

## Analisis Prediksi dan Klasifikasi Kualitas Udara DKI Jakarta Menggunakan *Long Short-Term Memory (LSTM)* dan *Temporal Fusion Transformer (TFT)*

Aulia Ulfah <sup>a,1</sup>, Taswanda Taryo <sup>b,2</sup>, Ahmad Musyafa <sup>b,3\*</sup>

<sup>a,b</sup> Pasca Sarjana Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Banten, Indonesia  
e-mail: <sup>1</sup>ulfaulia4931@gmail.com, <sup>2</sup>dosen02234@unpam.ac.id, <sup>3</sup>dosen00668@unpam.ac.id

\*Corresponding author

Submitted Date: January 14<sup>th</sup>, 2026  
Revised Date: April 28<sup>th</sup>, 2026

Reviewed Date: March 17<sup>th</sup>, 2026  
Accepted Date: June 27<sup>th</sup>, 2026

### Abstract

Air quality in Jakarta is an environmental issue that affects public health, requiring an accurate analytical system. This study aims to analyze, predict, and classify air quality by comparing Long Short-Term Memory (LSTM) and Temporal Fusion Transformer (TFT) models. The data consist of time-series observations from 2020–2024, covering PM10, PM2.5, SO<sub>2</sub>, CO, O<sub>3</sub>, and NO<sub>2</sub> parameters. The research stages include data preprocessing, missing value interpolation, normalization, lag feature construction, and sequential data splitting into 80% training, 10% validation, and 10% testing sets to preserve temporal characteristics. The results show that TFT outperforms LSTM. For regression, TFT achieved R<sup>2</sup> values of 0.927 for SO<sub>2</sub>, 0.619 for CO, and 0.363 for NO<sub>2</sub>, while LSTM produced negative R<sup>2</sup> values for all parameters. For ISPU category classification, TFT achieved 90% accuracy, whereas LSTM achieved 86% accuracy and tended to be biased toward the majority class. These results indicate that TFT is more capable of capturing temporal patterns and complex relationships among variables, providing a more consistent deep learning approach for air quality prediction and classification.

Keywords: Air quality; LSTM, TFT; Pollution prediction; ISPU

### Abstrak

Kualitas udara di DKI Jakarta merupakan permasalahan lingkungan yang berdampak pada kesehatan masyarakat sehingga diperlukan sistem analisis yang akurat. Penelitian ini bertujuan menganalisis, memprediksi, dan mengklasifikasikan kualitas udara dengan membandingkan model *Long Short-Term Memory (LSTM)* dan *Temporal Fusion Transformer (TFT)*. Data yang digunakan berupa data time series periode 2020–2024 dengan parameter PM10, PM2.5, SO<sub>2</sub>, CO, O<sub>3</sub>, dan NO<sub>2</sub>. Tahapan penelitian meliputi *preprocessing* data, *interpolasi missing values*, normalisasi, pembentukan fitur *lag*, serta pembagian data secara berurutan menjadi 80% data pelatihan, 10% validasi, dan 10% pengujian untuk mempertahankan karakteristik temporal. Hasil menunjukkan bahwa TFT memiliki performa lebih baik dibandingkan LSTM. Pada regresi, TFT menghasilkan R<sup>2</sup> sebesar 0,927 pada SO<sub>2</sub>, 0,619 pada CO, dan 0,363 pada NO<sub>2</sub>, sedangkan LSTM menghasilkan R<sup>2</sup> negatif pada seluruh parameter. Pada klasifikasi kategori ISPU, TFT mencapai akurasi 90%, sementara LSTM mencapai 86% dan cenderung bias terhadap kelas mayoritas. Hasil tersebut menunjukkan bahwa TFT lebih mampu menangkap pola temporal dan hubungan kompleks antarvariabel serta memberikan pendekatan *deep learning* yang lebih konsisten untuk prediksi dan klasifikasi kualitas udara.

Kata Kunci: Kualitas udara; LSTM, TFT; Prediksi polusi; ISPU

## 1. Pendahuluan

Kualitas udara merupakan salah satu permasalahan lingkungan yang berdampak signifikan terhadap kesehatan masyarakat, khususnya di wilayah perkotaan seperti DKI Jakarta yang memiliki tingkat emisi tinggi dari sektor transportasi, industri, dan aktivitas urban. Dinamika konsentrasi polutan yang bersifat fluktuatif menjadikan analisis kualitas udara sebagai permasalahan yang kompleks, sehingga diperlukan pendekatan yang akurat untuk mendukung sistem pemantauan dan pengambilan keputusan berbasis data.

Berbagai penelitian menunjukkan bahwa metode *deep learning* efektif dalam menangani data deret waktu (*time series*) untuk prediksi kualitas udara. Model *Long Short-Term Memory* (LSTM) telah banyak digunakan karena kemampuannya dalam menangkap dependensi temporal jangka panjang. Penelitian oleh [1], [2] menunjukkan bahwa LSTM mampu memodelkan tren polusi udara dengan cukup baik, meskipun performanya masih terbatas ketika menghadapi data yang kompleks dan memiliki tingkat *noise* tinggi. Untuk mengatasi keterbatasan tersebut, beberapa studi mengembangkan pendekatan lanjutan seperti model *hybrid* berbasis LSTM [3], [4] serta integrasi mekanisme *attention* [5] guna meningkatkan akurasi prediksi.

Seiring perkembangan model berbasis *transformer*, *Temporal Fusion Transformer* (TFT) muncul sebagai metode yang lebih adaptif dalam menangani data *time series* multivariat. TFT memiliki keunggulan dalam memodelkan hubungan kompleks antar variabel melalui mekanisme *attention*, *variable selection*, dan *gating*. Penelitian oleh [6], [7] menunjukkan bahwa TFT mampu mengungguli model konvensional seperti LSTM, GRU, dan BiLSTM dalam prediksi kualitas udara. Selain itu, performa TFT juga terbukti unggul dalam berbagai domain lain seperti prediksi energi [8], [9] dan aplikasi *smart city* [10], yang menunjukkan kemampuannya dalam menangani data kompleks secara lebih efektif.


Meskipun demikian, sebagian besar penelitian terdahulu masih berfokus pada tugas prediksi (regresi) dan belum banyak yang mengintegrasikan klasifikasi kategori kualitas udara dalam satu kerangka analisis. Selain itu, studi komparatif antara LSTM dan TFT dalam konteks kualitas udara di Indonesia, khususnya DKI Jakarta, masih terbatas. Hal ini menunjukkan adanya *research gap*, yaitu belum tersedianya pendekatan komprehensif yang menggabungkan prediksi numerik dan klasifikasi kategori kualitas udara secara simultan menggunakan model *deep learning*.

