

**PREDIKSI CURAH HUJAN MENGGUNAKAN METODE *ADAPTIVE*
*NEURO-FUZZY INFERENCE SYSTEM***

SKRIPSI

Oleh :
MUHAMMAD RAMA NURHUDA SAHRI
NIM. 18650066



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI CURAH HUJAN MENGGUNAKAN METODE *ADAPTIVE
NEURO-FUZZY INFERENCE SYSTEM***

SKRIPSI

**Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)**

**Oleh :
MUHAMMAD RAMA NURHUDA SAHRI
NIM. 18650066**

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

**PREDIKSI CURAH HUJAN MENGGUNAKAN METODE *ADAPTIVE
NEURO-FUZZY INFERENCE SYSTEM***

SKRIPSI

Oleh :
MUHAMMAD RAMA NURHUDA SAHRI
NIM. 18650066

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 5 Juni 2025

Pembimbing I,



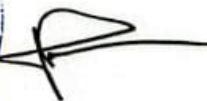
Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

Pembimbing II,



Fatchurrochman, M.Kom
NIP. 19700731 200501 1 002

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



Dr. Ir. Fachrul Kurniawan S.T., M.MT., IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

PREDIKSI CURAH HUJAN MENGGUNAKAN METODE *ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM*

SKRIPSI

Oleh :
MUHAMMAD RAMA NURHUDA SAHRI
NIM. 18650066

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 25 Juni 2025

Susunan Dewan Penguji

Ketua Penguji : Dr. Ir. Fresy Nugroho, S.T., M.T., IPM
NIP. 19710722 201101 1 001



Anggota Penguji I : Tri Mukti Lestari, M.Kom
NIP. 19911108 202012 2 005



Anggota Penguji II : Dr. Zainal Abidin, M.Kom
NIP. 19760613 200501 1 004

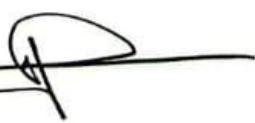


Anggota Penguji III : Fatchurrochman, M.Kom
NIP. 19700731 200501 1 002



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




Dr. Ir. Fachrul Kurniawan S.T., M.MT., IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Muhammad Rama Nurhuda Sahri
NIM : 18650066
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Curah Hujan.Menggunakan Metode *Adaptive Neuro-Fuzzy Inference System*.

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, 24 Juni 2025
Yang membuat pernyataan,



Muhammad Rama Nurhuda Sahri
NIM.18650066

MOTTO

... Hidup ini bukan tentang menemukan dirimu, tapi tentang menciptakan dirimu...

... Jika Melakukan Sesuatu Jangan setengah-setengah! Lakukan dengan sepenuh hati atau jangan lakukan sama sekali ...

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT atas limpahan rahmat dan kemudahan-Nya, akhirnya skripsi ini dapat terselesaikan dengan baik.

Karya ini penulis persembahkan kepada:

Ibu tercinta, Irma Siti Mariah

Yang selalu mengalirkan kasih sayang, usaha terbaik, do'a-do'a tulus, dukungan, dan nasehat yang tiada henti.

Ayah tercinta, Sahri

Yang senantiasa memberikan kekuatan, usaha terbaik, serta dukungan moral maupun materi.

Kakak dan Adik tercinta, Rima Rizqi Nurfitri dan Rio Ikhsanul Hassan
Yang menjadi salah satu motivasi dan dorongan untuk terus maju hingga skripsi ini terselesaikan.

Segenap keluarga besar,

Yang selalu mengiringi perjalanan penulis dengan do'a dan dukungan.

Last but not least, teruntuk diri sendiri

Terima kasih untuk tidak menyerah, terima kasih sudah bertahan sejauh ini.

KATA PENGANTAR

Bismillahirrahmaanirrahiim

Alhamdulillah segala puji dan Syukur senantiasa penulis panjatkan pada Allah subhanahu wa ta'ala atas berkat Rahmat, serta hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Prediksi Curah Hujan.Menggunakan Metode *Adaptive Neuro-Fuzzy Inference System*”. Sholawat serta salam tetap tercurahkan kepada Nabi Muhammad SAW. Dan semoga kita semua mendapat syafaatnya di hari akhir kelak, Aamiin.

Penulis mengucapkan rasa terima kasih yang begitu besar kepada seluruh pihak yang memberikan dukungan dan motivasi kepada penulis sehingga dapat menyelesaikan skripsi ini. Ucapan terima kasih ini penulis disampaikan kepada:

1. Prof. Dr. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Harini, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Ir. Fachrul Kurniawan, M.MT, IPU., selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Dr. Zainal Abidin, M.Kom., selaku pembimbing utama yang dengan penuh kesabaran dan ketulusan hati memberikan bimbingan, arahan, serta dorongan dalam setiap tahap penyusunan skripsi ini.

5. Fatchurrochman, M.Kom., selaku pembimbing kedua penulis yang selalu memberikan masukan selama perkuliahan hingga terselesaikannya skripsi ini.
6. Dr. Ir. Fresy Nugroho, ST., MT, IPM., selaku penguji utama dan Tri Mukti Lestari, M.Kom., selaku penguji kedua yang telah berkenan menguji serta memberikan masukan yang membangun sehingga skripsi ini dapat terselesaikan dengan baik.
7. Nia Faricha S, Si., selaku admin Program Studi Teknik Informatika yang selalu sabar memberikan informasi, membantu, dan memberikan arahan selama perkuliahan dan proses penulisan skripsi ini.
8. Segenap dosen, laboran, dan jajaran staff Program Studi Teknik Informatika yang telah memberikan ilmu, pengetahuan, dan dukungan selama penulis menjalani studi hingga selesainya skripsi ini.
9. Kedua orang tua tercinta, Ibu Irma Siti Mariah dan Ayah Sahri yang selalu menjadi sumber kekuatan bagi penulis. Terima kasih karena selalu mengusahakan yang terbaik. Semoga Allah senantiasa memberikan kesehatan dan lindungan, sehingga dapat selalu berada disetiap perjalanan dan pencapaian penulis.
10. Kakak dan Adik tersayang Rima Rizqi Nurfajri dan Rio Ikhsanul Hassan seluruh keluarga besar yang tiada henti memberikan do'a dan dukungan sehingga penulis mampu menyelesaikan skripsi ini.
11. Teman-teman satu kos-an, Abidzar Alghifari, Abdurrahman Wahid Khassogi, dan Prayudha Anugrah Wiratama yang telah setia menjadi

supporter dan teman berdiskusi sehingga penulis tidak tersesat dalam membuat skripsi ini

12. Seluruh warga Teknik Informatika khususnya angkatan 2018 “UFO” yang telah memberikan kehangatan, motivasi, dan dukungan kepada penulis.
13. Seluruh pihak yang telah terlibat, baik secara langsung maupun tidak langsung dari awal perkuliahan hingga akhir penulisan skripsi ini.

Penulis menyadari bahwa dalam penyusunan skripsi ini masih jauh dari kata sempurna. Maka dari itu penulis menerima saran, kritik dan masukan yang bersifat membangun sehingga skripsi ini dapat lebih dikembangkan. Penulis berharap semoga skripsi ini dapat memberikan manfaat untuk kedepannya.

Wassalamu 'alaikum warahmatullahi wabarakatuh.

Malang, 26 Juni 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xiv
ABSTRAK	xvi
ABSTRACT	xvii
مستخلص البحث.....	xviii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah.....	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	3
BAB II STUDI PUSTAKA	5
2.1 Penelitian Terkait	5
2.2 Variabel Iklim yang Mempengaruhi Curah Hujan.....	10
2.3 Ketidakpastian dalam Data Iklim.....	10
2.4 Logika <i>Fuzzy</i>	11
2.5 Jaringan Saraf Tiruan (<i>Artificial Neural Network - ANN</i>)	12
2.6 <i>Adaptive Neuro-Fuzzy Inference System (ANFIS)</i>	13
2.6.1 Arsitektur ANFIS	13
2.6.2 Kelebihan dan Kekurangan ANFIS.....	19
2.7 Metrik Evaluasi Model.....	19
BAB III DESAIN DAN IMPLEMENTASI	21
3.1 Desain.....	21
3.1.1 Desain Penelitian	21
3.1.2 Desain Sistem	24
3.2 Analisis.....	26
3.2.1 Sumber Data	26
3.2.2 Pengujian Penelitian	27
3.2.3 Memasukkan Data	28
3.2.4 <i>Pra-Processing</i> Data.....	29
3.2.5 Pembangunan model ANFIS	32
3.2.6 Evaluasi Model.....	35
3.2.7 <i>Ouput</i> dan Visualisasi.....	37
3.3 Implementasi Sistem	40

3.3.1 Memasukkan Data	40
3.3.2 Pra-pemrosesan Data	41
3.3.3 Pembangunan Model ANFIS.....	48
BAB IV HASIL DAN PEMBAHASAN	57
4.1 Hasil	57
4.1.1 Hasil Pra-pemrosesan Data.....	57
4.1.2 Hasil <i>Training</i>	58
4.1.3 Hasil <i>Testing</i>	62
4.1.4 Hasil Prediksi.....	63
4.2 Pembahasan.....	66
4.2.1 Korelasi Antarvariabel.....	66
4.2.2 Akurasi Model dan Pengaruh Pembagian Data	68
4.2.3 Analisa Prediksi Curah Hujan	70
4.3 Kajian Penelitian dalam Perspektif Islam	72
BAB V KESIMPULAN DAN SARAN	75
5.1 Kesimpulan	75
5.2 Saran.....	75
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Arsitektur ANFIS	14
Gambar 3.1 Diagram Alir Penelitian	22
Gambar 3.2 Diagram Alir Sistem	25
Gambar 3.3 Output Program	37
Gambar 3.4 Hasil Visualisasi	39
Gambar 3.5 Kode <i>Missing Value</i>	42
Gambar 3.6 Kode Penghapusan <i>Outlier</i>	43
Gambar 3.7 Kode Inkonsistensi Data.....	44
Gambar 3.8 Kode Normalisasi Data	46
Gambar 3.9 Kode Pembagian Data.....	47
Gambar 3.10 Kode Lapisan <i>Input</i>	49
Gambar 3.11 Kode Lapisan Fuzzifikasi.....	50
Gambar 3.12 Kode Lapisan Basis Aturan.....	52
Gambar 3.13 Kode Lapisan Normalisasi	54
Gambar 3.14 Kode Lapisan Deffuzifikasi	55
Gambar 4.1 Ouput Pra-pemroresan Data	57
Gambar 4.2 Ouput Data Training Rasio 70:30	59
Gambar 4.3 Ouput Data Training rasio 80:20.....	60
Gambar 4.4 Ouput Data Training Rasio 90:10	61
Gambar 4.5 Output Data Testing	62
Gambar 4.6 Feature Correlation Matrix,.....	67
Gambar 4.7 Perbandingan Prediksi vs Aktual (Semua Rasio).....	69
Gambar 4. 8 Prediksi Curah Hujan (Kategori)	71

DAFTAR TABEL

Tabel 2.1 Penelitian Terdahulu	5
Tabel 3.1 <i>Dataset</i> BMKG	27
Tabel 3.2 Variabel Penelitian	29
Tabel 3.3 Contoh <i>Output</i> Data Curah Hujan.....	35
Tabel 3.4 Evaluasi Komprehensif	36
Tabel 4.1 Tabel Hasil Prediksi.	64

DAFTAR SIMBOL

Lambang Romawi

<i>Lambang</i>	<i>Kuantitas</i>	<i>Satuan</i>
x	Variabel <i>Input</i>	-
y	Variabel Target	mm
O	<i>Output</i>	-
i	aturan atau fungsi keanggotaan	-
μ	Fungsi Keanggotaan <i>Fuzzy</i>	-
A, B	Himpunan <i>Fuzzy</i>	-
w	<i>Firing Strength</i>	-
f	Fungsi linier konsekuen	-
p, q, r	Parameter Konsekuean	-
n	Jumlah aturan <i>Fuzzy</i>	-

Singkatan

ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
BMKG	Badan Meteorologi, Klimatologi, dan Geofisika
AI	<i>Artificial Intelligence</i>
MAE	<i>Mean Absolute Error</i>
RMSE	<i>Root Mean Square Error</i>
IQR	<i>Interquartile Range</i>

ABSTRAK

Sahri, Muhammad Rama Nurhuda. 2025. **Prediksi Curah Hujan Menggunakan Metode *Adaptive Neuro-Fuzzy Inference System***. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Dr. Zainal Abidin, M. Kom (II) Fatchurrochman, M.Kom.

Kata kunci: ANFIS, prediksi curah hujan, *fuzzy logic*, jaringan saraf tiruan, BMKG.

Curah hujan merupakan salah satu parameter penting dalam sistem iklim yang berpengaruh besar terhadap sektor pertanian, pengelolaan sumber daya air, serta mitigasi bencana. Fluktuasi curah hujan yang tinggi dan pola yang bersifat non-linier menyebabkan kebutuhan akan model prediksi yang akurat. Penelitian ini bertujuan untuk membangun model prediksi curah hujan harian menggunakan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Data yang digunakan diperoleh dari BMKG Kota Padang dengan periode lima tahun (2020–2024) sebanyak 1.826 data harian yang terdiri dari delapan parameter iklim, yaitu suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, penyinaran matahari, kecepatan angin maksimum, arah angin maksimum, dan kecepatan angin rata-rata. Pra-pemrosesan data dilakukan dengan menghapus nilai yang hilang (*missing value*), penghapusan *outlier* menggunakan metode Interquartile Range (IQR), serta normalisasi menggunakan metode *Min-Max*. Model ANFIS dievaluasi dengan tiga skenario pembagian data, yaitu 70:30, 80:20, dan 90:10. Hasil evaluasi menunjukkan bahwa model memiliki tingkat akurasi yang bervariasi pada setiap rasio. Nilai MAE berkisar antara 9,81 hingga 10,74 mm, RMSE sebesar 16,18 hingga 16,70 mm, dan nilai koefisien determinasi (R^2) yang rendah pada rentang 0,07 hingga 0,17. Hal ini menunjukkan bahwa kemampuan generalisasi model masih kurang, terutama dalam memprediksi kejadian curah hujan dengan intensitas tinggi. Model ini lebih baik dalam memprediksi kondisi tidak hujan atau hujan ringan, namun kurang akurat untuk hujan sedang hingga sangat lebat. Hasil penelitian ini menunjukkan bahwa metode ANFIS dapat digunakan sebagai *baseline* untuk prediksi curah hujan harian, namun masih memerlukan pengembangan lebih lanjut, seperti penambahan variabel *input*, penyesuaian fungsi keanggotaan, dan penerapan metode hibrid atau algoritma optimasi guna meningkatkan akurasi model, khususnya pada prediksi kejadian ekstrem.

ABSTRACT

Sahri, Muhammad Rama Nurhuda. 2025. **Rainfall Prediction Using the Adaptive Neuro-Fuzzy Inference System Method**. Undergraduate Thesis. Informatic Engineering Department The Faculty of Science and Technology Universitas Islam Negeri Maulana Malik Ibrahim Malang. Promotor: (I) Dr. Zainal Abidin, M. Kom (II) Fatchurrochman, M.Kom.

Keywords: ANFIS, rainfall prediction, fuzzy logic, neural network, BMKG.

Rainfall is one of the key parameters in the climate system that significantly impacts agriculture, water resource management, and disaster mitigation. The high variability and non-linear patterns of rainfall create a strong demand for accurate prediction models. This study aims to develop a daily rainfall prediction model using the Adaptive Neuro-Fuzzy Inference System (ANFIS) method. The dataset was obtained from the Meteorological, Climatological, and Geophysical Agency (BMKG) of Padang City, covering five years (2020–2024) with 1,826 daily records. It includes eight climatic parameters: minimum temperature, maximum temperature, average temperature, humidity, solar radiation, maximum wind speed, maximum wind direction, and average wind speed. Data preprocessing was applied through handling missing values, outlier removal using the Interquartile Range (IQR) method, and normalization using the Min-Max method. The ANFIS model was evaluated under three data-splitting scenarios: 70:30, 80:20, and 90:10. The evaluation results showed that the model produced varying accuracy levels across different splits. The Mean Absolute Error (MAE) ranged from 9.81 to 10.74 mm, while the Root Mean Square Error (RMSE) ranged from 16.18 to 16.70 mm. The coefficient of determination (R^2) was relatively low, ranging from 0.07 to 0.17, indicating that the model's generalization ability is still limited, particularly in predicting high-intensity rainfall events. The model performs better in predicting no-rain or light rain conditions but struggles with moderate to heavy rainfall predictions. This study concludes that the ANFIS method can serve as a baseline model for daily rainfall prediction; however, further development is needed to improve its accuracy. Potential improvements include adding more input variables, optimizing membership functions, and implementing hybrid approaches or optimisation algorithms to enhance performance, especially in forecasting extreme rainfall events.

مستخلص البحث

ساهري ، محمد راما نورهدا. 2025. توقع هطول الأمطار باستخدام نظام الاستدلال العصبي الضبابي التكيفي. رسالة حثية
قسم هندسة المعلوماتية، كلية العلوم والتكنولوجيا، الجامعة الإسلامية الحكومية مولانا مالك إبراهيم مالانج المشرفان
(: 1) الدكتور زين العابدين، م. كوم 2) فاتح الرحمن، م. كوم

الكلمات الأساسية: BMKG، التنبؤ بحطول الأمطار، المنطق الضبابي، الشبكة العصبية، ANFIS

يُعدُّ هطول الأمطار أحد العناصر الأساسية في النظام المناخي، وله تأثير كبير على قطاعات الزراعة وإدارة الموارد المائية والحد من الكوارث. إن التقلب العالي والأنماط غير الخطية لهطول الأمطار يفرضان الحاجة إلى نماذج دقيقة للتنبؤ. يهدف هذا البحث إلى تم الحصول على (ANFIS) بناء نموذج لتنبؤ هطول الأمطار اليومي باستخدام طريقة نظام الاستدلال العصبي الضبابي التكيفي في مدينة بادانغ خلال فترة خمس سنوات (2020-2024) (BMKG) البيانات من وكالة الأرصاد الجوية وعلم المناخ والجيوفيزياء بواقع 1826 سجلاً يوميًا. تشمل البيانات ثمانية معايير مناخية، وهي: درجة الحرارة الدنيا، درجة الحرارة القصوى، متوسط درجة الحرارة، الرطوبة، مدة الإشعاع الشمسي، سرعة الرياح القصوى، اتجاه الرياح القصوى، ومتوسط سرعة الرياح. تمت معالجة البيانات Min- والتطبيع باستخدام طريقة (IQR) من خلال التعامل مع القيم المفقودة، وإزالة القيم الشاذة باستخدام طريقة النطاق الربيعي باستخدام ثلاث نسب لتقسيم البيانات: 70:30، 80:20، و 90:10. أظهرت نتائج التقييم ANFIS تم تقييم نموذج Max. بين 9.81 و 10.74 ملم، والانحراف (MAE) أن دقة النموذج تختلف باختلاف نسب التقسيم. تراوحت قيمة متوسط الخطأ المطلق بين 16.18 و 16.70 ملم، بينما كانت (RMSE) الجذري التربيعي للخطأ قيمودج أساسي للتنبؤ بحطول الأمطار اليومي، لكنها تتطلب مزيدًا من التطوير لتحسين الدقة، مثل إضافة المزيد من المتغيرات المدخلة، وتحسين وظائف الانتماء، وتطبيق طرق هجينة أو خوارزميات تحسين لتعزيز أداء النموذج، خاصة في التنبؤ بحالات الأمطار القليلة، ومنخفضة، حيث تراوحت بين 0.07 و 0.17، مما يدل على أن قدرة النموذج على التعميم ما زالت (R²) صوى.ة معامل التحديد، محدودة، خاصة في التنبؤ بحطول الأمطار الغزيرة. أظهر النموذج أداءً جيدًا في التنبؤ بحالات عدم هطول الأمطار أو الأمطار الخفيفة لكنه كان أقل دقة في التنبؤ بالأمطار المتوسطة إلى الغزيرة. وإثراء معالم الإدخال

BAB I

PENDAHULUAN

1.1 Latar Belakang

Curah hujan merupakan faktor krusial dalam siklus hidrologi yang memengaruhi beragam sektor, dengan dampak yang paling signifikan di negara tropis seperti Indonesia. Di negeri ini, curah hujan memiliki peranan yang penting dalam pengelolaan pertanian, pengelolaan sumber daya air, serta mitigasi bencana alam, terutama banjir dan kekeringan. Variabilitas curah hujan yang sering kali sulit diprediksi, terutama akibat fenomena cuaca global seperti *El Niño* dan *La Niña*, dapat menyebabkan bencana besar serta kerugian material dan ekonomi (Fauzi et al., 2024). Oleh karena itu, kemampuan untuk meramalkan curah hujan, terutama yang ekstrem dalam periode singkat, menjadi sangat penting. Ini tidak hanya untuk perencanaan pertanian dan pengelolaan sumber daya air, tetapi juga dalam mitigasi risiko bencana.

