

PREDIKSI POLUSI UDARA BERDASARKAN TINGKAT CURAH HUJAN MENGGUNAKAN MODEL LSTM, BILSTM DAN PROPHET

Nuraina^{1*}, Erwin Setiawan Panjaitan², Sofiana Nurjanah³

^{1,2,3}Program Studi Magister Teknologi Informasi, Universitas Mikroskil

Email: ^{1*}204212080@students.mikroskil.ac.id, ²erwin@mikroskil.ac.id,

³sofiana.nurjanah@mikroskil.ac.id

Abstract: *The city of Jakarta, as the center of Indonesia's economic life and growth, continues to experience an astonishing population surge, reaching 11,248,839 people by 2024. However, this growth is inseparable from negative consequences, such as increased activity and modernization, which significantly affect air quality. Air pollution, as a direct impact of these changes, has exceeded national air quality standards, endangering human, animal, and plant health. Understanding the relationship between air pollution and weather conditions is crucial in determining future control measures. In this study, we used the LSTM, BiLSTM, and Prophet models on air pollution data. The results show that the single BiLSTM model and the BiLSTM-Prophet hybrid model provide the best performance, with accuracy levels reaching 99.32% and 99.31%, respectively. These findings provide a solid basis for forecasting and controlling potential future air pollution levels, as well as identifying key factors contributing to air quality in the capital city.*

Keyword: *Air Pollution, LSTM, BiLSTM, Prophet, Rainfall*

Abstrak: Kota Jakarta, sebagai pusat kehidupan dan pertumbuhan ekonomi Indonesia, terus mengalami lonjakan penduduk yang menakjubkan, mencapai 11.248.839 orang pada tahun 2024. Namun, pertumbuhan ini tidak terlepas dari konsekuensi negatif, seperti peningkatan aktivitas dan modernisasi, yang secara signifikan mempengaruhi kualitas udara. Polusi udara, sebagai dampak langsung dari perubahan ini, telah melampaui standar kualitas udara nasional, membahayakan kesehatan manusia, hewan, dan tumbuhan. Memahami hubungan antara polusi udara dan kondisi cuaca sangat penting dalam menentukan langkah-langkah pengendalian di masa depan. Dalam penelitian ini, kami menggunakan model LSTM, BiLSTM, dan Prophet pada data polusi udara. Hasil penelitian menunjukkan bahwa model tunggal BiLSTM dan model hybrid BiLSTM-Prophet memberikan kinerja terbaik, dengan tingkat akurasi masing-masing mencapai 99,32% dan 99,31%. Temuan ini memberikan dasar yang kuat untuk memperkirakan dan mengendalikan potensi tingkat polusi udara di masa depan, serta mengidentifikasi faktor-faktor kunci yang berkontribusi terhadap kualitas udara di ibu kota.

Kata kunci: Polusi udara, LSTM, BiLSTM, Prophet, Curah hujan

PENDAHULUAN

[1] [2]Polusi udara adalah pencemaran atmosfer sekitarnya akibat keberadaan bahan kimia, gas, atau partikulat. Kualitas udara umumnya dinilai dari

konsentrasi parameter polusi udara yang diukur lebih tinggi atau lebih rendah dari nilai Standar Kualitas Udara Ambien Nasional. Paparan lingkungan terhadap polusi udara dipelajari secara luas karena sifatnya yang ada di mana-mana. Polusi

udara memiliki efek merugikan pada kesehatan manusia, termasuk peningkatan risiko penyakit kardiovaskular dan pernapasan seperti asma dan penyakit paru obstruktif kronis (PPOK). Misalnya, salah satu partikulat halus (PM_{2.5}) dan polutan udara dapat menembus jauh ke dalam paru-paru dan masuk ke dalam aliran darah, menyebabkan peradangan dan stres oksidatif, yang dapat berkontribusi pada perkembangan berbagai masalah kesehatan, bahkan saat ini beban penyakit yang disebabkan oleh polusi udara diperkirakan berada pada tingkat yang sebanding dengan risiko kesehatan global utama seperti pola makan atau pola makan yang tidak sehat dan merokok tembakau. Contoh lain adalah polutan NO_x dan Sox mempengaruhi kesuburan tanaman, tetapi paparan PM dan/atau O₃ di permukaan tanah menunjukkan dampak yang lebih merugikan pada vegetasi. Hal ini disebabkan oleh sumber alami, seperti debu dan asap dari kebakaran dan gunung berapi, serta aktivitas manusia, termasuk penggunaan bahan bakar dan proses industri [3], [4], [5], [6], [7], [8].

[9], [10] Penelitian tentang hubungan antara curah hujan, lalu lintas kendaraan dan konsentrasi polusi udara dilakukan di Seoul, Korea dengan menggunakan analisis jalur. Hasil penelitian menunjukkan bahwa curah hujan secara langsung memiliki efek pencucian sehingga dapat mengurangi konsentrasi polutan, tetapi juga memiliki efek tidak langsung ketika hujan deras visibilitas pengemudi menurun, menyebabkan kendaraan berjalan lambat dan menghasilkan konsentrasi polutan yang lebih tinggi. Studi lain juga membahas hubungan antara polusi udara dan kondisi cuaca, seperti curah hujan, suhu, kelembaban, dan arah angin menggunakan berbagai metode penelitian, seperti analisis statistik, pemodelan numerik, dan eksperimen. Curah hujan dapat menurunkan kualitas udara dengan melarutkan polutan dan membawanya ke permukaan tanah. Suhu tinggi dapat meningkatkan kualitas udara dengan

mempercepat reaksi kimia yang dapat memecah polutan. Kelembaban tinggi dapat meningkatkan kualitas udara dengan mengikat polutan dan mencegahnya menyebar ke atmosfer. Arah angin dapat mempengaruhi dispersi polutan di atmosfer [11], [12], [13].

Berangkat dari penelitian yang mengusulkan pendekatan dengan menggabungkan empat model berbeda yaitu Prophet, SARIMA, SVR, dan LSTM untuk meningkatkan akurasi prediksi data deret waktu dengan hasil pengujian yang menemukan bahwa akurasi model hybrid LSTM-Prophet dalam membuat prediksi adalah 99,74% dengan akurasi yang masuk dalam kategori sangat baik dibandingkan 3 model lainnya, Penelitian ini juga memberikan rencana tindak lanjut untuk menambah fitur cuaca dan faktor lingkungan lainnya sehingga dapat membantu meningkatkan akurasi prediksi. Mengingat hasil penelitian dan harapan bahwa integrasi data yang semakin kompleks diharapkan dapat membantu mengidentifikasi pola dan hubungan yang lebih kompleks dalam memprediksi pemahaman hubungan antara polusi udara dan kondisi cuaca, penting untuk dilakukan dalam upaya memperkirakan potensi tingkat polusi di masa depan untuk menyiapkan langkah-langkah pengendalian pencemaran udara. Proses pemahaman dapat dilakukan dengan melakukan analisis prediktif data deret waktu dari kumpulan data polusi udara dan kumpulan data curah hujan yang disimpan dari waktu ke waktu menggunakan model Hybrid Long Sort-Term Model (LSTM), Bidirectional Long Sort-Term Model (BiLSTM) dan model Prophet yang telah teruji cocok digunakan dalam penelitian prediksi data deret waktu [14], [15].