Berdasarkan permasalahan tersebut, Tujuan penelitian ini melakukan pendekatan komparatif menggunakan dua model *deep learning*, yaitu *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT), untuk melakukan prediksi dan klasifikasi kualitas udara menggunakan data multivariat periode 2020-2024 di DKI Jakarta. Pemilihan kedua metode ini didasarkan pada keunggulannya dalam menangani data *non-linear* dan kompleks, di mana LSTM efektif dalam memodelkan dependensi temporal, sedangkan TFT unggul dalam menangkap interaksi antar variabel melalui mekanisme *attention*. Kontribusi utama penelitian ini adalah menghadirkan pendekatan terintegrasi berbasis *deep learning* yang menggabungkan prediksi dan klasifikasi kualitas udara, serta memberikan analisis komparatif yang komprehensif antara LSTM dan TFT dalam konteks data kualitas udara di Indonesia.

## 2. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimen komparatif untuk menganalisis dan membandingkan kinerja dua model *deep learning*, yaitu *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT), dalam tugas prediksi (*regression*) dan klasifikasi kualitas udara berbasis data deret waktu. Dataset yang digunakan berasal dari portal Satu Data Jakarta dengan periode 2020-2024 yang mencakup 5.902 data, dengan variabel utama berupa parameter polutan PM<sub>10</sub>, PM<sub>2.5</sub>, SO<sub>2</sub>, CO, O<sub>3</sub>, dan NO<sub>2</sub>, serta atribut waktu dan kategori kualitas udara.

Secara keseluruhan, alur penelitian meliputi pengumpulan data, *preprocessing* dan *feature engineering*, pembagian data secara berurutan berdasarkan waktu, pembangunan dan pelatihan model *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT), prediksi dan klasifikasi kualitas udara, serta evaluasi dan analisis perbandingan performa kedua model. Tahapan tersebut dirancang untuk memberikan evaluasi yang komprehensif terhadap kemampuan masing-masing model dalam menangani data kualitas udara yang bersifat multivariat dan memiliki pola temporal yang kompleks [11]. Alur keseluruhan penelitian ditunjukkan pada gambar 1.



Gambar 1 Alur Penelitian

Tahap *preprocessing* dilakukan untuk memastikan kualitas data sebelum digunakan dalam proses pelatihan model. Proses ini meliputi penanganan missing values menggunakan metode *forward-fill* dan *backward-fill* untuk menjaga kontinuitas data deret waktu, serta deteksi dan penanganan *outlier* menggunakan metode *Interquartile Range* (IQR) agar tidak terjadi distorsi pada proses pembelajaran model. Selanjutnya, dilakukan normalisasi data menggunakan *MinMaxScaler* untuk menyamakan skala antar fitur dan mempercepat proses konvergensi model. Metode ini mentransformasikan seluruh nilai fitur ke dalam rentang 0-1 sehingga dapat mengurangi dominasi variabel dengan skala yang lebih besar terhadap proses pembelajaran model.

Proses normalisasi dilakukan menggunakan persamaan berikut [12]:

$$X' = \frac{1 - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Keterangan:

- (X') : nilai hasil normalisasi  
(X) : nilai data asli  
(X\_{min}) : nilai minimum pada fitur  
(X\_{max}) : nilai maximum pada fitur

Untuk menangkap pola temporal, dilakukan *feature engineering* berupa pembentukan lag hingga 60 hari serta perhitungan *rolling mean* 3 dan 7 hari. Dataset kemudian dibagi secara berurutan (*time-series split*) menjadi 80% data pelatihan, 10% validasi, dan 10% pengujian guna menghindari data *leakage* dan

menjaga karakteristik temporal data. Selain itu, untuk menghindari data *leakage*, proses normalisasi menggunakan *MinMaxScaler* dilakukan hanya pada data pelatihan, kemudian parameter scaling yang diperoleh diterapkan pada data validasi dan pengujian. Pembentukan fitur *lag* dan *rolling mean* juga dilakukan secara kausal tanpa menggunakan informasi dari masa depan.

Tabel 1 Arsitektur dan Parameter Model

| Parameter      | LSTM | TFT  |
|----------------|------|------|
| Window size    | 60   | 60   |
| Optimizer      | Adam | Adam |
| Learning rate  | 1e-3 | 1e-4 |
| Epoch maksimum | 100  | 100  |
| Dropout        | 0.3  | 0.1  |
| Early stopping | Ya   | Ya   |

Menurut tabel 1, perbandingan arsitektur dan parameter utama yang dipakai pada model LSTM dan *Temporal Fusion Transformer* (TFT) dalam proses prediksi dan klasifikasi kualitas udara. Model LSTM dibangun menggunakan *framework* TensorFlow/Keras dengan arsitektur yang terdiri dari lapisan *Bidirectional LSTM* sebanyak 128 unit untuk menangkap pola temporal dua arah, diikuti oleh lapisan LSTM satu arah sebanyak 64 unit. Untuk meningkatkan stabilitas pelatihan dan mengurangi *overfitting*, diterapkan *Batch Normalization* dan *Dropout* sebesar 0.3. Keluaran dari model kemudian diproses melalui lapisan Dense dengan 64 neuron menggunakan aktivasi ReLU, dan diakhiri dengan lapisan output untuk memprediksi nilai polutan secara simultan. Model dilatih menggunakan *optimizer Adam* dengan *learning rate* 1e-3 dan fungsi *loss Mean Squared Error* (MSE), dengan jumlah *epoch* maksimum 100, serta menggunakan mekanisme *Early Stopping* dan *ReduceLROnPlateau* untuk menjaga generalisasi model. Pendekatan LSTM dipilih karena kemampuannya dalam menangkap dependensi jangka panjang pada data deret waktu [1].

Model *Temporal Fusion Transformer* (TFT) dibangun menggunakan *framework* PyTorch Forecasting sebagai pendekatan berbasis *transformer* yang mampu menangkap hubungan temporal jangka panjang dan kompleks. Model ini dikonfigurasi dengan *hidden size* sebesar 256, jumlah *attention head* sebanyak 16, *hidden continuous size* sebesar 64, serta *dropout* sebesar 0.1. TFT memanfaatkan berbagai fitur input, termasuk nilai historis polutan, fitur *lag* hingga 60 hari, *rolling features*, serta fitur temporal seperti hari dan bulan. Mekanisme *attention* yang dimiliki TFT memungkinkan model untuk memilih fitur dan periode waktu yang paling relevan dalam proses prediksi. Dalam proses pelatihan, digunakan *optimizer Adam* dengan *learning rate* 1e-4, *batch size* 64, dan maksimum 100 *epoch*, serta *Early Stopping* untuk mencegah *overfitting*.

