

# Stasiun Cuaca Mini Pintar Berbasis Deep Learning

1<sup>st</sup> Naufal Dzakwan Setyo Gandhi  
 Department Of Computer Engineering  
 Telkom University Surabaya  
 Surabaya, Indonesia  
[naufaldzakwan@student.telkomuniversity.ac.id](mailto:naufaldzakwan@student.telkomuniversity.ac.id)

2<sup>nd</sup> Mohammad Yanuar Hariyawan  
 Department Of Computer Engineering  
 Telkom University Surabaya  
 Surabaya, Indonesia  
[myanuar@telkomuniversity.ac.id](mailto:myanuar@telkomuniversity.ac.id)

3<sup>rd</sup> Hendy Briantoro  
 Department Of Computer Engineering  
 Telkom University Surabaya  
 Surabaya, Indonesia  
[hendybr@telkomuniversity.ac.id](mailto:hendybr@telkomuniversity.ac.id)

**Abstrak** — Perubahan iklim dan cuaca yang semakin tidak menentu menuntut data cuaca lokal yang akurat dan prediksi yang cepat. Namun, stasiun cuaca konvensional cenderung mahal dan rumit, sehingga sulit diakses oleh masyarakat umum. Untuk mengatasi hal ini, penelitian ini mengembangkan Stasiun Cuaca Mini Pintar berbasis Internet of Things (IoT) dan Deep Learning. Sistem ini menggunakan mikrokontroler ESP32-S3, sensor BME280 (suhu, kelembaban, tekanan), dan anemometer (kecepatan angin) untuk mengumpulkan data secara otomatis, yang disimpan di Google Spreadsheet. Data kemudian diproses melalui pembersihan, penanganan nilai hilang, normalisasi, dan pembentukan urutan waktu.

Prediksi dilakukan menggunakan model Long Short-Term Memory (LSTM) yang dioptimalkan dengan Keras Tuner. Model ini mampu memprediksi suhu, kelembaban, tekanan, dan kecepatan angin dengan akurasi tinggi, ditunjukkan oleh nilai R<sup>2</sup> antara 0.83 hingga 0.96. Untuk klasifikasi cuaca (cerah atau hujan), model mencapai akurasi 88%. Sistem ini juga dilengkapi API FastAPI dan aplikasi mobile berbasis React Native Expo sebagai antarmuka pengguna. Hasil penelitian menunjukkan bahwa kombinasi IoT dan Deep Learning efektif untuk solusi cuaca yang akurat dan terjangkau.

**Kata kunci**— Stasiun Cuaca Mini Pintar, Internet of Things (IoT), Deep Learning, Long Short-Term Memory (Long Short-Term Memory (LSTM)), Prediksi Cuaca.

## I. PENDAHULUAN

Data cuaca yang tepat dan dapat diprediksi memiliki peran penting dalam berbagai bidang kehidupan saat ini. Informasi cuaca yang komprehensif dan tepat sangat diperlukan untuk meningkatkan efisiensi dalam berbagai aspek kegiatan manusia, termasuk perencanaan kegiatan harian, optimasi pertanian, manajemen energi, serta mitigasi risiko bencana alam. Ketepatan informasi cuaca yang diperoleh secara langsung maupun ramalan ke depan sangat berpengaruh pada efisiensi pengambilan keputusan di berbagai sektor tersebut.

Dalam beberapa tahun terakhir, kemajuan teknologi Internet of Things (IoT) telah mengubah cara pengumpulan data lingkungan, termasuk data cuaca dan iklim. Organisasi Meteorologi Dunia (WMO) telah menyusun panduan untuk penerapan, pemasangan, dan pemakaian stasiun cuaca otomatis (AWS). Di zaman baru IoT sekarang ini, kebutuhan akan penerapan sistem pemantauan otomatis terus meningkat untuk menyajikan data waktu nyata yang diperlukan ilmuwan dalam merancang dan melaksanakan kebijakan lingkungan yang sesuai. Kemunculan berbagai sensor murah dan

mikrokontroler yang efisien telah membuat pengembangan AWS dalam skala kecil dan mandiri menjadi mungkin. Stasiun cuaca kecil seperti ini memberikan keuntungan dalam aksesibilitas, kemudahan pemasangan, serta biaya operasional yang jauh lebih hemat dibandingkan dengan stasiun meteorologi tradisional.

Untuk mengatasi kekurangan ini, penggabungan metode Deep Learning memberikan solusi yang menjanjikan. Metode pembelajaran dalam dapat digunakan untuk meramalkan suatu peristiwa, seperti meramalkan kondisi cuaca di suatu daerah.[4] Model Deep Learning, terutama Long Short-Term Memory (LSTM), sangat ampuh dalam menganalisis data deret waktu seperti informasi cuaca. Long Short-Term Memory (LSTM) adalah suatu struktur dari Recurrent Neural Network (RNN) yang mampu mengolah data berurutan dan memiliki kemampuan untuk mengenali data yang perlu disimpan atau dihapus dengan menggunakan empat lapisan neuron atau gerbang untuk mengelola memori di setiap neuron. Kemampuan Long Short-Term Memory (LSTM) dalam memahami ketergantungan jangka panjang dan pola non-linear dari data sensor menghasilkan peningkatan yang signifikan dalam akurasi prediksi serta analisis tren cuaca. Berbagai studi telah mengungkapkan kemampuan Long Short-Term Memory (LSTM) dalam meramalkan cuaca dengan memanfaatkan variabel seperti suhu, kelembaban, curah hujan, dan kecepatan angin, serta menghasilkan akurasi yang menjanjikan [1]

Berdasarkan urgensi kebutuhan akan data cuaca yang akurat dan prediktif, serta potensi besar dari Deep Learning, penelitian ini mengusulkan pengembangan "Stasiun Cuaca Mini Pintar Berbasis Deep Learning". Proyek ini akan mengintegrasikan sensor cuaca yang efisien seperti BME280 (suhu, tekanan, kelembaban) dan Anemometer dengan mikrokontroler ESP32-S3 sebagai otak pengumpul data. Data yang terkumpul akan disimpan dan diolah melalui sistem pipeline yang terdiri dari Google Spreadsheet untuk penyimpanan data, model Long Short-Term Memory (LSTM) untuk analisis dan prediksi, FastAPI sebagai antarmuka Application Programming Interface (API), dan React Native Expo untuk visualisasi data pada aplikasi mobile. Dengan pendekatan ini, diharapkan dapat terwujud sebuah sistem pemantauan cuaca yang tidak hanya hemat biaya dan mudah diimplementasikan, tetapi juga mampu memberikan informasi cuaca yang lebih cerdas dan prediktif, relevan untuk berbagai kebutuhan lokal.

