

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Yang Relevan

Dari Sejumlah Sumber Yang ditelaah Melalui metode *Systematic Literature Review* (SLR) terhadap berbagai artikel ilmiah bereputasi, teridentifikasi sejumlah penelitian yang relevan dengan penerapan Deep Learning, Khususnya Arsitektur *Long Short-Term Memory* (LSTM), dalam analisis dan klasifikasi cuaca ekstrem. Salah satu penelitian yang sangat relevan adalah karya (Parameters et al., 2019) yang berjudul *Prediksi Parameter cuaca menggunakan Deep Learning Long Short-Term Memory* (LSTM), yang berfokus pada pengembangan model LSTM untuk Memprediksi parameter cuaca menggunakan data historis BMKG berbentuk deret waktu, meliputi suhu udara, kelembapan udara, tekanan udara, dan kecepatan angin. Hasil penelitian menunjukkan bahwa penelitian menunjukkan bahwa LSTM mampu menghasilkan akurasi yang lebih baik dibandingkan metode statistik konvensional seperti ARIMA maupun jaringan saraf tiruan dasar dalam menangkap pola temporal yang kompleks. Kesamaan penelitian ini dengan penelitian penulis terletak pada penggunaan model LSTM dan data cuaca *time series*, sedangkan perbedaannya terletak pada tujuan penelitian, di mana Eko Supriyadi menitikberatkan pada prediksi kuantitatif parameter cuaca, sementara penelitian penulis berfokus pada klasifikasi kondisi cuaca ekstrem.

Penelitian lain yang juga menggunakan pendekatan LSTM dilakukan oleh. (Firdaus & Paputungan, 2022) dalam jurnal JUPIN berjudul *Prediksi Curah Hujan Menggunakan Metode Long Short-Term Memory* mengkaji kemampuan model LSTM dalam memprediksi curah hujan harian berbasis data deret waktu. Penelitian ini menunjukkan bahwa LSTM mampu memodelkan pola non-linear pada data curah hujan dengan performa yang lebih baik dibandingkan metode konvensional. Relevansi penelitian ini dengan penelitian penulis terletak pada penggunaan arsitektur LSTM dan karakteristik data meteorologi berbasis *time series*. Perbedaannya adalah penelitian Firdaus et al. berfokus pada peramalan curah hujan, sedangkan penelitian penulis menggunakan LSTM untuk mengklasifikasikan kejadian cuaca ekstrem.

Penelitian Selanjutnya (Siregar et al., 2020) berjudul *Klasifikasi untuk Prediksi Cuaca Menggunakan Ensemble Learning Menggunakan Ensemble Learning* membahas

penerapan beberapa algoritma *machine learning* seperti Decision Tree, Naïve Bayes, dan Random Forest dalam mengklasifikasikan kondisi cuaca menjadi hujan dan tidak hujan. Data yang digunakan berasal dari pengamatan BMKG dengan variabel suhu udara, kelembapan, tekanan udara, kecepatan angin, dan curah hujan. Hasil penelitian menunjukkan bahwa Random Forest memberikan tingkat akurasi tertinggi dibandingkan algoritma lainnya. Penelitian ini relevan sebagai pembandingan metode, karena sama-sama bertujuan melakukan klasifikasi cuaca, namun berbeda pendekatan. Penelitian Siregar menggunakan *ensemble learning* klasik, sedangkan penelitian penulis menggunakan pendekatan *Deep Learning* berbasis LSTM.

menerapkan hasil definisi ekstrem tersebut dalam sistem klasifikasi berbasis *Deep Learning*.

Penelitian dari (J. K. Putri, 2024) berjudul *Perbandingan Model ARIMA dan Recurrent Neural Network (RNN) untuk Peramalan Cuaca Ekstrem* memberikan wawasan terkait perbandingan metode statistik dan jaringan saraf dalam analisis data cuaca ekstrem. Penelitian ini menunjukkan bahwa model RNN memiliki performa yang lebih baik dibandingkan ARIMA dalam menangani data curah hujan ekstrem yang bersifat non-linear dan fluktuatif, sehingga memperkuat argumen bahwa pendekatan *Deep Learning*, termasuk LSTM, lebih unggul untuk data klimatologi deret waktu. Kesamaan dengan penelitian penulis terletak pada penggunaan data *time series* cuaca, sementara perbedaannya adalah fokus penelitian Jambura pada peramalan kuantitatif, sedangkan penelitian penulis menitikberatkan pada klasifikasi kejadian ekstrem.

