau *grid search*. Penelitian kami mengadopsi prinsip keadilan perbandingan yang serupa dengan melakukan kalibrasi parameter yang ketat untuk memastikan bahwa peningkatan performa model bukan sekadar hasil dari penyesuaian hiperparameter yang tidak merata.

Dalam studi oleh Zoremsanga dan Hussain (2024), ditemukan bahwa arsitektur *hybrid* yang menggabungkan lapisan *deep learning* (seperti BiLSTM) dengan lapisan *dense* (ANN) dan lapisan *dropout* (contoh: PSO-BiLSTM-ANN II) memberikan performa terbaik dalam meminimalkan *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE). Hal ini memberikan justifikasi teoritis bagi penelitian kami untuk mengeksplorasi integrasi lapisan serupa guna mengatasi masalah *overfitting* serta meningkatkan kemampuan model dalam menangkap ketergantungan jangka panjang dalam data deret waktu (*time series*) curah hujan yang kompleks. Senada dengan tantangan yang dihadapi oleh Zoremsanga dan Hussain (2024) pada data meteorologi di Aizawl, Mizoram, penelitian kami juga memperhatikan karakteristik data meteorologi yang memiliki nilai hilang (*missing values*) dan potensi ketidakkonsistenan input. Oleh karena itu, prosedur pra-pemrosesan data yang ketat—meliputi pembersihan data, penanganan nilai hilang, dan normalisasi Min-Max—menjadi aspek krusial dalam kedua penelitian ini untuk

menjaga stabilitas model.

Sementara Zoremsanga dan Hussain (2024) berfokus pada wilayah geografis spesifik di India, penelitian kami memperluas cakupan implementasi pada karakteristik topografi dan pola iklim yang berbeda. Dengan demikian, penelitian ini berkontribusi dalam memvalidasi keandalan model yang diusulkan oleh Zoremsanga dan Hussain (2024) pada skala dan lingkungan yang berbeda.

Tabel 4. 8 Hasil Penelitian Zoremsanga

Model	RMSE	MAE	R2
PSO-BiLSTM-ANN II	16.17	9.06	0.05
PSO-RNN-ANN	16.18	9.37	0.05
PSO-LSTM-ANN II	16.27	9.58	0.04
PSO-LSTM-ANN III	16.27	9.75	0.04
PSO-BiLSTM-ANN I	16.29	9.41	0.03
PSO-BiLSTM-ANN III	16.29	9.48	0.03
PSO-LSTM-ANN I	16.30	9.74	0.02
PSO-ANN I	16.33	8.87	0.03
PSO-LSTM	16.34	9.05	0.02
PSO-ANN II	16.35	8.81	0.03
PSO-BiLSTM	16.38	8.86	0.02
PSO-SVR	17.28	12.81	-0.1

Hasil penelitian ini dibandingkan dengan beberapa studi terdahulu untuk menempatkan posisi akurasi model dalam konteks pemodelan curah hujan harian. Sebagaimana disajikan pada tabel 4.8, penelitian ini menunjukkan performa yang kompetitif jika dibandingkan dengan penelitian yang menggunakan karakteristik data serupa, khususnya data harian BMKG di wilayah Indonesia. Jika dibandingkan dengan penelitian Alvines dkk. (2025) yang menggunakan data harian BMKG di wilayah Sumatera dengan metode Ridge Regression, model yang diusulkan dalam penelitian ini menunjukkan peningkatan akurasi yang signifikan dengan nilai RMSE 9,65 dibandingkan 14,62, serta mampu menghasilkan nilai R2 positif sebesar 0,33, berbeda dengan hasil penelitian terdahulu yang memperoleh nilai R2 negatif. Hal serupa juga terlihat saat dibandingkan dengan penelitian Usman dkk. (2023) yang menggunakan metode Artificial Neural Network (ANN) pada data BMKG di Semarang, di mana model Gradient Boosting dengan optimasi

RandomizedSearchCV dalam penelitian ini mampu menekan nilai RMSE dan MAE menjadi lebih rendah (RMSE 9,65; MAE 6,11). Temuan ini memberikan bukti empiris bahwa strategi prapemrosesan data melalui imputasi KNN dan optimasi parameter yang tepat sangat krusial dalam meningkatkan reliabilitas prediksi curah hujan di wilayah tropis. Perbedaan signifikan terlihat ketika dibandingkan dengan studi Kumar dkk. (2023) dan Barera dkk. (2021) yang mencatatkan nilai metrik error yang jauh lebih rendah. Perbedaan nilai ini dipahami sebagai dampak dari perbedaan karakteristik data cuaca lintas wilayah (geografis), di mana dataset di wilayah Delhi atau Inggris memiliki pola musiman yang jauh lebih stabil dan prediktabilitas yang lebih tinggi dibandingkan dengan data curah hujan di Malang, Indonesia yang memiliki sifat sangat volatil dan stokastik. Selain itu, perbedaan kompleksitas fitur dan arsitektur model yang digunakan seperti penggunaan Deep Learning atau CatBoost pada skala data yang berbeda juga berkontribusi terhadap variasi performa tersebut. Secara keseluruhan, model yang diusulkan dalam penelitian ini membuktikan bahwa meskipun dihadapkan pada karakteristik data cuaca yang menantang dan sulit diprediksi, penggunaan algoritma Gradient Boosting yang dioptimasi secara tepat mampu memberikan hasil yang sangat kompetitif dan jauh lebih unggul dibandingkan dengan model-model dasar atau metode regresi linier yang sering digunakan dalam studi serupa di Indonesia. Hasil ini memperkuat posisi penelitian ini sebagai kontribusi praktis dalam peningkatan akurasi sistem peringatan dini berbasis data cuaca di tingkat regional.

Tabel 4. 9 Perbandingan penelitian lain

Referensi	Data	Metode	Hasil Terbaik
Kumar dkk (2023)	Data Harian dan mingguan (Delhi)	CatBoost + standart scaler dengan data 70 train, 15 validation, 15 test.	RMSE =0.0010 MAE =0.00077 R2 = 0.99
Barera dkk (2021)	Data Harian (Inggris)	Menghilangkan data kategorikal dan tidak lengkap dalam dataset + pemilihan fitur Matriks Korelasi + Optimasi GridSearch CV XGBoost dan LSTM-Networks. Data 70:30.	RMSE = 0.377 MAE = 0.072 RMSLE =

			0.111
Alvines dkk (2025)	Data Harian BMKG (Sumatera)	Ridge Regression + Imputasi KNN = 5	RMSE = 14.62 MAE = 12.38 R2 = -0.69 (Minus)
Usman dkk (2023)	Data Harian BMKG (Semarang)	AAN (Artificial Neural Network) dengan data 70:30	RMSE = 13.05 MAE = 6.62
Penelitian ini	Data Harian BMKG (Malang)	Gradient Boosting + Imputasi KNN = 5 + Optimasi RandomSearchCV dengan data 80:20.	RMSE = 9.65 MAE = 6.11 R2 = 0.33

4.3 Integrasi penelitian dengan Al-Qur'an dan Hadits

Mengintegrasikan penelitian tentang pemodelan curah hujan dengan nilai-nilai Al-Qur'an akan memberikan dimensi filosofis dan spiritual yang kuat pada penelitian ini. Hal ini menunjukkan bahwa sains bukan sebagai entitas yang terpisah, melainkan sebagai upaya manusia untuk memahami ayat-ayat kauniyah yaitu tanda-tanda kebesaran Allah di alam semesta. Santo Agustinus bersikap terhadap Bibel, mengatakan bahwa antara teks Al-quran dan fakta-fakta ilmiah selalu ada keserasian. Al-quran menyebutkan fakta-fakta yang banyak hubungannya dengan sains yang jauh lebih besar dibandingkan dalam Injil dan tidak ada soal-soal yang tersebut dalam Alquran yang dapat dibohongkan dengan sains (Bucaille, 1979).