Polusi Udara

Polusi udara adalah kondisi ketika zat pencemar berada di atmosfer dalam konsentrasi yang melebihi batas normal sehingga berdampak negatif terhadap kesehatan manusia, makhluk hidup, dan

lingkungan. Peningkatan polusi udara umumnya disebabkan oleh aktivitas manusia seperti industri, transportasi, dan urbanisasi, meskipun faktor alami seperti kebakaran hutan dan badai debu juga berkontribusi.

Polutan udara berperan dalam perubahan iklim melalui efek rumah kaca dan keberadaan aerosol yang memengaruhi radiasi matahari serta pembentukan awan. Dampak polusi udara antara lain gangguan sistem pernapasan, hujan asam, peningkatan ozon permukaan, serta kerusakan ekosistem. Partikulat halus (PM_{2.5}) menjadi perhatian utama karena dapat masuk ke dalam paru-paru dan aliran darah serta terbawa jarak jauh di atmosfer.

Menurut Badan Perlindungan Lingkungan (EPA), enam polutan utama yang sering digunakan sebagai indikator kualitas udara adalah materi partikulat (PM), nitrogen dioksida (NO₂), ozon (O₃), sulfur dioksida (SO₂), timbal (Pb), dan karbon monoksida (CO). Polutan-polutan tersebut sebagian besar dihasilkan dari pembakaran bahan bakar fosil dan aktivitas industri serta memiliki dampak signifikan terhadap kesehatan dan lingkungan.

Prediksi Polusi Udara

Mirip dengan peramalan cuaca, ada model untuk memprediksi tingkat polusi udara dan kualitas udara. Ada banyak model prakiraan yang membutuhkan lebih banyak kompleksitas daripada model prakiraan cuaca. Model-model ini adalah simulasi matematis tentang bagaimana polutan udara menyebar di udara [16].

Prediksi polusi udara dianggap sebagai investasi yang berguna di berbagai tingkatan, mulai dari individu hingga global. Prediksi yang akurat dapat membantu orang untuk merencanakan, mengurangi dampak kesehatan, dan menghemat biaya. Ketika orang menyadari variasi kualitas udara yang mereka hirup, efek polutan pada kesehatan mereka, dan konsentrasi yang dapat menyebabkan efek samping, mereka lebih mungkin untuk mengubah

perilaku mereka dan menuntut kebijakan publik yang lebih baik. Kesadaran ini dapat menciptakan lingkungan yang lebih bersih dan populasi yang lebih sehat. Pemerintah juga menggunakan prediksi polusi udara untuk menetapkan prosedur yang dapat mengurangi keparahan polusi udara [17].

Tingkat konsentrasi polutan udara dapat berubah secara dinamis dipengaruhi oleh berbagai faktor, seperti aktivitas manusia, kondisi meteorologi, dan curah hujan. Variasi tersebut membentuk pola deret waktu (time series) yang dapat dianalisis dan diprediksi menggunakan metode statistik maupun machine learning. Prediksi kualitas udara menjadi penting karena dapat membantu dalam perencanaan mitigasi dampak polusi serta pengambilan keputusan berbasis data.

Dalam beberapa tahun terakhir, pendekatan berbasis deep learning, khususnya Long Short-Term Memory (LSTM) dan Bidirectional Long Short-Term Memory (BiLSTM), banyak digunakan untuk prediksi deret waktu karena kemampuannya dalam menangkap pola temporal dan dependensi jangka panjang pada data. Selain itu, metode Prophet juga sering digunakan dalam peramalan time series karena mampu menangani tren, musiman, dan perubahan pola secara fleksibel dengan proses pemodelan yang relatif sederhana.

Dengan memanfaatkan metode-metode tersebut, penelitian mengenai prediksi konsentrasi polutan udara dapat memberikan gambaran mengenai kecenderungan kualitas udara di masa mendatang. Informasi ini diharapkan dapat mendukung upaya pemantauan lingkungan serta perumusan kebijakan yang berkaitan dengan pengendalian pencemaran udara.

Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu jenis Recurrent Neural Network (RNN) yang dirancang untuk mengatasi permasalahan vanishing gradient dan kesulitan RNN dalam menangkap dependensi jangka panjang.

LSTM memiliki kemampuan menyimpan informasi dalam jangka waktu yang lebih lama melalui mekanisme sel memori (memory cell) dan gerbang (gates) yang mengatur aliran informasi.

Struktur LSTM terdiri dari tiga komponen utama, yaitu **forget gate**, **input gate**, dan **output gate**. Forget gate berfungsi menentukan informasi yang perlu dibuang dari memori, input gate mengatur informasi baru yang ditambahkan, sedangkan output gate menentukan informasi yang akan dikeluarkan sebagai hasil. Mekanisme ini memungkinkan LSTM mempelajari pola temporal secara lebih efektif, sehingga banyak digunakan dalam pemodelan data deret waktu dan prediksi.

Bidirectional Long Short-Term Memory (BiLSTM)

Bidirectional Long Short-Term Memory (BiLSTM) merupakan pengembangan dari LSTM yang menggunakan dua lapisan LSTM, yaitu forward dan backward. Arsitektur ini memungkinkan model memproses data dari dua arah, sehingga informasi dari masa lalu dan masa depan dapat dimanfaatkan secara bersamaan.

Kemampuan tersebut membuat BiLSTM lebih efektif dalam memahami pola pada data deret waktu dibandingkan LSTM satu arah, terutama pada data yang memiliki keterkaitan konteks yang kuat antar waktu. Oleh karena itu, BiLSTM banyak digunakan dalam berbagai aplikasi seperti pengenalan suara, pemrosesan bahasa alami, klasifikasi deret waktu, dan prediksi.

Prophet

Prophet merupakan metode peramalan deret waktu yang dikembangkan oleh tim Data Science Facebook dan dirancang untuk memodelkan data time series menggunakan pendekatan model aditif. Model ini menggabungkan beberapa komponen utama, yaitu tren, musiman, efek khusus (seperti hari libur atau kejadian tertentu), dan komponen kesalahan.

Prophet memiliki keunggulan dalam menangani data yang memiliki pola musiman kuat, data yang hilang, serta perubahan tren. Selain itu, metode ini relatif mudah digunakan dan efektif untuk peramalan data deret waktu dengan karakteristik tren non-linear, sehingga banyak diterapkan dalam berbagai studi prediksi.