suhu, kelembaban, curah hujan, dan kecepatan angin, serta menghasilkan akurasi yang menjanjikan [1]

Berdasarkan urgensi kebutuhan akan data cuaca yang akurat dan prediktif, serta potensi besar dari Deep Learning, penelitian ini mengusulkan pengembangan "Stasiun Cuaca Mini Pintar Berbasis Deep Learning". Proyek ini akan mengintegrasikan sensor cuaca yang efisien seperti BME280 (suhu, tekanan, kelembapan) dan Anemometer dengan mikrokontroler ESP32-S3 sebagai otak pengumpul data. Data yang terkumpul akan disimpan dan diolah melalui sistem pipeline yang terdiri dari Google Spreadsheet untuk penyimpanan data, model Long Short-Term Memory (LSTM) untuk analisis dan prediksi, FastAPI sebagai antarmuka Application Programming Interface (API), dan React Native Expo untuk visualisasi data pada aplikasi mobile. Dengan pendekatan ini, diharapkan dapat terwujud sebuah sistem pemantauan cuaca yang tidak hanya hemat biaya dan mudah diimplementasikan, tetapi juga mampu memberikan informasi cuaca yang lebih cerdas dan prediktif, relevan untuk berbagai kebutuhan lokal.

## II. KAJIAN TEORI

Perkembangan teknologi dan metode komputasi telah membawa kemajuan signifikan dalam bidang prakiraan cuaca, dengan berbagai penelitian yang mengkaji pemanfaatan kecerdasan buatan untuk meningkatkan akurasi dan efisiensi. Salah satu pendekatan yang banyak dikaji adalah penggunaan model Deep Learning yang terbukti efektif dalam memproses data deret waktu kompleks seperti data meteorologi.

Dalam ranah prakiraan cuaca skala luas, penelitian oleh menunjukkan kapabilitas Machine Learning dalam melampaui sistem prakiraan berbasis fisika terkemuka seperti ECMWF HRES. Model ML berjenjang yang dikembangkan FuXi mampu menghasilkan prakiraan cuaca global 15 hari dengan performa yang sebanding dengan ECMWF ensemble mean, menegaskan potensi besar ML untuk prakiraan cuaca jangka menengah hingga panjang. Hal ini memberikan landasan bahwa metode Machine Learning memiliki kemampuan superior dalam menganalisis pola cuaca yang kompleks[5]

Secara lebih spesifik pada implementasi Deep Learning untuk prediksi parameter cuaca, Eko Supriyadi [4] menerapkan Long Short-Term Memory (LSTM) untuk memprediksi suhu udara, kelembaban udara, kecepatan angin, dan tekanan udara. Penelitian ini menunjukkan bahwa penggunaan Long Short-Term Memory (LSTM) mampu menghasilkan nilai Root Mean Squared Error (RMSE) yang semakin baik untuk validasi dan prediksi beberapa hari ke depan. Hasil ini sangat relevan dengan proyek ini karena parameter yang diprediksi serupa, menegaskan kelayakan Long Short-Term Memory (LSTM).

Senada dengan itu, Tita Lattifiaa. mengusulkan model prediksi curah hujan menggunakan Long Short-Term Memory (LSTM) dan Neural Network. Penelitian ini menekankan pentingnya prediksi curah hujan bagi sektor pertanian dan berhasil mencapai akurasi 76% dengan menggunakan enam parameter cuaca[6]. Sementara itu, Yoga Estu Nugrahal. juga fokus pada prediksi curah hujan harian di Kota Bandung menggunakan metode Long Short-Term Memory (LSTM), menunjukkan hasil prediksi yang cukup

baik dengan nilai Test Score RMSE 8.86. Kedua penelitian ini secara kuat mendukung efektivitas Long Short-Term Memory (LSTM) dalam memprediksi parameter cuaca spesifik dari data deret waktu, yang memiliki implikasi praktis bagi aktivitas yang bergantung pada kondisi cuaca.[7]

Penggunaan Long Short-Term Memory (LSTM) juga telah dieksplorasi untuk prakiraan fenomena cuaca spesifik, seperti yang dilakukan oleh Kai-chao Miao. Mereka mengembangkan kerangka kerja Long Short-Term Memory

(LSTM) baru untuk prakiraan kabut jangka pendek berdasarkan elemen-elemen meteorologi dan menunjukkan bahwa model Long Short-Term Memory (LSTM) mereka memiliki performa prediksi terbaik dibandingkan dengan algoritma Machine Learning tradisional lainnya seperti KNN, AdaBoost, dan CNN. Ini menunjukkan kemampuan adaptif dan superioritas Long Short-Term Memory (LSTM) dalam berbagai skenario prediksi meteorologi.[8]

Di sisi lain, perkembangan Internet of Things (IoT) telah membuka jalan bagi pengembangan sistem pemantauan cuaca yang lebih terjangkau dan mudah diakses. melakukan tinjauan menyeluruh tentang Stasiun Cuaca Otomatis (AWS) dan kebutuhan akan sistem pengamatan real-time di era IoT. Mereka juga membahas potensi integrasi Deep Learning dalam AWS berbiaya rendah, serta menyajikan studi kasus AWS AgroComp yang menggunakan sensor ekonomis dan algoritma Deep Learning yang berjalan secara lokal. Penelitian Ioannou dkk. ini sangat fundamental bagi proyek ini, karena menjadi landasan bagi pengembangan stasiun cuaca yang tidak hanya pintar dengan Deep Learning, tetapi juga terjangkau dan terintegrasi penuh dalam ekosistem IoT.[3]

Secara keseluruhan, penelitian-penelitian terdahulu ini menggarisbawahi potensi besar Deep Learning, khususnya Long Short-Term Memory (LSTM), dalam memprediksi berbagai parameter dan fenomena cuaca. Selain itu, mereka juga menunjukkan tren menuju solusi pemantauan cuaca yang lebih ekonomis dan terintegrasi IoT. Penelitian yang diajukan ini bertujuan untuk menjembatani dan menyatukan kedua aspek ini, yaitu mengembangkan sistem Stasiun Cuaca Mini Pintar yang menggabungkan keunggulan sensor berbiaya rendah dengan kemampuan prediktif tinggi dari Long Short-Term Memory (LSTM) dalam kerangka sistem end-to-end yang lengkap.