Penelitian oleh (Adrianti et al., 2024) berjudul *Analisis Indeks Iklim Ekstrem di Indonesia* menggunakan pendekatan indeks ETCCDI untuk menganalisis kejadian iklim ekstrem, seperti hari kering berturut-turut (CDD), hari basah berturut-turut (CWD), curah hujan ekstrem (R95p), dan curah hujan maksimum harian (RX1day). Hasil penelitian menunjukkan adanya peningkatan kejadian cuaca ekstrem di beberapa wilayah Indonesia. Penelitian ini sangat relevan karena menyediakan kerangka konseptual dan metodologis dalam mendefinisikan cuaca ekstrem, yang kemudian dimanfaatkan oleh penulis sebagai dasar penentuan label dalam sistem klasifikasi cuaca ekstrem berbasis *Deep Learning*.

Menurut Badan Meteorologi, Klimatologi, dan Geofisika (BMKG), cuaca ekstrem merupakan kondisi cuaca yang tidak normal atau tidak lazim yang berpotensi

menimbulkan kerugian terhadap keselamatan jiwa maupun harta benda. Definisi ini mengacu pada Peraturan Kepala BMKG Nomor KEP.009 Tahun 2010 tentang Prosedur Standar Operasional Pelaksanaan Peringatan Dini, Pelaporan, dan Diseminasi Informasi Cuaca Ekstrem. Dalam ketentuan tersebut dijelaskan bahwa suatu kejadian dikategorikan sebagai cuaca ekstrem apabila memenuhi ambang batas operasional tertentu, yaitu curah hujan dengan intensitas sama atau lebih dari 50 mm dalam 24 jam, kecepatan angin lebih dari 25 knot (sekitar 45 km/jam), serta suhu udara yang menyimpang $\pm 3^{\circ}\text{C}$ dari nilai normal wilayah setempat. Ambang batas ini digunakan secara resmi dalam sistem peringatan dini dan pelaporan kejadian cuaca ekstrem di Indonesia. Oleh sebab itu, penelitian ini menggunakan kriteria operasional BMKG tersebut sebagai dasar dalam proses pelabelan data untuk mengklasifikasikan kondisi cuaca ke dalam kategori Normal, Sedang, dan Ekstrem secara sistematis dan berbasis regulasi nasional. BMKG. (2023).

2.2 Landasan Teori

Landasan teori membahas teori-teori yang mendasari penelitian ini. Penelitian ini berfokus pada penerapan Deep Learning menggunakan arsitektur Long Short-Term Memory (LSTM) untuk klasifikasi cuaca ekstrem. Teori-teori berikut digunakan untuk memperkuat dasar ilmiah penelitian ini.

2.2.1 Cuaca Dan Parameter Meteorologi

Cuaca merupakan kondisi atmosfer pada suatu wilayah dalam rentang waktu tertentu yang dipengaruhi oleh berbagai parameter meteorologi seperti suhu udara, kelembaban relatif, curah hujan, kecepatan angin, dan radiasi matahari. Parameter-parameter tersebut bersifat dinamis dan saling berinteraksi sehingga membentuk pola cuaca yang kompleks. Perubahan nilai pada satu parameter dapat memengaruhi parameter lainnya, sehingga analisis cuaca membutuhkan pendekatan yang mampu menangkap hubungan non-linear antar variabel atmosfer.

Dalam penelitian-penelitian berbasis data meteorologi, parameter seperti suhu dan kelembaban relatif sering digunakan sebagai variabel utama dalam pemodelan karena memiliki keterkaitan erat dengan proses atmosfer dan perubahan kondisi cuaca. Data meteorologi umumnya diperoleh melalui sistem Automatic Weather Station (AWS) yang merekam parameter cuaca secara periodik dan terintegrasi. Pemanfaatan data dari AWS

memungkinkan analisis berbasis data historis untuk membangun model prediktif menggunakan pendekatan kecerdasan buatan.