Penelitian Terdahulu

Peramalan data deret waktu univariat polusi udara menggunakan jaringan saraf LSTM telah dieksplorasi dalam beberapa makalah. Hamami dan Dahlan mengusulkan model jaringan saraf menggunakan LSTM untuk memperkirakan konsentrasi polusi udara, termasuk PM10, SO₂, CO, O₃, dan NO₂ [18]. Alhirmizy dan Qader menggunakan LSTM untuk meramalkan kualitas udara Madrid, dengan mempertimbangkan beberapa variabel *input* seperti SO₂, NO₂, NO, dan CO [19]. Peng, Bychkov, Liu, dan Hmelnov mengusulkan model Attention-CNN-LSTM untuk peramalan konsentrasi polutan udara, menggabungkan variabel autokorelasi spasial dan ketergantungan temporal [20]. Belavadi, Rajagopal, R, dan Mohan menggunakan model RNN LSTM untuk memperkirakan konsentrasi polutan udara di kota Bengaluru, memanfaatkan data dari jaringan sensor nirkabel dan inisiatif Data Terbuka Pemerintah India [21]. Makalah ini menunjukkan efektivitas jaringan saraf LSTM dalam meramalkan konsentrasi polusi udara.

Model dua arah dianalisis untuk memprediksi tingkat polusi udara di beberapa makalah. Model dua arah ditemukan memberikan hasil yang lebih baik dan dipilih untuk analisis lebih lanjut di salah satu makalah [22]. Makalah lain juga menggunakan model dua arah untuk memprediksi tingkat kualitas udara di Delhi dan menemukan bahwa pendekatan yang mereka usulkan mengungguli beberapa metode dasar [23]. Selain itu, sebuah makalah menggunakan model memori jangka pendek dua arah untuk memperkirakan tingkat polutan PM_{2.5}

dan menemukan bahwa model yang mereka usulkan memiliki akurasi yang lebih besar dibandingkan dengan model yang ada [24].

LSTM, LSTM dua arah, dan Prophet semuanya digunakan untuk prediksi data deret waktu. LSTM adalah metode pembelajaran mendalam yang telah banyak digunakan untuk prediksi akurat data deret waktu [25]. LSTM dua arah (BiLSTM) adalah perpanjangan dari LSTM yang mempertimbangkan konteks masa lalu dan masa depan, memungkinkan ketergantungan jangka panjang yang lebih baik dalam data [26]. Prophet adalah model prediksi hibrida yang menggabungkan algoritma Prophet dengan LSTM untuk menangkap fitur periodik dan dependensi temporal dalam data, menghasilkan akurasi prediksi yang lebih baik [27].

Berdasarkan penjabaran atas penelitian sejenis terdahulu, maka kontribusi dari penelitian ini adalah melakukan prediksi tingkat polusi udara berdasarkan curah hujan dengan model hybrid LSTM-Prophet dan BiLSTM-Prophet. Penambahan curah hujan ditambahkan sebagai variabel karna beberapa penelitian menyatakan bahwa curah hujan terbukti memberikan efek pencucian pada polusi udara, sehingga akan mempengaruhi hasil prediksi polusi udara. Hasil prediksi diharapkan dapat membantu pemerintah ataupun masyarakat untuk dapat menyusun rencana penanggulangan atau pencegahan peningkatan polusi udara yang membahayakan manusia, hewan, dan juga lingkungan.

METODE

Analisis Masalah

Sepanjang studi literatur penulis, beberapa penelitian berfokus pada ruang lingkup prediksi jenis polutan PM (PM10 dan PM2.5) karena ini adalah jenis polutan yang cenderung memiliki efek buruk jika terhirup bagi kesehatan manusia, sementara yang lain memilih untuk melihat jenis polutan lain, yaitu, partikel (PM10), partikel (PM2.5), nitrogen dioksida (NO2), ozon (O3),

sulfur dioksida (SO₂), timbal (Pb), dan karbon monoksida (CO) dengan pengaruhnya terhadap banyak hal, seperti: kesehatan manusia, pertumbuhan/kesehatan tanaman atau daun tanaman, pengaruh cuaca dan iklim, hingga prediksi harga saham. Berbagai macam algoritma juga diterapkan, mulai dari algoritma tunggal hingga mencoba merancang model hybrid dengan menggabungkan kinerja model algoritma tunggal dari jenis pembelajaran yang diawasi / tanpa pengawasan, machine learning / deep learning. Semuanya dilakukan untuk melatih model sehingga menemukan model mana yang dapat bekerja paling baik dan menghasilkan tingkat akurasi prediksi terbaik. Namun, sejauh penulis melakukan studi literatur penelitian yang membahas perbandingan antara model LSTM-Prophet dan BiLSTM-Prophet untuk bidang analisis prediksi data deret waktu, belum ditemukan. Masing-masing model LSTM, Bidirectional LSTM, dan Prophet sering digunakan secara terpisah atau dipasangkan dengan model lain dan sering kali menunjukkan hasil yang lebih baik daripada model klasifikasi pembelajaran mesin. Penambahan fitur curah hujan dan kegiatan klasifikasi pra-prediksi dalam model deep learning juga diharapkan dapat meningkatkan tingkat akurasi model prediksi.

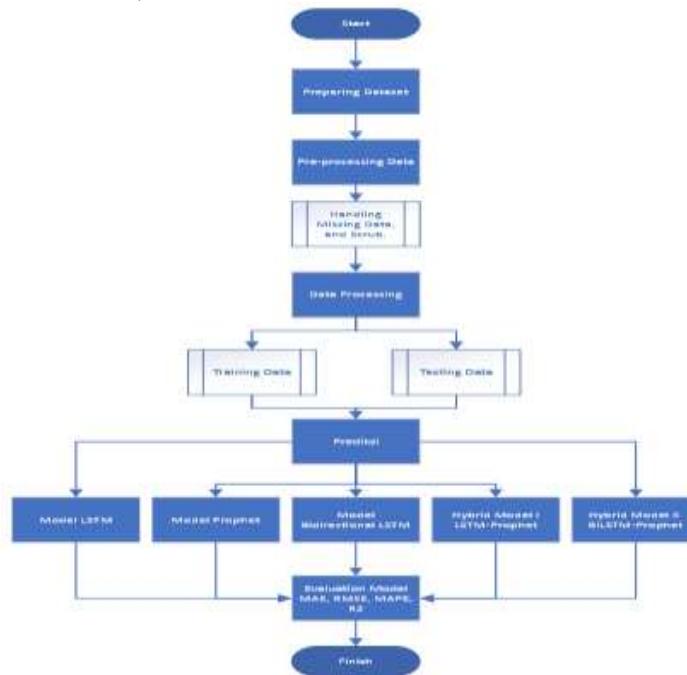
Dalam penelitian pada tahun 2022, pendekatan diusulkan dengan menggabungkan empat model berbeda, dengan kombinasi SVR-SARIMA, SVR-Prophet, LSTM-SARIMA, dan LSTM-Prophet. Berdasarkan hasil pengujian pada partikel PM10, SO₂, CO, O₃, dan NO₂ dengan 4 model tunggal, ditemukan bahwa partikel SO₂ dan PM10 pada tahun 2022 mengalami peningkatan dan termasuk dalam kategori tidak sehat dengan perkiraan rata-rata jumlah bulanan untuk SO₂ sebesar 122.1219 µg/m³ dan PM10 sebesar 146.4578 µg/m³. Prediksi efek musiman menunjukkan peningkatan partikel SO₂ dan NO₂ selama musim kemarau dan musim hujan hingga tahun 2023. Berdasarkan hasil evaluasi 4 model