Prediksi curah hujan pada dasarnya adalah upaya manusia untuk mempeleajari *sunnatullah* sebagai konsep hukum alam dalam meteorologi dengan ketetapan Allah swt yang mengatur keteraturan alam semesta. Hujan bukan berarti kejadian acak yang tak bermakna, melainkan bagian dari sistem besar yang diatur oleh Allah swt. Dengan menggunakan *Machine Learning* penelitian ini sedang berusaha untuk membaca keteraturan yang Allah swt tetapkan dalam siklus hidrologi. Penelitian ini

adalah bentuk ikhtiar untuk memahami tanda-tanda yang dikirimkan oleh Allah swt demi kemaslahatan makhluk di bumi. Karena Allah swt menyatakan dalam Alquran tentang rahmat-Nya yaitu hujan adalah kabar gembira sebagaimana Al-Qur'an surat Al-A'raf ayat 57 berikut.

وَهُوَ الَّذِي يُرْسِلُ الرِّيحَ بُشْرًا بَيْنَ يَدَيْ رَحْمَتِهِ ۖ حَتَّىٰ إِذَا أَقْلَّتْ سَحَابًا ثِقَالًا سُقْنَاهُ لِبَلَدٍ مَّيِّتٍ فَأَنْزَلْنَا بِهِ الْمَاءَ فَأَخْرَجْنَا بِهِ مِنْ كُلِّ الثَّمَرَاتِ ۚ كَذَٰلِكَ نُخْرِجُ الْمَوْتَىٰ لَعَلَّكُمْ تَذَكَّرُونَ

Artinya : “Dan Dialah yang meniupkan angin sebagai pembawa berita gembira sebelum kedatangan rahmat-Nya (hujan); hingga apabila angin itu telah membawa awan mendung, Kami halau ke suatu daerah yang tandus, lalu Kami turunkan hujan di daerah itu, maka Kami keluarkan dengan sebab hujan itu pelbagai macam buah-buahan. Seperti itulah Kami membangkitkan orang-orang yang telah mati, mudah-mudahan kamu mengambil pelajaran”. (QS Al-A'raf Ayat 57)

Didalam Tafsir Al-Misbah karya Quraish Shihab dijelaskan tentang ayat ini bahwa hanya Allahlah yang mengirim angin sebagai pembawa berita datangnya rahmat melalui hujan yang menumbuhkan tanaman dan menyiraminya. Angin itu membawa awan yang berisikan air. Kami giring awan tersebut ke suatu daerah yang tidak ditumbuhi tanaman seperti orang mati yang tidak berkehidupan. Hujan pun lalu turun. Dengan ayat itu Allah menumbuhkan berbagai macam buah-buahan. Seperti halnya daerah tersebut dihidupkan dengan ditumbuhkannya tanaman, begitulah Kami menjadikan orang-orang yang telah mati, hidup kembali. Semoga dengan kejadian ini kalian ingat kekuasaan Allah dan yakin dengan adanya hari kebangkitan. Ayat ini membenarkan sebuah penemuan ilmiah yang belum diketahui saat al-Qur'an diturunkan, yaitu angin mengandung uap air. Ketika dihembus, angin akan berkumpul di suatu tempat dan menjadi awan. Awan inilah yang kemudian menurunkan hujan setelah berkumpul dan menebal (Shihab, 2002).

Dalam Islam manusia dianjurkan untuk memaksimalkan potensi akal dalam mengelola bumi dan tidak untuk merusaknya. Optimasi model Gradient Boosting yang dilakukan pada penelitian ini merupakan perwujudan dari kaum yang berfikir. Islam memandang ilmu pengetahuan sebagai alat untuk mengambil manfaat dari alam. Penelitian ini mencoba meningkatkan presisi prediksi curah hujan yang

selaras dengan semangat Islam dalam mitigasi risiko bencana dan mengoptimalkan pemanfaatan air hujan untuk pertanian dan kehidupan. Dalam Al Qur'an dijelaskan bahwa pada pergantian malam dan siang dan hujan yang diturunkan dari langit sehingga dapat memberi kehidupan di Bumi dan dari pergeseran udara ke berbagai arah dengan kekuatan dan suhu yang berbeda serta bahaya dan manfaatnya terdapat kebesaran Allah bagi kaum yang berpikir karena akalunya. Sehingga kita sebagai manusia dianjurkan mengerti mengenai curah hujan supaya dapat berkontribusi dalam memperkirakan curah hujan yang baik dengan harapan dapat dijadikan sebagai hal yang berguna dan bermanfaat bagi kegiatan manusia moderen pada masa sekarang dan makhluk hidup lainnya. Sebagaimana Al-Qur'an Surah Al-Jatsiyah ayat 5 yang berbunyi sebagai berikut.

وَاخْتَلَفَ اللَّيْلُ وَالنَّهَارُ وَمَا أَنْزَلَ اللَّهُ مِنَ السَّمَاءِ مِنْ رِزْقٍ فَأَحْيَا بِهِ الْأَرْضَ بَعْدَ مَوْتِهَا وَتَصْرِيفِ
الرِّيْحِ ؕ آيَاتٍ لِّقَوْمٍ يَعْقِلُونَ

Artinya : *“Dan pada pergantian malam dan siang dan hujan yang diturunkan Allah dari langit lalu dihidupkan-Nya dengan air hujan itu bumi sesudah matinya; dan pada perkisaran angin terdapat tanda-tanda (kekuasaan Allah) bagi kaum yang berakal”*.(QS Al-Jatsiyah Ayat 5)

Sebagaimana dijelaskan pada Tafsir Ringkas jilid 1 oleh Lajnah Pentashihan Mushaf Al quran Republik Indonesia bahwa pada perbedaan malam dan siang yang datang silih berganti, malam datang lalu siang pergi, dan pada apa yang diturunkan Allah dari langit, seperti hujan sebagai rezeki lalu dengan air hujan itu dihidupkan-Nya bumi setelah matinya, yaitu kering, dan demikian pula pada perkisaran angin ke berbagai arah, perbedaan suhu dan kekuatannya serta manfaat dan bahayanya, terdapat pula tanda-tanda keesaan, kekuasaan, dan kebesaran Allah swt bagi kaum yang menegrti (Al-Quran, 2016).

Dalam dunia *data science*, kualitas data dan proses evaluasi adalah segalanya yang sejalan dengan Islam melalui konsep *tabbayun* dengan meneliti kebenaran informasi. Sebagaimana dijelaskan dalam Al qur'an surah Al-Hujurat ayat 6 yang mana menjelaskan bahwa jika datang orang fasik membawa berita kepada orang

beriman, maka periksalah dengan teliti dengan *tabayyun*. Meskipun ayat ini konteksnya adalah berita sosial, prinsipnya dapat ditarik ke dalam sains dengan jangan menerima hasil prediksi mentah-mentah sebelum diuji melalui proses evaluasi kinerja model yang objektif seperti analisis yang kritis terhadap penemuan pada penelitian ini yang hasil evaluasi modelnya telah diuji dengan menemukan nilai R2 yang negatif, hal seperti itulah bentuk *tabayyun* ilmiah yang jujur. Berikut ini adalah bunyi surah Al-Hujurat ayat 6.