Pada model *Temporal Fusion Transformer* (TFT), digunakan fungsi objektif *quantile loss* untuk meningkatkan kemampuan model dalam menangani ketidakpastian prediksi pada data *time-series*.


Persamaan *quantile loss* dirumuskan sebagai berikut [13]:

$$QL(y, \hat{y}, q) = \begin{cases} q(y - \hat{y}), & y \geq \hat{y} \\ (1 - q)(\hat{y} - y), & y < \hat{y} \end{cases} \quad (2)$$

Keterangan:

- $QL(y, \hat{y}, q)$  : nilai *Quantile Loss* pada tingkat kuantil  
 $y$  : nilai aktual (*actual value*)  
 $\hat{y}$  : nilai prediksi (*predicted value*)  
 $q$  : tingkat kuantil, dengan  
 $y - \hat{y}$  : selisih nilai aktual dan nilai prediksi ketika prediksi berada di bawah nilai aktual  
 $\hat{y} - y$  : selisih [13] nilai prediksi dan nilai aktual ketika prediksi berada di atas nilai aktual

Evaluasi kinerja model dilakukan pada data uji menggunakan metrik regresi dan klasifikasi. Untuk tugas prediksi, digunakan *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *koefisien determinasi* ( $R^2$ ), yang masing-masing dirumuskan [1]:



Root Mean Squared Error (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

Mean Absolute Error (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

R-squared ( $R^2$ ):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Keterangan:

$y_i$  : nilai aktual pada waktu ke-(i)  
 $\hat{y}_i$  : nilai prediksi pada waktu ke-(i)  
 $\bar{y}$  : rata-rata dari nilai aktual  
 $n$  : jumlah data pengamatan  
 $(i)$  : indeks pengamatan

Untuk mengukur performa model dalam klasifikasi kualitas udara, digunakan metrik berikut [14] :

Akurasi (*Accuracy*)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

Presisi (*Precision*)

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

Recall (*Sensitivity*)

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

F1-Score

$$F1 = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (9)$$

Keterangan:

TP (*True Positive*) : Jumlah prediksi positif yang benar  
TN (*True Negative*) : Jumlah prediksi negatif yang benar  
FP (*False Positive*) : Jumlah prediksi positif yang salah  
FN (*False Negative*) : Jumlah prediksi negatif yang salah

Metrik-metrik tersebut berguna untuk mengevaluasi performa model dalam mengklasifikasikan kualitas udara ke dalam kategori tertentu (contoh: baik, sedang, tidak sehat, sangat tidak sehat, berbahaya). Model yang punya nilai akurasi, presisi, *recall*, dan *F1-score* lebih tinggi dianggap lebih baik dalam klasifikasi. Dengan perhitungan ini, dilakukan perbandingan antara metode LSTM dan TFT untuk tahu model mana yang lebih baik dalam melakukan prediksi dan klasifikasi kualitas udara di DKI Jakarta [15][16].

### 3. Hasil dan Pembahasan

#### a. Hasil Pengumpulan dan Preprocessing Data

Data yang digunakan dalam penelitian ini diperoleh dari portal resmi Satu Data Jakarta ([satudata.jakarta.go.id](http://satudata.jakarta.go.id)) yang memuat informasi kualitas udara di DKI Jakarta pada periode 2020-2024 dengan total 5.902 data.

| periode_data | tanggal    | stasiun | pm10 | pm25 | so2 | co | o3  | no2 | max | critical | kategori    |
|--------------|------------|---------|------|------|-----|----|-----|-----|-----|----------|-------------|
| 202001       | 2020-01-01 | DKI5    | 38   | NaN  | 38  | 25 | 48  | 9   | 48  | O3       | BAIK        |
| 202001       | 2020-01-02 | DKI5    | 45   | NaN  | 38  | 39 | 102 | 8   | 102 | O3       | TIDAK SEHAT |
| 202001       | 2020-01-03 | DKI5    | 51   | NaN  | 37  | 27 | 63  | 10  | 63  | O3       | SEDANG      |
| 202001       | 2020-01-04 | DKI5    | 51   | NaN  | 38  | 19 | 85  | 10  | 85  | O3       | SEDANG      |
| 202001       | 2020-01-05 | DKI5    | 52   | NaN  | 39  | 25 | 62  | 9   | 62  | O3       | SEDANG      |

Gambar 2 Dataset Kualitas Udara DKI Jakarta Tahun 2020-2024


Menurut gambar 2, dataset bersifat time-series multivariat yang mencakup variabel waktu (tanggal), lokasi pemantauan (stasiun), serta konsentrasi polutan PM<sub>10</sub>, PM<sub>2.5</sub>, SO<sub>2</sub>, CO, O<sub>3</sub>, dan NO<sub>2</sub>, dilengkapi dengan indeks waktu (*time\_idx*). Selain itu, dataset juga memuat atribut nilai maksimum harian, parameter kritis, dan kategori Indeks Standar Pencemar Udara (ISPU) yang digunakan dalam tugas klasifikasi. Karakteristik data menunjukkan fluktuasi polutan yang dinamis dan tidak linier, sehingga sesuai untuk dimodelkan menggunakan pendekatan *deep learning* berbasis deret waktu seperti LSTM dan *Temporal Fusion Transformer* (TFT).

Dari hasil identifikasi awal, ditemukan adanya missing values pada beberapa variabel polutan. Variabel PM<sub>2.5</sub> memiliki jumlah missing value tertinggi sebanyak 764 data, diikuti oleh PM<sub>10</sub> sebanyak 345 data, SO<sub>2</sub> sebanyak 172 data, CO sebanyak 88 data, O<sub>3</sub> sebanyak 103 data, dan NO<sub>2</sub> sebanyak 98 data.