tunggal, ditemukan bahwa kinerja model SVR lebih baik dibandingkan 3 model lainnya, dengan rata-rata 4.695 RSME, dan 5.842 MAE. Sementara itu, dalam kinerja 4 model hybrid yang dikembangkan, ditemukan bahwa akurasi model hybrid LSTM-Prophet dalam membuat prediksi sebesar 99,74% dengan akurasi termasuk dalam kategori sangat baik dengan nilai RSME 12.319, MAE 12.057, dan nilai MAPE 0,259. Dikatakan

bahwa ada peluang untuk perbaikan di masa depan dengan mempertimbangkan penambahan fitur cuaca dan aspek lingkungan seperti data lalu lintas, data konsumsi energi, dan data lain yang berpotensi mempengaruhi polusi udara [14].

Tahapan Metode Penelitian

Tahapan metode penelitian yang akan dilakukan:



Gambar I. Tahapan metode penelitian

Metode Pengumpulan Data

Data yang digunakan untuk memprediksi tingkat pencemaran udara adalah data Air Pollution Standard Index (ISPU) mulai 2016 –2021, dari 5 stasiun pemantauan kualitas udara, yaitu: SPKU Kelapa Gading, SPKU Bundaran HI, SPKU Kebon Jeruk dan SPKU Jagakarsa berjumlah 10.960 catatan, terdiri dari 5 jenis polutan (PM10, SO2, Co, O3 dan

NO2) yang ditarik dari Dinas Lingkungan Hidup Provinsi DKI Jakarta yang disediakan melalui website Open Data Jakarta di Tautan: <https://data.jakarta.go.id>. Selain dataset ISPU, dataset USCB CHIRPS Rainfall (curah hujan) diperoleh dari situs web ClimateSERV 2.0 melalui tautan: <https://climateserv.servirglobal.net/>.

Tabel 1. Atribut dan label himpunan data

Label	Deskripsi Label	Contoh Data
Tanggal	Tanggal pengukuran kualitas polutan udara	01/01/2016
Stasiun	Lokasi pengukuran kualitas polutan udara	DKI1 (Bunderan HI)
10 PM	Partikel kasar dengan diameter 2,5 hingga 10 mikrometer	59

SO2	Sulfur dioksida membentuk asam sulfat, yang juga merupakan komponen hujan asam	19
co	Karbon Monoksida adalah gas beracun yang tercipta saat karbon dibakar	27
O3	Ozon adalah polutan udara sekunder yang dibuat dari reaksi kimia dengan polutan udara	31
No2	Gas nitrogen dioksida yang molekulnya terbuat dari atom nitrogen dan oksigen	1
maks	Nilai terukur tertinggi dari parameter polutan pada pengukuran waktu yang sama	59
Kritis	Polutan dengan hasil pengukuran tertinggi	10 PM
Kategori	Kategori hasil perhitungan indeks polusi udara standar	SEDANG
Tanggal	Tanggal pengukuran curah hujan	2016-1-1
Curah hujan UCSB CHIRPS: rata-rata	Ukuran curah hujan rata-rata dalam satu tanggal	25.573.00,00

Pra-Pemrosesan Data

1. Menangani Nilai yang Hilang

Pada tahap ini, dari total 10960 dataset catatan, penyaringan nilai yang hilang dilakukan dengan menghapus nilai kosong dari data menggunakan alat RapidMiner. Ditemukan sebanyak 4811 catatan yang hilang, sehingga kumpulan data yang tersisa adalah 6149 catatan.

2. Scrub

Pada tahap Scrub, tahap penggabungan kedua dataset menjadi satu data akan dilakukan yang terdiri dari kolom 'Date, Station, pm10, so2, co, no2, Max, Critical, Category, Date, dan Rain'. Kemudian, pembersihan data dengan menghilangkan kolom data yang tidak digunakan untuk pengujian aktivitas pada dataset seperti variabel 'max', 'critical', dan 'category' pada dataset ISPU dan kolom 'date' pada dataset curah hujan, Menyesuaikan tipe data seperti variabel 'date/date' diubah menjadi tipe data tanggal. Variabel polutan dan curah hujan diubah menjadi tipe data numerik.

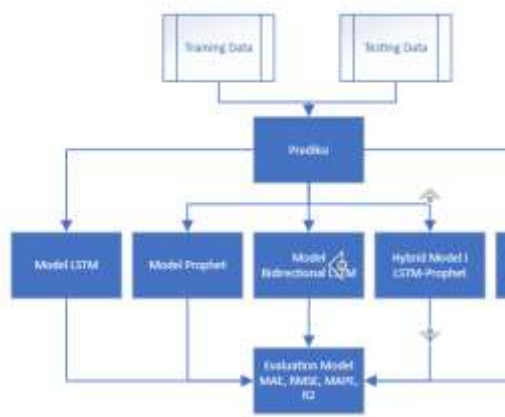
Memproses Data

Pada tahap ini, data dibagikan, kumpulan data dibagi menjadi pengujian data dan

pelatihan data. Setelah menghilangkan nilai yang hilang yang ada, himpunan data yang akan digunakan memiliki 6149 baris pengamatan, Untuk pengujian, himpunan data dibagi menjadi data pelatihan dan pengujian dengan proporsi 90%: 10%, 80%: 20%, dan 70%: 30%.

Prediksi dan Evaluasi Hasil Prediksi

Setelah berbagi data, kegiatan prediksi dilakukan dengan model tunggal yaitu model LSTM, BiLSTM, dan Prophet, kemudian dibangun model hybrid LSTM-Prophet dan BiLSTM-Prophet. Kemudian hasil prediksi dievaluasi menggunakan matriks MAE, RMSE, MAPE, dan R-Square.