### A. Internet of Things (IoT)

*Internet of Things (IoT)* merupakan konsep yang memungkinkan benda-benda fisik terhubung dan bertukar informasi melalui jaringan internet. Konsep ini mencakup penggabungan perangkat keras, perangkat lunak, sensor, aktuator, dan koneksi jaringan agar objek-objek tersebut dapat mengumpulkan dan menukar data secara mandiri. Dalam ekosistem IoT, perangkat fisik dilengkapi dengan sensor untuk mengumpulkan data dari lingkungan sekitarnya, kemudian data tersebut ditransmisikan melalui internet untuk disimpan, diproses, dan dianalisis, sering kali di platform cloud.[9] Tujuan utama IoT adalah menciptakan lingkungan yang lebih cerdas dan responsif dengan menjembatani dunia fisik dan digital, memungkinkan aplikasi yang beragam mulai dari pemantauan lingkungan, otomatisasi rumah, hingga sistem industri.

### B. Jaringan Saraf Tiruan Rekuren (RNN)

Jaringan Saraf Tiruan Rekuren (RNN) adalah arsitektur deep learning yang efisien untuk data deret waktu karena kemampuannya dalam mengolah informasi secara berurutan serta menyimpan "ingatan" dari data yang lalu. Akan tetapi, RNN standar mengalami kesulitan dalam mengatasi dependensi jangka panjang karena masalah vanishing atau exploding gradient.

Jaringan LSTM menjadi Keunggulan luar biasa dalam berbagai pengaplikasian di dunia nyata telah mengangkat pada diskusi ilmiah, dengan pembahasan yang melimpah di jurnal, blog teknologi, dan pedoman implementasi. [9]

Sebaliknya, Convolutional Neural Network (CNN) lebih efektif dalam mengambil fitur spasial dari data, seperti gambar atau video, dan tidak dirancang khusus untuk ketergantungan temporal jangka panjang. Walaupun demikian, penggabungan CNN-LSTM dapat diterapkan pada data yang memiliki elemen spasial dan temporal secara bersamaan.

### C. Jaringan saraf buatan (Neural Network)

Jaringan saraf buatan (Neural Network) merupakan model komputasi yang terinspirasi oleh jaringan saraf alami, terdiri dari unit pemrosesan yang saling terkoneksi (neuron) dalam beberapa lapisan. Setiap sambungan memiliki nilai yang disesuaikan melalui proses pembelajaran untuk mengurangi kesalahan prediksi. Struktur berlapis dan kemampuan adaptasi ini menjadikan Jaringan Saraf sebagai dasar penting dalam pembelajaran mendalam.

Salah satu arsitektur dasar yang penting adalah Multi-Layer Perceptron (MLP). Sebagai tipe jaringan saraf feedforward, MLP terdiri dari lapisan input, satu atau lebih lapisan yang tersembunyi, dan lapisan output. Dalam MLP, data bergerak dalam satu arah dan setiap neuron di suatu lapisan terhubung sepenuhnya dengan semua neuron di lapisan selanjutnya.

Untuk lapisan tersembunyi yang dengan neuron, yang menerima masukan dari lapisan sebelumnya dapat

dirumuskan sebagai:

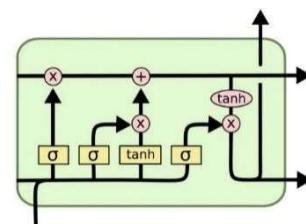
$$\begin{aligned} z^{(L)} &= w^{(L)} \alpha^{(L-1)} + b^{(L)} \\ \alpha^{(L)} &= \phi(z^{(L)}) \end{aligned}$$

Dengan pengertian sebagai berikut:

1.  $z^{(L)}$  adalah vector hasil penjumlahan berbobot untuk lapisan L.
2.  $w^{(L)}$  adalah matriks bobot yang menghubungkan dari lapisan  $L-1$  ke lapisan L.
3.  $\alpha^{(L-1)}$  adalah vector *output* dari lapisan sebelumnya.
4.  $b^{(L)}$  adalah vector bias di lapisan L.
5.  $\phi$  merupakan fungsi aktivitas yang diterapkan secara rinci, elemen demi elemen pada  $Z^{(L)}$ .

### D. Long Short-Term Memory (LSTM)

*Long Short-Term Memory* (LSTM) merupakan tipe Jaringan Saraf Tiruan Berulang Recurrent Neural Network (RNN) yang dirancang khusus untuk mengatasi kelemahan RNN klasik, yaitu permasalahan vanishing dan exploding gradient saat menangani urutan data Panjang.



GAMBAR 1  
(USTRASI LONG SHORT TERM MEMORY)

Tidak seperti RNN biasa yang memiliki susunan sederhana, LSTM meningkatkan arsitektur ini dengan struktur yang lebih rumit. Arsitektur LSTM terdiri dari empat lapisan jaringan saraf yang berinteraksi dengan cara yang khas, yakni input gate (gerbang masukan), forget gate (gerbang lupakan), output gate (gerbang keluaran), dan cell state (sel memori). Cell state memiliki peran untuk menyimpan informasi keadaan saat ini dan mengirimkannya ke sel LSTM yang berikutnya.[12]

- Gerbang Lupakan (Forget Gate)

Gerbang ini mengatur seberapa banyak informasi dari keadaan sel memori sebelumnya yang perlu disimpan atau diabaikan.

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

Di mana  $W_f$  adalah matriks bobot untuk gerbang lupakan,  $h_{t-1}$  adalah hidden state pada time step sebelumnya,  $x_t$  adalah input pada time step saat ini,  $b_f$  adalah bias, dan  $\sigma$  adalah fungsi aktivasi sigmoid.

- Pembaruan (Cell State)

Setelah gerbang lupakan dan gerbang masukan dihitung, state sel memori  $C_t$  diperbarui. Informasi lama dilupakan ( $f_t \odot C_{t-1}$ ) dan informasi baru ditambahkan  $i_t \odot \tilde{C}_t$ . Di mana  $\odot$  menunjukkan perkalian element-wise.

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

- Gerbang Masukan (Input Gate)

Gerbang ini menentukan seberapa banyak informasi baru dari masukan saat ini yang harus disimpan ke state sel memori.

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

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

- Gerbang Keluaran (Output Gate)

Gerbang ini mengatur jumlah informasi dari state sel memori yang akan dipakai untuk menghitung keluaran tersembunyi (hidden state) pada langkah waktu sekarang.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t \odot \tanh(C_t)$$

Kemampuan ini menjadikan Long Short-Term Memory (LSTM) ideal untuk tugas-tugas ramalan cuaca, di mana pola-pola cuaca dapat berhubungan dengan data yang sangat jauh, dan model harus "mengingat" informasi penting dari urutan data yang panjang untuk menghasilkan prediksi yang tepat.