يَا أَيُّهَا الَّذِينَ ءَامَنُوا إِن جَاءَكُمْ فَاسِقٌ بِنَبَأٍ فَتَبَيَّنُوا أَن تُصِيبُوا قَوْمًا بِجَهْلَةٍ فَتُصْبِحُوا عَلَىٰ مَا فَعَلْتُمْ نَادِمِينَ

Artinya : “Hai orang-orang yang beriman, jika datang kepadamu orang fasik membawa suatu berita, maka periksalah dengan teliti agar kamu tidak menimpakan suatu musibah kepada suatu kaum tanpa mengetahui keadaannya yang menyebabkan kamu menyesal atas perbuatanmu itu”. (QS Al-Hujurat Ayat 6)

Tafsir Al Munir menjelaskan bahwa surah ini kemudian membahas etika sosial kemasyarakatan yang bersifat umum, etika-etika yang berkaitan dengan interaksi manusia antara satu dengan yang lain dengan mengonfirmasikan perbuatan mulia dan mencela perbuatan hina, guna menegakkan pilar-pilar masyarakat yang mulia. Surah al-Hujurat memerintahkan orang-orang Mukmin supaya memverifikasi kebenaran suatu kabar dan jangan memercayai desas-desus yang disebarkan orang-orang fasik. “Wahai orang-orang yang beriman! Jika seseorang yang fasik datang kepadamu membawa suatu berita, maka telitilah kebenarannya, agar kamu tidak mencelakakan suatu kaum karena kebodohan (kecerobohan), yang akhirnya kamu menyesali perbuatanmu itu” (Wahbah Az-Zuhaili, 2016).

Penelitian ini tidak hanya bertujuan untuk meningkatkan akurasi teknis prediksi curah hujan, tetapi juga sebagai bentuk tadabbur alam. Sebagaimana dijelaskan dalam QS. Al-A'raf: 57, hujan adalah rahmat Allah yang diturunkan melalui sistem yang teratur. Melalui pendekatan *Machine Learning* dan *hyperparameter tuning*, penelitian ini berupaya menyingkap pola dari keteraturan

(*Sunnatullah*) tersebut. Langkah ini sejalan dengan semangat Islam yang mewajibkan manusia untuk menjadi khalifah yang berilmu, dengan senantiasa melakukan *tabayyun* melalui evaluasi empiris yang ketat terhadap setiap temuan, demi memberikan manfaat bagi umat manusia dalam mengantisipasi perubahan cuaca.

Penelitian ini diintegrasikan dengan tiga dimensi aspek muamalah sebagai landasan etika dan spiritual. Dalam *Muamalah Ma'a Allah*, penelitian ini diniatkan sebagai bentuk *amanah* intelektual untuk menyingkap hukum alam prediksi curah hujan melalui analisis data yang jujur dan objektif dan niat sebagai ibadah yang menjadikan penelitian sebagai bentuk syukur atas akal yang diberikan Allah swt. Sehingga peneliti menyadari bahwa data yang diolah adalah bagian dari *Sunnatullah* yang ditetapkan-Nya. Pada hakikat ilmu, prediksi curah hujan adalah upaya manusia untuk memahami hukum alam yang ditetapkan Allah SWT. Setelah melakukan *RandomizedSearchCV* dan optimasi model, hasilnya diserahkan kepada Allah yang biasa disebut dengan *tawakal*. Ilmu yang kita dapat adalah bentuk pembukaan atau *Fath* dari Allah bagi hamba yang mau berusaha. Hal ini menunjukkan bahwa manusia mempunyai keterbatasan yang selaras dalam QS. Luqman ayat 34 Allah menegaskan bahwa hanya Dia yang mengetahui kapan hujan akan turun. Penelitian ini diposisikan sebagai ikhtiar manusia untuk membaca tanda-tanda alam, bukan sebagai klaim untuk mendahului takdir atau pengetahuan mutlak Allah. Berikut adalah bunyi QS. Luqman ayat 34.

إِنَّ اللَّهَ عِنْدَهُ عِلْمُ السَّاعَةِ وَيُنَزِّلُ الْغَيْثَ وَيَعْلَمُ مَا فِي الْأَرْحَامِ ۚ وَمَا تَدْرِي نَفْسٌ مَّاذَا تَكْسِبُ غَدًا ۚ
وَمَا تَدْرِي نَفْسٌ بِأَيِّ أَرْضٍ تَمُوتُ ۚ إِنَّ اللَّهَ عَلِيمٌ خَبِيرٌ

Artinya : “Sesungguhnya Allah, hanya pada sisi-Nya sajalah pengetahuan tentang Hari Kiamat; dan Dialah Yang menurunkan hujan, dan mengetahui apa yang ada dalam rahim. Dan tiada seorangpun yang dapat mengetahui (dengan pasti) apa yang akan diusahakannya besok. Dan tiada seorangpun yang dapat mengetahui di bumi mana dia akan mati. Sesungguhnya Allah Maha Mengetahui lagi Maha Mengenal”. (QS Luqman Ayat 34)

Sebagaimana dijelaskan pada Tafsir Jalalain yang mengatakan bahwa

(Sesungguhnya Allah, hanya pada sisi-Nya sajalah pengetahuan tentang hari kiamat) yakni kapan kiamat itu akan terjadi (dan Dialah yang menurunkan) dapat dibaca *wa yunzilu dan wa yunazzilu* (hujan) dalam waktu-waktu yang Dia ketahui (dan mengetahui apa yang ada di dalam rahim) apakah laki-laki atau perempuan; tidak ada seorang pun yang mengetahui salah satu dari tiga perkara itu melainkan hanya Allah swt. (Dan tiada seorang pun yang dapat mengetahui dengan pasti apa yang akan diusahakannya besok) apakah kebaikan ataukah keburukan, tetapi Allah swt. mengetahuinya. (Dan tiada seorang pun yang dapat mengetahui di bumi mana dia akan mati) hanya Allah swt sajalah yang mengetahui hal ini. (Sesungguhnya Allah Maha Mengetahui) segala sesuatu (lagi Maha Mengenal) pada yang tersembunyi sebagaimana mengenal-Nya pada yang tampak. Imam Bukhari telah meriwayatkan sebuah hadis melalui sahabat Ibnu Umar r.a. bahwasanya kunci-kunci kegaiban itu ada lima perkara, antara lain sesungguhnya Allah hanya pada sisi-Nya sajalah pengetahuan tentang hari kiamat, dan seterusnya (Imam Jalaludin Muhammad bin Ahmad Mahalli dan Syaikh Jalaluddin Abdurahman bin Abi Bakar Suyuti, 2010).