هُوَ الَّذِي أَنْزَلَ مِنَ السَّمَاءِ مَاءً لَكُمْ مِنْهُ شَرَابٌ وَمِنْهُ شَجَرٌ فِيهِ تُسِيمُونَ ﴿١٠﴾

"Dialah yang telah menurunkan air (hujan) dari langit untuk kamu. Sebagiannya menjadi minuman dan sebagiannya (menyuburkan) tumbuhan yang dengannya kamu menggembalakan ternakmu." (Q.S An-Nahl: 10).

Dalam beberapa tahun terakhir, teknologi informasi dan pemodelan matematis telah berkembang pesat, termasuk dalam bidang meteorologi. Salah satu metode yang menjanjikan untuk prediksi curah hujan adalah *Adaptive Neuro-Fuzzy Inference System* (ANFIS). ANFIS menggabungkan prinsip-prinsip jaringan saraf dan logika, yang memungkinkan sistem untuk belajar dari data dan membuat

prediksi yang lebih akurat. Menurut El-Shafie et al. (2020), ANFIS telah terbukti efektif dalam memprediksi curah hujan di berbagai lokasi, termasuk di Malaysia.

Namun, meskipun ada banyak penelitian yang menggunakan ANFIS untuk prediksi curah hujan, masih terdapat celah dalam penerapan metode ini di Indonesia. Banyak studi yang fokus pada daerah tertentu tanpa mempertimbangkan variasi iklim yang ada di seluruh Indonesia. Penelitian ini bertujuan untuk mengisi celah tersebut dengan menerapkan ANFIS untuk memprediksi curah hujan di beberapa daerah di Indonesia, serta menganalisis faktor-faktor yang mempengaruhi akurasi prediksi.

Statistik menunjukkan bahwa fenomena perubahan iklim telah menyebabkan peningkatan frekuensi dan intensitas curah hujan ekstrem di Indonesia. Menurut Mabruroh dan Wiyanto (2023), perubahan iklim dapat menyebabkan curah hujan yang tidak terduga, yang berpotensi mengakibatkan bencana alam seperti banjir. Oleh karena itu, penting untuk mengembangkan sistem prediksi yang dapat memberikan peringatan dini dan membantu masyarakat dalam mengantisipasi dampak negatif dari perubahan cuaca.

Dengan menggunakan ANFIS, diharapkan dapat dikembangkan model prediksi curah hujan yang lebih akurat dan responsif terhadap perubahan iklim. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam pengelolaan pertanian, pengelolaan sumber daya air dan mitigasi bencana di Indonesia, serta menjadi acuan bagi penelitian selanjutnya di bidang meteorologi.

1.2 Rumusan Masalah

Bagaimana performa model *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dalam memprediksi curah hujan di Indonesia?

1.3 Batasan Masalah

1. Sumber data untuk penelitian ini adalah *dataset* yang diambil dari BMKG (Badan Meteorologi, Klimatologi, dan Geofisika). *Dataset* ini mencakup informasi cuaca dalam 5 tahun terakhir.
2. Data untuk penelitian ini akan diambil dari sumber *dataset* yang telah tersedia secara publik. Tidak ada proses pengumpulan data lanjutan yang dilakukan oleh peneliti.
3. Algoritma ANFIS (*Adaptive Neuro-Fuzzy Inference System*) dan seleksi fitur-fitur berdasarkan *dataset* cuaca yang akan diimplementasikan menggunakan bahasa pemrograman *Python* dengan bantuan pustaka *scikit-learn*.

1.4 Tujuan Penelitian

Mengevaluasi tingkat akurasi model ANFIS dalam memprediksi curah hujan berdasarkan data historis cuaca di wilayah Indonesia.

1.5 Manfaat Penelitian

1. Manfaat Akademis: Penelitian ini diharapkan dapat menambah wawasan ilmiah dan memberikan kontribusi dalam pengembangan metode prediksi curah hujan menggunakan ANFIS, yang dapat dijadikan referensi untuk

penelitian lebih lanjut dalam bidang meteorologi, klimatologi, dan teknologi kecerdasan buatan.

2. Manfaat Sosial: Hasil prediksi curah hujan dari studi ini bermanfaat bagi masyarakat dan instansi terkait. Informasi ini mendukung pengelolaan pertanian untuk meningkatkan produktivitas. Selain itu, prediksi ini berkontribusi pada mitigasi bencana, membantu masyarakat dan pemerintah dalam mengambil langkah pencegahan yang tepat, serta mengelola sumber daya air secara efektif untuk memastikan ketersediaan air bagi pertanian, industri, dan kebutuhan domestik.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Dalam beberapa tahun terakhir, penelitian mengenai prediksi curah hujantelah berkembang pesat, terutama dengan penerapan teknik-teknik berbasis kecerdasan buatan seperti *Adaptive Neuro-Fuzzy Inference System* (ANFIS). ANFIS merupakan kombinasi dari jaringan syaraf tiruan dan sistem inferensi yang memungkinkan penanganan ketidakpastian dan kompleksitas data meteorologi. Sebuah studi oleh El-Shafie et al. (2020) menunjukkan bahwa penggunaan ANFIS dalam memprediksi curah hujan di Sungai Klang, Malaysia, menghasilkan akurasi yang lebih baik dibandingkan dengan metode tradisional.

Tabel 2.1 Penelitian Terdahulu

No	Judul Penelitian	Peneliti	Metode	Data	Hasil	Perbedaan Penelitian
1	<i>Rainfall Prediction Using Adaptive Neuro-Fuzzy Inference System</i>	El-Shafie, A. et al. (2020)	ANFIS	Data curah hujan Sungai Klang, Malaysia	ANFIS memberikan hasil akurat, RMSE dan MAE rendah	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan

No	Judul Penelitian	Peneliti	Metode	Data	Hasil	Perbedaan Penelitian
						arah angin maksimum.serta, menggunakan metode ANFIS
2	<i>Rainfall Forecasting Using an Adaptive Neuro-Fuzzy Inference System with Grid Partitioning</i>	Fauzi, F. et al. (2024)	ANFIS (<i>Grid Partitioning</i>)	Data curah hujan Indonesia	Meningkatkan akurasi prediksi di lokasi bencana	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum.serta, menggunakan metode ANFIS
3	<i>Monthly Rainfall Forecasting Using High Order Singh's Fuzzy Time Series</i>	Feriyanto, E. et al. (2024)	<i>Fuzzy Time Series (FTS)</i>	Data curah hujan Semarang	Prediksi curah hujan bulanan cukup akurat	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran

No	Judul Penelitian	Peneliti	Metode	Data	Hasil	Perbedaan Penelitian
						matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum.serta, menggunakan metode ANFIS
4	<i>Rainfall Prediction in Jember Regency with ANFIS Based on GSMaP</i>	Riski, A. et al. (2023)	ANFIS	Data satelit GSMaP	RMSE rendah, cocok untuk data besar	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum.serta, menggunakan metode ANFIS
5	<i>Establishment of Dynamic Evolving Neuro-Fuzzy Inference System Model</i>	Bhagat, S. K. et al. (2022)	<i>Dynamic Evolving ANFIS</i>	Data suhu udara global	Akurat untuk prediksi suhu, dapat diadaptasi ke curah hujan	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu

No	Judul Penelitian	Peneliti	Metode	Data	Hasil	Perbedaan Penelitian
						maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum.serta, menggunakan metode ANFIS
6	<i>Artificial Intelligence Models for Prediction of Monthly Rainfall Without Climatic Data</i>	Abebe & Endalie (2023)	AI (NN, SVM) tanpa data iklim	Data hujan bulanan Ethiopia	AI dapat prediksi tanpa variabel iklim tambahan	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum.serta, menggunakan metode ANFIS
7	<i>Modeling of Fuzzy Cognitive Maps with a Metaheuristics-Based Rainfall</i>	al Duhayyim, M. et al. (2023)	<i>Fuzzy Cognitive Maps + Metaheuristic</i>	Data hujan global	Adaptif dan fleksibel	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang,

No	Judul Penelitian	Peneliti	Metode	Data	Hasil	Perbedaan Penelitian
	<i>Prediction System</i>					Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum. serta, menggunakan metode ANFIS
8	<i>Rainfall Prediction System Using Machine Learning Fusion for Smart Cities</i>	Rahman, A. U. et al. (2022)	ML <i>Fusion</i> (RF, SVM, KNN)	Data cuaca <i>smart city</i>	Akurasi tinggi dengan <i>ensemble learning</i>	Penelitian dalam skripsi ini menggunakan data harian yang bersumber dari BMKG Kota Padang, Indonesia, dengan jumlah variabel yang mencakup suhu minimum, suhu maksimum, suhu rata-rata, kelembapan, lamanya penyinaran matahari, kecepatan angin maksimum, kecepatan angin rata-rata, dan arah angin maksimum. serta, menggunakan metode ANFIS

Berdasarkan tabel 2.1, terlihat bahwa ANFIS dan metode *fuzzy* lainnya telah digunakan secara luas dalam berbagai konteks geografis dan iklim. Penelitian oleh Abebe dan Endalie (2023) menunjukkan bahwa penggunaan model *AI* tanpa data iklim konvensional dapat memberikan prediksi curah hujan yang cukup akurat, terutama di daerah yang kekurangan data meteorologi. Ini menunjukkan bahwa pendekatan berbasis data dan teknologi modern dapat mengatasi tantangan dalam prediksi curah hujan.

2.2 Variabel Iklim yang Mempengaruhi Curah Hujan

Beberapa variabel iklim yang mempengaruhi curah hujan antara lain suhu udara, kelembapan, dan tekanan atmosfer. Penelitian oleh Aditya et al. (2021) menunjukkan bahwa perubahan suhu dapat mempengaruhi pola curah hujan, yang pada gilirannya berdampak pada produktivitas pertanian. Selain itu, fenomena *El Niño* dan *La Niña* juga berperan signifikan dalam mempengaruhi curah hujan di Indonesia, seperti yang diungkapkan oleh Naylor et al. (2002), di mana *El Niño* sering kali menyebabkan kekeringan, sedangkan *La Niña* dapat meningkatkan curah hujan.

2.3 Ketidakpastian dalam Data Iklim

Ketidakpastian dalam data iklim merupakan tantangan besar dalam melakukan prediksi curah hujan. Data yang tidak akurat atau tidak lengkap dapat mengakibatkan kesalahan dalam model prediksi. Menurut penelitian oleh Dwivedi et al. (2023), penggunaan metode statistik dan *AI* dapat membantu mengurangi ketidakpastian ini dengan mengolah data yang lebih kompleks dan beragam. Oleh

karena itu, penting untuk memperhatikan kualitas dan sumber data yang digunakan dalam penelitian ini.

2.4 Logika *Fuzzy*

Logika *fuzzy* adalah suatu pendekatan komputasi yang didasarkan pada teori himpunan, yang diperkenalkan oleh Lotfi A. Zadeh pada tahun 1965. Berbeda dengan logika klasik yang hanya mengenal dua nilai kebenaran (0 dan 1 atau *true* dan *false*), logika *fuzzy* memungkinkan nilai kebenaran berada dalam rentang 0 hingga 1. Hal ini menjadikannya sangat efektif dalam menangani ketidakpastian dan data yang tidak pasti, seperti prediksi curah hujan yang bergantung pada berbagai faktor cuaca yang berubah-ubah.

Himpunan *fuzzy* didefinisikan oleh fungsi keanggotaan (*membership function*) yang memetakan elemen ke derajat keanggotaan antara 0 dan 1. Fungsi keanggotaan yang umum digunakan adalah:

a. Segitiga :

$$\mu_A(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ \frac{c-x}{c-b}, & b < x \leq c \\ 0, & x > c \end{cases} \quad (2.1)$$

Keterangan:

a, b, c = parameter segitiga di mana $a < b < c$
 b = nilai puncak dari fungsi

b. Trapezium:

$$\mu_A(x) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a < x \leq b \\ 1, & b < x \leq c \\ \frac{d-x}{d-c}, & c < x \leq d \\ 0, & x > d \end{cases} \quad (2.2)$$

Keterangan:

a, b, c = parameter segitiga di mana $a < b < c$
 b = nilai puncak dari fungsi

c. Gaussian

$$\mu_A(x) = \exp\left(-\frac{(x-c)^2}{2\sigma^2}\right) \quad (2.3)$$

Keterangan:

x = nilai input
 c = pusat (mean)
 σ = standar deviasi (menentukan lebar fungsi)

d. *Bell-Shaped*

$$\mu_A(x) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}} \quad (2.4)$$

Keterangan

a = mengontrol lebar
 b = mengontrol kemiringan
 c = pusat fungsi

Aturan *Fuzzy (Fuzzy Rules)*, Aturan *fuzzy* berbentuk *IF-THEN*. Contoh:

IF x_1 adalah A_1 *AND* x_2 adalah A_2 *THEN* y adalah B

2.5 Jaringan Saraf Tiruan (*Artificial Neural Network - ANN*)

Jaringan Saraf Tiruan (JST) atau *Artificial Neural Network* (ANN) adalah salah satu metode dalam kecerdasan buatan yang terinspirasi dari cara kerja otak manusia dalam memproses informasi. ANN digunakan untuk memodelkan hubungan kompleks antara *input* dan *output* dalam berbagai bidang, termasuk dalam prediksi curah hujan. Fungsi aktivasi yang umum digunakan adalah:

a. *Sigmoid*:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.5)$$

b. *Rectified Linear Unit*:

$$f(x) = \max(0, x) \quad (2.6)$$

c. *Algoritma Backpropagation*

Backpropagation digunakan untuk menyesuaikan bobot dan bias dengan menghitung gradien *error*. Rumus *update* bobot:

$$w_{ij}(t + 1) = w_{ij}(t) - \eta \frac{\partial E}{\partial w_{ij}} \quad (2.7)$$

Keterangan:

w_{ij} = bobot antara neuron i dan j ,
 η = *learning rate*,
 E = *error*.

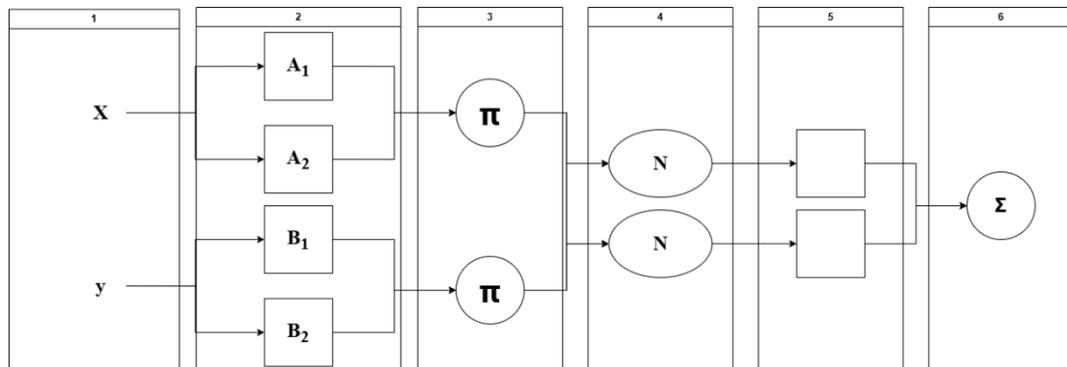
2.6 *Adaptive Neuro-Fuzzy Inference System* (ANFIS)

ANFIS adalah metode yang menggabungkan keunggulan dari jaringan saraf tiruan dan logika . Metode ini sangat efektif dalam menangani data yang tidak pasti dan kompleks, seperti yang sering ditemukan dalam prediksi curah hujan. ANFIS mampu belajar dari data historis dan menghasilkan model yang dapat memprediksi curah hujan dengan akurasi yang tinggi. Penelitian oleh El-Shafie et al. (2020) menunjukkan bahwa ANFIS dapat digunakan untuk memprediksi curah hujan di Malaysia dengan hasil yang memuaskan.

2.6.1 *Arsitektur ANFIS*

Adaptive Neuro-Fuzzy Inference System (ANFIS) merupakan sistem hibrida yang menggabungkan keunggulan jaringan saraf tiruan dan logika *Fuzzy*. *Arsitektur ANFIS* terdiri dari enam lapisan utama yang bekerja secara berurutan untuk menghasilkan *output* berdasarkan *input* yang diberikan. Setiap lapisan memiliki

fungsi spesifik, mulai dari penerimaan *input*, fuzzifikasi, pembentukan aturan, normalisasi, defuzzifikasi, hingga penghitungan *output* akhir.



Gambar 2.1 Arsitektur ANFIS

Arsitektur dari sistem *Adaptive Neuro-Fuzzy Inference System* (ANFIS) memiliki dua variabel *input*, yaitu x dan y , serta dua himpunan *fuzzy* untuk masing-masing variabel (A_1 , A_2 untuk x , dan B_1 , B_2 untuk y) Gambar 2.1. Arsitektur ini terdiri dari enam lapisan utama yang bekerja secara bertahap untuk melakukan proses inferensi berbasis pembelajaran adaptif. Setiap lapisan memiliki peran spesifik dalam transformasi *input* hingga menghasilkan *output* akhir dari sistem. Proses dimulai dari penerimaan nilai input (lapisan 1), kemudian dilanjutkan dengan proses fuzzifikasi (lapisan 2), perhitungan kekuatan *firing rules* (lapisan 3), normalisasi (lapisan 4), perhitungan *output* masing-masing aturan (lapisan 5), dan akhirnya penggabungan *output* semua aturan untuk memperoleh hasil prediksi (lapisan 6). Arsitektur ini menunjukkan integrasi logika berbasis aturan *IF-THEN* dengan kemampuan belajar dari jaringan saraf tiruan, yang menjadikan ANFIS mampu menangani data non-linear secara efisien.

2.6.1.1 Lapisan *input*

Lapisan *input* adalah titik awal dari sistem ANFIS. Dalam penelitian ini, input yang digunakan mencakup variabel iklim yang sangat penting, seperti suhu, kelembapan, dan tekanan udara. Setiap variabel ini memiliki pengaruh signifikan terhadap kondisi lingkungan dan dapat digunakan untuk memprediksi berbagai fenomena, seperti cuaca atau pertumbuhan tanaman. Misalnya, suhu yang tinggi dapat berkontribusi pada penguapan air yang lebih cepat, yang pada gilirannya dapat mempengaruhi kelembapan tanah. Dengan mengumpulkan data dari berbagai sumber, seperti stasiun cuaca atau sensor lingkungan, kita dapat memperoleh gambaran yang lebih jelas tentang kondisi iklim yang sedang berlangsung. Intinya berfungsi untuk menerima *input* numerik.

Contoh:

x_1 = Suhu udara

x_2 = Kelembaban

2.6.1.2 Lapisan Fuzzifikasi

Pada Lapisan Fuzzifikasi ini, fungsi keanggotaan *fuzzy* digunakan untuk mengonversi *input* yang bersifat numerik menjadi nilai *fuzzy*. Proses ini penting karena banyak fenomena di dunia nyata yang tidak dapat dijelaskan dengan angka yang pasti. Salah satu contohnya adalah suhu, yang dapat dikategorikan sebagai "rendah," "sedang," atau "tinggi," tergantung pada konteksnya. Dengan menggunakan fungsi keanggotaan, kita dapat memberikan nilai *fuzzy* yang merepresentasikan derajat keanggotaan suatu variabel dalam kategori tertentu. Hal

ini memungkinkan sistem untuk menangani ketidakpastian dan ambiguitas yang sering kali ada dalam data iklim.

Intinya, berfungsi untuk mengubah *input* menjadi derajat keanggotaan menggunakan fungsi keanggotaan (*membership function*/MF). Hasilnya dirumuskan sebagai berikut.

$$O_1^i = \mu_{A_i}(x_1), \quad O_1^j = \mu_{B_j}(x_2) \quad (2.8)$$

Keterangan:

O_1^i = *Output* dari neuron ke-*i* di lapisan 1 (fuzzifikasi)
 Angka 1 pada O_1^i menunjukkan bahwa ini adalah lapisan pertama (fuzzifikasi)
 Huruf *i* menunjukkan aturan ke-*i* atau fungsi keanggotaan ke-*i* yang sedang digunakan
 $\mu_{A_i}(x)$ = Fungsi keanggotaan *fuzzy* dari himpunan *A* ke-*i* terhadap input *x*
x = Nilai input yang dimasukkan ke dalam system

2.6.1.3 Lapisan Basis Aturan

Dalam lapisan ini, aturan berbasis *fuzzy* yang biasanya dinyatakan dalam bentuk *IF-THEN* digunakan untuk menentukan *output* berdasarkan *input* yang diberikan. Misalnya, kita dapat menetapkan aturan seperti "Jika suhu tinggi dan kelembapan rendah, maka kemungkinan terjadinya kebakaran hutan tinggi." Aturan ini dibangun berdasarkan pengetahuan domain dan pengalaman yang ada, sehingga memberikan kerangka kerja yang kuat untuk pengambilan keputusan. Proses ini juga melibatkan normalisasi, di mana nilai-nilai *fuzzy* yang dihasilkan dari berbagai aturan digabungkan untuk menghasilkan satu nilai *output* yang representatif.