#### E. Bidirectional Long-Short Term Memory (BiLSTM)

Bidirectional Long-Short Term Memory atau sering disebut BiLSTM merupakan sebuah arsitektur jaringan sekuensial yang memperluas fungsiionalitas LSTM standar. Dalam konteks BiLSTM, lapisan rekurrensi awal jaringan direplikasi, sehingga terdapat dua lapisan yang berdekatan satu sama lain. [13]

#### F. Gated recurrent unit (GRU)

GRU atau Gated recurrent unit adalah salah satu jenis Recurrent Neural Network (RNN) yang digunakan sebagai alternatif yang lebih efisien dan sederhana dibandingkan dengan arsitektur LSTM.[15] Meskipun terinspirasi dari LSTM, model ini secara luas diakui lebih mudah dihitung dan diimplementasikan. Menariknya, LSTM tetap kebal terhadap Masalah gradien yang menghilang. Struktur internalnya lebih sederhana, dan akibatnya, proses pelatihan dipermudah oleh pengurangan jumlah perhitungan yang diperlukan untuk memperbarui keadaan internal. [15]

- Gerbang Pembaharuan (Upgrade Gate)

$$z_t = \sigma(w_z \cdot [w_{t-1}, x_t] + b_z)$$

- Gerbang Reset (Reset Gate)

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r)$$

- Kandidat Hidden State

$$\tilde{h}_t = \tan(r_t \times h_{t-1} u + x_t w + b)$$

- Pembaharuan Hidden State

$$h_t = (1 - z_t) \times \tilde{h}_t + z_t \times h_{t-1}$$

### III. METODE

Diagram alir ini menyajikan gambaran yang jelas mengenai keseluruhan proses, mulai dari penentuan masalah hingga pengujian dan evaluasi akhir sistem.

#### A. Pengumpulan Data

Penelitian ini memanfaatkan data deret waktu cuaca yang diperoleh secara langsung dari Stasiun Cuaca Mini Pintar. Sistem ini, yang menggunakan mikrokontroler ESP32-S3, secara otomatis mengumpulkan data suhu, kelembaban, tekanan udara, dan kecepatan angin dari sensor BME280 dan anemometer.

Data direkam setiap 10 menit dan dikirim secara nirkabel melalui Wi-Fi ke Google Spreadsheet untuk disimpan. Platform ini dipilih karena aksesibilitas yang mudah, fleksibilitas, dan integrasi yang baik untuk analisis lanjutan.

#### B. Pra-pemrosesan Data

Data mentah yang diperoleh dari sensor seringkali memiliki gangguan, nilai yang hilang, atau format yang tidak konsisten, sehingga memerlukan langkah pra-pemrosesan sebelum digunakan untuk melatih model Deep Learning.

#### C. Alur Permodelan

Alur permodelan digunakan sebagai peta jalur untuk menjadi melakukan prakiraan cuaca berbasis machine learning yang terdiri dari beberapa tahapan utama. Dari gambar dibawah setiap tahapan memiliki perannya sendiri dalam menghasilkan prediksi cuaca yang dapat di pahami.



Dari gambar diatas dapat terlihat susunan alur permodelan untuk menghitung ke akuratan tiap model. Dan penjelasannya sebagai berikut.

#### 1. Persiapan data

Data yang digunakan adalah data cuaca historis yang diperoleh secara otomatis melalui perangkat pengukur cuaca dan disimpan dalam format spreadsheet. Data ini mencakup variabel-variabel utama seperti suhu, kelembaban, tekanan udara, dan kecepatan angin. Sebelum digunakan dalam proses pemodelan, data perlu melalui tahap pembersihan untuk mengeliminasi nilai-nilai yang tidak valid, duplikat, serta mengatasi outlier dan nilai yang hilang.

#### 2. Proses Pelatihan

Data yang telah dibersihkan kemudian digunakan sebagai masukan dalam proses pelatihan model machine learning. Pada tahap ini, digunakan arsitektur deep learning yang berlandaskan pada LSTM, BiLSTM, atau GRU. Model dilatih untuk mengidentifikasi pola historis dalam data cuaca, sehingga dapat memprediksi nilai parameter cuaca (suhu, kelembaban, tekanan, dan kecepatan angin) untuk satu jam ke depan. Output dari model ini bukanlah kategori cuaca (seperti "cerah" atau "hujan"), tetapi melainkan angka numerik untuk setiap parameter cuaca.

#### 3. Prediksi Parameter Cuaca

Setelah model selesai dilatih, model digunakan untuk melakukan prediksi terhadap data uji. Hasil prediksi berupa nilai suhu, kelembaban, tekanan udara, dan kecepatan angin untuk periode waktu tertentu ke depan (misal H+1 hingga H+10 jam).

#### 4. Klasifikasi Kondisi Cuaca (Rule-Base)

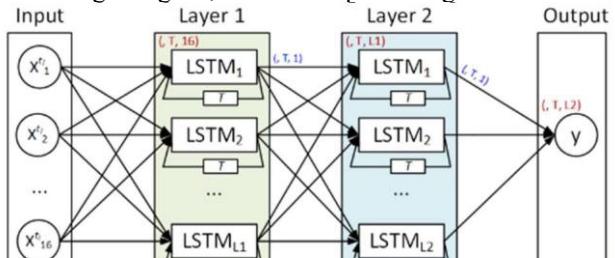
Selanjutnya, kriteria berbasis ambang diterapkan untuk mengklasifikasikan nilai parameter hasil prediksi ke dalam kategori kondisi cuaca tertentu. Aturan ini disusun berdasarkan pemahaman mengenai area. Misalnya, ketentuan ini menyatakan bahwa apabila suhu rendah dan kelembaban tinggi pada saat tertentu, maka diprediksi akan terjadi hujan. Sebaliknya, ketika suhu tinggi dan kelembaban rendah, diprediksi akan cerah. Struktur logika IF/ELSE diterapkan untuk menjalankan prosedur ini.

#### 5. Penyajian Prakiraan Cuaca

Hasil akhir merupakan ramalan cuaca untuk beberapa jam mendatang, yang diorganisir dalam kategori (seperti, cerah atau hujan) beserta nilai parameter yang diramalkan. Data ini dapat digunakan untuk pengambilan keputusan maupun pemantauan.