Tabel 2 Missing Value

| Variabel          | Jumlah Missing | Persentase (%) |
|-------------------|----------------|----------------|
| PM <sub>10</sub>  | 345            | 5.85%          |
| PM <sub>2.5</sub> | 764            | 12.95%         |
| SO <sub>2</sub>   | 172            | 2.91%          |
| CO                | 88             | 1.49%          |
| O <sub>3</sub>    | 103            | 1.75%          |
| NO <sub>2</sub>   | 98             | 1.66%          |


Pada tabel 2, jumlah *missing value* cukup signifikan pada beberapa variabel menunjukkan bahwa kualitas data awal belum optimal, sehingga diperlukan proses penanganan untuk menghindari bias pada model. Selain identifikasi *missing value*, dilakukan analisis korelasi antar variabel polutan menggunakan *Pearson Correlation* untuk memahami hubungan antar parameter kualitas udara.



Gambar 3 Heatmap Korelasi Antar Variabel Polutan Kualitas Udara

Pada gambar 3, sebagian besar variabel menunjukkan korelasi positif dengan tingkat hubungan yang berbeda-beda. Korelasi tertinggi ditemukan antara  $PM_{10}$  dan  $PM_{2.5}$  sebesar 0.81, yang menunjukkan hubungan kuat karena keduanya berasal dari sumber emisi yang serupa, seperti transportasi dan aktivitas industri. Selain itu, CO memiliki korelasi positif terhadap  $PM_{2.5}$  dan  $PM_{10}$ , sedangkan beberapa hubungan negatif ditemukan antara  $SO_2$  dan CO serta  $O_3$  dan  $NO_2$ , meskipun relatif lemah. Hasil ini menunjukkan bahwa data kualitas udara memiliki hubungan antar variabel yang kompleks, sehingga penggunaan model multivariat seperti *Long Short-Term Memory* (LSTM) dan *Temporal Fusion Transformer* (TFT) dinilai sesuai untuk menangkap interaksi antar fitur dan pola temporal secara lebih efektif.

Selain analisis korelasi, dilakukan visualisasi distribusi kelas kategori ISPU untuk memahami karakteristik data pada proses klasifikasi.



Gambar 4 Distribusi Kelas Kategori ISPU

Distribusi data pada gambar 4 menunjukkan dominasi kategori “sedang”, sedangkan kategori “baik” dan “tidak sehat” memiliki jumlah data yang lebih sedikit. Sementara itu, kategori “sangat tidak sehat” dan “berbahaya” tidak ditemukan pada dataset. Kondisi ini menunjukkan adanya ketidakseimbangan kelas (class imbalance) yang berpotensi memengaruhi performa model klasifikasi, terutama dalam mengenali kategori minoritas, sehingga model cenderung lebih dominan memprediksi kategori “sedang”.

Outlier diidentifikasi dan dikendalikan menggunakan metode Interquartile Range (IQR).

Tabel 3 Statistik Data Sebelum dan Sesudah Outlier Handling

|      | Statistik $PM_{10}$ (Before) | $PM_{10}$ (After) | $PM_{2.5}$ (Before) | $PM_{2.5}$ (After) | $SO_2$ (Before) | $SO_2$ (After) |
|------|------------------------------|-------------------|---------------------|--------------------|-----------------|----------------|
| Mean | 53.87                        | 53.78             | 78.30               | 78.14              | 38.16           | 38.15          |
| Std  | 15.39                        | 14.95             | 23.17               | 22.34              | 14.59           | 14.58          |
| Min  | 3                            | 14                | 10                  | 19.5               | 2               | 2              |
| Max  | 187                          | 94                | 287                 | 135.5              | 112             | 91             |

Terlihat pada tabel 3, bahwa nilai maksimum mengalami penurunan yang signifikan setelah proses outlier handling, khususnya pada  $PM_{2.5}$  dan  $PM_{10}$ . Hal ini menunjukkan bahwa nilai ekstrem berhasil dikendalikan, sehingga distribusi data menjadi lebih stabil dan tidak bias terhadap nilai anomali.

Pada model *Temporal Fusion Transformer* (TFT), dilakukan proses *feature engineering* untuk meningkatkan kemampuan model dalam menangkap pola temporal dan hubungan antar variabel.

Tabel 4 Contoh Data Hasil Feature Engineering

| Tanggal Stasiun | PM <sub>10</sub> | PM <sub>2.5</sub> | SO <sub>2</sub> | CO    | O <sub>3</sub> | NO <sub>2</sub> | Lag-2 | Lag-3 | Roll Mean (3) | Roll Mean (7) | Hari  | Bulan |   |
|-----------------|------------------|-------------------|-----------------|-------|----------------|-----------------|-------|-------|---------------|---------------|-------|-------|---|
| 2020-01-08      | DKI5             | -0.12             | -1.03           | 0.12  | 1.16           | 2.23            | -0.92 | -0.61 | -0.69         | -0.49         | -0.20 | 0     | 0 |
| 2020-01-09      | DKI4             | 1.88              | -1.03           | -0.00 | 2.59           | 2.29            | -0.74 | -0.52 | -0.61         | -0.22         | -0.32 | 1     | 0 |
| 2020-01-10      | DKI5             | -0.66             | -1.03           | -0.07 | 1.91           | 0.86            | -1.10 | -0.34 | -0.52         | -0.50         | -0.43 | 2     | 0 |

Penambahan fitur lag dan rolling mean pada tabel 4 memungkinkan model untuk memahami pola historis serta tren jangka pendek, sedangkan fitur waktu seperti hari dan bulan membantu dalam menangkap pola musiman. Hal ini menjadi salah satu keunggulan model TFT dibandingkan LSTM dalam memodelkan data *time-series* multivariat.

Normalisasi dilakukan menggunakan metode *MinMaxScaler* untuk menyamakan skala antar variabel ke dalam rentang 0-1. Pendekatan ini bertujuan untuk mengurangi perbedaan skala antar fitur sehingga proses pembelajaran model menjadi lebih stabil dan tidak didominasi oleh variabel dengan rentang nilai yang lebih besar.

Tabel 5 Statistik Data Setelah Normalisasi

| Statistik | PM10  | PM2.5 | SO2   | CO    | O3    | NO2   |
|-----------|-------|-------|-------|-------|-------|-------|
| Mean      | 0.525 | 0.532 | 0.505 | 0.451 | 0.415 | 0.459 |
| Std       | 0.183 | 0.195 | 0.208 | 0.213 | 0.241 | 0.237 |
| Min       | 0.000 | 0.000 | 0.000 | 0.000 | 0.000 | 0.000 |
| Max       | 1.000 | 1.000 | 1.000 | 1.000 | 1.000 | 1.000 |

Hasil normalisasi ditunjukkan pada tabel 5 bahwa seluruh variabel berada dalam rentang skala yang seragam dengan nilai minimum sebesar 0.000 dan maksimum sebesar 1.000. Karakteristik ini menunjukkan bahwa proses transformasi berhasil dilakukan menggunakan *MinMaxScaler*, sehingga setiap fitur memiliki skala yang sebanding dan mampu mengurangi bias pembelajaran model akibat perbedaan rentang nilai antar variabel. Nilai mean dan standar deviasi yang berbeda antar fitur menunjukkan distribusi data tetap dipertahankan setelah proses normalisasi.