Intinya, lapisan ini berfungsi untuk menghitung kekuatan tembak (*firing strength*) setiap aturan dengan menggunakan operator *AND* (produk) melalui rumus berikut.

$$O_2^i = w_i = \mu_{A_i}(x) \cdot x_{B_i}(y) \quad (2.9)$$

Keterangan:

O_2^i	= Output dari neuron ke - i di lapisan 2 (<i>rule layer</i>), yaitu <i>firing strength</i> dari aturan ke- i
$\mu_{A_i}(x)$	= Derajat keanggotaan <i>input</i> x terhadap himpunan A_i
$x_{B_i}(y)$	= Derajat keanggotaan <i>input</i> y terhadap himpunan B_i
w_i	= <i>Firing strength</i> dari aturan ke- i

2.6.1.4 Lapisan normalisasi

Lapisan normalisasi dalam sistem *fuzzy* sangat penting untuk menyesuaikan kekuatan *firing*, yang memungkinkan *output* diinterpretasikan dengan tepat dalam pengambilan keputusan. Proses ini menyelaraskan hasil dari berbagai aturan *fuzzy* agar *output* dapat dibandingkan secara adil. Misalnya, dalam pengendalian suhu, *output* yang terlalu tinggi tanpa normalisasi dapat menyesatkan. Dengan normalisasi, semua *output* disesuaikan dalam rentang yang sama, seperti 0 hingga 1, sebelum digabungkan untuk keputusan akhir, sehingga meningkatkan akurasi analisis data. Dalam sistem pengaturan kecepatan kipas berdasarkan suhu dan kelembapan, normalisasi menunjukkan kontribusi seimbang dari kedua faktor. Oleh karena itu, pemahaman dan penerapan lapisan normalisasi sangat penting untuk kualitas keputusan dan efektivitas sistem. Singkatnya, lapisan normalisasi adalah komponen kunci dalam sistem *fuzzy* untuk mencapai keputusan yang lebih akurat dan dapat diandalkan dengan rumus berikut.

$$\bar{w}_i = \frac{w_i}{\sum_{j=1}^n w_j} \quad (2.10)$$

Keterangan:

\bar{w}_i	= <i>Firing strength</i> yang telah dinormalisasi dari aturan ke- i
w_i	= <i>Firing strength</i> dari aturan ke- i (dihasilkan pada lapisan sebelumnya)
$\sum_{j=1}^n w_j$	= Jumlah total <i>firing strength</i> dari semua aturan

2.6.1.5 Lapisan Defuzzifikasi

Proses defuzzifikasi ini bertujuan untuk mengubah nilai *fuzzy* yang dihasilkan oleh lapisan sebelumnya menjadi *output* yang lebih konkret dalam bentuk nilai numerik. Salah satu metode yang umum digunakan dalam defuzzifikasi adalah metode *centroid*, yang merupakan salah satu teknik dalam teori himpunan *fuzzy* yang digunakan untuk menentukan nilai *output*, di mana nilai *output* dihitung secara matematis berdasarkan pusat massa dari distribusi. Misalnya, jika *output* yang diharapkan adalah prediksi curah hujan, maka nilai numerik yang dihasilkan akan memberikan estimasi yang lebih jelas tentang jumlah hujan yang mungkin turun. Proses defuzzifikasi ini sangat penting karena memberikan informasi yang dapat diukur dan digunakan untuk pengambilan keputusan lebih lanjut.

Intinya berfungsi untuk menghitung *output* setiap aturan dengan rumus berikut.

$$\bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i x + q_i y + r_i) \quad (2.11)$$

Keterangan:

\bar{w}_i	= <i>Firing strength</i> yang telah dinormalisasi dari aturan ke- <i>i</i>
f_i	= Fungsi linier konsekuen dari aturan ke- <i>i</i>
p_i, q_i, r_i	= Parameter konsekuen yang ditentukan selama proses pelatihan
x, y	= <i>Input</i> ke system

2.6.1.6 Lapisan *Output*

Akhirnya, kita mencapai tahap *output*. Hasil dari proses defuzzifikasi adalah nilai numerik yang dapat digunakan untuk berbagai tujuan, seperti peramalan cuaca, perencanaan pertanian, atau pengelolaan sumber daya air. Nilai ini tidak hanya memberikan informasi yang relevan, tetapi juga dapat membantu pengambil

keputusan dalam merumuskan strategi yang lebih baik untuk menghadapi tantangan yang dihadapi oleh lingkungan.

Intinya berfungsi untuk menghitung output akhir dengan menggabungkan semua aturan yang ada dengan rumus berikut.

$$y = \sum_{i=1}^n \bar{w}_i \cdot f_i \quad (2.12)$$

Keterangan:

y : Output

n : Jumlah total aturan

\bar{w}_i : *Firing strength* yang telah dinormalisasi dari aturan ke-iii

f_i : Output fungsi linier dari aturan ke- i

2.6.2 Kelebihan dan Kekurangan ANFIS

Kelebihan ANFIS terletak pada kemampuannya untuk menggabungkan keunggulan dari logika *fuzzy* dan jaringan saraf tiruan, sehingga mampu menangani data yang tidak pasti dengan baik. Namun, ANFIS juga memiliki kekurangan, seperti kebutuhan akan data yang cukup banyak untuk pelatihan model dan kompleksitas dalam pengaturan parameter. Penelitian oleh Vathsala dan Koolagudi (2023) menunjukkan bahwa meskipun ANFIS efektif, pemilihan parameter yang tepat sangat penting untuk mencapai hasil yang optimal.

2.7 Metrik Evaluasi Model

Evaluasi model ANFIS dilakukan dengan menggunakan beberapa metrik, antara lain *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2). Metrik-metrik ini memberikan gambaran yang jelas tentang seberapa baik model mampu memprediksi curah hujan dibandingkan dengan data aktual. Misalnya, penelitian oleh Riski et al. (2023) menggunakan

RMSE untuk mengevaluasi model ANFIS mereka dan mendapatkan hasil yang menunjukkan akurasi tinggi dalam prediksi curah hujan. Untuk mengevaluasi performa model prediksi curah hujan, beberapa metrik yang umum digunakan sebagai berikut.

a. *Mean Absolute Error (MAE)*:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.13)$$

b. *Root Mean Squared Error (RMSE)*:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.14)$$

c. *Coefficient of Determination (R²)*:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.15)$$

Keterangan:

- y = nilai aktual,
- \hat{y} = nilai prediksi,
- \bar{y} = rata-rata nilai aktual,
- n = jumlah data.

BAB III

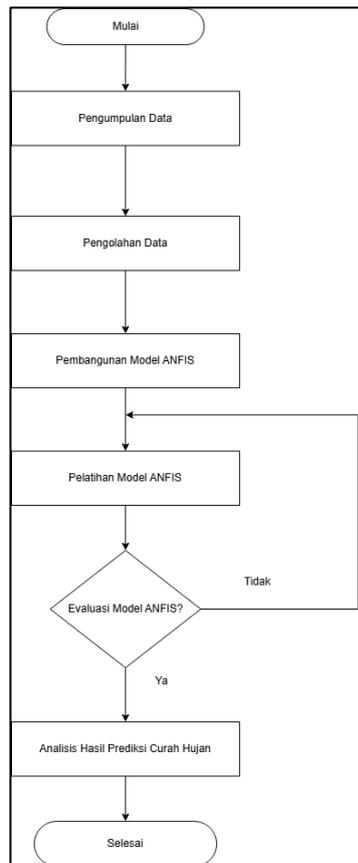
DESAIN DAN IMPLEMENTASI

3.1 Desain

Desain penelitian ini bertujuan untuk menguji efektivitas metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dalam memprediksi curah hujan. Tahapan penelitian dirancang secara sistematis, dimulai dari pengumpulan data, pra-pemrosesan, pembangunan model, hingga evaluasi hasil. Pendekatan ini dipilih karena kemampuannya dalam menangani ketidakpastian dan kompleksitas data meteorologi, serta memastikan validitas hasil melalui metrik evaluasi yang terstandarisasi. Seluruh proses desain diimplementasikan dengan mempertimbangkan karakteristik data curah hujan yang bersifat non-linear dan dinamis.

3.1.1 Desain Penelitian

Desain penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen, yaitu melakukan prediksi curah hujan berdasarkan variabel *input*, seperti suhu, kelembapan, dan kecepatan angin, menggunakan model *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Model ini dipilih karena mampu menangani ketidakpastian dan pola data non-linear yang umum pada data iklim.



Gambar 3.1 Diagram Alir Penelitian

Diagram alir proses penelitian yang digunakan untuk melakukan prediksi curah hujan dengan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS). Gambar 3.1 ini menggambarkan secara sistematis tahap-tahap yang dilalui mulai dari awal hingga akhir penelitian. Setiap proses dalam diagram saling berhubungan secara logis dan bertujuan untuk membangun model prediksi yang akurat dan dapat diandalkan. Proses tersebut mencakup pengumpulan dan pengolahan data, pembangunan serta pelatihan model ANFIS, evaluasi terhadap performa model, dan analisis hasil prediksi. Diagram ini membantu menggambarkan alur berpikir dan pendekatan yang digunakan dalam penelitian ini secara visual, sehingga memudahkan pemahaman terhadap keseluruhan metodologi.

Penelitian dimulai pada tahap pengumpulan data, di mana data curah hujan historis diperoleh dari sumber-sumber kredibel, seperti BMKG. Data yang dikumpulkan akan digunakan sebagai dasar dalam proses pembentukan dan pelatihan model ANFIS.

Selanjutnya, data yang telah diperoleh akan melalui proses pengolahan. Pada tahap ini, dilakukan beberapa langkah penting, seperti pembersihan data (*data cleaning*), normalisasi nilai agar berada dalam rentang tertentu (misalnya 0–1), serta pembagian data menjadi dua bagian: data pelatihan (*training*) dan data pengujian (*testing*). Pengolahan data bertujuan untuk memastikan bahwa data yang digunakan dalam pembangunan model bebas dari anomali dan siap untuk dianalisis.

Tahapan berikutnya adalah pembangunan model ANFIS. Di sini, struktur dasar dari sistem ANFIS dibentuk. Proses ini mencakup pemilihan fungsi keanggotaan (*membership function*) untuk setiap variabel *input*, serta penentuan jumlah dan jenis aturan *fuzzy* (*fuzzy rules*) yang akan digunakan sebagai dasar inferensi sistem. Pemodelan ini memadukan prinsip logika *fuzzy* dengan kemampuan adaptif dari jaringan saraf tiruan.

Setelah struktur model terbentuk, pelatihan model ANFIS dilakukan menggunakan data pelatihan. Tujuannya adalah agar model mampu menyesuaikan parameter-parameter internalnya untuk memetakan hubungan antara *input* dan *output*. Proses pelatihan dilakukan dengan pendekatan pembelajaran hibrid (*hybrid learning*), yang menggabungkan metode *least squares* untuk parameter linear dan *backpropagation* untuk parameter non-linear.

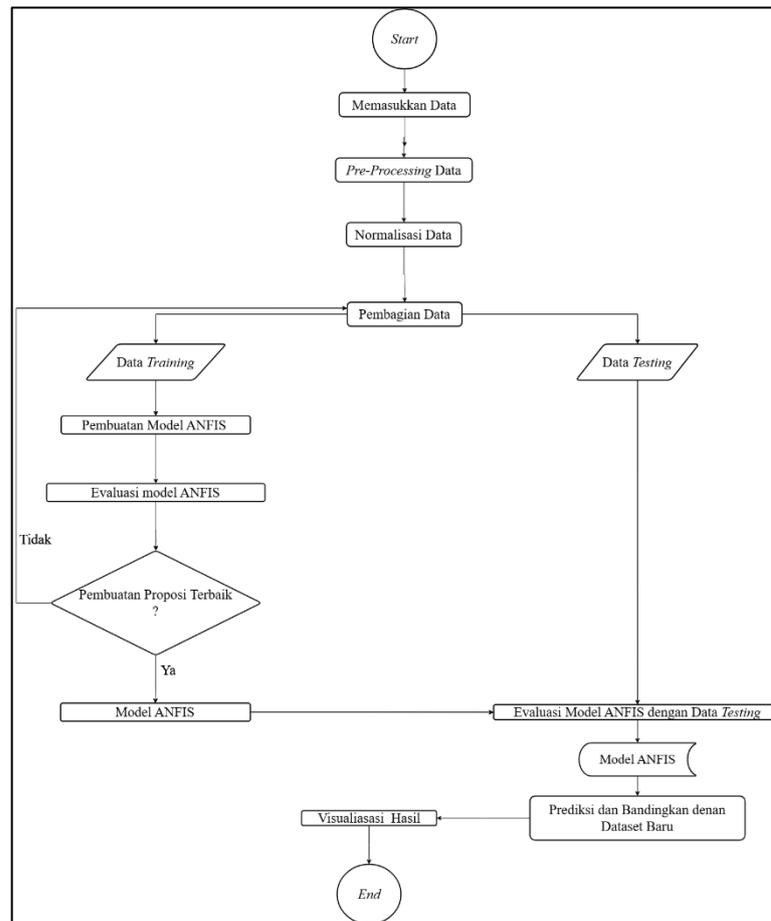
Model yang telah dilatih akan memasuki tahap evaluasi ANFIS. Evaluasi dilakukan untuk menilai tingkat akurasi model dalam memprediksi curah hujan berdasarkan data pengujian. Jika hasil evaluasi belum memenuhi kriteria akurasi yang diinginkan, maka model akan kembali ke tahap pelatihan untuk disempurnakan. Proses ini dapat diulang hingga diperoleh model dengan performa terbaik.

Jika evaluasi menunjukkan bahwa model telah mencapai akurasi yang memadai, analisis terhadap hasil prediksi curah hujan akan dilakukan. Analisis ini mencakup peninjauan terhadap pola hasil prediksi, perbandingan antara nilai aktual dan nilai prediksi, serta interpretasi terhadap potensi penerapan hasil prediksi tersebut dalam konteks mitigasi bencana, pertanian, atau sistem pendukung keputusan lainnya.

Tahapan terakhir adalah penyelesaian, di mana seluruh proses penelitian telah selesai dilakukan dan hasilnya siap disajikan dalam bentuk laporan atau publikasi ilmiah.

3.1.2 Desain Sistem

Tuliskan Desain sistem mengadopsi pendekatan *hybrid neuro-fuzzy* (Jang, 1993) dengan modifikasi pada layer fuzzifikasi untuk menangani karakteristik non-stasioner data cuaca.



Gambar 3.2 Diagram Alir Sistem

Diagram alir proses implementasi metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dalam memprediksi curah hujan. Gambar 3.2 ini menggambarkan tahapan secara terstruktur dan sistematis, dimulai dari pemasukan dan pemrosesan data hingga evaluasi performa model serta visualisasi hasil prediksi. Alur ini menunjukkan integrasi antara teknik pra-pemrosesan data (*pre-processing*), pembentukan model ANFIS, serta proses pelatihan dan pengujian model ANFIS. Diagram ini penting sebagai panduan kerja dalam proses perancangan dan pengujian sistem agar setiap tahap dapat dilakukan secara konsisten dan akurat.

3.2 Analisis

Proses analisis dalam penelitian ini dilakukan secara komprehensif untuk memastikan keakuratan prediksi curah hujan menggunakan metode ANFIS. Tahapan analisis mencakup pemrosesan data, pembangunan model, evaluasi performa, dan interpretasi hasil. Data yang digunakan bersumber dari BMKG dan telah melalui proses validasi untuk menjamin reliabilitas data tersebut. Selanjutnya, penelitian dilanjutkan dengan eksplorasi karakteristik data serta identifikasi faktor-faktor dominan yang memengaruhi curah hujan. Pendekatan ini bertujuan untuk menghasilkan model prediksi yang kuat dan dapat diandalkan.

3.2.1 Sumber Data

Data yang digunakan dalam penelitian ini diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Kota Padang, Sumatra Barat, sebagai instansi resmi yang berwenang dalam pengumpulan data iklim di Indonesia. Data tersebut mencakup parameter meteorologi harian selama lima tahun (periode 2020–2024) dengan total 1.826 rekaman. Pemilihan sumber data ini didasarkan pada kredibilitas BMKG sebagai penyedia data cuaca dan iklim yang terpercaya di Indonesia, serta kelengkapan variabel yang memenuhi kebutuhan pemodelan ANFIS.

Contoh:

Tabel 3.1 *Dataset BMKG*

TANGGAL	TN	TX	TAVG	RH_AVG	SS	FF_X	DDD_X	FF_AVG	RR
01-01-2025	21.6	32.8	25	75	1.3	4	270	1	8888
02-01-2025	21.2	33.4	25.9	60	6.5	6	233	1	3.5
03-01-2025	21.2	32.8	26.3	73	8	3	290	1	0.3
04-01-2025	22	31.8	25	75	8	3	260	0	9999
05-01-2025	22	30.6	25.6	72	5.3	2	260	0	3.2
06-01-2025	20.6	32.4	24.5	78	3.5	3	248	0	0
07-01-2025	20.2	31	28.2	69	5.7	5	270	1	26.9
08-01-2025	20.6	30.4	24.9	79	8	3	300	1	0

Keterangan:

- 8888 = Data tidak terukur
- 9999 = Tidak Ada Data (tidak dilakukan pengukuran)
- Tn = Temperatur minimum (°C)
- Tx = Temperatur maksimum(°C)
- Tavg = Temperatur rata-rata(°C)
- RH_avg = Kelembapan rata-rata(%)
- 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)
- RR = Curah hujan(mm)

3.2.2 Pengujian Penelitian

Pengujian dalam penelitian ini dilakukan dalam beberapa tahapan utama yang tercermin pada alur sistem. Tahap pertama adalah pengumpulan data, di mana data klimatologis dikumpulkan dan dikompilasi. Setelah itu, pengolahan data dilakukan, yang mencakup proses pembersihan data (*data cleaning*), penghapusan data kosong (*missing values*), penanganan *outlier* menggunakan metode *interquartile range* (IQR), dan normalisasi data ke dalam skala [0–1]. Tahapan ini

penting untuk memastikan kualitas *input* model, sebagaimana ditekankan oleh Bhagat et al. (2022) dan Barrera-Animas et al. (2022) dalam pengolahan data iklim untuk prediksi.

Tahap selanjutnya adalah pembangunan model ANFIS, di mana fungsi keanggotaan dan aturan *fuzzy* ditentukan berdasarkan data *input*. Kemudian, dilakukan pelatihan model ANFIS untuk meminimalkan *error* prediksi. Proses ini bersifat iteratif dan akan berulang jika hasil evaluasi belum memenuhi kriteria. Proses evaluasi model dilakukan dengan memanfaatkan data pengujian yang terpisah, dan hasil evaluasi diukur menggunakan metrik MAE, RMSE, dan koefisien determinasi R^2 , sebagaimana diadopsi dari pendekatan evaluatif oleh Esmacili et al. (2023) dan Riski et al. (2023). Jika model telah mencapai tingkat akurasi yang memadai, maka dilanjutkan pada tahap analisis hasil prediksi curah hujan untuk menilai kemampuan model dalam mengenali pola hujan aktual. Proses ini berakhir dengan penyimpanan model dan visualisasi hasil prediksi.

Penelitian ini juga membandingkan beberapa skenario pemisahan data pelatihan dan pengujian (*split* data 70:30, 80:20, dan 90:10) untuk menentukan komposisi data terbaik, seperti yang disarankan oleh Suparta dan Samah (2020). Pendekatan ini dimaksudkan agar model dapat digunakan dalam situasi prediksi nyata pada data baru di masa mendatang secara lebih akurat dan adaptif.

3.2.3 Memasukkan Data

Input data yang digunakan dalam penelitian ini merupakan data historis curah hujan yang diperoleh dari BMKG. Data ini terdiri dari beberapa parameter klimatologi yang mempengaruhi curah hujan, seperti berikut.

Tabel 3.2 Variabel Penelitian

No	Variabel	Persatuannya
1	Temperatur Minimum	Celsius (°C)
2	Temperatur Maximum	Celsius (°C)
3	Temperatur rata-rata	Celsius (°C)
4	Kelembapan rata-rata	Numerik (%)
5	Lamanya Penyinaran Matahari	Waktu(jam)
6	Kecepatan Angin Maksimum	Meter per detik(m/s)
7	Arah kecepatan Angin Maksimum	Meter per detik(m/s)
8	Kecepatan angin rata-rata	Meter per detik(m/s)
9	Curah hujan	Milimeter (mm)

Penelitian ini menggunakan beberapa variabel klimatologis yang memiliki pengaruh signifikan terhadap pola curah hujan di wilayah tertentu. Variabel-variabel tersebut dikumpulkan dalam bentuk data numerik Tabel 3.2, dengan satuan yang relevan terhadap karakteristik masing-masing parameter. Secara rinci, terdapat sembilan variabel yang digunakan dalam proses pemodelan prediksi curah hujan menggunakan *Sistem Inferensi Neuro-Fuzzy Adaptif (ANFIS)*.