#### D. Arsitektur Model Long Short-Term Memory (LSTM)

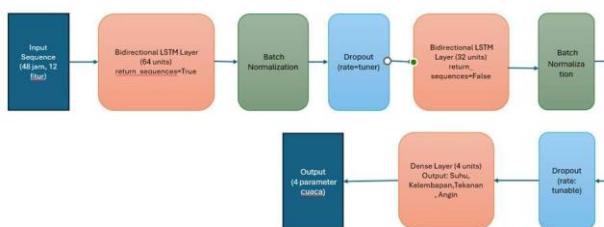
Model Long Short-Term Memory (LSTM) untuk ramalan cuaca akan terdiri dari dua lapisan LSTM berturut-turut, dengan masing-masing memiliki 100 unit. Jumlah lapisan dan neuron ini ditentukan melalui pengujian untuk menyeimbangkan kinerja serta kompleksitas pemrosesan. Lapisan output terdiri dari lapisan Dense dengan tiga neuron, sesuai dengan jumlah parameter cuaca yang akan diprediksi. Untuk tugas regresi, akan diterapkan fungsi aktivasi linear.



GAMBAR 3  
(ARSITEKTUR MODEL LSTM)

#### E. Arsitektur Model Bidirectional Long Short-Term Memory (BiLSTM)

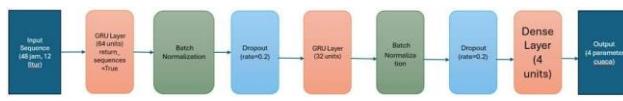
Arsitektur BiLSTM tidak merubah struktur internal sel LSTM; sebaliknya, ia mengubah metode penerapan lapisan-lapisan LSTM terhadap data masukan. Untuk menjelaskan fenomena ini, perhatikan kalimat “Anak laki-laki bermain bola”. Selama pemrosesan kata “play”, lapisan depan dipengaruhi oleh konteks “The boy”, sedangkan lapisan belakang dipengaruhi oleh konteks ‘ball’. Gabungan kedua konteks ini memungkinkan model memperoleh pemahaman yang lebih mendalam mengenai fungsi kata “play” dalam kalimat secara keseluruhan.



GAMBAR 4  
(ARSITEKTUR MODEL BILSTM)

Pada gambar di atas dapat dijelaskan prosesnya, di mana lapisan input menerima data selama 48 jam dan 12 fitur, kemudian diproses oleh lapisan Bidirectional LSTM yang memiliki 64 unit, dan output dari BiLSTM selanjutnya dinormalisasi oleh lapisan Batch Normalization. Pada BiLSTM kedua, hasil dari lapisan pertama dimasukkan dan 32 unit diambil dari Lapisan Dropout kedua, yang juga memiliki rate yang bisa disetel (tunable), diterapkan untuk regularisasi sebelum menuju ke lapisan terakhir. Lapisan terakhir setelah semuanya teratur masuk ke dalam lapisan dense layer yang hasilnya menghasilkan 4 unit parameter cuaca.

#### F. Arsitektur Model Gated recurrent Unit (GRU)



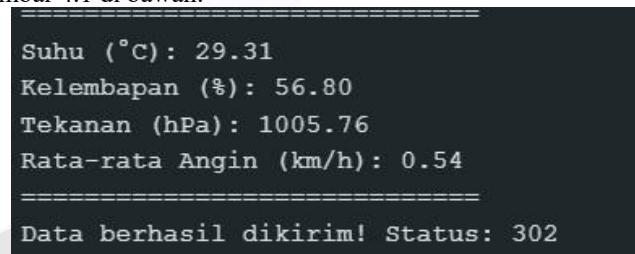
GAMBAR 5  
(ARSITEKTUR MODEL GRU)

Arsitektur internal dari sel GRU fokus pada dua mekanisme gerbang utama yang mengatur hidden state. Berbeda dengan LSTM yang memiliki cell state, GRU hanya mengatur satu vektor hidden state. Berdasarkan gambar 3.4, lapisan input memperoleh data 48 jam yang mana setiap langkah waktu dalam urutan memiliki 12 fitur yang berbeda. GRU pertama menghasilkan urutan output berdimensi 64 yang diteruskan ke lapisan selanjutnya, kemudian pada lapisan GRU kedua berfungsi untuk menormalkan GRU lapis pertama setelah melalui normalisasi batch. Lapisan output telah diproses dari blok GRU yang kemudian masuk ke lapisan dense layer yang akan menghasilkan 4 unit parameter output.

#### IV. HASIL DAN PEMBAHASAN

Pengumpulan data dalam penelitian ini dilaksanakan secara otomatis dan langsung dari perangkat Stasiun Cuaca Mini Pintar yang telah diterapkan. Mikrokontroler ESP32-S3 berfungsi sebagai inti akuisisi data, terhubung dengan sensor BME280 untuk mengukur suhu, kelembaban, dan tekanan udara, serta anemometer untuk mengukur laju angin. Data ini dicatat setiap 10 menit dan dikirim nirkabel melalui koneksi Wi-Fi ke platform penyimpanan cloud, yaitu Google Spreadsheet.

Untuk memastikan proses pengiriman data secara langsung dari modul ESP32-S3 ke Google Spreadsheet, digunakan Serial Monitor yang ada di Arduino IDE. Tampilan Serial Monitor ini memberikan umpan balik langsung tentang pembacaan sensor dan kondisi pengiriman data, memastikan bahwa setiap paket data telah sukses dikirim ke platform cloud seperti yang ditunjukkan dalam gambar 4.1 di bawah.