## b. Hasil Prediksi Kualitas Udara

Hasil prediksi kualitas udara menunjukkan perbedaan performa yang signifikan antara model LSTM dan *Temporal Fusion Transformer* (TFT).


Berikut hasil prediksi model LSTM:

Tabel 6 Evaluasi Regresi Model LSTM (RMSE, MAE, R<sup>2</sup>)

|                   | RMSE   | MAE    | R <sup>2</sup> |
|-------------------|--------|--------|----------------|
| PM <sub>10</sub>  | 14.143 | 10.786 | -0.082         |
| PM <sub>2.5</sub> | 19.756 | 16.211 | -0.038         |
| SO <sub>2</sub>   | 21.231 | 19.734 | -0.026         |
| CO                | 6.921  | 6.040  | -0.004         |
| O <sub>3</sub>    | 8.364  | 6.464  | -0.103         |
| NO <sub>2</sub>   | 11.485 | 9.231  | -0.128         |

Evaluasi regresi model *Long Short-Term Memory* (LSTM) pada tabel 6 menunjukkan kinerja yang kurang optimal dalam memprediksi kualitas udara. Hal ini ditunjukkan oleh nilai RMSE dan MAE yang

relatif tinggi pada beberapa parameter, khususnya  $PM_{2.5}$  dan  $SO_2$ , serta nilai koefisien determinasi ( $R^2$ ) yang negatif pada seluruh polutan. Nilai  $R^2$  yang negatif mengindikasikan bahwa model tidak mampu merepresentasikan hubungan antara variabel input dan *output* secara memadai, bahkan performanya lebih rendah dibandingkan pendekatan *baseline* sederhana berbasis rata-rata. Kinerja yang kurang optimal ini mengindikasikan adanya keterbatasan LSTM dalam menangkap pola kompleks pada data kualitas udara yang bersifat multivariat dan fluktuatif. Selain itu, tidak adanya variabel eksternal seperti faktor meteorologi (misalnya suhu, kelembapan, dan kecepatan angin) diduga turut membatasi kemampuan model dalam memahami dinamika pembentukan polutan di atmosfer.



Gambar 5 Prediksi vs Aktual LSTM

Pada gambar 5 memperlihatkan hasil evaluasi visual menunjukkan perbedaan yang cukup jelas antara kedua model. Pada LSTM, garis prediksi cenderung lebih halus dan tidak mampu mengikuti fluktuasi tajam pada data aktual, yang mengindikasikan terjadinya *underfitting*. Sebaliknya, model TFT mampu mengikuti pola naik-turun data dengan lebih baik, termasuk pada perubahan yang bersifat ekstrem. Perbedaan ini memperkuat temuan kuantitatif sebelumnya, bahwa TFT memiliki kemampuan yang lebih baik dalam menangkap dinamika temporal jangka pendek maupun jangka panjang. Dengan demikian, model ini lebih representatif dalam merefleksikan kondisi nyata kualitas udara yang bersifat dinamis dan tidak linier.


Sebaliknya, model TFT menunjukkan performa prediksi yang lebih stabil dan akurat, bisa dilihat dari hasil berikut ini:

Tabel 7 Evaluasi Regresi Model TFT (RMSE, MAE,  $R^2$ )

|            | RMSE   | MAE    | $R^2$  |
|------------|--------|--------|--------|
| $PM_{10}$  | 12.689 | 10.317 | 0.136  |
| $PM_{2.5}$ | 19.851 | 16.432 | -0.005 |
| $SO_2$     | 5.313  | 4.291  | 0.927  |
| CO         | 4.524  | 3.829  | 0.618  |
| $O_3$      | 15.665 | 12.023 | -1.496 |
| $NO_2$     | 9.456  | 8.293  | 0.363  |

Berbeda dengan LSTM, tabel 7 menunjukkan bahwa model *Temporal Fusion Transformer* (TFT) menghasilkan kinerja yang lebih baik dalam tugas prediksi kualitas udara. Hal ini terlihat dari nilai RMSE dan MAE yang lebih rendah, serta nilai koefisien determinasi ( $R^2$ ) yang positif pada sebagian besar parameter polutan. Peningkatan performa paling signifikan terlihat pada parameter  $SO_2$  dan CO, yang menunjukkan bahwa model mampu menjelaskan variabilitas data dengan lebih baik. Namun demikian, performa prediksi pada beberapa parameter tertentu masih menunjukkan keterbatasan, yang mengindikasikan bahwa tidak seluruh pola polutan dapat dimodelkan secara optimal. Kondisi ini diduga dipengaruhi oleh karakteristik data yang fluktuatif serta tidak disertakannya variabel eksternal seperti suhu, kelembapan, curah hujan, dan kecepatan angin yang dapat memengaruhi dinamika kualitas udara. Secara

keseluruhan, hasil ini menunjukkan bahwa TFT lebih efektif dalam menangkap hubungan nonlinier dan interaksi antar variabel pada data multivariat. Mekanisme *attention* dan *gating* yang dimiliki TFT memungkinkan model memfokuskan pembelajaran pada informasi temporal yang relevan, sehingga menghasilkan prediksi yang lebih stabil dan adaptif terhadap perubahan pola data.



Gambar 6 Prediksi vs Aktual TFT

Gambar 6 memperlihatkan hasil evaluasi visual yang menunjukkan bahwa model *Temporal Fusion Transformer* (TFT) mampu mengikuti pola temporal data aktual dengan lebih baik dibandingkan model LSTM. Garis prediksi TFT terlihat memiliki tingkat kesesuaian yang lebih tinggi terhadap fluktuasi nilai aktual pada berbagai parameter polutan, termasuk perubahan yang bersifat tajam dan dinamis. Kemampuan ini mencerminkan efektivitas TFT dalam menangkap dependensi temporal jangka pendek maupun jangka panjang pada data kualitas udara multivariat. Kesesuaian pola antara nilai prediksi dan aktual tersebut sejalan dengan diperolehnya nilai *Root Mean Square Error* (RMSE) yang lebih rendah serta koefisien determinasi ( $R^2$ ) yang positif pada sebagian besar polutan, yang mengindikasikan peningkatan akurasi dan kemampuan generalisasi model. Hasil ini menegaskan bahwa mekanisme *attention* dan *gating* pada arsitektur TFT berperan penting dalam memfokuskan pembelajaran model pada informasi temporal yang paling relevan, sehingga memungkinkan representasi dinamika kualitas udara yang lebih akurat dan stabil dibandingkan dengan pendekatan LSTM konvensional.