Dalam *Muamalah Ma'a Nas*, sebagai bentuk keadilan sosial dengan prediksi yang akurat, masyarakat terutama pemangku kebijakan, petani atau penduduk di area rawan bencana dapat lebih siap, sehingga mengurangi kerugian ekonomi dan penderitaan sesama. Pada mitigasi bencana penelitian prediksi curah hujan memiliki implikasi sosial yang besar untuk perlindungan jiwa dan harta seperti peringatan dini banjir. Ini adalah bentuk implementasi *maqashid syariah* untuk menjaga keberlangsungan hidup manusia (*hifdzun nafs*). Sehingga menjadi kemanfaatan bagi manusia lain. Hal ini selaras dengan pandangan Islam yang mengajarkan bahwa sebaik-baik manusia adalah yang paling bermanfaat bagi orang lain seperti hadist Nabi yang diriwayatkan oleh Ath-Thabari dalam al-Mu'jam al-Awsath VI/58. Syaikh al-Albani menyatakan hasan dalam ash-Shahihah nomor 426 sebagai mana berikut :

خَيْرُ النَّاسِ أَنْفَعُهُمْ لِلنَّاسِ

Artinya : “Sebaik-baik manusia adalah yang paling bermanfaat untuk orang lain”. HR. Ath-Thabari dalam al-Mu’jam al-Awsath VI/58. Syaikh al-Albani menyatakan hasan dalam ash-Shahihah no. 426. (Ayub, 2015)

Dalam *Muamalah Ma'a Alam*, penelitian ini merupakan bentuk menjaga keseimbangan karena Islam melarang perusakan alam. Penelitian cuaca membantu kita memahami perubahan iklim agar manusia lebih bijak dalam beraktivitas, menjaga keseimbangan ekosistem agar tidak terjadi kerusakan *fasad* di muka bumi. Sebagai *tadabur alam* karena mempelajari variabel cuaca seperti suhu, kelembapan, penyinaran matahari adalah bentuk *tadabbur* dengan merenungi tanda-tanda kebesaran Allah di alam semesta. Sebagai *khalifah* di bumi karena Allah menunjuk manusia sebagai pemimpin (*khalifah*) di bumi untuk mengelola dan melestarikan lingkungan yang selaras dengan QS. Al-Baqarah ayat 30.

وَإِذْ قَالَ رَبُّكَ لِلْمَلَائِكَةِ إِنِّي جَاعِلٌ فِي الْأَرْضِ خَلِيفَةً قَالُوا أَتَجْعَلُ فِيهَا مَنْ يُفْسِدُ فِيهَا وَيَسْفِكُ الدِّمَاءَ وَنَحْنُ نُسَبِّحُ بِحَمْدِكَ وَنُقَدِّسُ لَكَ قَالَ إِنِّي أَعْلَمُ مَا لَا تَعْلَمُونَ

Artinya : “Ingatlah ketika Tuhanmu berfirman kepada para Malaikat: ‘Sesungguhnya Aku hendak menjadikan seorang khalifah di muka bumi’. Mereka berkata: ‘Mengapa Engkau hendak menjadikan (khalifah) di bumi itu orang yang akan membuat kerusakan padanya dan menumpahkan darah, padahal kami senantiasa bertasbih dengan memuji Engkau dan mensucikan Engkau?’ Tuhan berfirman: ‘Sesungguhnya Aku mengetahui apa yang tidak kamu ketahui’”. (QS Al-Baqarah Ayat 30)

K.H. Bisri Mustofa menjelaskan pada tafsir Al Ibriz pada ayat 30-39 bahwa Ketika Allah Swt berkehendak akan menciptakan Nabi Adam As, Allah Swt berfirman kepada para Malaikat, adapun sabda-Nya sebagai berikut: “Aku, Allah akan menciptakan Khalifah di bumi.”. Para Malaikat menjawabnya; “Kenapa Tuan berkehendak untuk menciptakan khalifah di bumi berupa makhluk yang senang akan membuat kerusakan dan saling bunuh-membunuh, sedangkan kita (Malaikat) semua masih tetap setia membaca tasbih, tahmid dan mengesakan Tuan.” Allah Swt berfirman lagi, adapun sabdanya sebagai berikut: “Aku mengetahui apa yang kalian tidak mengetahuinya.” Dan setelah Nabi Adam As tercipta, lalu Ia mengajarkannya

nama-nama suatu benda. Setelah itu barang-barang tersebut diperlihatkan kepada Malaikat dan Ia bersabda: Hai para Malaikat coba sebutkan nama benda-benda ini, kalau memang kalian semua itu benar. Malaikat menjawab-Nya: Maha Suci Tuhan kami, kami semua tidak tahu apa-apa terkecuali apa yang telah Engkau ajarkan kepada kami semua, sesungguhnya Engkau adalah dzat yang Maha Mengetahui dan Maha Bijaksana. Kemudian Allah Swt berfirman: “Hai Adam, coba ceritakan kepada para Malaikat akan nama benda-benda ini”, dan setelah Nabi Adam As bercerita kepada para Malaikat. Maka Allah Swt pun berfirman: “Bukankah Aku sudah berbicara bahwa Aku mengetahui sesuatu yang samar baik yang ada di langit atau di bumi. Dan Aku tahu apa yang kalian tampilkan atau apa yang kalian sembunyikan.”. Kemudian Allah Swt berfirman kepada para Malaikat: “Berikanlah sujud penghormatan kalian kepada Adam”, lalu para Malaikat bersujud kepada Adam terkecuali Iblis. Iblis membangkang dan sombong, ia termasuk dalam golongan orang-orang yang kafir. Dan Allah berfirman kepada Adam; “Kamu dan istrimu bermukimlah di dalam Surga dan makanlah apa yang ada di dalamnya sesukamu, tetapi janganlah mendekati pohon ini dan kalau kamu mendekatinya maka kamu termasuk orang-orang yang berbuat kerusakan.”. Di saat Nabi Adam A.S. dan ibu Hawa sudah bermukim di Surga dalam waktu tidak begitu lama, keduanya digoda oleh Syaitan sehingga memakan buah pohon Khuldi tersebut. Pada akhirnya Nabi Adam dan ibu Hawa diusir dari Surga, sampai ada sebuah perintah bahwa bapak Adam dan keturunannya tetap bermukim dan menempati Bumi, lalu keduanya menangis tersedu-sedu. Kemudian Nabi Adam dianugrahi oleh Allah Swt berupa do’a yang harus segera dibaca, yang kalau do’a tersebut dibaca maka Nabi Adam A.S mendapatkan ampunan dan maaf dari Allah Swt. Adapun kalimat do’a tersebut, yaitu: Rabbii Inni dzalamtu nafsii dzulman kabiiran, wa laa yaghfiru al-dzunuuba illa anta faghfirlil dzunuubii. Nabi Adam diperintah untuk turun dari Surga dan menetap di Bumi dengan keturunannya, sampai ada sebuah keterangan; Siapa pun dari anak turun Nabi Adam As. Yang mengikuti petunjuk Tuhan, maka ia tidak akan pernah merasa khawatir dan tidak akan menemukan kesusahan pada hari esok di dalam akhirat. Adapun orang-orang Kafir dan orang-orang yang mendustakan terhadap ayat-ayat Tuhan, orang-orang

tersebut akan mendapatkan bagian Neraka dan kekal di dalamnya selama-lamanya (K.H. Bisri Mustofa, 2016).