Pendekatan berbasis data (data-driven approach) dalam analisis meteorologi semakin berkembang seiring meningkatnya ketersediaan data sensor. Model deep learning memungkinkan proses pembelajaran langsung dari data historis tanpa harus merumuskan model fisik atmosfer secara eksplisit. Hal ini membuka peluang untuk melakukan klasifikasi maupun prediksi kondisi cuaca secara otomatis berdasarkan pola yang dipelajari dari data sebelumnya. (Haris et al., 2025)

Pada konteks operasional di Indonesia, cuaca dipahami sebagai fenomena yang terjadi di atmosfer bumi dan dipengaruhi oleh perbedaan kondisi fisis antarwilayah, terutama suhu dan kelembapan yang bervariasi dari satu tempat ke tempat lain. Perbedaan ini dapat muncul karena variasi pemanasan matahari berdasarkan letak lintang, sehingga perubahan cuaca pada suatu wilayah tidak selalu dapat digeneralisasi sama untuk semua lokasi. (Diani et al., 2012)

Cuaca ekstrem merujuk pada kondisi cuaca yang nilainya berada pada bagian “ekstrem” dibanding kondisi umum, dan dalam kajian cuaca ekstrem sering didekati menggunakan ambang batas (threshold) atau pendekatan berbasis persentil agar sesuai karakter lokal. Dalam studi hujan ekstrem, contoh ambang tetap yang digunakan adalah 100 mm/hari dengan rujukan kriteria BMKG, dan pendekatan persentil juga digunakan untuk mendefinisikan ambang yang mengikuti karakteristik setempat (misalnya “percentile threshold” untuk ambang lokal). (Ettema & Aldrian, 2012)

Cuaca merupakan fenomena atmosfer yang berubah dalam skala waktu relatif singkat dan dipengaruhi oleh kondisi fisis di atmosfer. Dalam pengamatan meteorologi, cuaca direpresentasikan melalui beberapa parameter utama seperti curah hujan, suhu udara, dan angin yang menggambarkan dinamika atmosfer di suatu lokasi. Parameter-parameter ini menjadi indikator penting karena perubahan nilainya dapat menunjukkan kondisi atmosfer normal maupun tidak normal. Dalam dokumen Meteorha BMKG juga dijelaskan aspek curah hujan sebagai bagian dari karakteristik cuaca, termasuk konsep “sifat hujan” yang diklasifikasikan menjadi di atas normal, normal, dan di bawah normal berdasarkan perbandingan terhadap rata-ratanya (normal hujan bulanan didasarkan pada rata-rata periode panjang). Dengan demikian,

parameter meteorologi tidak hanya digunakan untuk menggambarkan kondisi cuaca harian, tetapi juga untuk menilai apakah suatu kondisi termasuk normal atau menyimpang dari nilai rujukan klimatologis. BMKG. (2023).

Data parameter cuaca dalam penelitian diperoleh dari stasiun pengamatan otomatis/modern yang mampu menghasilkan data beresolusi waktu tinggi. Dalam alur pengolahan informasi cuaca, data mentah beresolusi tinggi umumnya memuat variabel-variabel kunci seperti intensitas dan curah hujan, tekanan udara, temperatur, arah dan kecepatan angin, serta kelembapan; variabel-variabel ini menjadi input penting untuk analisis dan pemodelan lebih lanjut pada kajian cuaca berbasis data. (Diani et al., 2012; Pedroso De Lima, n.d.)

2.2.2 Data *Time Series*

Data time series atau data deret waktu adalah data yang dicatat secara berurutan berdasarkan interval waktu tertentu dan memiliki ketergantungan antar waktu (temporal dependency). Dalam konteks meteorologi, data cuaca seperti suhu, kelembapan, dan kecepatan angin umumnya direkam secara berkala, misalnya setiap 10 menit atau setiap jam. Karakteristik ini menyebabkan nilai pada waktu tertentu dipengaruhi oleh nilai pada waktu sebelumnya, sehingga analisisnya memerlukan model yang mampu memahami urutan dan pola temporal.

Pada pemodelan berbasis deep learning, data meteorologi yang dikumpulkan secara periodik melalui AWS diproses sebagai data deret waktu untuk menangkap hubungan jangka pendek maupun jangka panjang antar observasi. Studi sebelumnya menunjukkan bahwa arsitektur berbasis Recurrent Neural Network (RNN) dan pengembangannya seperti Long Short-Term Memory (LSTM) efektif dalam memodelkan data time-based karena mampu menyimpan informasi historis melalui mekanisme memori internal. (Haris et al., 2025)

Karakteristik temporal pada data cuaca menuntut penggunaan model yang tidak hanya mempertimbangkan nilai saat ini, tetapi juga pola pergerakan nilai pada periode sebelumnya. Oleh karena itu, pendekatan deep learning berbasis sequential learning menjadi relevan untuk digunakan dalam penelitian ini, khususnya dalam klasifikasi cuaca ekstrem yang dipengaruhi oleh dinamika atmosfer dari waktu ke waktu. (Haris et al., 2020)

2.2.3 Machine Learning

Machine Learning merupakan cabang dari kecerdasan buatan yang memungkinkan sistem untuk mempelajari pola dari data tanpa diprogram secara eksplisit. Dalam konteks analisis meteorologi, machine learning digunakan untuk memodelkan hubungan kompleks dan non-linear antar parameter atmosfer seperti suhu, kelembaban, dan variabel cuaca lainnya. Pendekatan ini menjadi alternatif dari metode statistik konvensional yang seringkali memiliki keterbatasan dalam menangkap dinamika atmosfer yang berubah secara cepat dan tidak linier.