Gambar II. Tahapan Prediksi

HASIL DAN PEMBAHASAN Pemodelan Data

Prosedur pemodelan dalam penelitian ini terdiri dari 3 tahap, yaitu: dataset akan dibagi menjadi training dataset dan testing dataset. Proses pembagian dataset dilakukan menjadi 3 kategori untuk masing-masing model, yaitu dengan rasio pelatihan : pengujian (90 : 10, 80 : 20, dan 70 : 30), kemudian setelah dataset dibagi, prosedur selanjutnya adalah menerapkan model pada data untuk menganalisis data dan membuat prediksi kapan model berjalan akan dijalankan selama 2 nilai zaman, Pertama nilai epochs ditentukan secara langsung (epochs = 100) untuk setiap prediksi, Kemudian yang kedua menggunakan teknik peningkatan nilai epochs menggunakan iterasi hingga diperoleh nilai epochs terbaik yang kemudian akan digunakan dalam proses prediksi, kemudian prosedur ketiga adalah mengevaluasi kinerja masing-masing model.

Memisahkan Dataset

Kumpulan data yang akan digunakan terdiri dari 6149 baris observasi dan 8 kolom observasi. Dalam aktivitas uji coba model, dataset akan dibagi menjadi data pelatihan dengan proporsi 90% dan sisanya 10% menjadi data pengujian, 80% data pelatihan dan sisanya 20% data pengujian, dan terakhir 70% data pelatihan dengan 30% data pengujian. Berbagai rasio ditetapkan dengan tujuan untuk tidak membatasi proporsi data sambil mencoba berbagai kemungkinan

untuk setiap model hingga akhirnya dapat dilihat seberapa banyak pembagian yang mampu melatih model dengan lebih baik. Pengujian tidak terbatas pada setiap kategori tetapi dilakukan berdasarkan jumlah data yang tersedia dalam rentang waktu dari 01-01-2016 hingga 31-12-2021 berdasarkan 5 jenis partikel penyebab polusi udara dan pengaruhnya terhadap curah hujan. Tampilan Kode Daftar 6 di bawah ini dilakukan dengan pembagian 70% dan 30% untuk semua partikel.

Daftar Kode 1 Membagi Himpunan Data

```
# Bagikan Dataset untuk PM10
X_train_pm10, X_test_pm10,
y_train_pm10, y_test_pm10 =
train_test_split(X, y_pm10,
test_size=0,3, random_state=42)

# Bagi Dataset untuk SO2
X_train_so2, X_test_so2, y_train_so2,
y_test_so2 = train_test_split(X,
y_so2, test_size=0,3, random_state=42)

# Bagi Dataset untuk CO
X_train_co, X_test_co, y_train_co,
y_test_co = train_test_split(X, y_co,
test_size=0,3, random_state=42)

# Bagi Dataset untuk O3
X_train_o3, X_test_o3, y_train_o3,
y_test_o3 = train_test_split(X, y_o3,
test_size=0,3, random_state=42)

# Bagi Dataset untuk NO2
X_train_no2, X_test_no2, y_train_no2,
y_test_no2 = train_test_split(X,
y_no2, test_size=0,3, random_state=42)
```

Namun pada dasarnya, sebelum dataset dibagi, ada beberapa kegiatan yang harus dilakukan untuk memastikan bahwa model dapat diimplementasikan, beberapa hal yang dilakukan dalam penelitian ini adalah menjalankan fungsi untuk mengubah kolom 'Tanggal/Tanggal' menjadi tipe data 'datetime' untuk memudahkan manipulasi tanggal, memisahkan variabel dependen dari variabel independen karena dalam pengujian ini akan menjalankan model prediksi polusi udara dengan melihat pengaruh curah hujan, Sehingga 'curah hujan' dan 'tanggal' dinyatakan sebagai variabel independen (X) sedangkan partikel polusi udara 'PM10', 'SO2', 'CO', 'O3', dan 'No2' yang merupakan variabel target yang akan diprediksi dinyatakan sebagai variabel dependen (Y). Hanya

setelah itu kumpulan data dipisahkan oleh proporsi tertentu, penggunaan `train_test_split` dari `scikit-learn` membantu menghasilkan subset kumpulan data yang dapat digunakan untuk melatih dan menguji model. Sedangkan kegiatan setelah membagi dataset atau sebelum masuk ke dalam uji model yang dilakukan dalam penelitian ini adalah mengubah format input menjadi tiga dimensi, pada tahap ini format input model disesuaikan terutama karena dalam pengujian ini penulis menggunakan model jaringan saraf berulang atau sejenisnya yang membutuhkan input dalam format tiga dimensi (jumlah sampel, jumlah langkah waktu, jumlah fitur). Proses ini juga disebut `reshape` di mana proses ini penting untuk memastikan bahwa data disusun dengan benar sebelum disematkan ke dalam model. Berikut kode prosesnya.

Model Tunggal

LSTM Model

Memori jangka pendek panjang adalah jenis arsitektur jaringan saraf rekursif (RNN) yang dirancang untuk mengatasi masalah dalam memahami dan mengingat informasi jangka panjang. LSTM menggunakan sel memori untuk menyimpan dan mengalirkan informasi dengan menerima input dalam bentuk urutan data dari waktu ke waktu (deret waktu) di mana setiap elemen dalam urutan dapat memiliki banyak fitur. Model ini sering dijelaskan dengan ketersediaan tiga jenis gerbang: `Lupakan Gerbang`, `Gerbang Input` dan `Gerbang Keluaran`.

Dalam pembuatan model LSTM untuk partikel `pm10`, ia menggunakan sintaks `'tf.keras.models.Sequential'` yang mendefinisikan model berurutan dari pustaka `tensorflow.keras.models`, yang berarti model memiliki satu lapisan LSTM yang ditambahkan setiap lapisan satu per satu secara berurutan. maka perintah `'tf.keras.layers.LSTM(128,input_shape=(1,X_train_pm10.shape[2]))'` berarti menambahkan layer LSTM dengan 128 unit dan `'input shape'` ini berarti model

diharapkan menerima input dengan shape (jumlah waktu, jumlah fitur) dan mengembalikan output dengan shape (jumlah_waktu, jumlah_unit_LSTM). dan terakhir tambahkan `'tf.keras.layers.Dense(1)'` Lapisan padat dengan neuron 1, yang akan menghasilkan output prediksi dan ini adalah langkah terakhir dari implementasi model.

BILSTM Model

LSTM dua arah atau sering disebut `BiLSTM`, adalah varian model LSTM dari model jaringan saraf yang juga dirancang untuk memproses dan memahami urutan data dalam dua arah: maju (dari awal hingga akhir) dan mundur (dari ujung ke awal). Hal ini memungkinkan model untuk lebih memahami konteks dan pola urutan data yang kompleks. Atau singkatnya, `BiLSTM` adalah LSTM dari dua set sel memori, satu memproses urutan maju dan yang lainnya memproses urutan mundur secara bersamaan. Dalam pustaka seperti `'hard'`, implementasi `BiLSTM` dapat menggunakan lapisan `'Bidirectional'`.