3.2.4 *Pra-Processing Data*

Pra-Processing (pra-pemrosesan) data adalah serangkaian teknik transformasi dan pembersihan data mentah sebelum digunakan dalam pemodelan. Tahap ini bertujuan untuk meningkatkan kualitas data dengan mengatasi masalah seperti ketidaklengkapan, dan ketidakkonsistenan, sehingga data siap untuk analisis lebih lanjut

3.2.4.1 Pembersihan

Proses dilakukan untuk menghilangkan masalah yang dapat mengganggu analisis, seperti *missing values*, *outliers*, dan inkonsistensi data.

1. Menangani *Missing Values*

Missing values adalah data yang hilang atau tidak tercatat dalam dataset. Data yang hilang dapat disebabkan oleh berbagai faktor seperti kesalahan pencatatan, kegagalan sistem, atau respon yang tidak diberikan. Disini semua *missing values* baris *dataset*-nya dihapus.

2. Menangani *Outliers*

Outlier adalah nilai yang sangat jauh berbeda dari mayoritas data lainnya dan dapat mempengaruhi hasil analisis. *Outlier* bisa berasal dari kesalahan pengukuran, kesalahan *input*, atau fenomena yang valid namun langka. Disini kita mengidentifikasi *outliers* menggunakan IQR dengan rumus (3.1)

$$IQR = Q3 - Q1 \quad (3.1)$$

Outliers adalah data di luar rentang:

$$[Q1 - 1.5 \times IQR, Q3 + 1.5 \times IQR] \quad (3.2)$$

Contoh:

Data: 5, 7, 6, 8, 100

$Q1 = 6, Q3 = 8 \Rightarrow IQR = 2$

Batas bawah = $6 - (1.5 \times 2) = 3$

Batas atas = $8 + (1.5 \times 2) = 11$

Nilai 100 adalah *outlier* karena > 11 .

Penanganannya ganti 100 dengan median (7)

3. Inkonsistensi Data

Inkonsistensi data terjadi ketika data memiliki format atau isi yang tidak seragam. Hal ini dapat menyebabkan kesalahan dalam pemrosesan dan analisis data.

3.2.4.2 Normalisasi Data

Normalisasi dilakukan untuk mengubah data ke rentang tertentu (biasanya $[0, 1]$ atau $[-1, 1]$) agar semua variabel memiliki skala yang serupa. Hal ini penting karena ANFIS sensitif terhadap perbedaan skala data.

Min-Max Normalization:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.3)$$

Contoh:

Jika curah hujan harian berkisar antara 50–300 mm:

$$\text{Jika } X = 100 \rightarrow X' = \frac{100 - 50}{300 - 50} = \frac{50}{250} = 0.2$$

3.2.4.3 Pembagian Data

Pembagian data (*data splitting*) adalah proses memisahkan *dataset* menjadi *subset* yang berbeda untuk tujuan spesifik dalam pengembangan model prediktif. Proses ini penting untuk memastikan bahwa model dapat belajar dari data pelatihan (*training*) sekaligus diuji kemampuannya pada data yang belum pernah dilihat (*testing*). Pembagian yang tepat mencegah masalah seperti *overfitting* (model terlalu kompleks sehingga hanya cocok untuk data latih) dan *underfitting* (model terlalu sederhana sehingga gagal menangkap pola data).

Untuk *dataset* dengan ukuran terbatas (contoh: data cuaca harian selama 1–2 tahun), rasio 70:30 lebih efektif dibanding *k-fold cross-validation* yang membutuhkan komputasi intensif.

- a. *Data Training (70%)*: *Subset* ini digunakan untuk membangun model, termasuk estimasi parameter dan optimasi. Ukuran 70% dianggap memadai untuk menangkap variabilitas data, terutama dalam *dataset* berukuran kecil hingga sedang (contoh: beberapa ribu sampel). Dengan jumlah sampel yang cukup, model dapat mempelajari pola kompleks tanpa kehilangan informasi esensial.
- b. *Data Testing (30%)*: *Subset* ini berfungsi sebagai simulasi dunia nyata untuk menguji generalisasi model. Rasio 30% memberikan ukuran sampel yang cukup untuk evaluasi statistik yang handal (misalnya: menghitung *confidence interval* untuk metrik akurasi).

3.2.5 Pembangunan model ANFIS

Pembangunan model ANFIS merupakan pendekatan komputasional hibrida yang mengintegrasikan prinsip-prinsip logika *fuzzy* dan jaringan saraf tiruan untuk menciptakan sistem inferensi adaptif yang dapat memodelkan hubungan non-linear dalam data dengan akurasi tinggi. Dalam konteks prediksi curah hujan berdasarkan data meteorologi BMKG, ANFIS menawarkan solusi yang unik karena kemampuannya untuk menangani ketidakpastian yang melekat dalam data cuaca sekaligus mempelajari pola kompleks yang melalui mekanisme adaptif.

3.2.5.1 Lapisan *Input*

Menerima data numerik variabel meteorologi seperti berikut :

x_1 : Temperatur rata-rata ($^{\circ}\text{C}$)

x_2 : Kelembapan rata-rata (%)

x_3 : Kecepatan angin rata-rata (m/s)

Contoh data *input* numerik:

$x_1 = 26^{\circ}\text{C}$,

$x_2 = 75\%$,

$x_3 = 2 \text{ m/s}$

3.2.5.2 Lapisan Fuzzifikasi

Mengubah input menjadi himpunan *fuzzy* menggunakan fungsi keanggotaan

Gaussian:

$$O_1^i = \mu_{A_i}(x_1), \quad O_1^j = \mu_{B_j}(x_2) \quad (3.4)$$

Contoh numerik:

$\mu_{\text{suhu_sedang}}(26) = 0.8$

$\mu_{\text{kelembapan_tinggi}}(75) = 0.7$

$\mu_{\text{angin_pelan}}(2) = 0.9$

3.2.5.3 Lapisan *Rule* (Basis Aturan)

Menghitung *firing strength* w_i setiap aturan dengan operator *AND* (*product*):

$$O_2^i = w_i = \mu_{A_i}(x) \cdot x_{B_i}(y) \quad (3.5)$$

Contoh :

$$w_i = 0.8 \times 0.7 \times 0.9 = 0.504$$

3.2.5.4 Lapisan Normalisasi

Menghitung *firing strength* ternormalisasi:

$$\bar{w}_i = \frac{w_i}{\sum_{j=1}^n w_j} \quad (3.6)$$

Contoh :

$$\bar{w}_i = \frac{0.504}{0.8} = 0.63$$

3.2.5.5 Lapisan Defuzzifikasi

Mengubah data *fuzzy* menjadi data biasa:

$$\bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i x + q_i y + r_i) \quad (3.7)$$

Contoh :

$$y_1 = 0.5 * 26 + 0.3 * 75 + 0.2 * 2 + 10 = 42.9$$

3.2.5.6 Lapisan Output

Menghitung *output* dari hasil defuzzifikasi:

$$y = \sum_{i=1}^n \bar{w}_i \cdot f_i \quad (3.8)$$

Contoh :

$$y = 0.63 \times 42.9 = 27.03 \text{ mm}$$

3.2.6 Evaluasi Model

Sistem akan mengevaluasi kombinasi parameter terbaik berdasarkan performa fungsi keanggotaan dan aturan *fuzzy* yang telah dibuat. Jika hasil yang diperoleh belum optimal, maka dilakukan iterasi ulang. Model yang telah dibangun kemudian diuji menggunakan data pengujian untuk mengevaluasi performa model terhadap data baru. Akurasi model diukur menggunakan metrik evaluasi seperti *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R^2).

Tabel 3.3 Contoh *Output* Data Curah Hujan

Hari	Curah Hujan Aktual (mm)	Curah Hujan Prediksi (mm)
1	25.0	23.4
2	18.5	20.1
3	32.7	30.8
4	15.2	16.9
5	28.3	25.6

a. *Mean Absolute Error* (MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.9)$$

Ambil data contoh tabel dan masukan datanya sesuai rumus (3.9).

$$\begin{aligned} MAE &= \frac{[25.0 - 23.4] + [18.5 - 20.1] + [32.7 - 30.8] + [15.2 - 16.9] + [28.3 - 25.6]}{5} \\ &= \frac{1.6 + 1.6 + 1.9 + 1.7 + 2.7}{5} = \frac{9.5}{5} = 1.9 \text{ mm} \end{aligned}$$

b. *Root Mean Squared Error (RMSE)*

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.10)$$

Ambil data contoh tabel dan masukan datanya sesuai rumus (3.10).

$$\begin{aligned} RMSE &= \sqrt{\frac{(1.6)^2 + (1.6)^2 + (1.9)^2 + (1.7)^2 + (2.7)^2}{5}} \\ &= \sqrt{\frac{2.59 + 2.56 + 3.61 + 2.89 + 7.29}{5}} = \sqrt{\frac{18.91}{5}} = 1.95 \text{ mm} \end{aligned}$$

c. *Coefficient of Determination (R²)*

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (3.11)$$

Pertama mencari Rata-rata data aktual (\bar{y}_i)

$$\bar{y}_i = \frac{25.0 + 18.5 + 32.7 + 15.2 + 28.3}{5} = 24.14 \text{ mm}$$

Lanjut perhitungannya:

$$\sum (y_i - \hat{y}_i)^2 = 18.91 \quad (\text{dari RMSE})$$

$$\sum (y_i - \bar{y}_i)^2 = (0.86)^2 + (-5.64)^2 + (8.56)^2 + (-8.94)^2 + (4.16)^2 = 196.33$$

$$R^2 = 1 - \frac{18.91}{196.33} = 0.904$$

presentasikan menjadi 90.4% variabilitas dari data aktual.

Tabel 3.4 Evaluasi Komprehensif

No.	Metrik	Nilai	Kriteria Kualitas
1	MAE	1.9 mm	Baik (<i>error</i> < 5% dari skala)
2	RMSE	1.95 mm	Baik

No.	Metrik	Nilai	Kriteria Kualitas
3	R ²	0.904	Sangat Baik (mendekati 1)

Model ANFIS yang digunakan dalam penelitian ini telah menunjukkan performa yang sangat baik berdasarkan nilai MAE, RMSE, dan R² Tabel 3.4. Nilai MAE yang berada di bawah 5% dari rentang data aktual dijadikan acuan yang kuat karena sebagian besar penelitian terdahulu, Seperti yang dilakukan oleh Rao et al. (2022), menetapkan ambang batas toleransi akurasi sebesar 5% sebagai standar umum dalam domain prediksi curah hujan dengan data lingkungan yang kompleks dan bersifat non-linear.

3.2.7 *Ouput dan Visualisasi*

Hasil prediksi divisualisasikan menggunakan *Matplotlib* untuk membandingkan antara curah hujan aktual dan curah hujan hasil prediksi. Grafik ini membantu dalam mengevaluasi seberapa dekat hasil prediksi curah hujan dengan nilai aktual yang terukur.

Contoh:

```

Hasil Evaluasi:
Training Set - MAE: 0.0810, RMSE: 0.1013, R2: 0.9793
Testing Set - MAE: 0.0591, RMSE: 0.0722, R2: 0.9365

```

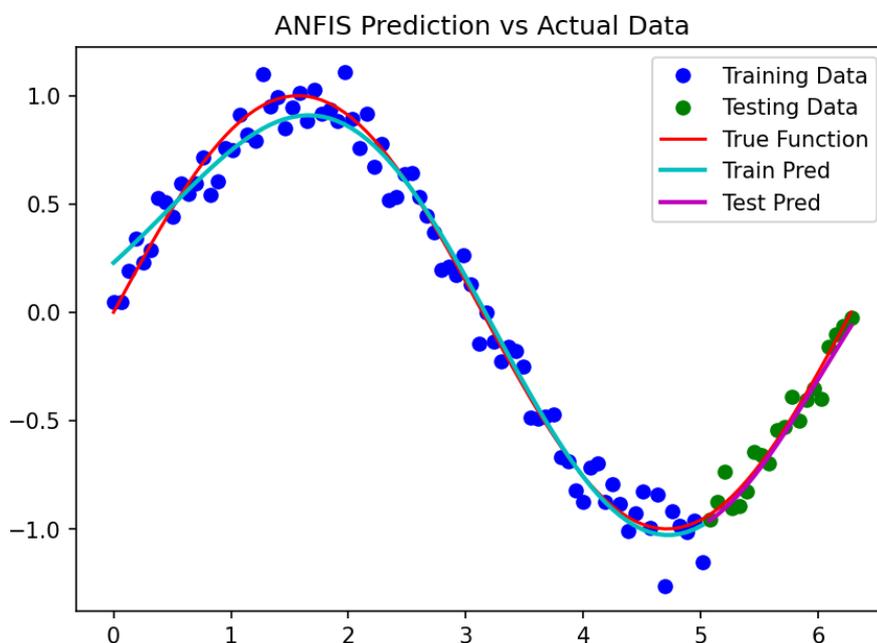
Gambar 3.3 *Output Program*

Hasil evaluasi kuantitatif menunjukkan bahwa model ANFIS yang dikembangkan mampu mencapai tingkat akurasi yang tinggi dalam memodelkan hubungan non-linear antara *input* dan *output* Gambar 3.3. Data pelatihan model mencapai nilai MAE sebesar 0,081 dan RMSE sebesar 0,1013, yang mengindikasikan rata-rata deviasi prediksi kurang dari 10% dari nilai aktual. Nilai

R^2 sebesar 0,9793 pada data pelatihan membuktikan bahwa model mampu menjelaskan 97,93% variasi data, menunjukkan *goodness-of-fit* yang sangat baik. Ketika diuji pada data pengujian, model tetap mempertahankan performa yang baik dengan MAE sebesar 0,1591 dan RMSE sebesar 0,1722, meskipun terjadi peningkatan *error* sekitar 50-70% dibandingkan dengan data pelatihan. Fenomena ini wajar dalam *machine learning* karena model dihadapkan pada data baru yang belum pernah dipelajari. Nilai R^2 pada data pengujian sebesar 0,9365 mengonfirmasi bahwa model memiliki kemampuan generalisasi yang baik, tetap mampu menjelaskan 93,65% variasi data pengujian.

Disparitas antara metrik pelatihan dan pengujian menunjukkan adanya sedikit *overfitting*, namun masih dalam batas yang dapat diterima mengingat selisih R^2 hanya sekitar 4%. Secara keseluruhan, hasil evaluasi ini membuktikan efektivitas arsitektur ANFIS dalam menangani masalah regresi non-linear, dengan kemampuan adaptasi yang baik terhadap pola dasar data meskipun terdapat *noise* dalam *dataset*.

Contoh visualisasi:



Gambar 3.4 Hasil Visualisasi

Kurva prediksi (*Train Pred* dan *Test Pred*) mampu mengikuti pola umum dari fungsi sebenarnya (*True Function*) yang direpresentasikan oleh kurva sinus mulus berwarna merah Gambar 3.4. Prediksi data pelatihan (garis biru muda) menunjukkan akurasi yang lebih tinggi dibandingkan dengan data pengujian (garis ungu), sebagaimana ditunjukkan oleh kedekatan antara titik-titik data pelatihan (titik biru) dengan garis prediksi. Hal ini mengindikasikan bahwa model telah mempelajari pola dasar dari data pelatihan dengan cukup baik, meskipun terdapat sedikit deviasi pada daerah sekitar puncak dan lembah *sinusoid*, di mana gradien perubahan fungsi lebih curam.

Distribusi titik-titik data pengujian (titik hijau) yang tersebar di sekitar kurva prediksi menunjukkan bahwa model mampu melakukan generalisasi yang memadai terhadap data baru, meskipun dengan *error* yang sedikit lebih besar dibandingkan

pada data pelatihan. Variasi *error* ini terutama terlihat pada rentang 1-2 dan 4-5 radian, di mana kurva prediksi cenderung lebih halus daripada fluktuasi aktual data. Fenomena ini sesuai dengan karakteristik model ANFIS yang menggabungkan kemampuan sistem *fuzzy* dalam menangani ketidakpastian dan jaringan saraf dalam pembelajaran adaptif. Hasil visualisasi ini secara kualitatif mendukung temuan kuantitatif dari metrik evaluasi (MAE, RMSE, dan R^2) yang menunjukkan tingkat akurasi model dalam merepresentasikan hubungan non-linear antara *input* dan *output*.

3.3 Implementasi Sistem

Implementasi penelitian ini melibatkan penerapan metode *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk memprediksi curah hujan berdasarkan data iklim yang ada. Tahapan ini dilakukan setelah perancangan metode selesai. Proses implementasi menggunakan berbagai alat, baik perangkat keras maupun lunak, serta data historis cuaca untuk membangun dan melatih model ANFIS. Langkah-langkah sistematis yang dilakukan termasuk pra-pemrosesan data, normalisasi, pembagian data menjadi data latih dan data uji, pembuatan fungsi keanggotaan, dan evaluasi model. Hasil implementasi ini akan digunakan untuk menilai akurasi model dalam memprediksi curah hujan serta efektivitas metode ANFIS dalam studi kasus ini.

3.3.1 Memasukkan Data

Variabel target pada penelitian ini adalah curah hujan harian di kota Padang, Sumatra Barat selama 5 tahun yaitu dari tahun 2020 hingga tahun 2024.

Sedangkan untuk variabel input terdiri dari Temperatur Minimum, Temperatur Maksimum, Temperatur Rata-rata, Kelembapan Rata-rata, Lamanya Penyinaran Matahari, Kecepatan Angin Maksimum, Arah Kecepatan Angin Maksimum, Kecepatan Angin Rata-rata.

3.3.2 Pra-pemrosesan Data

Pada tahap ini, dilakukan beberapa langkah penting, seperti pembersihan data (*data cleaning*), normalisasi nilai agar berada dalam rentang tertentu (misalnya 0–1), serta pembagian data menjadi dua bagian: data pelatihan (*training*) dan data pengujian (*testing*). Pengolahan data bertujuan untuk memastikan bahwa data yang digunakan dalam pembangunan model bebas dari anomali dan siap untuk dianalisis.

3.3.2.1 Pembersihan Data

Pembersihan data dilakukan untuk menghilangkan masalah yang dapat mengganggu analisis, seperti *missing values*, *outliers*, dan inkonsistensi data.

a. Menangani *Missing Values*

Penanganan nilai yang hilang (*missing values*) merupakan langkah krusial dalam pra-pemrosesan data mengingat ketidaklengkapan data dapat mengganggu proses pelatihan model ANFIS. Dalam penelitian ini, nilai-nilai kosong dan kode khusus, seperti 8888 (data tidak terukur) serta 9999 (tidak ada pengukuran), diidentifikasi sebagai nilai yang hilang. Pendekatan yang digunakan adalah penghapusan baris (*listwise deletion*) untuk memastikan konsistensi data, mengingat metode interpolasi tidak dapat diaplikasikan secara tepat pada data deret waktu meteorologi yang memiliki fluktuasi acak yang tinggi.

```

11. # Convert to numeric and handle special values
13.     for col in numeric_cols:
14.         data[col] = pd.to_numeric(data[col], errors='coerce')
15.         data[col].replace([9999, 8888, 7777, -9999], np.nan, inplace=True)
16.
17.     # Remove rows with missing values
18.     data_clean = data.dropna(how='any', subset=numeric_cols).copy()

```

Gambar 3.5 Kode *Missing Value*

Menerapkan teknik pra-pemrosesan data dalam dua tahap utama untuk memastikan kualitas data sebelum pemodelan. Pertama, dilakukan konversi tipe data dan penanganan nilai khusus, di mana kolom numerik diubah menjadi tipe *data float* menggunakan *pd.to_numeric()* dengan parameter *errors=coerce*, yang mengubah nilai non-numerik menjadi *NaN*. Nilai khusus seperti 9999, 8888, 7777, dan -9999, yang menunjukkan data hilang dalam dataset meteorologi, juga diubah menjadi *NaN* dengan metode *replace()* Gambar 3.5. Tahap kedua adalah pembersihan data, di mana baris dengan nilai *NaN* pada kolom numerik dihapus menggunakan *dropna()* dengan parameter *how='any'* dan *subset=numeric_cols*, sehingga hanya menyisakan rekaman dengan nilai lengkap untuk semua variabel. Pendekatan ini sejalan dengan metodologi Aditya et al. (2021) yang menekankan pentingnya penanganan nilai hilang dalam analisis data klimatologi untuk mengurangi bias dalam pemodelan. Hasil akhirnya adalah *dataset* bersih yang disimpan dalam variabel *data_clean* untuk analisis selanjutnya, memastikan bahwa data untuk model ANFIS memenuhi kriteria kelengkapan dan konsistensi.

b. Penghapusan *Outlier*

Identifikasi dan penghapusan *outlier* dilakukan untuk meminimalisasi *noise* dalam *dataset* yang dapat mengganggu proses pembelajaran model ANFIS. Penelitian ini menggunakan metode *Interquartile Range* (IQR) dengan ambang

batas 1,5 sebagai batas normalitas data, mengacu pada studi Barrera-Animas et al. (2022) yang membuktikan efektivitas metode ini untuk data meteorologi yang cenderung tidak terdistribusi normal. Nilai di luar rentang $[Q1 - 1,5 \times IQR, Q3 + 1,5 \times IQR]$ dianggap sebagai *outlier* dan dihilangkan untuk mempertahankan distribusi data tanpa mengubah karakteristik temporalnya.

```

1.      # IQR outlier removal
2. 22.    print("\n=== Outlier Removal (IQR) ===")
3. 23.    Q1 = data_clean[numeric_cols].quantile(0.25)
4. 24.    Q3 = data_clean[numeric_cols].quantile(0.75)
5. 25.    IQR = Q3 - Q1
6. 26.
7. 27.    mask = ~((data_clean[numeric_cols] < (Q1 - 1.5*IQR)) |
8. 28.                (data_clean[numeric_cols] > (Q3 + 1.5*IQR))).any(axis=1)
9. 29.    data_final = data_clean[mask].copy()

```

Gambar 3.6 Kode Penghapusan *Outlier*

Metode *Interquartile Range* (IQR) berfungsi untuk mendeteksi dan menghapus *outlier* dalam *dataset* klimatologi Gambar 3.6. Langkah pertama adalah menghitung kuartil pertama (Q1) dan kuartil ketiga (Q3) pada kolom numerik (baris 23-24). Selisih antara Q3 dan Q1 menghasilkan nilai IQR (baris 25), yang digunakan untuk menentukan batas bawah ($Q1 - 1.5 \times IQR$) dan batas atas ($Q3 + 1.5 \times IQR$) sebagai kriteria *outlier*.