Pada penerapan di bidang agro-meteorologi dan sistem berbasis sensor, machine learning telah digunakan untuk memproses data cuaca yang dikumpulkan secara periodik melalui perangkat Automatic Weather Station (AWS). Model berbasis data (data-driven model) memungkinkan sistem mempelajari pola historis dari parameter cuaca untuk menghasilkan prediksi atau estimasi kondisi tertentu. Pendekatan ini menunjukkan bahwa pemodelan berbasis pembelajaran mesin lebih adaptif terhadap variasi data lingkungan dibandingkan pendekatan matematis murni. Dalam supervised learning, model dilatih menggunakan data berlabel, di mana setiap data input memiliki target atau kelas tertentu.

Pada penelitian ini, parameter cuaca seperti suhu, curah hujan, dan angin digunakan sebagai fitur (input), sedangkan kategori cuaca ekstrem seperti hujan, panas, dan angin menjadi label keluaran (output). Pendekatan supervised learning memungkinkan model untuk memetakan hubungan antara variabel meteorologi terhadap kategori cuaca berdasarkan pola yang dipelajari dari data historis.

Meskipun metode machine learning tradisional seperti regresi atau decision tree mampu memberikan hasil yang cukup baik, metode tersebut memiliki keterbatasan dalam menangkap ketergantungan temporal pada data deret waktu. Oleh karena itu, pendekatan yang lebih spesifik terhadap data sequential, seperti deep learning berbasis recurrent network, menjadi solusi yang lebih relevan untuk pemodelan cuaca berbasis waktu (Hidayat & Farihah, 2020).

2.2.4 Deep Learning

Deep learning merupakan bagian dari machine learning yang memanfaatkan jaringan saraf tiruan berlapis (multi-layer) untuk memodelkan pola yang kompleks pada

data. Pendekatan ini banyak digunakan karena mampu menangkap representasi fitur secara otomatis dari data mentah, sehingga efektif untuk berbagai jenis data yang rumit. Dalam kajian deep learning, beberapa metode yang umum dibahas meliputi Convolutional Neural Network (CNN), Restricted Boltzmann Machines (RBM), dan autoencoder. CNN banyak digunakan untuk tugas pengenalan dan klasifikasi karena mampu mengekstraksi fitur melalui lapisan konvolusi, pooling, dan fully connected. RBM merupakan varian mesin Boltzmann dengan struktur yang dibuat lebih efisien untuk proses pelatihan, sedangkan autoencoder digunakan untuk membangun representasi data (encoding) serta dapat membantu memperbaiki atau merekonstruksi data yang mengalami kerusakan agar informasi penting tetap dapat dipelajari oleh model. Pada data yang berbentuk deret waktu (time series), tantangan utama bukan hanya mengenali pola pada satu waktu, tetapi juga memahami keterkaitan antar-waktu. Karena itu, deep learning juga berkembang ke arsitektur yang dirancang khusus untuk data sekuensial, yaitu Recurrent Neural Network (RNN). Long Short-Term Memory (LSTM) merupakan salah satu varian RNN yang populer karena memiliki mekanisme “memori” dan “gerbang” yang membantu model mempertahankan informasi penting dalam rentang waktu yang lebih panjang. Dengan kemampuan tersebut, LSTM relevan untuk analisis data cuaca dari AWS yang memiliki pola temporal, karena perubahan suhu, curah hujan, dan angin pada suatu periode sering berkaitan dengan kondisi periode sebelumnya. Dalam penelitian ini, konsep deep learning dimanfaatkan melalui penerapan LSTM untuk mempelajari pola temporal pada data cuaca, lalu menghasilkan keluaran berupa klasifikasi kondisi cuaca ke dalam kategori yang telah ditentukan.