Untuk memperkuat evaluasi performa model, penelitian ini juga melakukan perbandingan dengan metode baseline sederhana, yaitu *Linear Regression*. Penggunaan model *baseline* bertujuan untuk mengevaluasi sejauh mana pendekatan *deep learning*, khususnya LSTM dan *Temporal Fusion Transformer* (TFT), memberikan peningkatan performa dalam memodelkan kualitas udara dibandingkan metode regresi konvensional.

Tabel 8 Perbandingan Kinerja Model Prediksi Kualitas Udara Berdasarkan Nilai  $R^2$

| Polutan           | Linear Regression | LSTM   | TFT    |
|-------------------|-------------------|--------|--------|
| PM <sub>10</sub>  | -0.322            | -0.082 | 0.136  |
| PM <sub>2.5</sub> | -0.281            | -0.038 | -0.005 |
| SO <sub>2</sub>   | -0.150            | -0.026 | 0.927  |
| CO                | -0.192            | -0.004 | 0.618  |
| O <sub>3</sub>    | -0.881            | -0.103 | -1.496 |
| NO <sub>2</sub>   | -0.155            | -0.128 | 0.363  |

Perbandingan kinerja model pada tabel 8 menunjukkan performa *Linear Regression* yang relatif rendah dengan nilai koefisien determinasi ( $R^2$ ) negatif pada seluruh parameter polutan. Hal ini menunjukkan bahwa model regresi *linier* belum mampu menangkap pola temporal dan hubungan *nonlinier* pada data kualitas udara secara optimal. Dibandingkan dengan *baseline*, model LSTM menunjukkan peningkatan performa meskipun masih menghasilkan nilai  $R^2$  yang rendah pada beberapa parameter. Sementara itu, model *Temporal Fusion Transformer* (TFT) memperoleh performa terbaik pada sebagian besar polutan, khususnya SO<sub>2</sub>, CO, dan NO<sub>2</sub>. Hasil ini menunjukkan bahwa pendekatan berbasis *deep*

*learning*, terutama TFT, lebih efektif dalam memodelkan dinamika kualitas udara multivariat dibandingkan metode regresi konvensional karena memiliki kemampuan yang lebih baik dalam menangkap dependensi temporal dan interaksi antar variabel.

### c. Hasil Klasifikasi ISPU


Hasil klasifikasi Indeks Standar Pencemaran Udara (ISPU) menggunakan model yang diusulkan untuk polutan utama di DKI Jakarta dievaluasi berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score* pada parameter PM<sub>10</sub>, PM<sub>2.5</sub>, SO<sub>2</sub>, CO, O<sub>3</sub>, dan NO<sub>2</sub>.

Classification Report - Kategori ISPU:

|                    | precision | recall | f1-score | support |
|--------------------|-----------|--------|----------|---------|
| BAIK               | 0.00      | 0.00   | 0.00     | 28      |
| SEDANG             | 0.86      | 1.00   | 0.93     | 392     |
| TIDAK SEHAT        | 0.00      | 0.00   | 0.00     | 34      |
| SANGAT TIDAK SEHAT | 0.00      | 0.00   | 0.00     | 0       |
| BERBAHAYA          | 0.00      | 0.00   | 0.00     | 0       |
| accuracy           |           |        | 0.86     | 454     |
| macro avg          | 0.17      | 0.20   | 0.19     | 454     |
| weighted avg       | 0.75      | 0.86   | 0.80     | 454     |

Gambar 7 Hasil Klasifikasi Kategori ISPU LSTM

Hasil klasifikasi menggunakan model LSTM pada gambar 7 menunjukkan bahwa meskipun akurasi mencapai 86%, performa model tidak merata pada seluruh kelas. Model cenderung memprediksi sebagian besar data sebagai kategori “sedang”, yang merupakan kelas mayoritas dalam dataset. Hal ini terlihat dari nilai *precision*, *recall*, dan *F1-score* yang sangat rendah pada kelas “baik” dan “tidak sehat”. Kondisi ini mengindikasikan bahwa model mengalami bias terhadap distribusi data yang tidak seimbang (*class imbalance*), sehingga kurang mampu membedakan karakteristik antar kelas secara efektif. Dengan demikian, akurasi yang tinggi dalam hal ini tidak sepenuhnya mencerminkan kualitas model, karena tidak diikuti dengan performa yang baik pada kelas minoritas.



Gambar 8 Confusion Matrix Kategori ISPU LSTM

*Confusion matrix* kategori ISPU model LSTM pada gambar 8 menunjukkan pola serupa, yaitu memprediksi hampir seluruh data sebagai kategori sedang. Sebanyak 392 data sedang berhasil diprediksi dengan benar, namun 28 data kategori baik dan 34 data kategori tidak sehat salah diklasifikasikan sebagai sedang. Kategori sangat tidak sehat dan berbahaya tidak muncul pada data uji. Kondisi ini menunjukkan bahwa model belum mampu melakukan pemisahan batas keputusan antar kategori secara seimbang dan masih dipengaruhi oleh dominasi kelas mayoritas.


Hasil evaluasi ini menunjukkan bahwa meskipun model LSTM memiliki performa yang baik dari sisi akurasi, diperlukan peningkatan kualitas dan variasi data, serta penanganan ketidakseimbangan kelas, agar kemampuan klasifikasi model terhadap berbagai tingkat kualitas udara dapat ditingkatkan secara lebih komprehensif.