Dalam perspektif *Muamalah Ma'al Alam*, penelitian ini tidak hanya berfokus pada efisiensi algoritma, tetapi juga sebagai bentuk tanggung jawab sebagai khalifah untuk menjaga keseimbangan alam. Dengan adanya penelitian ini yang memberikan prediksi curah hujan harian, kita dapat meminimalisir risiko kerusakan lingkungan akibat ketidaksiapan menghadapi cuaca yang tidak pasti. Adanya penelitian ini sebagai ikhtiar untuk menjalin interaksi yang harmonis antara manusia dan alam, di mana sains digunakan untuk memahami tanda-tanda kebesaran-Nya agar kita dapat mengelola bumi dengan lebih bijak, efektif, dan penuh rasa syukur.

4.4 Intrumen Penelitian

Instrumen penelitian merupakan alat atau perangkat yang digunakan untuk mengumpulkan, mengolah, dan menganalisis data dalam rangka menjawab rumusan masalah yang telah ditetapkan. Dalam penelitian ini, instrumen yang digunakan terbagi menjadi dua aspek utama, yaitu perangkat keras, perangkat lunak, serta instrumen pengolahan data.

4.4.1 Perangkat Keras


Perangkat keras yang digunakan dalam penelitian ini dirancang untuk mendukung proses komputasi yang intensif, khususnya dalam tahap prapemrosesan data, pelatihan model (*training*), dan optimasi *hyperparameter*. Spesifikasi perangkat keras yang digunakan meliputi Processor AMD Ryzen 3 4000 Series yang mendukung pemrosesan paralel. Memori (RAM) 8 GB untuk memastikan kelancaran eksekusi manipulasi *dataset* berukuran besar dan operasi matriks pada pustaka *machine learning*. Unit Penyimpanan *Solid State Drive* (SSD) berkapasitas 512 GB untuk mempercepat waktu baca dan tulis data saat proses *training* model berjalan.

4.4.2 Perangkat Lunak

Perangkat lunak berfungsi sebagai lingkungan pengembangan dan wadah komputasi untuk membangun model prediksi. Perangkat lunak yang digunakan meliputi sistem operasi Windows sebagai platform utama eksekusi program. Bahasa pemrograman Python 3.13.5 sebagai bahasa utama dalam pengembangan skrip prapemrosesan, pemodelan, dan evaluasi. Pustaka atau *Library* pendukung komputasi dan pemodelan *Pandas* dan *NumPy* sebagai instrumen manipulasi, transformasi, dan analisis struktur data numerik. *Scikit-Learn* sebagai instrumen utama untuk membangun model *Gradient Boosting*, melakukan prapemrosesan *StandardScaler* dan *KNNImputer*, serta menjalankan teknik optimasi parameter menggunakan *RandomizedSearchCV*. *Matplotlib* dan *Seaborn* sebagai instrumen visualisasi data untuk menyajikan grafik distribusi, matriks korelasi, dan kurva perbandingan performa model.

4.4.3 Pengumpulan dan Variabel Data

Instrumen pengumpulan data dalam penelitian ini berupa *dataset* sekunder historis harian yang bersumber dari stasiun meteorologi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) wilayah Malang. Instrumen data ini mencakup variabel-variabel pengamatan meteorologi yang dikelompokkan ke dalam Variabel Independen yaitu fitur input dan Variabel Dependen yaitu target seperti pada Gambar 4.31.



Gambar 4. 29 Intrumen Penelitian

Seluruh instrumen di atas divalidasi dan diuji secara terintegrasi untuk memastikan bahwa proses eksperimen mulai dari penanganan *missing value*,

pelatihan algoritma *Gradient Boosting*, hingga evaluasi menggunakan metrik RMSE, MAE, dan R^2 dapat berjalan secara objektif, akurat, dan dapat direplikasi.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan mengenai prediksi curah hujan harian menggunakan algoritma *Gradient Boosting*, dapat disimpulkan beberapa poin utama yaitu pengaruh hasil optimasi yang mana proses optimasi hiperparameter terbukti secara signifikan meningkatkan stabilitas model dalam menangkap pola curah hujan dibandingkan dengan skenario *baseline*. Meskipun angka metrik *error* MAE dan RMSE pada *baseline* terkadang terlihat rendah, metrik R² yang rendah pada skenario tertentu mengonfirmasi bahwa optimasi sangat diperlukan untuk memastikan model melakukan generalisasi pola. Selanjutnya adalah komposisi data yang terdapat titik jenuh dalam penambahan data latih. Komposisi data 80/20 terbukti memberikan performa yang paling seimbang dan reliabel dibandingkan komposisi lainnya. Komposisi 90/10 cenderung menyebabkan model menjadi terlalu konservatif *bias* terhadap nilai rendah dan kehilangan fleksibilitas, sedangkan komposisi 50/50 atau 70/30 kurang memberikan informasi historis yang cukup bagi algoritma *Gradient Boosting* untuk mengenali pola musiman secara komprehensif. Tantangan prediksi evaluasi model *Gradient Boosting*, baik pada skenario *baseline* maupun *optimized*, masih menghadapi tantangan dalam memprediksi intensitas curah hujan ekstrem (>50 mm). Fenomena *underestimation* yang konsisten menunjukkan bahwa keterbatasan utama tidak lagi terletak pada struktur algoritma, melainkan pada distribusi data yang tidak seimbang dan keterbatasan variabel prediktor yang digunakan dalam merepresentasikan dinamika fisik atmosfer yang kompleks.

5.2 Saran

Berdasarkan hasil analisis dan keterbatasan penelitian, berikut adalah beberapa saran yang dapat diajukan untuk pengembangan penelitian selanjutnya yaitu untuk integrasi variabel meteorologi eksternal curah hujan sangat dipengaruhi oleh fenomena skala besar, disarankan untuk menambahkan fitur prediktor lain seperti

tekanan udara, indeks monsun, *Sea Surface Temperature* (SST), atau data satelit untuk meningkatkan sensitivitas model terhadap kondisi cuaca ekstrem. Penggunaan teknik *resampling* untuk mengatasi masalah *underestimation* pada hujan ekstrem, penelitian selanjutnya dapat menerapkan teknik *oversampling* seperti SMOTE untuk *time series* atau *cost-sensitive learning* yang memberikan bobot lebih tinggi pada kejadian hujan lebat agar model lebih responsif terhadap *outlier*. Eksplorasi arsitektur *hybrid* mengacu pada temuan Zoremsanga & Hussain (2024), disarankan untuk mengeksplorasi model *hybrid* yang menggabungkan keunggulan statistik *Gradient Boosting* dengan arsitektur *Deep Learning* seperti LSTM atau BiLSTM yang lebih unggul dalam menangkap ketergantungan temporal jangka panjang. Uji validitas geografis karena penelitian ini terbatas pada data cuaca harian di lokasi penelitian spesifik. Perlu dilakukan pengujian pada wilayah dengan topografi berbeda untuk melihat apakah model yang sama mampu memberikan akurasi yang konsisten.