2.2.5 Python


Bahasa pemrograman Python telah menjadi salah satu alat utama dalam komputasi ilmiah dan analisis data karena kemampuannya yang kuat dalam menangani operasi numerik dan manipulasi data dalam penelitian (*Millman & Aivazis, 2011*). Python mendukung beragam pustaka yang diperlukan dalam penelitian data seperti yang dilakukan dalam penelitian ini, termasuk pustaka untuk pengolahan data awal dan pemodelan dengan algoritma Deep Learning.

Dengan sintaks yang efisien serta ekosistem pustaka yang luas, Python

memungkinkan peneliti untuk menyusun alur kerja data secara terstruktur dari tahap praproses hingga evaluasi model, sehingga cocok digunakan untuk mengembangkan sistem klasifikasi cuaca ekstrem berbasis LSTM (Millman & Aivazis, 2007).

2.2.6 Arsitektur Long Short-Term Memory (LSTM).

Long Short-Term Memory (LSTM) merupakan arsitektur Recurrent Neural Network (RNN) yang diperkenalkan oleh Hochreiter dan Schmidhuber (1997) untuk mengatasi permasalahan *vanishing gradient* pada RNN konvensional. Permasalahan ini menyebabkan RNN sulit mempelajari ketergantungan jangka panjang pada data deret waktu karena gradien kesalahan yang mengalir ke belakang cenderung mengecil secara eksponensial. Untuk mengatasi hal tersebut, LSTM memperkenalkan memory cell yang dilengkapi dengan mekanisme gate sehingga memungkinkan aliran error yang stabil (*constant error flow*) melalui waktu. Dengan mekanisme ini, LSTM mampu menyimpan dan mempertahankan informasi penting dalam jangka waktu yang panjang. (Haris et al., 2025)



Gambar 2. 1 Arsitektur LSTM

Menurut Hochreiter dan Schmidhuber (1997), sebuah unit LSTM terdiri dari cell state dan tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*.

1. Forget Gate

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

Forget gate berfungsi untuk menentukan sejauh mana informasi sebelumnya pada *cell state* dipertahankan atau dihapus. Gerbang ini mengontrol aliran memori lama agar informasi yang tidak relevan dapat dilupakan.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

2. Input Gate

Input gate mengatur informasi baru yang akan disimpan ke dalam *cell state*. Informasi ini diperoleh dari input saat ini dan *hidden state* sebelumnya.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

3. Candidate Memory

Candidate memory menghasilkan kandidat nilai memori baru yang akan ditambahkan ke *cell state*.

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

4. Update Cell State

Cell state diperbarui dengan menggabungkan memori lama dan informasi baru berdasarkan keluaran *forget gate* dan *input gate*.

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

5. Output Gate

Output gate menentukan bagian dari *cell state* yang akan dikeluarkan sebagai *hidden state*.

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

2.2.7 Pre-Pemrosesan Data

Data cuaca dari AWS umumnya terekam dalam interval waktu tertentu dan memuat beberapa parameter dengan satuan serta rentang nilai yang berbeda. Sebelum dipakai untuk pemodelan, data perlu dipersiapkan agar lebih representatif, stabil saat dilatih, dan sesuai dengan format input model berbasis urutan. Teknik pra-pemrosesan yang digunakan pada penelitian ini meliputi agregasi data, penentuan ambang batas, serta normalisasi menggunakan Z-score.

2.2.7.1 Agregasi

Agregasi adalah proses mengelompokkan dan meringkas data deret waktu menjadi bentuk yang lebih sederhana agar lebih mudah diolah dan dianalisis. Pada penelitian ini, data AWS yang semula tercatat rapat per 10 menit dirangkum menjadi interval 1 minggu supaya pola perubahan cuaca lebih jelas dan input untuk pemodelan menjadi lebih stabil. Untuk curah hujan, ringkasan mingguan dinyatakan sebagai curah hujan akumulasi dalam setiap minggu, sehingga nilai mingguan diperoleh dengan menjumlahkan seluruh pengamatan curah hujan pada minggu tersebut. (Dainty et al.,

2016)

$$X_{sum(w)} = \sum_{t \in w} x_t \quad (7)$$

2.2.7.2 Ambang Batas Cuaca Ekstrem Berdasarkan BMKG

Dalam operasional meteorologi di Indonesia, penentuan cuaca ekstrem didasarkan pada ambang batas yang telah ditetapkan secara resmi oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Cuaca ekstrem didefinisikan sebagai kondisi cuaca yang tidak normal atau tidak lazim dan berpotensi menimbulkan kerugian terhadap keselamatan jiwa maupun harta benda. Penetapan ambang batas ini bertujuan untuk mendukung sistem peringatan dini dan pelaporan kejadian cuaca ekstrem secara konsisten dan terukur.

