

## **BAB I**

### **PENDAHULUAN**

Bab ini berisi penjelasan umum mengenai latar belakang dan dasar pemikiran yang melandasi dilaksanakannya penelitian. Pendahuluan bertujuan untuk memberikan gambaran menyeluruh tentang permasalahan yang diteliti, tujuan yang ingin dicapai, serta manfaat yang diharapkan dari hasil penelitian.

#### **1.1. Latar Belakang**

Dalam beberapa tahun terakhir, kualitas udara di berbagai kota besar di Indonesia, menunjukkan tren yang mengkhawatirkan akibat tingginya konsentrasi partikel debu halus di atmosfer. Salah satu parameter utama yang digunakan untuk mengukur tingkat pencemaran udara adalah Particulate Matter berukuran 10 mikrometer ( $PM_{10}$ ).  $PM_{10}$  merupakan partikel udara berukuran kecil yang dapat terhirup hingga saluran pernapasan bagian bawah dan menyebabkan gangguan kesehatan serius seperti gangguan paru-paru, jantung, hingga kematian dini, terutama pada kelompok rentan seperti anak-anak dan lansia [1].

Menurut Peraturan Menteri Lingkungan Hidup dan Kehutanan Republik Indonesia No. 14 Tahun 2020 tentang Indeks Standar Pencemar Udara (ISPU),  $PM_{10}$  termasuk dalam enam parameter utama yang digunakan dalam perhitungan indeks kualitas udara. Namun, berbagai studi menunjukkan bahwa  $PM_{10}$  sering kali menjadi parameter dominan dalam menentukan kategori ISPU, karena tingkat perubahan dan lonjakan konsentrasinya yang lebih signifikan dibanding parameter lain. Suryati et al. (2018) [2] menemukan bahwa di Kota Medan, nilai ISPU berbasis  $PM_{10}$  dapat mencapai kategori “tidak sehat”, sementara parameter lain tetap dalam kategori “baik” hingga “sedang”. Penelitian lain oleh Agista et al. (2021) [3] juga menunjukkan bahwa dalam penelitian di DKI Jakarta, hanya parameter  $PM_{10}$  dan  $O_3$  yang melampaui nilai ambang batas, sedangkan polutan lain seperti  $SO_2$ ,  $NO_2$ , dan  $CO$  tetap berada pada batas aman, menunjukkan dominasi  $PM_{10}$  dalam menentukan ISPU. Selain itu, Perdama et al. (2023) [4] menyatakan bahwa Bundaran HI merupakan AQMS pertama di Jakarta dan ditempatkan secara strategis di kawasan dengan aktivitas lalu lintas dan pusat bisnis yang sangat padat. Data Februari–Oktober 2021 menunjukkan bahwa

konsentrasi PM<sub>10</sub> di Bundaran HI sebagian besar berada pada kategori sedang, sehingga menjadikannya lokasi yang relevan dan ideal untuk penelitian prediksi PM<sub>10</sub>

Selain menjadi parameter dominan dalam ISPU, konsentrasi PM<sub>10</sub> juga dipengaruhi oleh faktor meteorologi. Karena itu, penelitian ini menggunakan suhu, kelembaban, dan kecepatan angin sebagai variabel independen. Gea et al. [5] menyatakan bahwa suhu tinggi membuat udara lebih panas dan kering sehingga partikulat lebih mudah terangkat. Kelembaban yang tinggi memperlambat dispersi akibat meningkatnya uap air sehingga PM<sub>10</sub> lebih mudah terakumulasi. Sementara itu, kecepatan angin menentukan penyebaran partikulat, di mana angin kencang menurunkan konsentrasi PM<sub>10</sub> dan angin lemah menyebabkan penumpukan. Girotti et al. (2025) [6] menjelaskan bahwa perubahan kondisi atmosferik seperti stabilitas lapisan atmosfer dan arah angin dapat mempengaruhi akumulasi PM<sub>10</sub> di wilayah perkotaan. Oleh karena itu, prediksi konsentrasi PM<sub>10</sub> yang akurat sangat penting sebagai dasar pengambilan keputusan dalam kebijakan mitigasi pencemaran udara, peringatan dini, serta perlindungan kesehatan masyarakat.