DAFTAR PUSTAKA

- Abduh, A. M., Ridla, R., & Nofri Andi. (1935). 3327-6848-1-Sm. *Jurnal Ulunnuha*, 6(Juni 2016), 63–81.
- Al-Quran, L. P. M. (2016). *Tafsir Ringkas Jilid 1 Juz 24-30*.
- Alvines, M., Ravi Wijayanto, M., Archi Daffa Danendra, M., Rizky Herdiansyah, M., Karimsyah Lubis, M., Ichsan Farel Rachmad, M., Ditha Tania, K., & Meiriza, A. (2025). Komparasi Ridge Regression, Random Forest, Dan Gradient Boosting Untuk Prediksi Curah Hujan Harian Di Sumatra Selatan Berbasis Time Series Cross-Validation. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(4), 5742–5748. <https://doi.org/10.36040/jati.v9i4.13915>
- Appiah-badu, N. K. A., Missah, Y. A. W. M., Amekudzi, L. K., Ussiph, N., Frimpong, T., & Ahene, E. (2022). Rainfall Prediction Using Machine Learning Algorithms for the Various Ecological Zones of Ghana. *IEEE Access*, 10, 5069–5082. <https://doi.org/10.1109/ACCESS.2021.3139312>
- Ayub, A. A. S. bin A. bin. (2015). *Al Ma'jum Al Awsat*. Al Hidayah.
- Bariri, S. P. A. G. L. L. (2025). *Tragedi Sumatera: Ketika Hutan Hilang, Bencana Datang*. Stagaw Lorelindubariri. <https://gaw-bariri.bmkg.go.id/index.php/karya-tulis-dan-artikel/artikel/385-tragedi-sumatera-ketika-hutan-hilang-bencana-datang>
- Barrera-Animas, A. Y., Oyedele, L. O., Bilal, M., Akinosho, T. D., Delgado, J. M. D., & Akanbi, L. A. (2022). Rainfall prediction: A comparative analysis of modern machine learning algorithms for time-series forecasting. *Machine Learning with Applications*, 7(August 2021), 100204. <https://doi.org/10.1016/j.mlwa.2021.100204>
- Bauer, P., Thorpe, A., & Brunet, G. (2015). The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47–55. <https://doi.org/10.1038/nature14956>
- BMKG. (2025). *Data Terbuka BMKG*. BMKG. <https://data.bmkg.go.id/>
- BPBD, M. C. (2024). *Infografis Sebaran Kejadian Bencana Per 1 Des. 2024*. MalangKab Portal Resmi Kabupaten Malang. <https://malangkab.go.id/content/bpbd-opd@3507-infografis-sebaran-kejadian-bencana-per-1-des-2024>
- Bucaille, M. (1979). *BIBLE, QURAN & Sains Modern*. 237.
- Chang, F. J., Chiang, Y. M., Tsai, M. J., Shieh, M. C., Hsu, K. L., & Sorooshian, S. (2014). Watershed rainfall forecasting using neuro-fuzzy networks with the assimilation of multi-sensor information. *Journal of Hydrology*, 508, 374–384. <https://doi.org/10.1016/j.jhydrol.2013.11.011>

- Chen, H., Chandrasekar, V., Tan, H., & Cifelli, R. (2019). Rainfall Estimation From Ground Radar and TRMM Precipitation Radar Using Hybrid Deep Neural Networks. *Geophysical Research Letters*, 46(17–18), 10669–10678. <https://doi.org/10.1029/2019GL084771>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 13-17-Aug*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, Y., Ge, D., Ming, D., Member, S., Xu, L., Wu, Q., & Ma, Y. (2025). Quantitative Hazard Prediction of Rainfall-Induced Shallow Landslides Considering Triggering and Predisposing Factors: A Case of Natural Terrain Landslides in Hong Kong. *IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING*, 18, 13472–13488. <https://doi.org/10.1109/JSTARS.2025.3570020>
- Clive Cookson. (2023). *AI outperforms conventional weather forecasting methods for first time*. Climate Science in Financial Times. <https://www.ft.com/content/ca5d655f-d684-4dec-8daa-1c58b0674be1>
- Dao, P. B., & Staszewski, W. J. (2021). Lamb wave based structural damage detection using stationarity tests. *Materials*, 14(22). <https://doi.org/10.3390/ma14226823>
- de Goncalves, L. G. G., Shuttleworth, W. J., Nijssen, B., Burke, E. J., Marengo, J. A., Chou, S. C., Houser, P., & Toll, D. L. (2006). Evaluation of model-derived and remotely sensed precipitation products for continental South America. *Journal of Geophysical Research Atmospheres*, 111(16), 1–13. <https://doi.org/10.1029/2005JD006276>
- Diodato, N., & Ceccarelli, M. (2009). Combining Satellite and Geospatial Technologies for Rainstorms Hazard Soft Mapping. *The Open Environmental Engineering Journal*, 2(1), 97–103. <https://doi.org/10.2174/1874829500902010097>
- Diykh, M., Ali, M., Farooque, A. A., Aldhafeeri, A. A., Jamei, M., & Labban, A. (2026). A robust artificial intelligence informed over complete rational dilation wavelet transform technique coupled with deep learning for long-term rainfall prediction. *Engineering Applications of Artificial Intelligence*, 165(PB), 113426. <https://doi.org/10.1016/j.engappai.2025.113426>
- Dong, J., Zeng, W., Wu, L., Huang, J., Gaiser, T., & Srivastava, A. K. (2023). Enhancing short-term forecasting of daily precipitation using numerical weather prediction bias correcting with XGBoost in different regions of China. *Engineering Applications of Artificial Intelligence*, 117, 105579. <https://doi.org/https://doi.org/10.1016/j.engappai.2022.105579>
- Du, Y., Xiao, X., Liu, F., Zhu, W., Mo, J., & Liu, Z. (2025). Causal effects of metabolites on malignant neoplasm of bone and articular cartilage: a mendelian randomization study. *Frontiers in Genetics*, 16(March), 1–12. <https://doi.org/10.3389/fgene.2025.1366743>

- Ejike, O., Ndzi, D., & Shakir, M. Z. (2025). Comparative Study of Machine Learning-Based Rainfall Prediction in Tropical and Temperate Climates. *Climate*, 13(8), 1–27. <https://doi.org/10.3390/cli13080167>
- Gill, N., Hall, P., Montgomery, K., & Schmidt, N. (2020). A responsible machine learning workflow with focus on interpretable models, post-hoc explanation, and discrimination testing. *Information (Switzerland)*, 11(3), 1–32. <https://doi.org/10.3390/info11030137>
- Guldogan, E., Yagin, F. H., Pinar, A., Colak, C., Kadry, S., & Kim, J. (2023). A proposed tree-based explainable artificial intelligence approach for the prediction of angina pectoris. *Scientific Reports*, 13(1), 1–12. <https://doi.org/10.1038/s41598-023-49673-2>
- Guo, Z., Zhang, F., & Ji, Y. (2023). Investigating the Nonlinear Relationship between Takeout Order Demand and Built Environment under Different Periods of COVID-19. *Journal of Advanced Transportation*, 2023. <https://doi.org/10.1155/2023/5248888>
- Haq Doost, Z. H., Alsuwaiyan, A., Abdulraheem, A., Al-Areeq, N. M., & Yaseen, Z. M. (2025). Rainfall Prediction Using Integrated Machine Learning Models With K-Means Clustering: A Representative Case Study of Harirud Murghab Basin-Afghanistan. *IEEE Access*, 13(April), 111628–111646. <https://doi.org/10.1109/ACCESS.2025.3581921>
- Hassan, M., Abu, M., Rony, T., Khan, A. R., Hassan, M., Yasmin, F., Nag, A., Zarin, T. H., Bairagi, A. K., Alshathri, S., & El-shafai, W. (2023). Machine Learning-Based Rainfall Prediction: Unveiling Insights and Forecasting for Improved Preparedness. *IEEE Access*, 11(November), 132196–132222. <https://doi.org/10.1109/ACCESS.2023.3333876>
- Hastuti, M. I., Min, K. H., & Lee, J. W. (2023). Improving Radar Data Assimilation Forecast Using Advanced Remote Sensing Data. *Remote Sensing*, 15(11). <https://doi.org/10.3390/rs15112760>
- Ho, J., Lin, C., & Chen, W. (2024). *Quantitative Precipitation Forecast with a Radar Data Assimilation Method for Rainfall-induced Shallow Landslide Predictions*. 1–24.
- Imam Jalaludin Muhammad bin Ahmad Mahalli dan Syaikh Jalaluddin Abdurahman bin Abi Bakar Suyuti. (2010). *Terjemah Tafsir Jalalain*.
- Jatim, R. K. (2026). *Cuaca Ekstrem Tekan Omzet Maskapai, INACA Sebut Kerugian Capai 25 Persen*. Kilasjatim.Com. <https://kilasjatim.com/2026/01/27/cuaca-ekstrem-tekan-omzet-maskapai-inaca-sebut-kerugian-capai-25-persen/>
- Jumadi. (2026). *Banjir Lumpuhkan Pertanian Batang, 139 Hektare Sawah Dinyatakan Puso*. Berita Kanal Pemkab Batang. <https://berita.batangkab.go.id/?p=1&id=14832>
- K.H. Bisri Mustofa. (2016). *Al Ibriz JUZ 1*.
- Khan, A. A., Chaudhari, O., & Chandra, R. (2024). A review of ensemble learning and data