BMKG menetapkan bahwa hujan lebat dikategorikan sebagai cuaca ekstrem apabila curah hujan mencapai atau melebihi 50 mm dalam 24 jam. Selain itu, angin kencang termasuk dalam kategori ekstrem ketika kecepatan angin melebihi 25 knot atau sekitar 45 km/jam. Pada parameter suhu udara, kondisi ekstrem terjadi apabila suhu menyimpang sebesar $\pm 3^{\circ}\text{C}$ dari nilai normal wilayah setempat. Ambang batas tersebut digunakan sebagai standar operasional dalam mengidentifikasi kejadian cuaca ekstrem di berbagai wilayah Indonesia. Dengan adanya kriteria ambang batas yang jelas, proses pelabelan data cuaca dapat dilakukan secara objektif dan selaras dengan standar meteorologi nasional. Dalam penelitian ini, ambang batas tersebut digunakan sebagai dasar untuk mengelompokkan kondisi cuaca ke dalam kategori Normal, Sedang, dan Ekstrem, sehingga sistem klasifikasi yang dikembangkan memiliki landasan yang sesuai dengan praktik operasional pemantauan cuaca di Indonesia. BMKG. (2023).

2.2.7.3 Normalisasi

Normalisasi data dilakukan untuk menyetarakan skala antar fitur agar perbedaan satuan dan rentang nilai (misalnya mm pada curah hujan, $^{\circ}\text{C}$ pada suhu, dan m/s pada kecepatan angin) tidak menyebabkan fitur dengan nilai lebih besar mendominasi proses pembelajaran model. Pada penelitian ini digunakan normalisasi Z-score (standardization)

yang mengubah setiap nilai fitur menjadi memiliki rata-rata 0 dan simpangan baku 1. Metode ini membantu proses pelatihan model menjadi lebih stabil serta mempercepat konvergensi, terutama pada model berbasis neural network seperti LSTM. Adapun Normalisasi Z-score dihitung menggunakan persamaan berikut:

$$x' = \frac{x - \mu}{\sigma} \quad (8)$$

Normalisasi diterapkan dengan prinsip fit pada data latih dan transform pada data uji. Parameter μ (rata-rata) dan σ (simpangan baku) dihitung hanya dari data latih, kemudian digunakan untuk menormalisasi data latih dan data uji. Pendekatan ini dilakukan untuk mencegah data *leakage* agar proses evaluasi mencerminkan kinerja model pada data yang belum pernah dilihat saat pelatihan.

Keterangan:

- x' = nilai hasil normalisasi (nilai standar)
- x = nilai asli sebelum normalisasi
- μ = rata-rata (mean) dari data latih pada fitur yang sama
- σ = simpangan baku (standard deviation) dari data latih pada fitur yang sama

2.2.6 Evaluasi Model

Evaluasi model dilakukan untuk mengukur performa sistem klasifikasi dalam mengenali kondisi cuaca ekstrim. Karena penelitian ini menggunakan pendekatan klasifikasi, maka digunakan empat matrix utama seperti berikut :

a) Akurasi (Accuracy)

Akurasi mengukur seberapa banyak prediksi model yang benar dibandingkan dengan jumlah total data.

Rumus Akurasi:

$$\text{Accuracy} = \frac{\text{True Positives} + \text{True Negatives}}{\text{Total Sample}} \quad (9)$$

Akurasi memberikan gambaran umum seberapa baik model dalam

memprediksi kondisi cuaca ekstrem secara keseluruhan. Namun, akurasi dapat menyesatkan jika dataset tidak seimbang, di mana model bisa saja memprediksi dengan sangat baik kelas mayoritas (misalnya, Normal) tetapi tetap memiliki akurasi tinggi meskipun salah dalam memprediksi kelas minoritas.

b) Precision (Presisi)

Precision mengukur akurasi dari prediksi positif. Ini menunjukkan berapa banyak dari prediksi kelas positif yang benar-benar positif.

Rumus Precision:

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \quad (10)$$

Precision sangat penting ketika biaya kesalahan positif tinggi. Misalnya, dalam peramalan cuaca ekstrem, kita ingin memastikan bahwa ketika model memprediksi cuaca ekstrem, prediksi tersebut benar-benar ekstrem dan tidak salah mengklasifikasikan Normal sebagai Ekstrem.

c) Recall (Sensitivitas)

Recall mengukur kemampuan model dalam mengenali semua data yang benar-benar positif untuk setiap kelas.