Fungsi `'build_bilstm_model'` digunakan untuk membangun model `BiLSTM`, dan untuk menambahkan lapisan LSTM dua arah yang memungkinkan model memproses data dalam dua arah (maju dan mundur) menggunakan `'tf.keras.layers.Bidirectional'`. Masih menggunakan 128 lapisan LSTM yang sama dengan model sebelumnya dengan lapisan padat 1 neuron sebagai output. Proses `comple` model menggunakan `pengoptimal Adam` dengan tingkat belajar yang dapat disesuaikan tetapi di sini menggunakan tingkat pembelajaran 0,001.

Model Prophet

Dalam analisis model nabi, perpustakaan nabi digunakan untuk membuat prediksi deret waktu. Untuk membuat dan melatih model nabi gunakan fungsi `'train_prophet_model'` (`data, changepoints=None`), dengan parameter `'data'` yang berisi deret waktu yang akan

digunakan untuk melatih model. Parameter 'change-points' juga dapat digunakan sebagai titik perubahan dalam deret waktu yang dapat diberikan untuk membantu model mengidentifikasi perubahan tren. Mode nabi yang telah dibentuk sebelumnya kemudian ditembakkan pada parameter 'data' dan mengembalikan model yang dilatih.

Model Hibrida

Pengujian dalam penelitian ini dilakukan dengan menggabungkan model LSTM-Prophet dan BiLSTM-Prophet. Dalam studi referensi tersebut, telah dicoba untuk menggabungkan LSTM-Prophet dengan pendekatan yang berbeda dan memperoleh akurasi prediksi sebesar 99,74%, dan nilai ini telah berhasil mengungguli model tunggal. Pendekatan bertumpuk, atau sering disebut sebagai pembelajaran ansambel, adalah strategi yang baik untuk meningkatkan kinerja prediktif dengan menggabungkan hasil dari beberapa model. Dalam penelitian ini, menggabungkan hasil model LSTM dan BiLSTM dengan Prophet secara bertumpuk diharapkan dapat meningkatkan akurasi prediksi.

Dalam pendekatan bertumpuk, aktivitas memberikan bobot yang berbeda pada prediksi setiap model dapat dilakukan, memungkinkan model untuk saling mendukung untuk meningkatkan akurasi secara keseluruhan.

Model hybrid yang dikembangkan akan menggunakan weighted average dari kedua model prediksi, weighted average memberikan bobot masing-masing prediksi dalam membuat prediksi akhir. yang dinyatakan sebagai berikut:

- Prediksi dari model pertama (Model A)
Melakukan aktivitas prediksi menggunakan model A pada himpunan data pengujian
- Prediksi dari model kedua (Model B)
Lakukan aktivitas prediksi menggunakan model B pada himpunan data pengujian
- Rata-rata Tertimbang

Perhitungan rata-rata tertimbang adalah dari prediksi model A dan model B, dimana setiap prediksi diberi bobot tertentu (dalam penelitian ini digunakan bobot 0,7 dan 0,3. Misalnya, P_a dan P_b adalah prediksi model A dan B, sedangkan W_a dan W_b adalah bobot dari masing-masing model. Prediksi akhir (P_{final}) dihitung sebagai berikut $P_{final} = W_a \times P_a + W_b \times P_b$

- Evaluasi model hibrida
Evaluasi kinerja menggunakan metrik evaluasi MAE, MAPE, RSME, dan R-Square.
- Penyesuaian Berat
Penyesuaian berat dapat dilakukan untuk meningkatkan kinerja model hibrida. Ini dapat dilakukan dengan menggunakan teknik seperti pengoptimalan seperti yang digunakan dalam penelitian ini atau pencarian kisi untuk menemukan bobot yang optimal.

Setelah model dijalankan dan hasil perhitungan Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Root Mean Squared Error (RMSE), dan R-Square untuk 5 model dengan beberapa partisi, yaitu bobot 90:10, 80:20 dan 70:30. Kemudian dibagi lagi menjadi 2 jenis zaman, yaitu zaman 100 dan zaman multi-level. Pengukuran ini memberikan gambaran tentang seberapa baik model prediksi cocok dengan data pengamatan. Semakin kecil nilai MAE, MAPE, dan RMSE, semakin baik model prediksinya. Sedangkan untuk R-Squared, semakin dekat nilainya ke 1, semakin baik model menjelaskan variasi data.

Perbandingan Model

Untuk membandingkan performa model Hybrid LSTM-Prophet atau BiLSTM-Prophet dan atau model LSTM, BiLSTM, atau Prophet tunggal. Model mana yang mampu memberikan kualitas prediksi yang lebih baik. Jadi berikut ini adalah ringkasan perbandingan kinerja tertinggi dari masing-masing model dan partisi berdasarkan hasil pengujian yang dilakukan.

Tabel 2. Nilai Rata-Rata Evaluasi Matriks Model Tunggal

Partisi	Model	MAE	RMSE	R-Square	MAPE
90/10 Epochs Bertingkat	LSTM	12.60416	17.0288	0.04088	0.66%
	BiLSTM	12.32232	17.14236	0.07038	0.622%
	Nabi	15.2709	19.92638	-0.29042	0.868%
80/20 Epochs Bertingkat	LSTM	12.02388	17.29266	-0.75368	0.672%
	BiLSTM	13.13608	17.15422	0.03664	0.602%
	Nabi	14.51322	19.66618	-0.2178	0.778%
70/30 Epochs Bertingkat	LSTM	12.49824	17.08424	0.04172	0.644%
	BiLSTM	12.05642	16.51538	0.1141	0.670%
	Nabi	14.6245	19.06488	-0.1878	0.79%
90/10 Zaman 100	LSTM	12.18496	17.58832	0.06142	0.654%
	BiLSTM	12.1393	17.0759	0.08672	0.672%
80/20 Zaman 100	LSTM	12.01144	17.36704	0.0591	0.658%
	BiLSTM	12.1513	17.34148	0.06812	0.656%
70/30 Zaman 100	LSTM	12.70452	17.17364	0.05936	0.678%
	BiLSTM	12.3636	17.0989	0.06642	0.652%

Perbandingan Model Tunggal:

Kesimpulan Hasil Prediksi Model Hibrida LSTM-Prophet dan BiLSTM-Prophet berdasarkan tabel di atas:

a. Akurasi Prediksi:

- Secara umum: Model BiLSTM menunjukkan kinerja terbaik dengan nilai MAE dan RMSE terendah pada semua partisi dan zaman dan menunjukkan nilai kesalahan terkecil dalam pengujian dengan partisi 80/20 menggunakan epoch multi-level dengan nilai akurasi 99,32%.
- Model LSTM memiliki kinerja yang sedikit lebih rendah daripada BiLSTM, tetapi masih lebih baik dari Prophet.
- Model Prophet memiliki kinerja terendah dengan skor MAE dan RMSE tertinggi.

b. Stabilitas Prediksi:

- Kinerja BiLSTM lebih stabil daripada LSTM dan Prophet pada semua partisi dan zaman.
- Performa LSTM dan Prophet cenderung lebih fluktuatif, terutama pada partisi 70/30.

c. Efek Partisi:

- Kinerja semua model umumnya meningkat dengan peningkatan proporsi data pelatihan (dari 70/30 menjadi 90/10).

d. Pengaruh Eboch:

- Dalam model LSTM dan BiLSTM, penggunaan zaman cascading menghasilkan kinerja yang lebih baik daripada zaman 100.
- Dalam model Nabi, perbedaan kinerja antara zaman bertingkat dan zaman 100 tidak terlalu signifikan.

e. Kesimpulan Terbaik: Berdasarkan analisis di atas, model BiLSTM dengan zaman bertingkat menunjukkan kinerja prediksi keseluruhan terbaik.

Berdasarkan hasil yang diperoleh, dapat dilihat bahwa untuk setiap kombinasi partisi data dan jumlah zaman, LSTM dan BiLSTM secara konsisten memberikan kinerja yang lebih baik dibandingkan model Prophet, yang diukur dengan MAE, RMSE, dan MAPE. Antara LSTM dan BiLSTM, kinerja BiLSTM sedikit unggul namun perbedaannya tidak signifikan sama sekali, karena perbedaan

nilai metrik antara keduanya tidak terlalu besar.

Tabel 3. Nilai Rata-Rata Evaluasi Matriks Model Hibrida

Partisi	Model	MAE	RMSE	R-Square	MAPE
90/10 Epochs Bertingkat	LSTM-Nabi	13.75816	18.26984	0.01368	0.712%
	Nabi BiLSTM	13.3616	18.3608	0.00448	0.704%
80/20 Epochs Bertingkat	LSTM-Nabi	13.04348	17.3587	0.0078	0.684%
	Nabi BiLSTM	13.23972	17.54328	0.00828	0.712%
70/30 Epochs Bertingkat	LSTM-Nabi	13.09116	17.34246	0.00846	0.686%
	Nabi BiLSTM	13.08014	17.33778	0.00602	0.692%
90/10 Zaman 100	LSTM-Nabi	12.32534	17.87418	0.03062	0.702%
	Nabi BiLSTM	12.0618	17.28128	0.04458	0.710%
80/20 Zaman 100	LSTM-Nabi	12.4484	17.45058	0.03036	0.712%
	Nabi BiLSTM	12.21242	17.2474	0.0356	0.69%
70/30 Zaman 100	LSTM-Nabi	12.71382	17.4468	0.03058	0.698%
	Nabi BiLSTM	12.59814	17.3683	0.04096	0.678%

Perbandingan Model Hibrida:

a. Akurasi Prediksi:

- Secara umum: Model BiLSTM-Prophet menunjukkan kinerja terbaik dengan nilai MAE dan RMSE terendah pada semua partisi dan zaman dan menunjukkan nilai kesalahan terkecil dalam pengujian dengan partisi 70/30 menggunakan epoch berjenjang dengan nilai akurasi 99,31%.
- Model LSTM-Prophet memiliki kinerja yang sedikit lebih rendah daripada BiLSTM-Prophet.
- Dapat dilihat bahwa nilai R-Square dari kedua model berada di kisaran rendah dan mendekati nol, menunjukkan bahwa model ini mungkin tidak begitu baik dalam menjelaskan variabilitas data.

b. Stabilitas Prediksi:

- Kinerja BiLSTM-Prophet lebih stabil dibandingkan LSTM-Prophet di semua partisi dan zaman.
- Performa LSTM-Prophet cenderung lebih fluktuatif, terutama pada partisi 70/30.

c. Efek Partisi:

- Kinerja semua model umumnya meningkat dengan peningkatan proporsi data pelatihan (dari 70/30 menjadi 90/10).

d. Pengaruh Epoch:

- Dalam model LSTM-Prophet dan BiLSTM-Prophet, penggunaan zaman berjenjang menghasilkan kinerja yang lebih baik daripada zaman 100.

- ##### e. Kesimpulan Terbaik: Berdasarkan analisis di atas, model BiLSTM-Prophet dengan zaman bertingkat menunjukkan kinerja prediksi keseluruhan terbaik.

Diskusi

Pemanfaatan Temuan Penelitian

Pemanfaatan temuan dari penelitian untuk memprediksi polusi udara yang terdampak curah hujan dapat memberikan manfaat yang besar, baik bagi masyarakat maupun pemerintah. Berikut adalah beberapa cara untuk menggunakannya:

A. Untuk Komunitas:

1. Peringatan Dini: Memberikan peringatan dini kepada masyarakat ketika terjadi peningkatan polusi udara karena curah hujan yang rendah memungkinkan mereka untuk mengambil tindakan pencegahan,

seperti memakai masker atau mengurangi aktivitas di luar ruangan.

2. **Perlindungan Kesehatan:** Informasi ini dapat membantu orang-orang, terutama mereka yang rentan terhadap dampak polusi udara, untuk mengambil tindakan perlindungan tambahan. Misalnya, mereka mungkin memilih untuk tinggal di dalam rumah selama periode dengan prediksi polusi tinggi.
3. **Pengurangan Paparan:** Mengetahui kapan polusi udara cenderung mencapai tingkat tinggi dapat membantu orang mengurangi paparan mereka dengan menghindari perjalanan atau aktivitas di luar ruangan pada waktu-waktu tertentu.

B. Untuk Pemerintah:

1. **Kebijakan Lingkungan:** Temuan penelitian ini dapat membantu pemerintah dalam merancang kebijakan untuk mengurangi polusi udara. Mereka dapat menggunakan informasi ini untuk menentukan langkah-langkah pengendalian emisi yang efektif.
2. **Sistem Peringatan Dini:** Pemerintah dapat menggunakan hasil penelitian ini untuk mengembangkan sistem peringatan dini yang lebih efektif terkait polusi udara. Ini akan membantu mengurangi dampak negatifnya terhadap kesehatan masyarakat.
3. **Penelitian Lebih Lanjut:** Penelitian lebih lanjut dapat dilakukan untuk lebih memahami hubungan antara curah hujan dan polusi udara, sehingga pemerintah dapat mengambil langkah yang lebih spesifik dan efektif untuk mengatasi masalah ini.