augmentation models for class imbalanced problems: Combination, implementation and evaluation. *Expert Systems with Applications*, 244(May 2023), 122778. <https://doi.org/10.1016/j.eswa.2023.122778>

Khan, M. I., & Maity, R. (2020). Hybrid Deep Learning Approach for Multi-Step-Ahead Daily Rainfall Prediction Using GCM Simulations. *IEEE Access*, 8(MI), 52774–52784. <https://doi.org/10.1109/ACCESS.2020.2980977>

KOMINFO. (2024). *Satu Data Kota Malang*. Satu Data Dinas KOMINFO Kota Malang. <https://satudata.malangkota.go.id/v2/publik/data/perencanaan/22>

Kumar, V., Kedam, N., Sharma, K. V., Khedher, K. M., & Alluqmani, A. E. (2023). A Comparison of Machine Learning Models for Predicting Rainfall in Urban Metropolitan Cities. *Sustainability (Switzerland)*, 15(18). <https://doi.org/10.3390/su151813724>

Latif, S. D., Alyaa Binti Hazrin, N., Hoon Koo, C., Lin Ng, J., Chaplot, B., Feng Huang, Y., El-Shafie, A., & Najah Ahmed, A. (2023). Assessing rainfall prediction models: Exploring the advantages of machine learning and remote sensing approaches. *Alexandria Engineering Journal*, 82(July), 16–25. <https://doi.org/10.1016/j.aej.2023.09.060>

Li, H., Guo, Q., Zhang, T., Zhou, S., & Guo, C. (2025). Interpretable Machine Learning for Predicting Anterior Uveitis in Axial Spondyloarthritis. *JCR: Journal of Clinical Rheumatology*, 31(5). https://journals.lww.com/jclinrheum/fulltext/2025/08000/interpretable_machine_learning_for_predicting.9.aspx

Liu, X., Yang, T., Hsu, K., Liu, C., & Sorooshian, S. (2017). Evaluating the streamflow simulation capability of PERSIANN-CDR daily rainfall products in two river basins on the Tibetan Plateau. *Hydrology and Earth System Sciences*, 21(1), 169–181. <https://doi.org/10.5194/hess-21-169-2017>

Lu, H., & Mazumder, R. (2020). Randomized Gradient Boosting Machine. *Siam J. OPTIM*, 30(4), 2780–2808. <https://hdl.handle.net/1721.1/130168%0AVersion:>

Manoj, O., & Ananth, J. P. (2020). MapReduce and Optimized Deep Network for Rainfall Prediction in Agriculture. *Computer Journal*, 63(6), 900–912. <https://doi.org/10.1093/comjnl/bxz164>

Mayr, A., Binder, H., Gefeller, O., & Schmid, M. (2014). The evolution of boosting algorithms: From machine learning to statistical modelling. *Methods of Information in Medicine*, 53(6), 419–427. <https://doi.org/10.3414/ME13-01-0122>

Meenal, R., Kailash, K., Michael, P. A., Joseph, J. J., Josh, F. T., & Rajasekaran, E. (2022). Machine learning based smart weather prediction. *Indonesian Journal of Electrical Engineering and Computer Science*, 28(1), 508–515.

<https://doi.org/10.11591/ijeecs.v28.i1.pp508-515>

Michaelides, S., Ivanov, S., Ruban, I., Charalambous, D., & Tymvios, F. (2020). *A Case Study of Weather Radar Data Assimilation Into the Harmonie Numerical Weather Prediction System*. <https://doi.org/10.5194/egusphere-egu2020-9350>

Monego, V. S., Anochi, J. A., & de Campos Velho, H. F. (2022). South America Seasonal Precipitation Prediction by Gradient-Boosting Machine-Learning Approach. *Atmosphere*, 13(2). <https://doi.org/10.3390/atmos13020243>

Oettl, D., & Veratti, G. (2021). A comparative study of mesoscale flow-field modelling in an Eastern Alpine region using WRF and GRAMM-SCI. *Atmospheric Research*, 249(September 2020), 105288. <https://doi.org/10.1016/j.atmosres.2020.105288>

Patil, K. R., Doi, T., Ratnam, J. V., & Behera, S. K. (2025). Enhancing Indian summer monsoon prediction: Deep learning approach for skillful long-lead forecasts of rainfall. *Applied Computing and Geosciences*, 26(August 2024), 100257. <https://doi.org/10.1016/j.acags.2025.100257>

Prameswari, L. B. (2026). *BNPB: Korban meninggal bencana Sumatera 1.177 orang per 4 Januari*. Antara Kantor Berita Indonesia. <https://www.antaranews.com/berita/5332846/bnpb-korban-meninggal-bencana-sumatera-1177-orang-per-4-januari>

Rasp, S., Dueben, P. D., Scher, S., Weyn, J. A., Mouatadid, S., & Thuerey, N. (2020). WeatherBench: A Benchmark Data Set for Data-Driven Weather Forecasting. *Journal of Advances in Modeling Earth Systems*, 12(11). <https://doi.org/10.1029/2020MS002203>

Reuters. (2024). *Indonesia predicted to have a normal wet season in 2025, weather agency says*. Reuters. <https://www.reuters.com/world/asia-pacific/indonesia-predicted-have-normal-wet-season-2025-weather-agency-says-2024-11-04/>

Riccio, D., Maturo, F., Mazzitelli, A., Maria Bifulco, G., & Paolone, F. (2025). Explainable gradient boosting for corporate crisis forecasting in Italian businesses. *Annals of Operations Research*, 353(2), 815–839. <https://doi.org/10.1007/s10479-025-06570-3>