Classification Report - Kategori ISPU

|                    | precision | recall | f1-score | support |
|--------------------|-----------|--------|----------|---------|
| BAIK               | 0.51      | 0.70   | 0.59     | 30      |
| SEDANG             | 0.95      | 0.93   | 0.94     | 501     |
| TIDAK SEHAT        | 0.72      | 0.67   | 0.69     | 51      |
| SANGAT TIDAK SEHAT | 0.00      | 0.00   | 0.00     | 0       |
| BERBAHAYA          | 0.00      | 0.00   | 0.00     | 0       |
| accuracy           |           |        | 0.90     | 582     |
| macro avg          | 0.44      | 0.46   | 0.45     | 582     |
| weighted avg       | 0.91      | 0.90   | 0.90     | 582     |

Gambar 9 Hasil Klasifikasi Kategori ISPU TFT

Hasil klasifikasi menggunakan model TFT pada gambar 9 menunjukkan peningkatan performa klasifikasi dibandingkan LSTM, dengan akurasi mencapai 90% serta distribusi performa yang lebih seimbang antar kelas. Tidak seperti LSTM, model ini mulai mampu mengenali kelas “baik” dan “tidak sehat”, meskipun performanya masih lebih rendah dibandingkan kelas mayoritas. Peningkatan ini menunjukkan bahwa TFT lebih efektif dalam mempelajari batas keputusan antar kelas pada data yang kompleks. Namun demikian, pengaruh ketidakseimbangan data masih terlihat, terutama pada kelas dengan jumlah sampel yang terbatas. Oleh karena itu, pendekatan tambahan seperti penanganan class imbalance masih diperlukan untuk meningkatkan performa model secara menyeluruh.



Gambar 10 Confusion Matrix Kategori ISPU TFT

Confusion matrix kategori ISPU model TFT pada gambar 10 menunjukkan performa yang cukup baik pada kelas sedang, dengan 468 data berhasil diprediksi secara benar dari total data aktual pada kelas tersebut. Namun, masih terdapat kesalahan klasifikasi pada kelas baik yang sebagian diprediksi sebagai sedang (9 data), serta pada kelas tidak sehat yang beberapa kali diprediksi sebagai sedang (17 data). Hal ini menunjukkan bahwa model cenderung bias ke kelas sedang karena distribusi data yang dominan pada kategori tersebut. Sementara itu, kelas sangat tidak sehat dan berbahaya tidak memiliki sampel sehingga tidak dapat dievaluasi lebih lanjut.

Tabel 9 Evaluasi Klasifikasi Kategori ISPU

|      | Model Accuracy | Weighted Precision | Weighted Recall | Weighted F1 | Macro F1 |
|------|----------------|--------------------|-----------------|-------------|----------|
| LSTM | 0.86           | 0.75               | 0.86            | 0.80        | 0.19     |
| TFT  | 0.90           | 0.91               | 0.90            | 0.90        | 0.45     |

Tabel 9 menunjukkan evaluasi klasifikasi dilakukan menggunakan metrik Weighted F1-score dan Macro F1-score untuk memperoleh pengukuran performa yang lebih komprehensif pada data yang tidak seimbang. Weighted F1-score mempertimbangkan proporsi jumlah data pada setiap kelas, sedangkan Macro F1-score mengevaluasi performa seluruh kelas secara setara tanpa dipengaruhi dominasi kelas mayoritas. Model TFT menunjukkan performa yang lebih baik dibandingkan LSTM dengan nilai Weighted F1 sebesar 0.90 dan Macro F1 sebesar 0.45, sedangkan LSTM hanya memperoleh Weighted F1 sebesar 0.80 dan Macro F1 sebesar 0.19. Nilai Macro F1 yang rendah pada LSTM mengindikasikan bahwa model masih kurang optimal dalam mengenali kategori minoritas dan cenderung bias terhadap kategori “sedang” sebagai kelas mayoritas. Sebaliknya, peningkatan nilai Macro F1 pada TFT menunjukkan kemampuan model yang lebih baik dalam membedakan antar kategori ISPU secara lebih seimbang.

#### d. Perbandingan dengan Studi Sebelumnya

Hasil penelitian ini sejalan dengan penelitian sebelumnya oleh [6], [7] yang menunjukkan bahwa model berbasis *Transformer*, khususnya *Temporal Fusion Transformer* (TFT), memiliki kemampuan yang baik dalam memodelkan data deret waktu multivariat dan dapat memberikan kinerja yang kompetitif dibandingkan model berbasis recurrent neural network seperti *Long Short-Term Memory* (LSTM), Gated Recurrent Unit (GRU), dan *Bidirectional Long Short-Term Memory* (BiLSTM) pada prediksi kualitas udara. Penelitian terdahulu juga menunjukkan bahwa mekanisme attention pada TFT memungkinkan model menangkap dependensi temporal dan hubungan antarvariabel secara lebih adaptif. Hal ini konsisten dengan hasil penelitian ini, di mana TFT menghasilkan nilai  $R^2$  yang lebih tinggi pada beberapa parameter polutan, sedangkan LSTM menghasilkan nilai  $R^2$  negatif pada seluruh parameter. Perbedaan kinerja tersebut menunjukkan bahwa TFT lebih mampu menangkap pola temporal dan hubungan kompleks antarvariabel pada data kualitas udara. Dengan demikian, hasil penelitian ini memperkuat temuan penelitian terdahulu bahwa pendekatan berbasis attention memiliki potensi yang lebih baik untuk pemodelan dan prediksi kualitas udara multivariat.

#### e. Pembahasan dan Implementasi

Secara keseluruhan, hasil penelitian menunjukkan bahwa model *Temporal Fusion Transformer* (TFT) memiliki performa yang lebih unggul dibandingkan *Long Short-Term Memory* (LSTM) baik dalam tugas prediksi maupun klasifikasi. Keunggulan ini terutama terlihat pada kemampuan model dalam menangkap pola temporal yang kompleks serta interaksi antar variabel dalam data multivariat.

Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa arsitektur berbasis *transformer* lebih efektif dalam memodelkan data deret waktu yang memiliki dependensi jangka panjang dan hubungan nonlinier. Dalam konteks kualitas udara, kemampuan ini menjadi krusial karena proses pembentukan polutan dipengaruhi oleh berbagai faktor yang saling berinteraksi secara dinamis. Meskipun demikian, hasil penelitian juga menunjukkan adanya keterbatasan, khususnya terkait ketidakseimbangan distribusi kelas dan tidak digunakannya variabel eksternal. Hal ini membuka peluang pengembangan lebih lanjut untuk meningkatkan performa model melalui integrasi data meteorologi serta penerapan teknik penyeimbangan data.