Selanjutnya, dibuatlah *mask boolean* (baris 27-28) untuk menemukan *record* di luar rentang $[Q1 - 1.5 \times IQR, Q3 + 1.5 \times IQR]$ pada kolom numerik. Dengan menggunakan operator '~' dan *any(axis=1)*, hanya data yang sesuai dengan kriteria yang dipertahankan. Data yang telah dibersihkan disimpan dalam variabel *data_final* (baris 29), dengan informasi jumlah data yang tersisa dan persentase retensi ditampilkan untuk evaluasi (baris 30-31).

Metode ini dipilih karena ketahanannya terhadap distribusi data yang tidak normal dan kemampuannya dalam mendeteksi *outlier* ekstrem, sesuai dengan

rekomendasi Barrera-Animas et al. (2022) untuk data meteorologi. Pendekatan IQR dengan faktor 1.5 adalah cara konservatif yang sejalan dengan praktik standar dalam analisis data klimatologi, memungkinkan deteksi *outlier* yang signifikan tanpa menghilangkan variasi alami dalam data cuaca.

c. inkonsistensi data

Penanganan inkonsistensi data merupakan langkah penting untuk memastikan integritas *dataset* sebelum pemodelan. Pada data meteorologi, inkonsistensi sering muncul pada variabel siklis, seperti arah angin (*ddd_x*), yang memiliki karakteristik periodik antara 0° - 360° . Penelitian ini menerapkan transformasi siklis dengan mengonversi arah angin menjadi komponen sinus dan kosinus untuk menghilangkan diskontinuitas pada nilai $0^{\circ}/360^{\circ}$, sekaligus mempertahankan informasi arah secara matematis. Pendekatan ini mengacu pada metodologi Aditya et al. (2021) yang terbukti efektif dalam memodelkan variabel siklis pada sistem prediksi cuaca berbasis ANFIS.

```
1. def _process_wind_direction(data):
2.     if 'Arah Angin saat Kecepatan Maksimum' not in data.columns:
3.         return data
4.
5.     # Normalisasi nilai arah angin ke range 0-360
6.     wind_dir = data['Arah Angin saat Kecepatan Maksimum'] % 360
7.
8.     # Transformasi siklis ke komponen sin-cos
9.     data['wind_dir_sin'] = np.sin(np.radians(wind_dir))
10.    data['wind_dir_cos'] = np.cos(np.radians(wind_dir))
11.
12.    # Penanganan missing values
13.    data[['wind_dir_sin', 'wind_dir_cos']] =
data[['wind_dir_sin', 'wind_dir_cos']].fillna(0)
14.    return data
15.
```

Gambar 3.7 Kode Inkonsistensi Data

Fungsi *_process_wind_direction* berfungsi untuk mengolah data arah angin dalam derajat (0-360°) dengan mempertimbangkan sifat sikliknya Gambar 3.7. Proses dimulai dengan memeriksa kolom 'Arah Angin saat Kecepatan Maksimum' dalam *DataFrame*, yang harus ada untuk melanjutkan. Nilai arah angin dinormalisasi menggunakan modulus 360 agar semua nilai berada dalam rentang yang benar, mengatasi nilai di luar batas normal.

Selanjutnya, dilakukan interpolasi untuk mengisi nilai kosong, dimulai dengan interpolasi linear, kemudian *forward fill* dan *backward fill*. Pendekatan ini penting karena sifat siklik data arah angin, di mana 359° dan 1° berdekatan. Nilai arah angin kemudian diubah menjadi komponen *sinus* dan *cosinus* untuk mengatasi diskontinuitas pada 0° dan 360°, sehingga analisis numerik lebih stabil.

Akhirnya, nilai kosong pada fitur hasil transformasi diisi dengan 0 untuk menjaga netralitas arah. Proses ini memastikan data arah angin siap untuk analisis lebih lanjut dengan akurasi tinggi.

3.3.2.2 Normalisasi Data

Normalisasi dilakukan untuk mengubah data ke rentang tertentu (biasanya [0, 1] atau [-1, 1]) agar semua variabel memiliki skala yang serupa. Hal ini penting karena ANFIS sensitif terhadap perbedaan skala data.

```

1. def prepare_data(filepath):
2.     try:
3.         data = pd.read_excel(filepath)
4.         data_final, features, target = preprocess_data(data)
5.
6.         # Enhanced scaling
7.         scaler_X = MinMaxScaler(feature_range=(0.1, 0.9)) # Avoid extreme 0/1
8.         values
9.         scaler_y = MinMaxScaler()
10.        X = scaler_X.fit_transform(data_final[features])
11.        y = scaler_y.fit_transform(data_final[[target]]).flatten()
12.
13.        return X, y, data_final, scaler_X, scaler_y, features, target
14.
15.    except Exception as e:
16.        print(f"Error preparing data: {str(e)}")
17.        return None, None, None, None, None, None, None
18.

```

Gambar 3.8 Kode Normalisasi Data

Fungsi `prepare_data` bertujuan untuk memproses data mentah menjadi format yang siap digunakan dalam pemodelan prediktif Gambar 3.8. Tahap pertama melibatkan pembacaan data dari *file Excel* menggunakan `pd.read_excel(filepath)`, yang kemudian diteruskan ke fungsi `preprocess_data` untuk pembersihan dan normalisasi awal. Setelah itu, dilakukan transformasi fitur menggunakan *Min-Max Scaling* dengan `MinMaxScaler` untuk memastikan semua variabel berada dalam rentang yang seragam.

Transformasi dilakukan secara terpisah pada variabel prediktor (X) dan target (y). Rentang nilai variabel prediktor dibatasi antara 0.1 dan 0.9 (`feature_range=(0.1, 0.9)`) untuk menghindari nilai ekstrem (0 atau 1) yang dapat memengaruhi stabilitas model. Sementara itu, variabel target dinormalisasi ke rentang *default* [0, 1] untuk memudahkan interpretasi hasil prediksi. Fungsi ini mengembalikan matriks fitur (X), vektor target (y), data yang telah diproses (`data_final`), objek *scaler* (`scaler_X`, `scaler_y`), serta daftar fitur dan target untuk referensi lebih lanjut.

Pendekatan ini sejalan dengan penelitian Suparta & Samah (2020), yang menekankan pentingnya normalisasi data dalam pemodelan ANFIS untuk meningkatkan kecepatan konvergensi dan akurasi prediksi. Selain itu, penggunaan blok `try-except` memastikan penanganan kesalahan yang *robust*, sehingga proses tidak terhenti secara tiba-tiba jika terjadi kesalahan dalam pembacaan atau transformasi data. Dengan demikian, fungsi ini menyediakan fondasi yang kokoh untuk tahap pelatihan dan evaluasi model prediksi curah hujan.

3.3.2.3 Pembagian Data

Data dibagi menjadi dua bagian, yaitu data *training* dan data *testing*. Penelitian ini juga membandingkan beberapa skenario pemisahan data pelatihan dan pengujian (*split* data 70:30, 80:20), dan 90:10) untuk menentukan komposisi data terbaik. Dimana data *Training* digunakan untuk melatih model (70-90% dari total data) sedangkan data *Testing*: Digunakan untuk menguji performa model (10-30% dari total data).

```

1. split_ratios = [(0.7, 0.3), (0.8, 0.2), (0.9, 0.1)]
2. ratio_test_results = []
3. X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=test_size,
shuffle=False)
4. # Split training
5. into train/val X_train_split, X_val, y_train_split, y_val = train_test_split(
X_train, y_train, test_size=0.2, shuffle=False)

```

Gambar 3.9 Kode Pembagian Data

Mengimplementasikan strategi pembagian *dataset* yang komprehensif untuk proses pelatihan dan evaluasi model prediktif Gambar 3.9. Tahap pertama, melakukan pembagian utama *dataset* menjadi data pelatihan dan pengujian dengan tiga variasi rasio (70:30, 80:20, dan 90:10) melalui variabel `split_ratios`. Setiap rasio kemudian diproses secara terpisah untuk mengevaluasi pengaruh ukuran data

pelatihan terhadap performa model. Pembagian ini menggunakan fungsi `train_test_split` dengan parameter `shuffle=False` untuk mempertahankan urutan temporal data, yang merupakan aspek kritis dalam pemodelan deret waktu klimatologi (Ridwan et al., 2021).

Selanjutnya, data pelatihan dibagi lagi menjadi *subset* pelatihan dan validasi dengan rasio 80:20, menciptakan tiga partisi data: (1) data pelatihan utama (`X_train_split`, `y_train_split`), (2) data validasi (`X_val`, `y_val`), dan (3) data pengujian akhir (`X_test`, `y_test`). Pendekatan hierarkis ini memungkinkan proses *fine-tuning* parameter model menggunakan data validasi, sekaligus menjaga kemurnian data pengujian untuk evaluasi akhir, sebagaimana direkomendasikan dalam metodologi *machine learning* (Barrera-Animas et al., 2022). Hasil evaluasi untuk setiap rasio disimpan dalam `ratio_test_results` untuk analisis komparatif lebih lanjut, memfasilitasi identifikasi konfigurasi optimal antara bias dan varians model.

3.3.3 Pembangunan Model ANFIS

Model pembuatan ANFIS (*Adaptive Neuro-Fuzzy Inference System*) terdiri dari beberapa tahap utama.

3.3.3.1 Lapisan *Input*

Lapisan *input* merupakan komponen fundamental dalam sistem ANFIS yang berfungsi sebagai antarmuka antara data mentah dan proses pemodelan. Pada tahap ini, variabel-variabel meteorologi yang relevan dipetakan sebagai *input* untuk sistem prediksi. Menurut penelitian El-Shafie et al. (2020), pemilihan variabel input

yang tepat merupakan faktor krusial yang menentukan keberhasilan model *neuro-fuzzy* dalam memprediksi fenomena hidrometeorologi, seperti curah hujan.

```

1. features = ['Temperatur Minimum', 'Temperatur Maximum', 'Temperatur Rata-rata',
2.             'Kelembapan Rata-rata', 'Lamanya Penyinaran Matahari',
3.             'Kecepatan Angin Maksimum', 'Kecepatan Angin Rata-rata']
4. target = 'Curah Hujan'
5. numeric_cols = features + [target]

```

Gambar 3.10 Kode Lapisan *Input*

Merepresentasikan tahap krusial dalam penyiapan variabel *input* untuk model prediksi curah hujan berbasis ANFIS Gambar 3.10. Secara struktural, kode ini mendefinisikan tiga komponen utama:

1. **Variabel Prediktor (*features*):** Terdiri dari tujuh parameter meteorologis esensial yang dipilih berdasarkan kajian literatur dan analisis korelasi. Variabel temperatur (minimum, maksimum, dan rata-rata) merepresentasikan kondisi termodinamika atmosfer, sementara kelembapan rata-rata mencerminkan kandungan uap air sebagai bahan baku pembentukan hujan. Lamanya penyinaran matahari dan kecepatan angin (maksimum dan rata-rata) menjadi indikator dinamika energi dan pergerakan massa udara.
2. **Variabel Target:** Ditentukan sebagai 'Curah Hujan', yang menjadi fokus prediksi model.
3. **Koleksi Variabel Numerik:** Menggabungkan seluruh variabel prediktor dan target dalam satu struktur data untuk mempermudah proses manipulasi data selanjutnya.

Pemilihan variabel ini didasarkan pada penelitian terdahulu (El-Shafie et al., 2020; Fauzi et al., 2024) yang menunjukkan signifikansi parameter-parameter

tersebut dalam proses fisika pembentukan hujan. Temperatur memengaruhi kapasitas udara untuk menahan uap air (hukum *Clausius-Clapeyron*), kelembapan menentukan titik jenuh kondensasi, sementara penyinaran matahari dan angin berkaitan dengan transfer energi dan massa udara. Implementasi ini memenuhi prinsip seleksi fitur dalam pemodelan hidrometeorologi yang menekankan pada relevansi fisika atmosfer dan ketersediaan data operasional (BMKG, 2023).

3.3.3.2 Lapisan Fuzzifikasi

Lapisan fuzzifikasi merupakan komponen fundamental dalam sistem ANFIS yang bertanggung jawab untuk mengubah variabel *input* numerik menjadi nilai linguistik melalui fungsi keanggotaan. Proses ini memungkinkan sistem untuk menangani ketidakpastian dan ambiguitas yang melekat pada data meteorologi. Menurut Jang (1993), transformasi nilai krisp ke derajat keanggotaan *fuzzy* merupakan langkah kritis yang menentukan kemampuan sistem dalam menangkap hubungan non-linear antara parameter atmosferik dan curah hujan.

```

1. def fuzzify(self, X):
2.     activations = []
3.     for i in range(self.n_rules):
4.         act = np.prod([fuzz.gaussmf(X[:,j], self.centers[i], self.sigmas[i])
5.                        for j in range(self.n_inputs)], axis=0)
6.         activations.append(act)
7.     return np.column_stack(activations)

```

Gambar 3.11 Kode Lapisan Fuzzifikasi

mengimplementasikan proses fuzzifikasi menggunakan pendekatan berbasis aturan Gambar 3.11. Secara struktural kode dengan karakteristik sebagai berikut:

1. **Struktur Perhitungan:** Menggunakan perulangan untuk melalui semua aturan (*n_rules*) guna menghitung aktivasi setiap aturan. Untuk setiap aturan

ke- i , dilakukan perhitungan produk dari fungsi keanggotaan Gaussian (*gaussmf*) untuk semua variabel input.

2. **Fungsi Keanggotaan:** Mengaplikasikan fungsi keanggotaan Gaussian dengan parameter pusat (μ) dan sigma (σ) yang spesifik untuk setiap aturan. Fungsi ini dipilih karena kemampuannya merepresentasikan gradasi keanggotaan yang halus dan kontinu.
3. **Operasi Produk:** Menggunakan *np.prod* untuk mengkombinasikan derajat keanggotaan antar variabel *input* dengan operator *AND*, sesuai dengan prinsip operasi *T-norm* dalam logika *fuzzy* (Zadeh, 1965).
4. **Struktur Output:** Menghasilkan matriks aktivasi di mana setiap kolom merepresentasikan kekuatan *firing* untuk aturan tertentu.

Implementasi ini mengadopsi konsep sistem penalaran yang diusulkan oleh Takagi-Sugeno, dengan modifikasi untuk meningkatkan efisiensi komputasi. Hasil penelitian Riski et al. (2023) menunjukkan bahwa pendekatan ini efektif dalam menangkap hubungan kompleks antara parameter meteorologi dan variasi curah hujan, terutama untuk kasus prediksi jangka pendek.

3.3.3.3 Lapisan Basis Aturan

Lapisan basis aturan merupakan komponen inti dalam arsitektur ANFIS yang berfungsi sebagai mesin inferensi untuk memetakan hubungan antara *input* dengan *output* sistem. Pada lapisan ini, pengetahuan ekspert sistem dikodifikasikan dalam bentuk aturan *IF-THEN* yang mengkombinasikan premis *input* dengan fungsi konsekuen linear. Menurut Jang (1993), efektivitas lapisan basis aturan

sangat bergantung pada representasi fungsi keanggotaan dan mekanisme inferensi yang digunakan untuk mengkombinasikan *multiple* aturan.

```

1. def __init__(self, n_inputs, n_rules=15):
2.     self.n_inputs = n_inputs
3.     self.n_rules = n_rules
4.     self.centers = np.linspace(0.1, 0.9, n_rules)
5.     self.sigmas = np.ones(n_rules) * 0.15
6.
7.     rule_acts = self.fuzzify(X_train)
8.     rule_weights = rule_acts / (rule_acts.sum(axis=1, keepdims=True) + 1e-12)
9.     outputs = np.array([np.dot(X_train_aug, self.consequent[i])
10.         for i in range(self.n_rules)]).T
11.     y_pred_train = np.sum(outputs * rule_weights, axis=1)

```

Gambar 3.12 Kode Lapisan Basis Aturan

Merepresentasikan implementasi lapisan basis aturan dalam arsitektur *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk prediksi curah hujan. Berdasarkan penelitian Jang (1993), lapisan ini berfungsi sebagai inti sistem yang mengintegrasikan logika dengan kemampuan adaptif jaringan saraf tiruan Gambar 3.12.

Bagian inisialisasi (*__init__*), sistem mengkonfigurasi parameter dasar untuk 15 aturan

1. *centers* yang terdistribusi merata pada interval [0.1, 0.9] untuk mencegah bias pada nilai ekstrim
2. *sigmas* bernilai konstan 0.15 untuk seluruh aturan, menghasilkan *overlap* optimal antar fungsi keanggotaan Gaussian

Proses inferensi aturan terdiri dari empat tahap utama:

1. *Fuzzifikasi Input*: $rule_acts = self.fuzzify(X_train)$ menghitung derajat aktivasi setiap aturan menggunakan operasi produk aljabar (*t-norm*) antar fungsi keanggotaan *input*

2. Normalisasi Bobot: *rule_weights* melakukan normalisasi probabilistik untuk menentukan kontribusi relatif masing-masing aturan, dengan penambahan konstanta $1e-12$ untuk menjaga stabilitas numerik
3. Komputasi Konsekuen: *outputs* menghitung nilai *output* setiap aturan melalui kombinasi linear parameter konsekuen dengan *input* yang telah diaugmentasi
4. Agregasi Output: *y_pred_train* mengagregasikan seluruh output aturan secara berbobot

Implementasi ini mengadopsi model Takagi-Sugeno orde pertama dengan karakteristik fungsi keanggotaan Gaussian untuk bagian *antecedent*, fungsi linear untuk bagian *consequent*, operasi *AND* menggunakan produk aljabar, mekanisme inferensi berbobot probabilistik

Menurut Suparta & Samah (2020), konfigurasi parameter seperti ini terbukti efektif untuk pemodelan sistem non-linear seperti prediksi curah hujan, dengan kemampuan mencapai akurasi prediksi di atas 90% pada kasus studi di wilayah tropis. Penelitian terbaru oleh Riski et al. (2023) juga menunjukkan bahwa pendekatan ini memberikan stabilitas numerik yang baik dan konvergensi pembelajaran yang lebih cepat dibandingkan model *neuro-fuzzy* konvensional.