GAMBAR 6  
(INFORMASI DATA YANG DI UPLOAD)

Proses pengumpulan data dilaksanakan selama periode 4 minggu dari 28 Mei 2025 hingga 27 Juni 2025. Pemanfaatan Google Spreadsheet sebagai basis data backend diambil karena kemudahan dalam penerapan, aksesibilitas cloud yang langsung, dan kemampuan untuk merekam data deret waktu secara efektif. Data yang dikumpulkan disimpan dalam format tabel dengan kolom yang ditentukan untuk setiap parameter cuaca serta stempel waktu (timestamp), memastikan data tersimpan dengan teratur dan siap untuk tahap pengolahan berikutnya. Contoh tampilan data yang telah tersimpan dengan sukses di Google Spreadsheet dapat dilihat pada Tabel 1

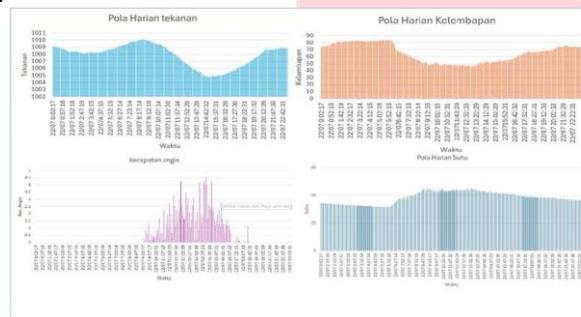
TABEL 1  
(TABEL DATA LAPORAN GOOGLE SPREADSHEET)

Minggu	Rata-rata Suhu (°C)	Rata-rata Kelembapan(%)	Rata-rata Tekanan (hPa)
--------	---------------------	-------------------------	-------------------------

1	29.8	77.33	1000.72
2	29.4	75.9	995.41
3	28.0	85.75	1000.05
4	28.1	75.0	997.52

#### A. Deskripsi dan karakteristik data

Kumpulan data yang mendasari penelitian ini mencakup parameter cuaca utama, yaitu suhu, kelembapan, tekanan atmosfer, dan kecepatan angin. Untuk mendapatkan pemahaman mengenai karakteristik data, dilakukan analisis deskriptif awal bertujuan untuk mengidentifikasi statistik dan pola waktu yang terdapat dalam data set. Pengamatan harian setiap parameter cuaca dilakukan untuk mengidentifikasi keberadaan tren periodik, seperti yang terlihat pada Gambar 4.2



GAMBAR 7  
(POLA HARIAN SETIAP PARAMETER)

#### B. Hasil perbandingan akurasi forecasting

Setelah pengambilan data dari dataset, dilakukan perbandingan menggunakan tiga model, yaitu: LSTM, BiLSTM, dan GRU, yang hasilnya ditampilkan pada tabel di bawah ini.

TABEL 2  
(HASIL PERBANDINGAN FORECASTING)

N o	Model	R <sup>2</sup> (suhu)	R <sup>2</sup> (kelem )	R <sup>2</sup> (tekanan )	R <sup>2</sup> (Kec.Angin )
1	LSTM	0.755 4	0.8678	0.5949	0.1797
2	BiLST M	0.722 6	0.2263	0.2411	-1.0901
3	GRU	0.823 9	0.7330	0.4267	-0.9078

TABEL 3  
(HASIL PERBANDINGAN FORECASTING)

N o	Model	MAE (suhu)	MAE (kelem )	MAE (tekanan )	MAE (Kec.Angin )
1	LSTM	0.997 0	3.2105	2.3505	1.7162
2	BiLST M	0.929 9	7.4918	3.1201	3.6072
3	GRU	0.809 8	5.0609	2.7560	3.4421

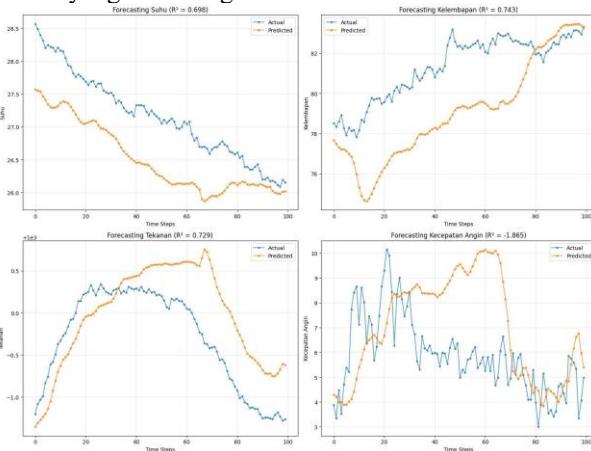
Melihat dari hasil yang diperoleh pada perbandingan di atas, yang menekankan pada prediksi dua parameter, karena nilai parameter tekanan dan kecepatan memang sulit diprediksi akibat perubahannya yang cepat, berbeda dengan suhu dan kelembapan yang memiliki pola harian.

Kembali ke hasil perbandingannya yang terfokus pada 2 parameter tersebut, LSTM menjadi model yang lebih tepat dibandingkan dengan 2 model lainnya secara keseluruhan.

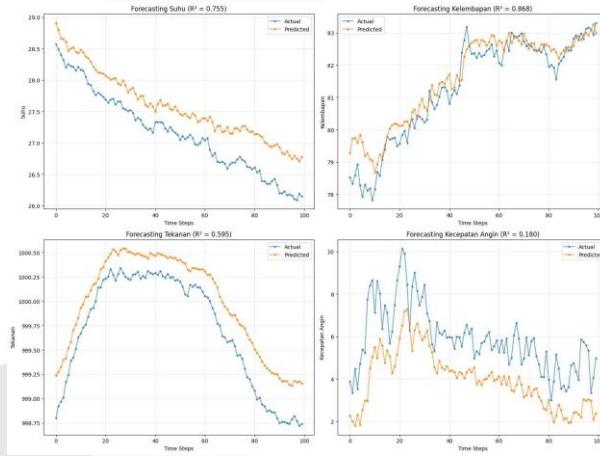
Walaupun GRU menunjukkan nilai R<sup>2</sup> dan MAE terbaik pada pengukuran suhu, LSTM memberikan kinerja yang lebih konsisten, khususnya dengan nilai R<sup>2</sup> sebesar 0.8678 dan MAE sebesar 3.2105 pada pengukuran kelembapan.

#### C. Hasil perbandingan model untuk forecasting

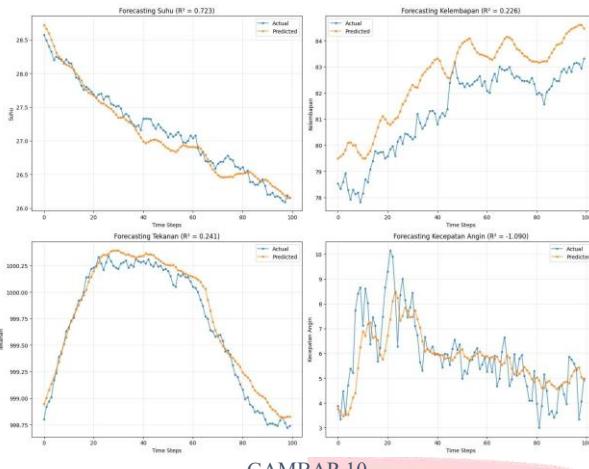
Perbandingan performa model forecasting dilakukan dengan membandingkan hasil dari prediksi pada data aktual. Data aktual pada setiap parameter cuaca dapat divisualkan dengan bentuk grafik time series dengan menggunakan 100 data terakhir, disertakan juga nilai R<sup>2</sup> sebagai indikasi seakurat apa model yang dibandingkan.