Rodriguez-Ramirez, M. A., & Fuentes-Mariles, Ó. A. (2023). Daily rainfall assimilation based on satellite and weather radar precipitation products along with rain gauge networks. *Journal of Hydroinformatics*, 25(6), 2354–2368. <https://doi.org/10.2166/hydro.2023.104>

Sathyanarayana, S., & Mohanasundaram, T. (2025). Stationarity and Unit Roots in Time Series: Theoretical Insights and Practical Considerations. In *IRA-International Journal of Management & Social Sciences (ISSN 2455-2267)* (Vol. 21, Issue 2). <https://doi.org/10.21013/jmss.v21.n2.p1>

Sharma, O., Trivedi, D., Pattnaik, S., Hazra, V., & Puhan, N. B. (2023). Improvement in

District Scale Heavy Rainfall Prediction Over Complex Terrain of North East India Using Deep Learning. *IEEE Transactions on Geoscience and Remote Sensing*, 61, 1–8. <https://doi.org/10.1109/TGRS.2023.3322676>

Shihab, M. Q. (2002). Tafsir-Al-Mishbah-Jilid-09-M.-Quraish-Shihab. In *Jakarta : Lentera Hati*.

Shrivastav, L. K., & Kumar, R. (2021). An Ensemble of Random Forest Gradient Boosting Machine and Deep Learning Methods for Stock Price Prediction. *Journal of Information Technology Research*, 15(1), 1–19. <https://doi.org/10.4018/jitr.2022010102>

Sinaga, A. A., Silvia, D., Arianti, D., Sinaga, J. A., & Purba, O. S. R. (2025). Curah Hujan Di Indonesia. *Jurnal Intelek Dan Cendekiawan Nusantara*, 2(6), 11497–11504. <https://jicnusantara.com/index.php/jicn>

Suhartono, & Subanar. (2006). The Effect of Decomposition Method As Data Preprocessing on Neural Networks Model for forecasting trend and seasonal time series. *Jurnal Teknik Industri*, 8(2), 156–164.

Sulochana, B. C., Pragada, B. S., Kiran, B. C., Reddy, G. A., & K, M. (2024). Machine Learning in Weather Forecasting: A Comparative Approach with Emphasis on Neural Networks and Optimizer. *2024 International Conference on Advances in Modern Age Technologies for Health and Engineering Science (AMATHE)*, 1–7. <https://doi.org/10.1109/AMATHE61652.2024.10582220>

Svetnik, V., Wang, T., Tong, C., Liaw, A., Sheridan, R. P., & Song, Q. (2005). Boosting: an Ensemble Learning Tool for Compound Classification and QSAR Modeling. *Journal of Chemical Information and Modeling*, 45(3), 786–799. <https://doi.org/10.1021/ci0500379>

Syukur, M. A. A., Suhartono, S., & Chamidy, T. (2025). Prediksi Kualitas Udara Menggunakan Metode CatBoost. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 10(2), 249–258. <https://doi.org/10.14421/jiska.2025.10.2.249-258>

Syukur, M. A. A., Suhartono, S., & Imamudin, M. (2026). Penerapan Metode Gradient Boosting Regressor Untuk Prediksi Curah Hujan Berdasarkan Data Cuaca Harian BMKG. *Bulletin of Data Science*, 5(3), 119–127. <https://doi.org/10.47065/bulletinds.v5i3.10071>

Tondang, Y. M., Situmorang, M., Ikhsan, T., & Darmawan, Y. (2023). Accuracy of Weather Radar Products for Rainfall Estimation in North Sumatra Region. *Prisma Sains : Jurnal Pengkajian Ilmu Dan Pembelajaran Matematika Dan IPA IKIP Mataram*, 11(2), 351. <https://doi.org/10.33394/j-ps.v11i2.7720>

Usman, C. D., Widodo, A. P., Adi, K., & Gernowo, R. (2023). Rainfall prediction model in Semarang City using machine learning. *Indonesian Journal of Electrical Engineering*

and Computer Science, 30(2), 1224–1231.
<https://doi.org/10.11591/ijeeecs.v30.i2.pp1224-1231>

Veverka, L. (2024). Assessing the Impact of Affiliate Marketing on E-Commerce Performance: a Time Series Analysis. *Investigacion Operacional*, 45(5), 711–727.

Wahbah Az-Zuhaili. (2016). Tafsir Al-Munir Jilid 13 Fi Aqidah, Syariah, Manhaj Terj. Abdul Hayyie al-kattani, dkk, Cet 1. *Gema Insani*, 9, 19.

Wang, J., Zhang, L., Guan, J., & Zhang, M. (2020). Evaluation of combined satellite and radar data assimilation with POD-4DEnVar method on rainfall forecast. *Applied Sciences (Switzerland)*, 10(16). <https://doi.org/10.3390/app10165493>

Weir, P., & Dahlhaus, P. (2024). Merging weather radar and rain gauges for dryland agriculture. *Journal of Southern Hemisphere Earth Systems Science*, 74(2), 1–20. <https://doi.org/10.1071/ES23023>

Xu, H., Zhai, G., & Li, X. (2018). Convective-stratiform rainfall separation of typhoon Fitow (2013): A 3D WRF modeling study. *Terrestrial, Atmospheric and Oceanic Sciences*, 29(3), 315–329. <https://doi.org/10.3319/TAO.2017.10.11.01>

Yin, J., Han, W., Gao, Z., & Chen, H. (2021). Assimilation of Doppler Radar Radial Wind Data in the GRAPES Mesoscale Model With Observation Error Covariances Tuning. *Quarterly Journal of the Royal Meteorological Society*, 147(737), 2087–2102. <https://doi.org/10.1002/qj.4036>

Zhang, X., Mohanty, S. N., Parida, A. K., Pani, S. K., Dong, B., & Cheng, X. (2020). Annual and Non-Monsoon Rainfall Prediction Modelling Using SVR-MLP: An Empirical Study from Odisha. *IEEE Access*, 8, 30223–30233. <https://doi.org/10.1109/ACCESS.2020.2972435>

Zhang, Z., Su, M., Jiang, P., Wang, X., Kong, L., Tong, X., & Wu, G. (2025). Interpretable machine learning model to predict 90-day radiographically confirmed pneumonia after chemotherapy initiation in non-Hodgkin lymphoma: development and internal validation of a single-center cohort. *Frontiers in Medicine*, 12(September), 1–19. <https://doi.org/10.3389/fmed.2025.1674896>

Zhao, C., Dong, L., Xie, B., Shi, W., Wang, A., Wu, J., & Li, Q. (2026). Extreme rainfall south of the Yangtze River in China during June 2024: Observational diagnosis and dynamical downscaling prediction. *Atmospheric Research*, 330(June 2024), 108616. <https://doi.org/10.1016/j.atmosres.2025.108616>

Zharova, A., Boer, A., Knoblauch, J., Schewina, K. I., & Vihs, J. (2024). An explainable multi-agent recommendation system for energy-efficient decision support in smart homes. *Environmental Data Science*, 3, 1–10. <https://doi.org/10.1017/eds.2024.8>

Zoremsanga, C., & Hussain, J. (2024). Particle Swarm Optimized Deep Learning Models for Rainfall Prediction : A Case Study in Aizawl , Mizoram. *IEEE Access*, 12(April),

57172–57184. <https://doi.org/10.1109/ACCESS.2024.3390781>