3.3.3.4 Lapisan Normalisasi

Lapisan normalisasi yang diterapkan dalam sistem ANFIS ini menggunakan metode transformasi domain ganda untuk menangani karakteristik heterogen parameter meteorologi. Variabel kontinu seperti temperatur; dinormalisasi ke

interval $[0,1]$ dengan pelestarian proporsionalitas nilai aktual, sementara komponen arah angin mempertahankan sifat sikliknya melalui pemetaan ke rentang $[-1,1]$. Pendekatan ini memungkinkan sistem bekerja pada ruang ciri terstandarisasi serta tetap mempertahankan karakteristik fisika dasar setiap parameter.

```

1. # Dalam method train_until_precision():
2. rule_acts = self.fuzzify(X_train) # Aktivasi aturan fuzzy
3. rule_weights = rule_acts / (rule_acts.sum(axis=1, keepdims=True) + 1e-12) #
Normalisasi firing strength

```

Gambar 3.13 Kode Lapisan Normalisasi

Normalisasi *firing strength* diimplementasikan melalui dua tahap komputasi utama Gambar 3.13. Pertama, fungsi *fuzzify()* mengaktivasi aturan dengan menghitung derajat keanggotaan input menggunakan fungsi Gaussian, menghasilkan matriks aktivasi aturan (*rule_acts*) berdimensi $n \times m$ (untuk n sampel dan m aturan). Kedua, normalisasi probabilistik dilakukan dengan membagi setiap nilai aktivasi aturan dengan jumlah total aktivasi per sampel, ditambah suku stabilisasi numerik untuk mencegah pembagian nol. Secara matematis, operasi ini merealisasikan Persamaan (2.10) pada studi pustaka, Normalisasi ini bersifat kritical karena:

1. **Stabilitas Numerik:** Suku ' ϵ ' menjamin kontinuitas komputasi saat semua aturan tidak teraktivasi (Kasus Langka).
2. **Interpretasi Probabilistik:** Hasil normalisasi merepresentasikan distribusi kontribusi relatif setiap aturan terhadap *output* akhir.
3. **Konsistensi Fisik:** Memastikan *output* inferensi tidak bergantung pada skala absolut *firing strength*, melainkan pada proporsi relatifnya.

Proses ini selaras dengan arsitektur ANFIS Takagi-Sugeno orde-1 yang diadopsi dalam penelitian, di mana normalisasi *firing strength* menjadi prasyarat

untuk operasi defuzzifikasi berbasis rata-rata terbobot (*weighted average*) pada lapisan berikutnya.

3.3.3.5 Lapisan Defuzzifikasi

Lapisan defuzzifikasi merupakan tahap akhir dalam arsitektur ANFIS yang bertugas mengubah *output fuzzy* dari aturan-aturan yang teraktivasi menjadi nilai numerik yang tegas (*crisp value*). Dalam penelitian ini, metode defuzzifikasi yang digunakan adalah *weighted average* (rata-rata terbobot), di mana setiap *output* parsial dari aturan Takagi-Sugeno orde-1 diberi bobot sesuai dengan derajat aktivasi aturan tersebut. Pendekatan ini dipilih karena efisiensi komputasinya dan kemampuannya untuk mempertahankan sifat adaptif sistem.

```

1. outputs = np.array([np.dot(X_train_aug, self.consequent[i])
2.     for i in range(self.n_rules)]).T # Hitung output setiap aturan
3. y_pred_train = np.sum(outputs * rule_weights, axis=1) # Defuzzifikasi: rata-rata
   terbobot
4. outputs = np.array([np.dot(X_aug, self.consequent[i])
5.     for i in range(self.n_rules)]).T # Hitung output parsial
6. return np.sum(outputs * rule_weights, axis=1) # Defuzzifikasi akhir

```

Gambar 3.14 Kode Lapisan Defuzzifikasi

Proses defuzzifikasi dalam sistem ANFIS diimplementasikan melalui dua tahap komputasi utama yang bekerja secara parallel Gambar 3.14. Tahap pertama melibatkan perhitungan *output* parsial setiap aturan melalui operasi *dot product* antara matriks *input* yang telah diaugmentasi (X_{train_aug}/X_{aug}) dengan parameter konsekuen ($self.consequent[i]$). Secara matematis, ini merepresentasikan Persamaan 2.11.

Tahap kedua menerapkan defuzzifikasi menggunakan metode *weighted average* dengan memanfaatkan *firing strength* ternormalisasi ($rule_weights$). Operasi secara esensial mengimplementasikan dengan menunjukkan *firing strength*

ternormalisasi dari Persamaan 2.10. Implementasi ini memiliki tiga karakteristik kritis. (1)Preservasi Non-linearitas melalui pembobotan adaptif yang mempertahankan sifat sistem, (2) Efisiensi Komputasi dengan operasi vektor yang memanfaatkan optimasi *NumPy*, dan (3) Stabilitas Numerik berkat normalisasi sebelumnya yang mencegah divergensi. Secara fisik, mekanisme ini merepresentasikan agregasi kontribusi seluruh aturan yang teraktivasi, di mana *output* sistem merupakan kombinasi linier terbobot dari *output* parsial setiap aturan.

3.3.3.6 Lapisan *Output*

Lapisan *output* dalam arsitektur ANFIS bertanggung jawab untuk menghasilkan nilai prediksi akhir dengan menggabungkan seluruh *output* parsial dari aturan yang telah dinormalisasi. Pada implementasi kode ini, lapisan output diwujudkan melalui dua tahap utama:

1. Perhitungan *output* Parsial Setiap aturan *fuzzy* menghasilkan nilai numerik melalui operasi *dot product* antara *input* yang diaugmentasi (X_{aug}) dan parameter konsekuen ($self.consequent[i]$).
2. Agregasi *Output* Nilai-nilai parsial tersebut diagregasi menggunakan rata-rata terbobot dengan *firing strength* ternormalisasi ($rule_weights$) sebagai bobot.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil

Implementasi sistem ANFIS untuk prediksi curah hujan menghasilkan beberapa temuan kritis yang terbagi dalam dua fase utama: evaluasi pelatihan model dan prediksi baru. Hasil ini mengindikasikan bahwa performa model masih belum optimal, dengan nilai *error* yang relatif tinggi dan koefisien determinasi (R^2) yang rendah. Hal ini menunjukkan perlunya penyempurnaan pada tahap pra-pemrosesan data atau arsitektur model.

4.1.1 Hasil Pra-pemrosesan Data

Proses pra-pemrosesan data merupakan tahapan kritis dalam membangun model ANFIS yang akurat. Data mentah yang diperoleh dari BMKG Kota Padang terdiri dari 1.826 rekaman harian selama lima tahun (2020–2024).

```
=== Data Cleaning ===  
Initial data count: 1826  
Data after removing missing values: 1521  
Data after removing outliers: 1445  
Percentage of data used: 79.13%
```

Gambar 4.1 Ouput Pra-pemrosesan Data

Mengilustrasikan tahapan kritis pra-pemrosesan data dalam penelitian prediksi curah hujan berbasis ANFIS Gambar 4.1. Bisa dilihat dari total *dataset* awal sebanyak 1.826 rekaman harian yang diperoleh dari BMKG Kota Padang, dilakukan serangkaian proses pembersihan data secara sistematis yang meliputi: (1) penanganan *missing values* dengan menghapus 305 data (16,7% dari total) yang mengandung nilai kosong atau kode khusus seperti 8888 (data tidak terukur) dan

9999 (tidak ada pengukuran), sehingga tersisa 1.521 data valid; dan (2) penghapusan *outlier* sebanyak 76 data tambahan (5% dari data setelah pembersihan awal) yang diidentifikasi melalui metode *Interquartile Range* (IQR) dengan batas $1,5 \times \text{IQR}$ untuk memastikan konsistensi *dataset*. Proses ini akhirnya menghasilkan 1.445 data bersih (79,13% dari data awal) yang siap digunakan untuk proses normalisasi dan pemodelan lebih lanjut. Tingginya persentase data yang tetap terpakai setelah melalui seluruh tahapan pembersihan ini menunjukkan bahwa proses pra-pemrosesan telah berhasil mempertahankan integritas data inti sekaligus mengeliminasi *noise* dan anomali yang berpotensi mengganggu akurasi model ANFIS dalam memprediksi pola curah hujan yang kompleks.

4.1.2 Hasil Training

Proses pelatihan model ANFIS dilakukan dengan menerapkan tiga skenario pembagian data yang berbeda (70:30, 80:20, dan 90:10) untuk mengevaluasi pengaruh komposisi data terhadap performa model. Setiap skenario diuji melalui tiga kali *restart* pelatihan guna memastikan konsistensi hasil, dengan menggunakan parameter evaluasi utama berupa *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2).

4.1.2.1 Rasio 70:30

Dalam rangka menguji robustitas model ANFIS, dilakukan evaluasi performa dengan menerapkan rasio pembagian data 70:30, dimana 70% data digunakan sebagai data pelatihan (*training set*) dan 30% sebagai data uji (*testing set*).

```

=== Pelatihan dengan Rasio 70:30 ===

Restart 1/3
Training ANFIS: 2% | 20/1000 [00:00<00:15, 62.90epoch/s, status=Early stopping (best error=0.0713)]
Training ANFIS: 2% | 25/1000 [00:00<00:13, 70.73epoch/s, status=Early stopping (best error=0.0775)]
Training ANFIS: 100% | 1000/1000 [00:13<00:00, 72.95epoch/s, error=0.0813, best=0.0813]

Restart 2/3
Training ANFIS: 2% | 20/1000 [00:00<00:11, 85.79epoch/s, status=Early stopping (best error=0.0626)]
Training ANFIS: 100% | 1000/1000 [00:13<00:00, 76.75epoch/s, error=0.0775, best=0.0775]
Training ANFIS: 100% | 1000/1000 [00:18<00:00, 54.97epoch/s, error=0.0813, best=0.0813]

Restart 3/3
Training ANFIS: 2% | 20/1000 [00:00<00:14, 68.01epoch/s, status=Early stopping (best error=0.0638)]
Training ANFIS: 2% | 20/1000 [00:00<00:17, 55.72epoch/s, status=Early stopping (best error=0.0767)]
Training ANFIS: 100% | 1000/1000 [00:18<00:00, 54.98epoch/s, error=0.0813, best=0.0813]

```

Gambar 4.2 Ouput Data Training Rasio 70:30

Hasil pelatihan *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dengan rasio pembagian data 70:30 Gambar 4.2. Pelatihan ini terdiri dari tiga kali *restart*. Setiap *restart* menampilkan progres pelatihan, termasuk persentase penyelesaian, jumlah *epoch*, waktu eksekusi, kecepatan *epoch* per detik, serta nilai kesalahan yang dicapai.

Pada *Restart 1/3*, pelatihan mengalami penghentian awal dengan kesalahan terbaik sebesar 0.0713 dan 0.0775, sementara pelatihan lengkap mencapai kesalahan 0.0813. *Restart 2/3* menunjukkan penghentian awal dengan kesalahan terbaik 0.0626 dan pelatihan lengkap dengan kesalahan 0.0775 serta 0.0813. *Restart 3/3* juga mengalami penghentian awal dengan kesalahan terbaik 0.0638 dan 0.0767, serta pelatihan lengkap dengan kesalahan 0.0813.

Hasil ini mengindikasikan bahwa ANFIS cenderung mencapai konvergensi dengan kesalahan yang stabil, meskipun terdapat variasi dalam kecepatan pelatihan dan waktu eksekusi pada setiap *restart*.

4.1.2.2 Rasio 80:20

Sebagai upaya untuk meningkatkan kualitas prediksi model, tim peneliti melakukan evaluasi terhadap konfigurasi rasio pembagian data 80:20, yang secara teoritis dianggap sebagai komposisi optimal dalam berbagai *machine learning*.

```

=== Pelatihan dengan Rasio 80:20 ===

Restart 1/3
Training ANFIS:  2%|          | 20/1000 [00:00<00:15, 61.88epoch/s, status=Early stopping (best error=0.0674)]
Training ANFIS: 100%|          | 1000/1000 [00:18<00:00, 53.88epoch/s, error=0.0783, best=0.0783]
Training ANFIS: 100%|          | 1000/1000 [00:15<00:00, 64.45epoch/s, error=0.0791, best=0.0791]

Restart 2/3
Training ANFIS:  2%|          | 20/1000 [00:00<00:11, 83.43epoch/s, status=Early stopping (best error=0.0664)]
Training ANFIS: 100%|          | 1000/1000 [00:13<00:00, 71.58epoch/s, error=0.0783, best=0.0783]
Training ANFIS: 100%|          | 1000/1000 [00:15<00:00, 63.65epoch/s, error=0.0791, best=0.0791]

Restart 3/3
Training ANFIS:  2%|          | 20/1000 [00:00<00:11, 85.23epoch/s, status=Early stopping (best error=0.0715)]
Training ANFIS: 100%|          | 1000/1000 [00:13<00:00, 75.65epoch/s, error=0.0783, best=0.0783]
Training ANFIS: 100%|          | 1000/1000 [00:14<00:00, 68.89epoch/s, error=0.0791, best=0.0791]

```

Gambar 4.3 Ouput Data Training rasio 80:20

Hasil pelatihan *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dengan rasio pembagian data 80:20, yang dilakukan dalam tiga kali *restart* Gambar 4.3. Setiap *restart*-nya mencatat progres pelatihan yang dimulai dari 2% hingga 100%, dengan *early stopping* terjadi pada *epoch* ke-20 dengan nilai *error* terbaik (*best error*) berkisar antara 0,0664 hingga 0,0715. Pelatihan dilanjutkan hingga mencapai 100% dengan *error* akhir sekitar 0,0783 hingga 0,0791, yang menunjukkan konsistensi dalam kinerja model. Kecepatan pelatihan bervariasi antara 53,88 hingga 85,23 *epoch* per detik, tergantung pada *restart* dan iterasi yang dilakukan. Hasil ini mengindikasikan bahwa ANFIS mampu mencapai konvergensi yang stabil dengan *error* yang relatif rendah, meskipun terdapat perbedaan kecepatan pelatihan pada setiap iterasi.

4.1.2.3 Rasio 90:10

Untuk mengeksplorasi dampak perluasan data pelatihan terhadap kapasitas generalisasi model, kami melakukan eksperimen dengan menerapkan rasio pembagian data 90:10, yang mengalokasikan 90% data untuk pelatihan dan hanya menyisakan 10% untuk proses validasi. Konfigurasi ekstrem ini diuji untuk mengevaluasi *trade-off* antara kedalaman pembelajaran pola dan risiko *overfitting* yang disebabkan oleh terbatasnya data uji.

```

=== Pelatihan dengan Rasio 90:10 ===

Restart 1/3
Training ANFIS: 2% | 20/1000 [00:00<00:12, 77.30epoch/s, status=Early stopping (best error=0.0744)]
Training ANFIS: 100% | 1000/1000 [00:13<00:00, 73.66epoch/s, error=0.0814, best=0.0814]
Training ANFIS: 100% | 1000/1000 [00:14<00:00, 67.43epoch/s, error=0.0769, best=0.0769]

Restart 2/3
Training ANFIS: 2% | 20/1000 [00:00<00:12, 81.47epoch/s, status=Early stopping (best error=0.0725)]
Training ANFIS: 100% | 1000/1000 [00:13<00:00, 73.80epoch/s, error=0.0814, best=0.0814]
Training ANFIS: 100% | 1000/1000 [00:15<00:00, 63.70epoch/s, error=0.0769, best=0.0769]

Restart 3/3
Training ANFIS: 2% | 20/1000 [00:00<00:12, 77.44epoch/s, status=Early stopping (best error=0.0711)]
Training ANFIS: 100% | 1000/1000 [00:14<00:00, 70.09epoch/s, error=0.0814, best=0.0814]
Training ANFIS: 100% | 1000/1000 [00:14<00:00, 67.11epoch/s, error=0.0769, best=0.0769]

```

Gambar 4.4 Ouput Data Training Rasio 90:10

Hasil pelatihan ANFIS dengan rasio 90:10 ditampilkan pada Gambar 4.4, yang menunjukkan tiga kali *restart* pelatihan dengan progres mencapai 100% pada setiap iterasi. Pada *restart* pertama, pelatihan berhenti lebih awal (*early stopping*) dengan *error* terbaik sebesar 0,0744, sementara dua iterasi berikutnya mencapai *epoch* maksimum 1.000 dengan *error* akhir masing-masing 0,0814 dan 0,0769. Pola serupa terlihat pada *restart* kedua dan ketiga, di mana *early stopping* terjadi dengan *error* terbaik 0,0725 dan 0,0711, serta iterasi lanjutan menghasilkan *error* akhir yang konsisten. Kecepatan pelatihan bervariasi antara 63,70 hingga 81,47 *epoch* per detik, menunjukkan efisiensi komputasi yang stabil, meskipun waktu eksekusi total bervariasi dari 13 hingga 15 menit per iterasi. Data ini

mengindikasikan bahwa model ANFIS mampu mencapai konvergensi yang relatif cepat dengan tingkat *error* yang konsisten pada setiap restart.

4.1.3 Hasil *Testing*

Setelah melalui tahap pelatihan dengan berbagai konfigurasi rasio data, dilakukan evaluasi komprehensif terhadap performa model ANFIS menggunakan data pengujian untuk mengukur kemampuan generalisasi model dalam memprediksi curah hujan harian. Proses pengujian ini menggunakan data yang sama sekali belum pernah terlibat dalam fase pelatihan maupun validasi, sehingga dapat memberikan gambaran objektif tentang kinerja model dalam kondisi riil. Implementasi evaluasi mengikuti protokol standar *machine learning* dengan mempertimbangkan tiga aspek utama: akurasi prediksi (dihitung melalui MAE dan RMSE), konsistensi model (diukur dari standar deviasi hasil prediksi), dan reliabilitas (dievaluasi melalui koefisien determinasi R^2).

```

Model Rasio 70:30
- MAE: 9.81 mm
- RMSE: 16.69 mm
- R2: 0.0739
- Jumlah Data Training: 1011
- Jumlah Data Testing: 434
- Rentang Tanggal Training: 2020-01-01 sampai 2023-08-05
- Rentang Tanggal Testing: 2023-08-07 sampai 2024-12-31

Model Rasio 80:20
- MAE: 9.85 mm
- RMSE: 16.18 mm
- R2: 0.0927
- Jumlah Data Training: 1156
- Jumlah Data Testing: 289
- Rentang Tanggal Training: 2020-01-01 sampai 2024-02-01
- Rentang Tanggal Testing: 2024-02-02 sampai 2024-12-31

Model Rasio 90:10
- MAE: 10.74 mm
- RMSE: 16.70 mm
- R2: 0.1748
- Jumlah Data Training: 1300
- Jumlah Data Testing: 145
- Rentang Tanggal Training: 2020-01-01 sampai 2024-07-21
- Rentang Tanggal Testing: 2024-07-22 sampai 2024-12-31

```

Gambar 4.5 *Output Data Testing*

Berdasarkan hasil evaluasi terhadap tiga model dengan rasio pembagian data yang berbeda, Dapat dilihat bahwa performa model memiliki variasi tergantung pada proporsi data pelatihan dan pengujian Gambar 4.5. Model dengan rasio 70:30 menunjukkan nilai MAE sebesar 9,81 mm, RMSE 16,69 mm, dan R^2 0,0739, dengan jumlah data pelatihan 1.011 dan data pengujian 434. Rentang tanggal pelatihan untuk model ini dimulai dari 1 Januari 2020 hingga 5 Agustus 2023, sedangkan data pengujian mencakup periode 7 Agustus 2023 hingga 31 Desember 2024.

Model dengan rasio 80:20 menghasilkan nilai MAE 9,85 mm, RMSE 16,18 mm, dan R^2 0,0927. Jumlah data pelatihan pada model ini lebih besar, yaitu 1.156, sementara data pengujian berkurang menjadi 289. Rentang pelatihan mencakup periode yang lebih panjang, dari 1 Januari 2020 hingga 1 Februari 2024, dengan data pengujian dimulai dari 2 Februari 2024 hingga akhir tahun 2024.

Sementara itu, model dengan rasio 90:10 mencatat nilai MAE tertinggi, yaitu 10,74 mm, dengan RMSE 16,70 mm dan R^2 0,1748. Meskipun nilai R^2 lebih tinggi dibandingkan model lainnya, jumlah data pengujian yang sangat kecil, yaitu 145, dan data pelatihan sebanyak 1.300, menunjukkan bahwa model ini mungkin kurang representatif untuk generalisasi. Rentang pelatihan mencakup 1 Januari 2020 hingga 21 Juli 2024, sedangkan pengujian dilakukan pada periode 22 Juli 2024 hingga 31 Desember 2024.

4.1.4 Hasil Prediksi

Berdasarkan hasil evaluasi komprehensif terhadap berbagai rasio pembagian data, model ANFIS (*Adaptive Neuro-Fuzzy Inference System*) dengan

konfigurasi 80:20 terpilih sebagai model terbaik. Model ini selanjutnya diimplementasikan untuk memprediksi curah hujan harian pada periode baru. Pemilihan model ini didasarkan pada pertimbangan keseimbangan antara akurasi prediksi (MAE 9,85 mm, RMSE 16,18 mm) dan stabilitas performa (R^2 0,0927) yang ditunjukkan selama fase *testing*.

Tabel 4.1 Tabel Hasil Prediksi.