Hamdan et al. [7] menunjukkan bahwa model LSTM mampu memprediksi emisi gas rumah kaca dan suhu global dengan tingkat akurasi yang tinggi, yang dapat membantu dalam perencanaan mitigasi perubahan iklim. Selain itu, Li [8] mengkaji beberapa model statistik dan pembelajaran mesin dan menemukan bahwa LSTM memberikan performa terbaik dalam prediksi harian emisi CO<sub>2</sub> dengan nilai R<sup>2</sup> sebesar 0,9844, mengungguli model lain seperti ARIMA dan regresi linear. Model Long Short-Term Memory (LSTM) merupakan salah satu arsitektur jaringan saraf tiruan yang efektif untuk memproses data deret waktu. Namun, dalam penelitian ini digunakan varian Bidirectional LSTM (Bi-LSTM), yang memiliki kemampuan untuk membaca urutan data dari dua arah waktu (maju dan mundur), sehingga menghasilkan konteks yang lebih lengkap dalam memahami pola data ISPU.

Namun, kendala utama dalam penggunaan Bidirectional LSTM adalah sensitivitasnya terhadap parameter dan risiko overfitting yang dapat mengurangi kemampuan generalisasi model. Untuk itu, penggunaan algoritma optimasi metaheuristik seperti Moth Flame Optimization (MFO) menjadi alternatif yang menjanjikan untuk mengoptimalkan hiperparameter model Bi-LSTM. Wang et al. [9] mengembangkan model hibrida yang menggabungkan MFO dengan Extreme Learning Machine (ELM), menghasilkan prediksi emisi CO<sub>2</sub> yang sangat akurat

dengan nilai  $R^2$  mencapai 96,5%. Studi ini menunjukkan bahwa MFO efektif dalam menemukan konfigurasi parameter yang optimal sehingga meningkatkan performa model prediksi.

Selain pengembangan dengan optimasi parameter, model Bi-LSTM dapat ditingkatkan lebih lanjut dengan mengintegrasikan *attention mechanism*, yang telah terbukti meningkatkan akurasi dalam banyak studi prediksi data deret waktu. Attention memungkinkan model untuk memberi bobot lebih besar pada langkah waktu yang paling relevan, sehingga mampu menangkap informasi penting dalam urutan data dan memperkuat memori jangka panjang [10]. Penelitian Guo et al. (2025) dan Hao et al. (2022) menunjukkan bahwa integrasi attention mechanism dalam BiLSTM menghasilkan peningkatan akurasi signifikan dalam prediksi curah hujan dan suhu atmosfer, dibandingkan dengan model tanpa attention [11]. Penelitian dari Zhang et al. [12] juga mencoba menggunakan model hybrid LSTM-SSA untuk memprediksi emisi CO<sub>2</sub> dan melaporkan peningkatan signifikan dalam akurasi dibandingkan LSTM tanpa optimasi. Chen et al. [13] mengaplikasikan PSO untuk mengoptimalkan parameter LSTM dalam memprediksi emisi CO<sub>2</sub>, menghasilkan pengurangan kesalahan prediksi yang substansial dan kestabilan model yang lebih baik. Namun, meskipun pendekatan ini berhasil, penggunaan langsung MFO sebagai algoritma optimasi dalam kombinasi dengan Bi-LSTM untuk prediksi kadar udara masih belum banyak dieksplorasi.

Penggunaan attention mechanism telah terbukti secara signifikan meningkatkan akurasi model prediktif, khususnya pada kasus data time-series kompleks seperti suhu dan kualitas udara, termasuk momen-momen terjadinya lonjakan konsentrasi PM<sub>10</sub> yang bersifat ekstrem dan berdampak signifikan terhadap kualitas udara [14]. Attention mechanism memberikan bobot dinamis pada urutan waktu yang paling relevan, sehingga memungkinkan model mempelajari korelasi jangka panjang secara lebih efektif [15].