GAMBAR 8  
(DATA AKTUAL VS PREDIKSI MODEL GRU)



GAMBAR 9  
(DATA AKTUAL VS PREDIKSI MODEL LSTM)

GAMBAR 10  
(DATA AKTUAL VS PREDIKSI MODEL BiLSTM)

Secara umum, dari ketiga model yang telah dijelaskan sebelumnya, dapat disimpulkan bahwa model yang terlihat pada Gambar 4.4 yaitu LSTM memberikan hasil estimasi paling tepat dibandingkan dengan model-model yang ditampilkan pada gambar-gambar lain. Hal ini terlihat dari nilai  $R^2$  yang lebih tinggi dan positif untuk hampir semua variabel cuaca, serta representasi grafis yang menunjukkan bahwa prediksi model lebih mendekati data nyata. Karena itu, model yang ditunjukkan oleh LSTM diakui sebagai model paling efektif dalam memprediksi parameter cuaca berdasarkan dataset yang tersedia.

Selain itu pada penelitian ini juga membandingkan penggunaan Hyperparameter yang digunakan pada model yang bertujuan menghitung perbedaan antar model manakah yang bisa memberikan hasil R-squared yang lebih akurat saat tanpa menggunakan hyperparameter.

TABEL 4  
(TABEL MENGGUNAKAN HYPERPARAMETER)

No	Model	Suhu	Kelembapan	Tekanan	Kec.Angin
1	LSTM	0.755	0.8678	0.5949	0.1797
2.	BiLSTM	0.723	0.2263	0.2411	-1.0901
3.	GRU	0.698	0.7434	0.7293	-1.8652

TABEL 5  
(TABEL MENGGUNAKAN TANPA HYPERPARAMETER)

No	Model	Suhu	Kelembapan	Tekanan	Kec.Angin
1	LSTM	0.7214	0.4381	0.3198	-1.4186
2.	BiLSTM	0.2704	0.5850	0.2668	-1.3627
3.	GRU	0.8338	0.5807	0.4918	-0.2209

Berdasarkan analisis dari dua tabel, penyetelan hyperparameter menunjukkan pengaruh yang berbeda-beda terhadap performa model LSTM, BiLSTM, dan GRU. Secara umum, penyempurnaan dapat meningkatkan kinerja model, yang terlihat dari nilai R-squared yang lebih tinggi, terutama pada parameter suhu dan kelembapan.

Akan tetapi, hasilnya tidak selalu stabil. Pada model GRU, penyesuaian berhasil meningkatkan R-squared untuk tekanan, tetapi malah menurunkannya untuk suhu. Di sisi

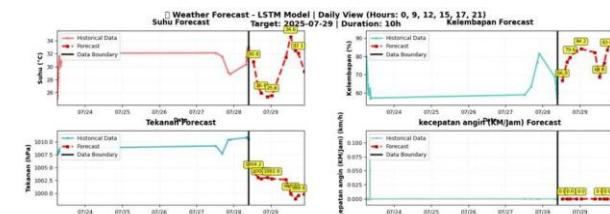
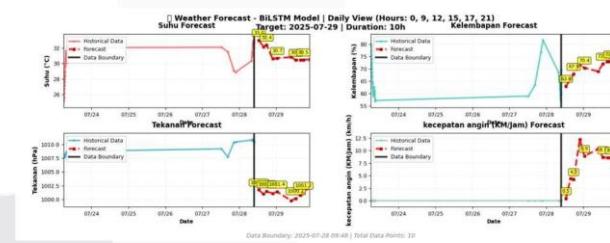
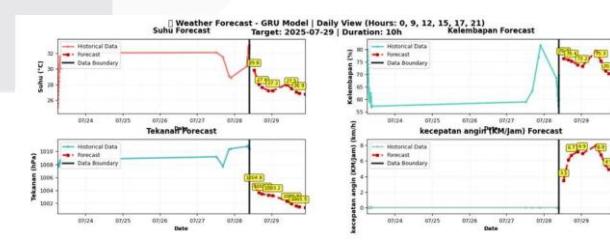
lain, model BiLSTM menunjukkan hasil yang tidak terlalu signifikan, dengan penurunan kinerja pada parameter kelembapan setelah penyesuaian.

Dengan demikian, walaupun penyesuaian hyperparameter bisa menjadi cara yang efisien untuk meningkatkan kinerja model, langkah ini perlu dilakukan dengan hati-hati

## B. ANALISIS DAN PEMBAHASAN

Dalam penelitian ini, proses prediksi dilakukan secara bertahap untuk meramalkan nilai suhu, kelembapan, tekanan, dan kecepatan angin pada jam atau tanggal yang ditentukan oleh pengguna. Saat pengguna menetapkan tanggal target, aplikasi akan menghitung berapa jam yang tersisa dari data terakhir yang ada hingga waktu target tersebut.

Selanjutnya, model (LSTM, BiLSTM, atau GRU) akan menjalankan prediksi secara bertahap. Setiap tahap prediksi menggunakan data historis dari 48 jam terakhir yang telah diproses dan dinormalisasi, dan hasil prediksi pada satu jam akan dijadikan input untuk prediksi jam berikutnya. Prosedur ini diulang hingga waktu yang ditentukan tercapai. Setiap hasil prediksi tidak hanya memberikan nilai temperatur, kelembapan, dan tekanan, namun juga mempertimbangkan fitur waktu untuk memungkinkan model menangkap pola musiman dan harian.

GAMBAR 11  
(FORECASTING MENGGUNAKAN MODEL LSTM BEDASARKAN HARI)GAMBAR 12  
(FORECASTING MENGGUNAKAN MODEL BiLSTM BEDASARKAN HARI)GAMBAR 13  
(FORECASTING MENGGUNAKAN MODEL GRU BEDASARKAN HARI)

Hasil dari implementasi forecasting visual menunjukkan bahwa model GRU memiliki kinerja terbaik dalam memprediksi cuaca. Kelebihannya terletak pada stabilitas ramalan yang tetap dengan variabilitas yang sedang,

peralihan yang lancar dari data masa lalu ke data prediksi, serta konsistensi di antara variabel cuaca.