Rumus Recall:

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}} \quad (11)$$

Recall penting ketika biaya kesalahan negatif tinggi, yaitu ketika kegagalan untuk memprediksi cuaca ekstrem sangat berisiko. Dalam kasus cuaca ekstrem, kesalahan untuk tidak mengidentifikasi kondisi ekstrem bisa sangat merugikan.

d) F1-Score

F1-score adalah rata-rata harmonik antara precision dan recall, memberikan gambaran lebih seimbang tentang performa model.

Rumus F1-Score:

$$F1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (12)$$

F1-score memberi gambaran keseluruhan tentang keseimbangan antara precision dan recall. Nilai F1-score yang lebih tinggi menunjukkan bahwa model memiliki performa yang lebih baik dalam menyeimbangkan keduanya.

e) Confusion Matrix

Confusion matrix memberikan gambaran lebih jelas mengenai kinerja model dengan menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas. Ini membantu untuk mengevaluasi kesalahan model secara lebih rinci, terutama dalam kasus dataset yang tidak seimbang.

Confusion Matrix:

Tabel 2. 1 Confusion matrix

	Predicted Normal	Predicted Extreme
Actual Normal	True Positives (TP)	False Negative (FN)
Actual Extreme	False Positives (FP)	True Negative (TN)

Evaluasi ini penting untuk memastikan bahwa model tidak hanya akurat, tetapi juga andal dalam mengklasifikasi kondisi ekstrem yang relatif jarang muncul dibandingkan data normal. (Fauzan et al., 2025)

2.2.8 Flowchart

Bagan alur atau *flowchart* merupakan representasi visual yang digunakan untuk menggambarkan urutan langkah dan aktivitas dalam suatu proses secara sistematis dengan memanfaatkan simbol-simbol standar yang saling terhubung. Flowchart digunakan untuk menunjukkan bagaimana suatu proses berjalan dari awal hingga akhir, termasuk aliran kegiatan, keputusan, serta hubungan antar tahapan dalam sistem. Dengan adanya flowchart, alur kerja yang kompleks dapat disederhanakan menjadi bentuk visual yang lebih mudah dipahami dan dianalisis. Selain berfungsi sebagai alat bantu dalam perancangan dan analisis sistem, flowchart juga memudahkan komunikasi antar pihak yang terlibat karena mampu memberikan gambaran yang jelas mengenai logika dan

urutan proses tanpa harus menjelaskan detail teknis secara mendalam. Oleh karena itu, flowchart sering digunakan dalam tahap perencanaan, dokumentasi, dan pengembangan sistem untuk memastikan bahwa alur proses yang dirancang telah sesuai dengan kebutuhan dan kondisi yang ada (Ilmu et al., 2016).

Gambar	Fungsi	Gambar	Fungsi
	Proses		Card
	Proses pilihan		Punched tape
	Keputusan		Summing Junction
	Input Data dan Output Informasi		Or
	Predefine Proses		Collate
	Internal Storage		Sort
	Dokumen		Extract
	MultiDokumen		Merge
	Terminator (mulai dan Akhir)		Storage Data
	Preparasi		Delay
	Manual Input		Sequential Access Storage
	Manual Operasi		Magnetic Disk
	Penghubung		Direct Access Storage
	Off Page Penghubung		Display

Gambar 2. 2 Flowchart

2.2.9 Metodologi Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode pemodelan data time series berbasis algoritma Long Short-Term Memory (LSTM). Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengolahan data numerik, pengukuran hubungan antar variabel, serta evaluasi performa model secara statistik untuk mendeteksi dan mengklasifikasikan kondisi cuaca ekstrem.

Tahapan penelitian diawali dengan identifikasi masalah dan penentuan tujuan penelitian, yaitu menganalisis pola cuaca serta mengklasifikasikan kondisi cuaca ke dalam beberapa kategori berdasarkan indikator ekstrem. Selanjutnya dilakukan pengumpulan data cuaca dari sumber resmi AWS/BMKG dengan variabel utama seperti curah hujan, suhu udara, dan kecepatan angin dalam rentang waktu tertentu.

Tahap berikutnya adalah analisis variabel untuk menentukan atribut yang relevan. Proses ini dilanjutkan dengan preprocessing data yang meliputi penggabungan dan pengurutan data berdasarkan waktu, penghapusan duplikasi, konversi tipe data menjadi numerik, serta penanganan missing value menggunakan teknik interpolasi. Tahapan ini bertujuan memastikan kualitas data sebelum digunakan dalam proses pemodelan.