Untuk memperoleh hasil prediksi yang optimal, penelitian ini mengembangkan model BiLSTM, kemudian menambahkan mekanisme attention (BiLSTM-Attention) guna memberikan fokus lebih pada informasi yang relevan. Proses ini dilengkapi dengan optimasi hyperparameter secara otomatis menggunakan algoritma MFO, yang efektif dalam mencari konfigurasi terbaik pada ruang parameter yang luas dan kompleks [16]. MFO mampu menyeimbangkan proses eksplorasi dan eksloitasi

dalam pencarian solusi optimal, seperti penentuan jumlah neuron dan nilai learning rate, yang berpengaruh besar terhadap kinerja model deep learning [9].

Pendekatan ini diharapkan dapat menghasilkan model prediksi yang akurat, stabil, dan andal dalam memetakan pola konsentrasi PM<sub>10</sub>, serta menjadi alat bantu yang efektif untuk mendukung pengambilan keputusan dalam kebijakan mitigasi pencemaran udara.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang tersebut, maka dapat diambil rumusan masalah sebagai berikut :

1. Sejauh mana model Bi-LSTM dengan mekanisme *attention* mampu memprediksi konsentrasi PM<sub>10</sub> secara akurat?
2. Bagaimana peran algoritma Moth Flame Optimization (MFO) dalam mengoptimalkan hiperparameter model BiLSTM-Attention untuk prediksi konsentrasi PM<sub>10</sub>?
3. Apakah penerapan model BiLSTM-Attention yang dioptimasi menggunakan MFO mampu meningkatkan akurasi prediksi konsentrasi PM<sub>10</sub> dibandingkan dengan model BiLSTM-Attention tanpa optimasi?

## 1.3. Tujuan Penelitian

Berdasarkan rumusan masalah tersebut, maka penelitian ini memiliki tujuan sebagai berikut :

1. Mengembangkan model prediksi konsentrasi PM<sub>10</sub> berbasis BiLSTM-Attention yang mampu menangkap pola temporal pada data deret waktu kualitas udara.
2. Menerapkan algoritma Moth Flame Optimization (MFO) untuk mengoptimalkan hiperparameter model BiLSTM-Attention, yaitu jumlah neuron, *dropout* dan *learning rate*.
3. Mengevaluasi performa tiga model, yaitu BiLSTM, BiLSTM-Attention, dan BiLSTM-Attention-MFO, dalam memprediksi konsentrasi PM<sub>10</sub> dengan menggunakan metrik evaluasi MAE, RMSE, MAPE, dan R<sup>2</sup>.

#### **1.4. Manfaat Penelitian**

Dengan dilakukannya penelitian ini, berbagai manfaat dapat diperoleh, sebagai berikut :

1. Memberikan kontribusi dalam pengembangan model hybrid berbasis BiLSTM-Attention dan algoritma Moth Flame Optimization (MFO) untuk prediksi konsentrasi PM<sub>10</sub> pada data deret waktu kualitas udara.
2. Menjadi referensi akademik dalam integrasi algoritma optimasi MFO dengan model BiLSTM-Attention dalam konteks prediksi PM<sub>10</sub>, yang masih terbatas dijelajahi dalam penelitian-penelitian sebelumnya.
3. Memberikan solusi prediktif yang akurat dan efisien dalam memproyeksikan tren konsentrasi PM<sub>10</sub>, sehingga dapat dimanfaatkan oleh lembaga lingkungan hidup dan membuat kebijakan untuk mendukung sistem peringatan dini serta strategi mitigasi pencemaran udara.
4. Mendukung upaya peningkatan kualitas lingkungan hidup secara berkelanjutan melalui pemanfaatan pendekatan teknologi berbasis kecerdasan buatan yang adaptif dan modern.

#### **1.5. Batasan Masalah**

Penelitian ini memiliki beberapa batasan masalah dalam melakukan penelitian, sebagai berikut :

1. Hanya berfokus pada prediksi konsentrasi PM<sub>10</sub> sebagai salah satu parameter utama pencemar udara.
2. Proses optimasi model BiLSTM-Attention dilakukan menggunakan algoritma Moth Flame Optimization (MFO) dengan tujuan mengoptimalkan hiperparameter model, yaitu jumlah neuron, dropout, dan learning rate.
3. Hanya fokus pada efektivitas MFO terhadap peningkatan performa BiLSTM-Attention.
4. Evaluasi performa model dilakukan menggunakan metrik evaluasi Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), dan koefisien determinasi ( $R^2$ ).