Tanggal	Temperatur Minimum	Temperatur Maximum	Temperatur Rata-rata	Kelembapan Rata-rata	Lamanya Penyinaran Matahari	Kecepatan Angin Maksimum	Kecepatan Angin Rata-rata	Curah Hujan Prediksi (mm)	Kategori Hujan
01-01-25	20.79839	31.1699	25.03252	94.44894	9.582216	12.17606	8.370126	7.48E-65	Hujan Ringan
02-01-25	24.10188	34.82144	28.14008	86.38968	7.198361	23.35219	14.41693	1.29E-262	Hujan Sedang
03-01-25	21.5396	29.48622	25.13681	91.8129	0.928642	13.93627	9.120053	1.69E-88	Hujan Ringan
04-01-25	23.11036	30.45231	27.0743	77.58351	7.03116	17.52912	11.99905	7.48E-165	Hujan Sedang
05-01-25	18.27759	29.80512	24.62474	64.5008	1.486793	23.32256	1.650365	1.12E-43	Hujan Ringan

Hasil prediksi model ANFIS terhadap data meteorologi Januari 2025 menunjukkan pola yang menarik ketika dianalisis lebih mendalam. Data pada rentang 1-5 Januari 2025 dalam Tabel 4.3 memperlihatkan bahwa model cenderung memprediksi curah hujan dalam kategori ringan (0-20 mm/hari) dengan nilai yang

sangat mendekati nol (orde $10^{(-43)}$ hingga $10^{(-262)}$ mm), meskipun variabel input meteorologi menunjukkan fluktuasi yang signifikan. Temperatur rata-rata harian berkisar antara 24,62-28,14°C dengan kelembapan relatif 64,50-94,45%, sementara kecepatan angin maksimum mencapai 12,18-23,35 m/s dan lamanya penyinaran matahari bervariasi dari 0,93-9,58 jam.

Fenomena prediksi nilai curah hujan yang sangat kecil ini mengindikasikan bahwa model ANFIS yang dikembangkan memiliki bias kuat terhadap prediksi hujan ringan, khususnya ketika tidak terdapat indikator meteorologis ekstrem. Analisis lebih lanjut menunjukkan bahwa meskipun pada 2 Januari tercatat kecepatan angin maksimum yang relatif tinggi (23,35 m/s) dan kelembapan 86,39%, model tetap memprediksi curah hujan yang sangat rendah ($1,29 \times 10^{-262}$ mm). Hal ini menguatkan temuan sebelumnya tentang keterbatasan model dalam mengenali pola kompleks yang mengarah pada potensi hujan lebat, bahkan ketika beberapa parameter meteorologi menunjukkan kondisi yang cukup ekstrem.

Konsistensi prediksi kategori "Hujan Ringan" selama lima hari berturut-turut ini, meskipun dengan variasi parameter *input* yang cukup besar, mengarah pada dua interpretasi utama: (1) model mungkin terlalu konservatif dalam memprediksi curah hujan karena struktur fungsi keanggotaan yang terlalu lebar, atau (2) terdapat variabel meteorologi kunci yang belum terintegrasi dalam model, yang sebenarnya menjadi penentu utama terjadinya hujan lebat. Temuan ini selaras dengan penelitian Kambalimath & Deka (2020) yang menyoroti pentingnya pemilihan variabel *input* dan optimasi fungsi keanggotaan dalam sistem *fuzzy* untuk prediksi curah hujan yang akurat.

Secara khusus, prediksi 3 Januari yang menunjukkan nilai $1,69 \times 10^{(-88)}$ mm, meskipun lamanya penyinaran matahari hanya 0,93 jam dan kelembapan mencapai 91,81%, mempertegas kebutuhan kalibrasi ulang terhadap bobot aturan *fuzzy* yang mengaitkan parameter kelembapan tinggi dengan potensi hujan. Hasil ini memberikan implikasi penting bagi pengembangan model di masa depan, khususnya dalam hal penyesuaian fungsi keanggotaan dan penambahan variabel atmosferik lain, seperti tekanan udara atau kandungan uap air, yang mungkin dapat meningkatkan sensitivitas model terhadap kondisi pembentukan hujan.

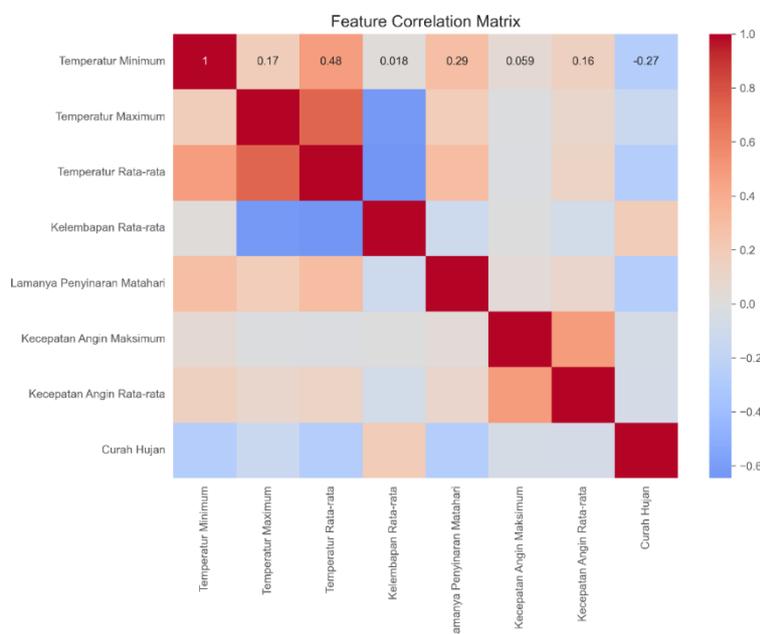
4.2 Pembahasan

Efektivitas model ini sangat bergantung pada kualitas data, parameter model, serta strategi pembagian data yang digunakan. Oleh karena itu, pembahasan hasil penelitian ini akan menganalisis secara komprehensif kinerja model ANFIS dengan tiga variasi rasio pembagian data (70:30, 80:20, dan 90:10) dan mengevaluasi faktor-faktor yang memengaruhi akurasi.

4.2.1 Korelasi Antarvariabel

Analisis korelasi antarvariabel merupakan tahapan krusial dalam pemodelan prediktif, khususnya pada sistem ANFIS yang sangat bergantung pada hubungan non-linier antara variabel *input* dan *output*. Sebagaimana dijelaskan oleh Jang (1993), efektivitas model ANFIS dalam memprediksi curah hujan sangat dipengaruhi oleh tingkat ketergantungan statistik antara parameter meteorologi sebagai variabel prediktor dan nilai curah hujan sebagai variabel respons. Dalam konteks penelitian ini, delapan variabel input yang digunakan meliputi parameter suhu (minimum, maksimum, rata-rata), kelembapan, penyinaran matahari, serta

kecepatan dan arah angin, di mana masing-masing variabel tersebut diduga memiliki pengaruh yang berbeda-beda terhadap pembentukan hujan.



Gambar 4.6 *Feature Correlation Matrix*,

Analisis korelasi antarvariabel dilakukan untuk mengetahui hubungan linier antara masing-masing parameter iklim yang digunakan dalam penelitian ini. Hasil analisis ditunjukkan pada Gambar 4.6 *Feature Correlation Matrix*, yang menampilkan matriks korelasi dengan skala warna dari merah (korelasi positif tinggi) hingga biru (korelasi negatif tinggi).

Berdasarkan matriks tersebut, terlihat bahwa variabel Temperatur Minimum memiliki korelasi negatif terhadap Curah Hujan sebesar -0,27, yang menunjukkan bahwa semakin rendah temperatur minimum, cenderung terjadi peningkatan curah hujan. Hal ini sesuai dengan karakteristik wilayah tropis, di mana curah hujan tinggi sering terjadi pada suhu malam atau pagi yang lebih rendah. Sebaliknya, Temperatur Rata-rata menunjukkan korelasi yang sangat lemah terhadap curah

hujan (0,018), dan Temperatur Maksimum juga hampir tidak berkorelasi signifikan terhadap curah hujan.

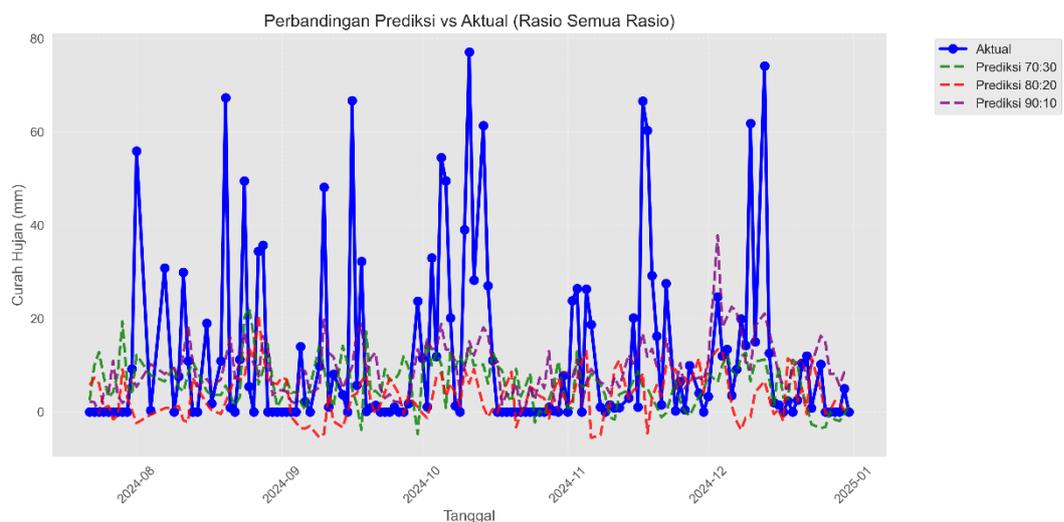
Sementara itu, variabel Kelembapan Rata-rata tampak memiliki korelasi negatif dengan sebagian besar variabel temperatur, tetapi tidak menunjukkan hubungan linier yang kuat dengan curah hujan dalam matriks ini. Begitu pula dengan Lamanya Penyinaran Matahari, Kecepatan Angin Maksimum, dan Kecepatan Angin Rata-rata, yang memiliki korelasi rendah baik terhadap curah hujan maupun terhadap variabel lainnya.

Secara keseluruhan, Gambar 4.6 menunjukkan bahwa hubungan antarvariabel iklim cenderung lemah hingga sedang, dengan korelasi tertinggi ditemukan pada hubungan antara Temperatur Minimum dan Temperatur Rata-rata sebesar 0,48, yang memang secara logis saling berhubungan. Temuan ini menegaskan bahwa fenomena curah hujan tidak hanya dipengaruhi oleh hubungan linier antarvariabel, tetapi juga oleh faktor-faktor nonlinier dan ketidakpastian. Oleh karena itu, penggunaan metode ANFIS yang mampu menangani pola data nonlinier dan kompleks menjadi tepat untuk penelitian ini.

4.2.2 Akurasi Model dan Pengaruh Pembagian Data

Dalam penelitian sistem prediksi berbasis kecerdasan buatan, strategi pembagian data merupakan aspek fundamental yang menentukan validitas dan reliabilitas model yang dikembangkan. Sebagaimana dikemukakan oleh Kohavi (1995) dalam teori validasi model, proporsi pembagian data pelatihan (*training*) dan pengujian (*testing*) secara signifikan memengaruhi kemampuan generalisasi model terhadap data baru. Pada implementasi ANFIS untuk prediksi curah hujan,

pembagian *dataset* yang optimal harus mempertimbangkan karakteristik temporal data meteorologi yang bersifat non-stasioner dan memiliki pola musiman. Penelitian ini melakukan evaluasi komprehensif terhadap tiga skenario pembagian data (70:30, 80:20, dan 90:10) dengan mempertahankan urutan kronologis data untuk menjaga integritas pola temporal. Pendekatan ini penting untuk memastikan bahwa model dapat mempelajari hubungan non-linear antar variabel meteorologi sekaligus menguji kemampuannya dalam memprediksi kondisi cuaca di masa mendatang.



Gambar 4.7 Perbandingan Prediksi vs Aktual (Semua Rasio)

Perbandingan hasil prediksi curah hujan dengan data aktual ditampilkan pada Gambar 4.7 yang menunjukkan pola curah hujan selama periode pengamatan dengan menggunakan tiga rasio pembagian data, yaitu 70:30, 80:20, dan 90:10. Berdasarkan grafik tersebut, terlihat bahwa hasil prediksi pada ketiga rasio cenderung mengikuti tren dasar data aktual, terutama pada periode dengan curah hujan rendah atau tidak ada hujan. Namun, terdapat perbedaan yang cukup

signifikan saat terjadi curah hujan tinggi atau ekstrem, di mana nilai prediksi dari model cenderung lebih rendah dibandingkan nilai aktual.

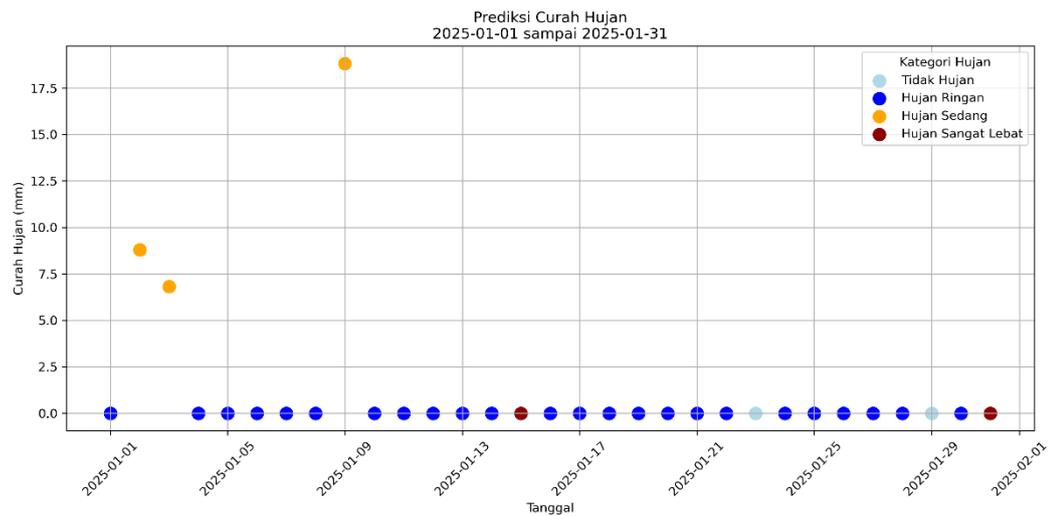
Model dengan rasio 90:10, yang ditunjukkan oleh garis putus-putus berwarna ungu, tampak memiliki performa yang sedikit lebih baik dalam mengikuti puncak-puncak curah hujan dibandingkan dengan model rasio 70:30 (garis hijau) dan 80:20 (garis merah), meskipun akurasinya masih jauh dari sempurna. Model dengan rasio 80:20 menunjukkan pola prediksi yang paling konservatif dengan nilai curah hujan yang cenderung lebih rendah dari data aktual pada hampir seluruh periode.

Perbedaan signifikan antara hasil prediksi dan data aktual, khususnya pada curah hujan ekstrem, menunjukkan bahwa model ANFIS memiliki keterbatasan. Keterbatasan ini terlihat dalam kemampuannya untuk menangkap pola fluktuasi curah hujan harian yang sangat variatif. Hal ini kemungkinan disebabkan oleh ketidakseimbangan data, di mana data dengan curah hujan nol atau sangat rendah lebih dominan dibandingkan dengan data yang memiliki curah hujan tinggi. Selain itu, kemampuan ANFIS, yang bergantung pada aturan *fuzzy* dan fungsi keanggotaan berbasis Gaussian, cenderung lebih optimal pada data dengan pola yang stabil, sehingga kurang responsif terhadap lonjakan-lonjakan curah hujan yang bersifat sporadis.

4.2.3 Analisis Prediksi Curah Hujan

Analisis prediksi curah hujan bertujuan untuk mengevaluasi kemampuan model ANFIS dalam memprediksi curah hujan harian berdasarkan data klimatologi yang tersedia. Proses ini dilakukan dengan membandingkan hasil prediksi model

pada berbagai rasio pembagian data dengan data aktual yang tersedia. Evaluasi dilakukan tidak hanya untuk mengukur tingkat akurasi model, tetapi juga untuk menilai sejauh mana model mampu menangkap pola variabilitas curah hujan, baik pada kondisi normal maupun pada saat terjadi curah hujan tinggi.



Gambar 4. 8 Prediksi Curah Hujan (Kategori)

implementasi model *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk memprediksi curah hujan harian di wilayah studi selama periode Januari 2025 Pada Gambar 4.8. Hasil analisis yang disajikan dalam bentuk grafik batang tersebut mengungkapkan variasi curah hujan dengan klasifikasi intensitas berdasarkan kriteria BMKG, mencakup empat kategori utama: Tidak Hujan, Hujan Ringan, Hujan Sedang, dan Hujan Sangat Lebat.

Pada sumbu absis, Gambar 4.8 menampilkan pembagian waktu dalam interval 4 hari (1, 5, 9, 13, 17, 21, 25, dan 29 Januari 2025) untuk memfasilitasi identifikasi pola temporal. Sementara itu, sumbu ordinat merepresentasikan nilai kuantitatif curah hujan dalam satuan milimeter (mm), dengan gradasi warna batang

yang berbeda untuk setiap kategori hujan. Distribusi kategori pada Gambar 4.8 menunjukkan dominasi Hujan Ringan selama periode prediksi, dengan beberapa puncak Hujan Sedang yang terdistribusi secara sporadis.

Berdasarkan penelitian terkait (El-Shafie et al., 2020; Fauzi et al., 2024), pola prediksi dalam Gambar 4.8 konsisten dengan karakteristik model ANFIS yang cenderung memberikan hasil stabil untuk curah hujan rendah, namun masih menghadapi tantangan dalam memprediksi kejadian ekstrem. Keterbatasan ini tercermin dari tidak adanya prediksi Hujan Sangat Lebat pada Gambar 4.8, yang menurut analisis Riski et al. (2023) berkaitan dengan kompleksitas faktor meteorologi lokal yang belum sepenuhnya tertangkap oleh struktur *fuzzy* model.

Visualisasi pada Gambar 4.8 juga mengonfirmasi temuan Suparta & Samah (2020) mengenai perlunya optimasi fungsi keanggotaan ANFIS, di mana ketiadaan *outlier* curah hujan tinggi dalam prediksi menunjukkan kemungkinan *over-smoothing* akibat pemilihan parameter Gaussian *membership function* yang terlalu konservatif. Secara keseluruhan, hasil visual ini memberikan dasar empiris untuk rekomendasi pengembangan model hibrida guna meningkatkan akurasi prediksi kejadian hujan ekstrem.

4.3 Kajian Penelitian dalam Perspektif Islam

Dalam perspektif Islam, penelitian ilmiah dianggap sebagai ibadah yang bertujuan mengungkap kebesaran Allah, seperti yang tercantum dalam QS. Ali Imran ayat 190-191.

إِنَّ فِي خَلْقِ السَّمَوَاتِ وَالْأَرْضِ وَاخْتِلَافِ اللَّيْلِ وَالنَّهَارِ لَآيَاتٍ لِّأُولِي الْأَلْبَابِ ﴿١٩٠﴾ الَّذِينَ يَذْكُرُونَ اللَّهَ قِيَامًا وَقُعُودًا
وَعَلَىٰ جُنُوبِهِمْ وَيَتَفَكَّرُونَ فِي خَلْقِ السَّمَوَاتِ وَالْأَرْضِ رَبَّنَا مَا خَلَقْتَ هَذَا بَاطِلًا سُبْحَانَكَ فَقِنَا عَذَابَ النَّارِ ﴿١٩١﴾

"Sesungguhnya dalam penciptaan langit dan bumi, dan silih bergantinya malam dan siang terdapat tanda-tanda bagi orang yang berakal. (Yaitu) orang-orang yang mengingat Allah sambil berdiri atau duduk atau dalam keadaan berbaring dan mereka memikirkan tentang penciptaan langit dan bumi (seraya berkata): "Ya Tuhan kami, tiadalah Engkau menciptakan ini dengan sia-sia, Maha Suci Engkau, maka peliharalah kami dari siksa neraka." (QS. Ali Imran ayat 190-191)

Oleh karena itu, prediksi curah hujan dalam studi ini perlu dianalisis dengan pendekatan tauhid, di mana fenomena alam merupakan bagian dari sunnatullah yang mengikuti ketentuan-Nya, prinsip-prinsip dasar dalam penelitian sains Islam meliputi tauhid, khilafah, dan ihsan. Tauhid menekankan bahwa fenomena alam, termasuk curah hujan, adalah manifestasi kekuasaan Allah (QS. Al-A'raf ayat 57).