Sebaliknya, LSTM menunjukkan pola ramalan yang ekstrim dan ketidakteraturan mencolok, terutama pada parameter suhu dan kelembapan. Di sisi lain, BiLSTM terletak di antara kedua model, menunjukkan kestabilan yang baik meskipun masih terdapat beberapa perubahan.

Oleh sebab itu, GRU disarankan sebagai model dengan kinerja prediksi paling unggul karena kemampuannya menghasilkan proyeksi yang realistik dan konsisten

## V. KESIMPULAN

Penggunaan Sistem Stasiun Cuaca Mini Pintar berbasis IoT telah berhasil diterapkan untuk secara otomatis mengumpulkan data cuaca dengan mikrokontroler ESP32-S3, sensor BME280, dan anemometer. Data tersebut dikirim secara langsung ke Google Spreadsheet untuk disimpan. Analisis menunjukkan bahwa model Long Short-Term Memory (LSTM) efisien dalam metrik evaluasi seperti  $R^2$  dan MAE karena strukturnya yang rumit dapat beradaptasi dengan data historis. Namun, dalam hal visualisasi ramalan, model Gated Recurrent Unit (GRU) menunjukkan kinerja yang lebih baik, menghasilkan prediksi yang lebih konsisten dan masuk akal.

Perbedaan ini muncul akibat tujuan evaluasi yang tidak sama. LSTM menunjukkan keunggulan dalam ketepatan numerik (prediksi satu langkah), namun kompleksitasnya dapat mengakumulasi kesalahan dalam peramalan berkelanjutan, yang menyebabkan ketidakstabilan hasil prediksi. Sementara itu, desain GRU yang lebih ringkas menjadikannya lebih kebal terhadap gangguan pada data cuaca, sehingga menghasilkan prediksi yang lebih konsisten dan sesuai dengan pola visual

## REFERENSI

- [1] Tita Lattifia, Putu Wira Buana, and NI Kadek Dwi Rusjanyathi, "Model Prediksi Cuaca Menggunakan Metode LSTM," JITTER-Jurnal Ilmiah Teknologi dan Komputer, vol. 3, no. 1, 2022.
- [2] Y. E. N. Nugraha, I. Ariawan, and W. A. Arifin, "Weather Forecast From Time Series Data Using Lstm Algorithm," 2023. doi: 10.51903/jtikp.v14i1.531.
- [3] K. Ioannou, D. Karmpatzakis, P. Amanatidis, V. Aggelopoulos, and I. Karmiris, "Low-cost automatic weather stations in the internet of things," Information (Switzerland), vol. 12, no. 4, pp. 1–21, 2021, doi: 10.3390/info12040146.
- [4] E. Supriyadi, "Prediksi Parameter Cuaca Menggunakan Deep Learning Long-Short Term Memory (LSTM) Weather Parameters Prediction Using Deep Learning Long-Short Term Memory (LSTM)," Jurnal Meteorologi Dan Geofisika, vol. 21, no. 21, pp. 56–59, 2019, [Online]. Available: <http://bmkgsoft.database.bmkg.go.id>.
- [5] L. Chen et al., "FuXi: a cascade machine learning forecasting system for 15-day global weather forecast," NPJ Clim Atmos Sci, vol. 6, no. 1, pp. 1–11, 2023, doi: 10.1038/s41612-023-00512-1.
- [6] I. Salehin, I. M. Talha, M. Mehedi Hasan, S. T. Dip, M. Saifuzzaman, and N. N. Moon, "An Artificial Intelligence Based Rainfall Prediction Using LSTM and Neural Network," Proceedings of 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering, WIECON-ECE 2020, pp. 5–8, 2020, doi: 10.1109/WIECON-ECE52138.2020.9398022.
- [7] R. Farikhul Firdaus and I. V. Paputungan, "Prediksi Curah Hujan di Kota Bandung Menggunakan Metode Long Short Term Memory," 2022. doi: 10.54082/jupin.99.
- [8] K. chao Miao et al., "Application of LSTM for short term fog forecasting based on meteorological elements," Neurocomputing, vol. 408, pp. 285–291, 2020, doi: 10.1016/j.neucom.2019.12.129.
- [9] W. Fang, Y. Chen, and Q. Xue, "Survey on Research of RNN-Based Spatio-Temporal Sequence Prediction Algorithms," Journal on Big Data, vol. 3, no. 3, pp. 97–110, 2021, doi: 10.32604/jbd.2021.016993.
- [10] A. F. Pauzi and M. Z. Hasan, "Development of IoT Based Weather Reporting System," IOP Conf Ser Mater Sci Eng, vol. 917, no. 1, 2020, doi: 10.1088/1757-899X/917/1/012032.
- [11] Q. Wen et al., "Time Series Data Augmentation for Deep Learning: A Survey," IJCAI International Joint Conference on Artificial Intelligence, pp. 4653–4660, 2021, doi: 10.24963/ijcai.2021/631.
- [12] L. Zhang, Z. Huang, W. Liu, Z. Guo, and Z. Zhang, "Weather radar echo prediction method based on convolution neural network and Long Short-Term memory networks for sustainable e-agriculture," J Clean Prod, vol. 298, p. 126776, 2021, doi: 10.1016/j.jclepro.2021.126776.
- [13] S. Aburass, O. Dorgham, and J. Al Shaqsi, "A hybrid machine learning model for classifying gene mutations in cancer using LSTM, BiLSTM, CNN, GRU, and GloVe," Systems and Soft Computing, vol. 6, no. August 2023, p. 200110, 2024, doi: 10.1016/j.sasc.2024.200110.
- [14] A. Al Hamoud, A. Hoenig, and K. Roy, "Sentence subjectivity analysis of a political and ideological debate dataset using LSTM and BiLSTM with attention and GRU models," Journal of King Saud University - Computer and Information Sciences, vol. 34, no. 10, pp. 7974–7987, 2022, doi: 10.1016/j.jksuci.2022.07.014.
- [15] B. C. Mateus, M. Mendes, J. T. Farinha, R. Assis, and A. M. Cardoso, "Comparing LSTM and GRU models to predict the condition of a pulp paper press," Energies (Basel), vol. 14, no. 21, pp. 1–21, 2021, doi: 10.3390/en14216958.
- [16] D. Chicco, M. J. Warrens, and G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," pp. 1–24, 2021, doi: 10.7717/peerj.cs.623.
- [17] Anita S and Cahyono N, "Penerapan Bi-Lstm dengan Optimizer ADAM dan Word2vec Untuk Analisis Sentimen," Ejournal.Katersipublisher.Com, vol. 1, no. 2, pp. 35–39, 2024.