Dengan memanfaatkan hasil penelitian ini secara efektif, masyarakat dan pemerintah dapat bekerja sama dalam mengurangi dampak negatif polusi udara dan

meningkatkan kualitas udara untuk kesejahteraan bersama.

SIMPULAN

Hasil penelitian menunjukkan bahwa model hybrid BiLSTM-Prophet dengan zaman multi-level menghasilkan prediksi parameter polusi udara yang paling akurat, menentukan zaman multi-level meningkatkan fleksibilitas model prediksi. Namun, akurasi tidak terlalu signifikan dengan model LSTM-Prophet, yang berarti penggunaan LSTM 2 lapis atau BiLSTM tidak terlalu unggul dengan hasil prediksi LSTM 1 lapis. Namun, jika dibandingkan dengan model tunggal, model hibrida ini menggabungkan kekuatan model LSTM/BiLSTM dan Prophet untuk meningkatkan akurasi prediksi. Penelitian ini dapat berguna untuk mengembangkan sistem pemantauan kualitas udara yang lebih akurat.

Dari hasil yang diperoleh, kedua model hybrid tersebut menunjukkan kinerja yang sama dari segi prediksi, namun tidak optimal dalam menjelaskan variabilitas data. Memilih model terbaik di antara keduanya mungkin perlu didasarkan pada faktor-faktor tambahan seperti kompleksitas model, kecepatan komputasi, dan interpretasi hasil, atau mungkin dimungkinkan untuk melakukan eksperimen lebih lanjut untuk membandingkan kinerja keduanya dalam konteks spesifik aplikasi atau kasus penggunaan.

Untuk penelitian lebih lanjut, fitur cuaca dan iklim serta faktor lingkungan lainnya dapat ditambahkan: melibatkan data cuaca yang lebih lengkap, seperti tekanan udara, kecepatan angin, kelembaban, suhu, data lalu lintas, konsumsi energi, dan data faktor industri sehingga dapat membantu meningkatkan akurasi prediksi pencemaran udara. Menggunakan metode atau algoritma pembelajaran mendalam lainnya sehingga dapat mengetahui model mana yang menghasilkan kinerja yang lebih baik untuk data deret waktu.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Universitas Mikroskil yang telah menjadi tempat dan tempat pembelajaran yang mendukung penulis dan juga kepada Dosen dan Dosen Pembimbing Penelitian yang telah banyak membantu dalam proses pemberian bimbingan, penilaian dan saran hingga selesainya laporan dan

artikel ini. Penulis juga mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan dorongan baik secara langsung maupun tidak langsung. Kontribusi mereka sangat berarti dalam menyukseskan penelitian ini.

DAFTAR PUSTAKA

- [1] A. A. Allam, A. A. Almetwally influence on human health and *pollution research international*
- [2] A. Kurniawan, "PENGUKURAN SO₂, O₃ DAN PM₁₀) DI B *Techno Sains*, vol. 7, 2017.
- [3] S. H. H. Al-Taai and . W. A. M Concept, Causes, Sources and I *Pollution*, vol. 19, no. 1, pp. 17-2
- [4] W. TEAM, "World Health Org September 2021. <https://www.who.int/publication> 2024].
- [5] Z. J. Andersen, "Air pollution ep
- [6] A. A. Almetwally, . M. Bin-Jum influence on human health and *Pollution Research*, vol. 27, no. 1
- [7] Y. Bian, Z. Huang, J. Ou, Z. Z Yin, C. Li, L. Chen, M. Shao an emissions in Guangdong Pro *Geosciences Union*, vol. 19, no.
- [8] F. Mahmood, M. F. Khokhar tropospheric ozone and climate panel data techniques," *Journal o*
- [9] H.-Y. Kwak, J. Ko, S. Lee ar rainfall, traffic flow performanc path analysis," *Elsevier*, vol. 25,
- [10] M. A. Faishol, E. and A. N. I Using Recurrent Neural Netwo *Teknologi Informasi*, vol. 18, no.
- [11] T. Handhayani, "An integrate conditions in Jakarta," *Scientific*
- [12] Y. Liu, P. Wang, Y. Li, L. Wen on meteorological factors and *Library of Medicine*, vol. 12, p. 9
- [13] H. Novianto, M. M. Azis and H. Mu, "Analisis per Yogyakarta pada masa," *Jurnal Rekayasa Proses*, v
- [14] R. Yunis, A. and D. , "Hybridization Model for *CogITo Smart Journal*, 2024.
- [15] Z. Wang and X. Gu, "A Time Series Prediction A Prophet Hybrid Model," *4th International Conferen Application (ICCEA)*, pp. 128-132, 2023.
- [16] aqicn.org, "Air Quality Forecasting - How accur 2015. [Online]. Available: <https://aqicn.org/faq/2-how-accurate-can-it-be/>. [Accessed 2024 02 2024].
- [17] I. S. Writers, "Can air pollution be predicted?," Available: <https://www.iqair.com/newsro> [Accessed 22 02 2024].
- [18] F. Hamami and I. A. Dahlan, "Univariate Time Pollution using LSTM Neural Network," 2020 , pp.
- [19] S. M. ALHIRMIZY and B. A. Qader, "Multivari LSTM for Madrid, Spain pollution," *International Information Science and Technology and Their* 2019.
- [20] P. Jiang, I. Bychkov, J. Liu and A. Hmelno concentrations based on spatio-temporal attention *Proceedings of the 1st International Workshop Computation Technologies and Systems*, vol. 2858,
- [21] S. V. Belavadi, S. Rajagopal, R. R and R. Mohar LSTM RNN and Wireless Sensor Networks," *Proo* pp. 241-248, 2020.
- [22] N. Fernandes and J. Gonçalves, "Multivariate an prediction using bidirectional LSTM," *11th Inte Forensics and Security (ISDFS)*, pp. 1-6, 2023.
- [23] R. Dua, D. Madaan, P. Mukherjee and B. La Bidirectional Long Short-Term Memory Network *IEEE Fifth International Conference on Big Applications (BigDataService)*, pp. 151-158, 2019.
- [24] S. Jeya and L. Sankari, "Air Pollution Prediction *International Conference on Intelligent Computing* pp. 736-741, 2020.
- [25] Y. Wang, D. Bao and S. J. Qin, "A novel bidirection

and its application in industrial process time series prediction," *Chemometrics and Intelligent Laboratory Systems*, vol. 240, 2023.

- [26] Y. Sun, L. Zhang and M. Yao, "Chaotic Time Series Prediction of Multi-Dimensional Nonlinear System Based on Bidirectional LSTM Model," *Chaos, Solitons & Fractals*, vol. 175, no. 1, 2023.
- [27] S. Su, Y. Sun, Y. Zeng and C. Peng, "Aviation risk prediction based on Prophet-LSTM hybrid algorithm," *Aircraft Engineering and Aerospace Technology*, vol. 95, no. 7, 2023.