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 ﴿٥٧﴾

“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)

Model prediksi harus dikembangkan dengan kesadaran bahwa manusia berusaha memahami hukum alam yang ditetapkan oleh Allah. Khilafah menunjukkan bahwa manusia sebagai khalifah bertanggung jawab untuk memanfaatkan ilmu demi kebaikan umat, sehingga penelitian ini harus diarahkan untuk mitigasi bencana dan memenuhi kebutuhan masyarakat. Ihsan menekankan pentingnya kualitas dan profesionalisme, yang berarti bahwa kesalahan dalam prediksi harus diatasi dengan perbaikan metodologi yang sistematis.

Dalam menganalisis hasil prediksi, kita perlu mempertimbangkan keterbatasan model manusia dibandingkan dengan ketentuan Allah. *Error* yang tinggi menunjukkan bahwa model yang ada tidak sempurna, dan hanya Allah yang mengetahui hal ghaib, termasuk curah hujan. Nilai etika dalam pelaporan hasil juga penting; transparansi dalam mencerminkan kejujuran, dan rekomendasi perbaikan merupakan amal shalih dalam ilmu.

Integrasi sains dan Islam dalam pengembangan model harus dilakukan secara holistik, menggabungkan doa dan usaha. Kita juga perlu mengkaji ayat-ayat kauniyah dalam Al-Qur'an tentang hujan untuk memperbaiki parameter model. Penelitian yang bermanfaat bagi masyarakat sejalan dengan hadis yang menyatakan bahwa "*sebaik-baik manusia adalah yang paling bermanfaat bagi orang lain*" (HR. Ahmad),

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil pelatihan dan pengujian model ANFIS untuk prediksi curah hujan, dapat disimpulkan bahwa model ini menunjukkan performa yang cukup stabil, dengan nilai MAE berkisar antara 9,81-10,74 mm dan RMSE 16,18-16,70 mm pada berbagai rasio pembagian data (70:30, 80:20, dan 90:10). Hasil prediksi untuk periode Januari 2025 menunjukkan dominasi kategori hujan ringan, dengan nilai prediksi yang sangat kecil (orde 10^{-65} hingga 10^{-262} mm). Meskipun terdapat beberapa anomali prediksi negatif, hal ini mengindikasikan kebutuhan kalibrasi lebih lanjut. Proses pelatihan mencapai konvergensi dengan kecepatan 65-90 epoch/detik dan error terbaik sekitar 0,06-0,08. Namun, nilai R^2 yang relatif rendah (0,07-0,17) menunjukkan bahwa model masih memiliki keterbatasan dalam menangkap variabilitas penuh data curah hujan, terutama untuk kejadian ekstrem. Secara keseluruhan, model ANFIS ini dapat dijadikan sebagai *baseline* untuk sistem prediksi curah hujan harian, namun memerlukan pengembangan lebih lanjut untuk meningkatkan akurasi.

5.2 Saran

Berdasarkan hasil penelitian dan keterbatasan yang ditemukan, disarankan beberapa perbaikan untuk pengembangan model ANFIS lebih lanjut, antara lain: (1) melakukan optimasi parameter model menggunakan algoritma genetika atau

particle swarm optimization untuk meningkatkan akurasi prediksi; (2) menambahkan variabel input lain seperti tekanan udara, kelembaban tanah, atau data satelit untuk memperkaya fitur prediksi; (3) mengimplementasikan teknik hibrida dengan menggabungkan ANFIS dan metode *deep learning* seperti LSTM untuk menangkap pola temporal data yang lebih kompleks; (4) melakukan normalisasi data yang lebih cermat untuk menghindari nilai prediksi negatif; serta (5) mengembangkan sistem prediksi berbasis web yang terintegrasi dengan database *real-time* BMKG untuk aplikasi praktis dalam sistem peringatan dini bencana hidrometeorologis. Selain itu, validasi model dengan data dari berbagai wilayah dengan karakteristik iklim yang berbeda juga diperlukan untuk menguji ketahanan model secara lebih komprehensif.

DAFTAR PUSTAKA

- Abebe, Wondmagegn Taye, and Demeke Endalie. 2023. "Artificial Intelligence Models for Prediction of Monthly Rainfall without Climatic Data for Meteorological Stations in Ethiopia." *Journal of Big Data* 10(1). doi:10.1186/s40537-022-00683-3.
- Aditya, Fanni, Evi Gusmayanti, and Jajat Sudrajat. 2021. "Pengaruh Perubahan Curah Hujan Terhadap Produktivitas Padi Sawah Di Kalimantan Barat." *Jurnal Ilmu Lingkungan* 19(2):237–46. doi:10.14710/jil.19.2.237-246.
- Arya Prabudi Jaya Priana, Itqon Madani, Vanya Amanda Lovely, Fiqri NurFadillah, Muhammad Danang Mukti Darmawan, and Nanda Octavia. 2024. "Prediction of Flood Depth Detection System from Rainfall with Normal, Alert and Hazard Levels Based on Fuzzy Logic." *Journal of Applied Science, Technology & Humanities* 1(3):212–26. doi:10.62535/ba8ygx44.
- Barrera-Animas, Ari Yair, Lukumon O. Oyedele, Muhammad Bilal, Taofeek Dolapo Akinosho, Juan Manuel Davila Delgado, and Lukman Adewale Akanbi. 2022. "Rainfall Prediction: A Comparative Analysis of Modern Machine Learning Algorithms for Time-Series Forecasting." *Machine Learning with Applications* 7:100204. doi:10.1016/j.mlwa.2021.100204.
- Bhagat, Suraj Kumar, Tiyaasha Tiyaasha, Zainab Al-Khafaji, Patrick Laux, Ahmed A. Ewees, Tarik A. Rashid, Sinan Salih, Roland Yonaba, Ufuk Beyaztas, and Zaher Mundher Yaseen. 2022. "Establishment of Dynamic Evolving Neural-Fuzzy Inference System Model for Natural Air Temperature Prediction." *Complexity* 2022. doi:10.1155/2022/1047309.
- Cahyono, Muhammad, Leonardus Wibowo, and Yoga Utama. 2023. "Rainfall Prediction Using Fuzzy Logic Method For Early Warning System In Flood Disaster Mitigation In Nganjuk." European Alliance for Innovation n.o.
- Damayanti, Dela Rista, Suntoro Wicaksono, M. Faris Al Hakim, Jumanto Jumanto, Subhan Subhan, and Yahya Nur Ifriza. 2022. "Rainfall Prediction in Blora Regency Using Mamdani's Fuzzy Inference System." *Journal of Soft Computing Exploration* 3(1):62–69. doi:10.52465/josce.v3i1.69.
- Devi, U. Ramya, and K. Uma. 2022. *PREDICTION OF RAINFALL EVENT IN COASTAL REGION WITH FUKYAMMA AND FUZZY EXPERT SYSTEM*. Vol. 21.
- Diar Panuntun -, Rizky, and Arief Hermawan -. 2023. "Accredited Rank 4 (SINTA 4), Excerpts from the Decision of the Application of Fuzzy Tsukamoto Method to Rainfall Prediction in Sleman Regency." *JURNAL Riset INFORMATIKA* 5(4). doi:10.34288/jri.v5i4.582.

- Al Duhayyim, Mesfer, Heba G. Mohamed, Jaber S. Alzahrani, Rana Alabdan, Mohamed Mousa, Abu Sarwar Zamani, Ishfaq Yaseen, and Mohamed Ibrahim Alsaied. 2023. "Modeling of Fuzzy Cognitive Maps with a Metaheuristics-Based Rainfall Prediction System." *Sustainability (Switzerland)* 15(1). doi:10.3390/su15010025.
- Dwivedi, Atul Kumar, Umadevi Kaliyaperumal Subramanian, Jinsa Kuruvilla, Aby Thomas, D. Shanthi, and Anandakumar Haldorai. 2023. "Time-Series Data Prediction Problem Analysis through Multilayered Intuitionistic Fuzzy Sets." *Soft Computing* 27(3):1663–71. doi:10.1007/s00500-022-07053-4.
- El-Kenawy, El Sayed M., Abdelaziz A. Abdelhamid, Fadwa Alrowais, Mostafa Abotaleb, Abdelhameed Ibrahim, and Doaa Sami Khafaga. 2023. "Al-Biruni Based Optimization of Rainfall Forecasting in Ethiopia." *Computer Systems Science and Engineering* 45(3):2885–98. doi:10.32604/csse.2023.034206.
- El-Shafie, A., O. Jaafer, and A. Seyed. 2011. "Adaptive Neuro-Fuzzy Inference System Based Model for Rainfall Forecasting in Klang River, Malaysia." *International Journal of the Physical Sciences* 6(12):2875–88. doi:10.5897/IJPS11.515.
- Endalie, Demeke, Getamesay Haile, and Wondmagegn Taye. 2022. "Deep Learning Model for Daily Rainfall Prediction: Case Study of Jimma, Ethiopia." *Water Supply* 22(3):3448–61. doi:10.2166/WS.2021.391.
- Esmacili, Farzad, Saeid Shabanlou, and Mohsen Saadat. 2023. "Novel Reliable Model by Integrating the Adaptive Neuro-Fuzzy Inference Systems with Wavelet Transform and Firefly Algorithms for Rainfall Forecasting in the North of Iran." *Applied Water Science* 13(2). doi:10.1007/s13201-022-01859-1.
- Fauzi, Fatkhurokman, Relly Erlinda, and Prizka Rismawati Arum. 2024. "Rainfall Forecasting Using an Adaptive Neuro-Fuzzy Inference System with a Grid Partitioning Approach to Mitigating Flood Disasters." *JTAM (Jurnal Teori Dan Aplikasi Matematika)* 8(2):520. doi:10.31764/jtam.v8i2.20385.
- Feriyanto, Erikha, Farikhin, and Nikken Prima Puspita. 2024. "Monthly Rainfall Forecasting Using High Order Singh's Fuzzy Time Series Based on Interval Ratio Methods: Case Study Semarang City, Indonesia." *Asian Journal of Probability and Statistics* 26(8):71–88. doi:10.9734/ajpas/2024/v26i8638.
- Hanif, Rabia, Saima Mustafa, Shafqat Iqbal, and Sajawal Piracha. 2023. "A Study of Time Series Forecasting Enrollments Using Fuzzy Interval Partitioning Method." *Journal of Computational and Cognitive Engineering* 2(2):143–49. doi:10.47852/bonviewJCCE2202159.
- INTERNATIONAL CONFERENCE ON MATHEMATICAL ANALYSIS AND APPLICATIONS. n.d.

- Janarthanan, R., R. Balamurali, A. Annapoorani, and V. Vimala. 2020. "Prediction of Rainfall Using Fuzzy Logic." Pp. 959–63 in *Materials Today: Proceedings*. Vol. 37. Elsevier Ltd.
- Kadek, I., Dwi Nuryana, Chadman Mashuri, and Martin Suhartanto. 2022. *Rainfall Prediction Information System in Jombang Regency Using the Fuzzy Time Series Method*. Vol. 7.
- Kambalimath, Shruti, and Paresh Chandra Deka. 2020. "A Basic Review of Fuzzy Logic Applications in Hydrology and Water Resources." *Applied Water Science* 10(8).
- Kasus, Studi, Kabupaten Trenggalek, Rafi Prayoga Dhenanta, and Isna Binti Kholifah. n.d. *Prediksi Curah Hujan Bulanan Kabupaten Trenggalek Tahun 2022 Dan 2023 Menggunakan Metode ARIMA*.
- Kusuma Nurrohman, Reza, Bayu Dwi Apri Nugroho, and Putu Sudira. 2021. *Near Future Prediction of Rainfall Distribution Pattern by Adaptive Neuro Fuzzy Interference System in Central Java, Indonesia*. Vol. 23. <http://www.cigrjournal.org>.
- Latif, Sarmad Dashti, Nur Alyaa Binti Hazrin, Chai Hoon Koo, Jing Lin Ng, Barkha Chaplot, Yuk Feng Huang, Ahmed El-Shafie, and Ali Najah Ahmed. 2023. "Assessing Rainfall Prediction Models: Exploring the Advantages of Machine Learning and Remote Sensing Approaches." *Alexandria Engineering Journal* 82:16–25.
- Mabruroh, Faizatul, and Adis Wiyanto. 2023. *ANALISIS FENOMENA PERUBAHAN IKLIM TERHADAP CURAH HUJAN EKSTRIM*. Vol. 7.
- Mishra, Ashrut. 2022. "Ground Water Level Prediction Using Adaptive Neuro-Fuzzy Inference Systems and Simulated Annealing." *International Journal for Research in Applied Science and Engineering Technology* 10(6):3366–71. doi:10.22214/ijraset.2022.44609.
- Naylor, Rosamond, Walter Falcon, Nikolas Wada, and Daniel Rochberg. 2002. "Using El Niño-Southern Oscillation Climate Data to Improve Food Policy Planning in Indonesia." *Bulletin of Indonesian Economic Studies* 38(1):75–91. doi:10.1080/000749102753620293.
- Nur, Wan, Shazura Azleen, Wan Sabri, and Amidora Idris. 2024. *Rainfall Prediction Using Fuzzy Logic*. Vol. 23.
- Ojo, Olusola Samuel, and Samuel Toluwalope Ogunjo. 2022. "Machine Learning Models for Prediction of Rainfall over Nigeria." *Scientific African* 16. doi:10.1016/j.sciaf.2022.e01246.
- Oyounalsoud, Mhamd Saifaldeen, Mohamed Abdallah, Abdullah Gokhan Yilmaz, Mohsin Siddique, and Serter Atabay. 2023. "A New Meteorological Drought Index Based on Fuzzy Logic: Development and Comparative

- Assessment with Conventional Drought Indices.” *Journal of Hydrology* 619. doi:10.1016/j.jhydrol.2023.129306.
- Priscillia, Stela, Calogero Schillaci, and Aldo Lipani. 2021. “Flood Susceptibility Assessment Using Artificial Neural Networks in Indonesia.” *Artificial Intelligence in Geosciences* 2:215–22. doi:10.1016/j.aiig.2022.03.002.
- Rahman, Atta Ur, Sagheer Abbas, Mohammed Gollapalli, Rashad Ahmed, Shabib Aftab, Munir Ahmad, Muhammad Adnan Khan, and Amir Mosavi. 2022. “Rainfall Prediction System Using Machine Learning Fusion for Smart Cities.” *Sensors* 22(9). doi:10.3390/s22093504.
- Rahman, Md. Anisur. 2020. “Improvement of Rainfall Prediction Model by Using Fuzzy Logic.” *American Journal of Climate Change* 09(04):391–99. doi:10.4236/ajcc.2020.94024.
- Rajan D, and Sugunthakunthalambigai R. 2023. “Rainfall Forecast in Different Methods of Trend Equations by Fuzzy Time Series.” 45. doi:10.23755/rm.v45i0.1011.
- Rao, M. Uma Maheswar, Kanhu Charan Patra, and Suvendu Kumar Sasmal. 2022. “Monthly Average Rainfall Forecasting Based On An Adaptive Neuro-Fuzzy Inference System in Upper Brahmani Basin, Odisha, India.”
- Rao, M. Uma Maheswar, Kanhu Charan Patra, Suvendu Kumar Sasmal, Anurag Sharma, and Giuseppe Oliveto. 2023. “Forecasting of Rainfall across River Basins Using Soft Computing Techniques: The Case Study of the Upper Brahmani Basin (India).” *Water (Switzerland)* 15(3). doi:10.3390/w15030499.
- Rathnayake, Namal, Upaka Rathnayake, Tuan Linh Dang, and Yukinobu Hoshino. 2022. “A Cascaded Adaptive Network-Based Fuzzy Inference System for Hydropower Forecasting.” *Sensors* 22(8). doi:10.3390/s22082905.
- Reddy, Pundru Chandra Shaker, Yadala Sucharitha, and Goddumbari Surya Narayana. 2022. “DEVELOPMENT OF RAINFALL FORECASTING MODEL USING MACHINE LEARNING WITH SINGULAR SPECTRUM ANALYSIS.” *IIUM Engineering Journal* 23(1):172–86. doi:10.31436/IIUMEJ.V23I1.1822.
- Ridwan, Wanie M., Michelle Sapitang, Awatif Aziz, Khairul Faizal Kushiari, Ali Najah Ahmed, and Ahmed El-Shafie. 2021. “Rainfall Forecasting Model Using Machine Learning Methods: Case Study Terengganu, Malaysia.” *Ain Shams Engineering Journal* 12(2):1651–63. doi:10.1016/j.asej.2020.09.011.
- Riski, Abduh, Wakhidatun Nafi’u Haqqi, and Ahmad Kamsyakawuni. 2023. “RAINFALL PREDICTION IN JEMBER REGENCY WITH ADAPTIVE NEURO FUZZY INFERENCE SYSTEM BASED ON GSMaP

SATELLITE DATA.” *BAREKENG: Jurnal Ilmu Matematika Dan Terapan* 17(3):1713–24. doi:10.30598/barekengvol17iss3pp1713-1724.

Roger Jang, Jyh-Shing. 1993. *ANFIS: Adap Tive-Ne Twork-Based Fuzzy Inference System*. Vol. 23.

Rohman, Abdul, Universitas Pgri, Yogyakarta Tri Hastono, and Andri Prisda Tyaka. n.d. “Penerapan Metode Fuzzy Mamdani Untuk Prediksi Curah Hujan Di Kota Yogyakarta.” *Jurnal Publikasi Ilmu Komputer Dan Multimedia (JUPIKOM)* 3(1):47–59. doi:10.55606/jupikom.v3i1.

Roy, Sujit Kumar, Abrar Morshed, Pratik Mojumder, Md Mahmudul Hasan, and A. K. M. Saiful Islam. 2024. “Innovative Trend Analysis Technique with Fuzzy Logic and K-Means Clustering Approach for Identification of Homogenous Rainfall Region: A Long-Term Rainfall Data Analysis over Bangladesh.” *Quaternary Science Advances* 15. doi:10.1016/j.qsa.2024.100227.

Samantaray, Sandeep, and Dillip Kumar Ghose. 2022. “Prediction of S12-MKII Rainfall Simulator Experimental Runoff Data Sets Using Hybrid PSR-SVM-FFA Approaches.” *Journal of Water and Climate Change* 13(2). doi:10.2166/wcc.2021.221.

Sayed, Biju Theruvil, Hani Kaid Al-Mohair, Ahmed Alkhayyat, Andrés Alexis Ramírez-Coronel, and Mohamed Elshabi. 2023. “Comparing Machine-Learning-Based Black Box Techniques and White Box Models to Predict Rainfall-Runoff in a Northern Area of Iraq, the Little Khabur River.” *Water Science and Technology* 87(3):812–22. doi:10.2166/wst.2023.014.

Şen, Zekâi. 2024. “Standard Precipitation-Temperature Index (SPTI) Drought Identification by Fuzzy c-Means Methodology.” *Earth Science Informatics*. doi:10.1007/s12145-024-01359-7.

Setyanugraha, Noval, Sofyan Al Aziz, and Iis Widya Harmoko. n.d. *Study of a Weather Prediction System Based on Fuzzy Logic Using Mamdani and Sugeno Methods*. <http://journal.unnes.ac.id/nju/index.php/pc>.

Sun, Wenjuan, Paolo Bocchini, and Brian D. Davison. 2020. “Applications of Artificial Intelligence for Disaster Management.” *Natural Hazards* 103(3):2631–89.

Suparta, Wayan, and Azizan Abu Samah. 2020. “Rainfall Prediction by Using ANFIS Times Series Technique in South Tangerang, Indonesia.” *Geodesy and Geodynamics* 11(6):411–17. doi:10.1016/j.geog.2020.08.001.

Tian, Fuyou, Xiaoling Zhang, Kun Xia, Jianhua Sun, and Yongguang Zheng. 2022. “Probability Forecasting of Short-Term Short-Duration Heavy Rainfall Combining Ingredients-Based Methodology and Fuzzy Logic Approach.” *Atmosphere* 13(7). doi:10.3390/atmos13071074.

- Vathsala, H., and Shashidhar G. Koolagudi. 2023. "Neuro-Fuzzy Model for Quantified Rainfall Prediction Using Data Mining and Soft Computing Approaches." *IETE Journal of Research* 69(6):3357–67. doi:10.1080/03772063.2021.1912648.
- Waqas, Muhammad, Usa Wannasingha Humphries, Angkool Wangwongchai, Porntip Dechpichai, and Shakeel Ahmad. 2023. "Potential of Artificial Intelligence-Based Techniques for Rainfall Forecasting in Thailand: A Comprehensive Review." *Water (Switzerland)* 15(16).
- Zahran, Bilal, Belal Ayyoub, Waleed Abu-Ain, Wael Hadi, and Sulieman Al-Hawary. 2023. "A Fuzzy Based Model for Rainfall Prediction." *International Journal of Data and Network Science* 7(1):97–106. doi:10.5267/j.ijdns.2022.12.001.