Setelah data bersih, dilakukan analisis data awal berupa analisis univariat untuk memahami distribusi masing-masing variabel dan analisis bivariat untuk melihat hubungan antar variabel. Data kemudian ditransformasikan ke dalam bentuk agregasi harian dan mingguan untuk membentuk pola time series yang lebih representatif.

Tahap selanjutnya adalah pembentukan indikator ekstrem berdasarkan ambang batas yang telah ditentukan. Data kemudian diberi label ke dalam tiga kelas, yaitu normal, sedang, dan ekstrem. Dataset dibagi menggunakan metode time-based split dengan proporsi 80% data latih dan 20% data uji untuk menjaga urutan kronologis data.


Sebelum pelatihan model, dilakukan normalisasi menggunakan metode Z-Score (StandardScaler) untuk menstandarkan skala fitur. Data kemudian dibentuk menjadi sekuens dengan pendekatan lookback window selama beberapa periode sebagai input model LSTM.

Model LSTM dibangun dengan arsitektur multilayer dan fungsi aktivasi Softmax untuk klasifikasi multikelas. Proses pelatihan dilakukan dengan fungsi loss categorical crossentropy serta mekanisme early stopping untuk menghindari overfitting.

Tahap akhir adalah evaluasi model menggunakan metrik accuracy, precision, recall, F1-score, dan confusion matrix. Hasil evaluasi kemudian dianalisis dan diinterpretasikan untuk menilai kemampuan model dalam mendeteksi pola dan mengklasifikasikan kondisi cuaca ekstrem secara akurat.

2.2.9 Kerangka Penelitian

Kerangka penelitian ini menggambarkan alur penelitian secara umum mulai dari permasalahan hingga hasil yang diperoleh. Penelitian diawali dengan identifikasi permasalahan terkait data cuaca yang bersifat deret waktu dan memiliki pola temporal yang kompleks, sehingga diperlukan metode yang mampu mengklasifikasikan cuaca ekstrem secara otomatis. Selanjutnya, data cuaca dari Automatic Weather Station (AWS) digunakan sebagai input penelitian dengan parameter suhu udara, curah hujan, dan kecepatan angin. Data tersebut kemudian diproses dan dianalisis menggunakan metode Deep Learning dengan arsitektur Long Short-Term Memory (LSTM) untuk melakukan klasifikasi cuaca ekstrem. Tahap akhir penelitian menghasilkan model klasifikasi cuaca ekstrem serta hasil evaluasi kinerja model sebagai dasar penarikan kesimpulan.



Gambar 2. 3 Kerangka Pemikiran

Kerangka penelitian ini diawali dengan permasalahan bahwa data cuaca dari Automatic Weather Station (AWS) bersifat deret waktu dengan pola temporal yang kompleks, sehingga klasifikasi cuaca ekstrem yang dilakukan secara konvensional belum optimal dan belum tersedia metode otomatis berbasis *Deep Learning*. Berdasarkan

permasalahan tersebut, penelitian ini menggunakan metode *Deep Learning* dengan arsitektur Long Short-Term Memory (LSTM) sebagai dasar pendekatan untuk klasifikasi data cuaca ekstrem.

1. Landasan penelitian dalam penelitian ini mencakup metode utama yang digunakan, yaitu *Deep Learning*, LSTM, dan klasifikasi data deret waktu, dengan dukungan bahasa pemrograman Python serta data cuaca AWS sebagai sumber data. Data yang digunakan berasal dari AWS Kabupaten Subang, Jawa Barat, dengan parameter meteorologi yang meliputi suhu udara, curah hujan, dan kecepatan angin.
2. Pada tahap proses analisis, data cuaca terlebih dahulu melalui tahap pra-pemrosesan untuk memastikan kualitas data yang digunakan. Selanjutnya, data diberi label kondisi cuaca ekstrem dan dimodelkan menggunakan LSTM untuk melakukan klasifikasi. Kinerja model kemudian dievaluasi untuk mengetahui kemampuan sistem dalam mengklasifikasikan cuaca ekstrem.
3. Output dari penelitian ini berupa model klasifikasi cuaca ekstrem berbasis LSTM, dataset cuaca yang telah berlabel status cuaca, serta informasi mengenai parameter yang dominan pada kondisi cuaca ekstrem