### 4. Kesimpulan dan Saran

Hasil penelitian menunjukkan bahwa kedua model dapat memanfaatkan data historis polutan untuk menghasilkan prediksi numerik dan klasifikasi kualitas udara, namun dengan tingkat kinerja yang berbeda. Hasil evaluasi menunjukkan bahwa LSTM belum mampu menangkap pola temporal kompleks secara optimal, terlihat dari nilai  $R^2$  negatif pada seluruh parameter polutan serta hasil klasifikasi yang cenderung bias terhadap kelas mayoritas meskipun mencapai akurasi 86%. Sebaliknya, TFT memberikan hasil yang lebih stabil pada tugas regresi maupun klasifikasi. Pada prediksi numerik, TFT menghasilkan nilai  $R^2$  yang lebih tinggi pada  $SO_2$  sebesar 0,927, CO sebesar 0,619, dan  $NO_2$  sebesar 0,363. Pada klasifikasi kategori ISPU, TFT mencapai akurasi 90% dengan performa yang lebih seimbang antar kelas, sehingga lebih efektif dalam memodelkan hubungan non-linear dan ketergantungan jangka panjang pada data kualitas udara.

Kontribusi utama penelitian ini adalah penyusunan kerangka analisis terpadu yang menggabungkan prediksi dan klasifikasi kualitas udara menggunakan dua pendekatan *deep learning* serta evaluasi empiris

pada data kualitas udara multivariat di Indonesia. Temuan menunjukkan bahwa TFT berpotensi lebih unggul dalam menangani data time-series yang kompleks dan dinamis dibandingkan model recurrent.

TFT juga berpotensi dikembangkan sebagai dasar sistem prediksi dan peringatan dini kualitas udara untuk mendukung pengambilan keputusan yang lebih responsif. Penelitian selanjutnya dapat menerapkan teknik penanganan ketidakseimbangan data, seperti oversampling, undersampling, atau class weighting, serta mengintegrasikan variabel eksternal seperti suhu, kelembapan, dan curah hujan. Selain itu, optimalisasi hyperparameter, eksplorasi arsitektur hibrida, dan pengembangan TFT berbasis data real-time dapat dilakukan untuk meningkatkan kinerja dan penerapan model.

## Referensi

- [1] A. Zhafran, H. Ramadhan, B. Rahayudi, and D. E. Ratnawati, "PREDIKSI POLUSI UDARA DI DKI JAKARTA DENGAN MENGGUNAKAN METODE LONG-SHORT TERM MEMORY ( LSTM )," vol. 1, no. 1, pp. 1–8, 2024.
- [2] M. A. S. S. G. C. S. Wahyudi, "Air Quality Prediction Model of Surabaya City Using Long Short Term Memory (LSTM) Method," *Int. J. Eng. Appl.*, vol. 12, 2024, [Online]. Available: <https://doi.org/10.15866/irea.v12i1.24289>
- [3] G. N. T. A. S. K. Depren, "Optimizing air quality predictions: A discrete wavelet transform and long short-term memory approach with wavelet-type selection for hourly PM10 concentrations," *J. Chemom.*, vol. 38, no. 4, 2024, [Online]. Available: <https://doi.org/10.1002/cem.3539>
- [4] G. X. H. Z. L. Y. M. Z. C. L. Y. Huang, "Research on Regional Collaborative Prediction of Air Quality Based on LSTM-FC," *Int. Conf. Comput. Inf. Sci. Appl. Technol.*, 2024, [Online]. Available: <https://doi.org/10.1109/CISAT62382.2024.10695184>
- [5] D. B. P. R. Ragiri, "A Deep Learning Approach to Enhance Air Quality Prediction: Comparative Analysis of LSTM, LSTM with Attention Mechanism and BiLSTM," *IEEE Reg. 10 Symp.*, 2024, [Online]. Available: <https://doi.org/10.1109/TENSYMP61132.2024.10752321>
- [6] C. Z. Y. Tang, "An Empirical Analysis of the Long Short Term Memory and Temporal Fusion Transformer Models on Regional Air Quality Forecast," *2023 Int. Conf. Cyber-Physical Soc. Intell.*, p. 73, Nov. 2023.
- [7] V. Santhana Lakshmi and M. S. Vijaya, "Air Quality Index Prediction Model Using Temporal Fusion Transformer," *Int. J. Intell. Syst. Appl. Eng.*, vol. 12, no. 14, pp. 418–429, 2024.
- [8] J. J. J. P. Costa, "Using Temporal Fusion Transformer Predictions to Maximise Use of Renewable Energy Sources," *Int. Work. Artif. Intell. Mach. Learn. Energy Transform.*, 2024, [Online]. Available: <https://doi.org/10.1109/AIE61866.2024.10561261>
- [9] Z. N. X. H. D. Z. Y. W. S. Lan, "Interpretable wind power forecasting combining seasonal-trend representations learning with temporal fusion transformers architecture," *Energy*, vol. 306, 2024, [Online]. Available: <https://doi.org/10.1016/j.energy.2024.132482>
- [10] S. R. S. L. T. Lewandowski, "Interpretable Bike-Sharing Activity Prediction with a Temporal Fusion Transformer to Unveil Influential Factors: A Case Study in Hamburg, Germany," *Sustain.*, vol. 16, no. 8, 2024, doi: <https://doi.org/10.3390/su16083230>.
- [11] M. Z. Wicaksono and L. E. Astrianty, "TIN : Terapan Informatika Nusantara Sistem Prediksi Kualitas Udara Menggunakan Algoritma Long Short- Term Memory ( LSTM ) TIN : Terapan Informatika Nusantara," vol. 6, no. 7, pp. 831–840, 2025, doi: <https://doi.org/10.47065/tin.v6i7.8619>.
- [12] S. Sinsomboonthong, "Performance Comparison of New Adjusted Min-Max with Decimal Scaling and Statistical Column Normalization Methods for Artificial Neural Network Classification," vol. 2022, 2022, doi: <https://doi.org/10.1155/2022/3584406>.
- [13] S. H. M. Hickman and P. T. Griffiths, "Short-term forecasting of ozone air pollution across Europe with transformers," pp. 1–20, 2023, doi: <https://doi.org/10.1017/eds.2023.37>.
- [14] S. A. Pratiwi, A. Fauzi, S. Arum, P. Lestari, and Y. Cahyana, "KLIK: Kajian Ilmiah Informatika dan Komputer Prediksi Persediaan Obat Pada Apotek Menggunakan Algoritma Decision Tree," *Media Online*, vol. 4, no. 4, pp. 2381–2388, 2024, doi: <https://doi.org/10.30865/klik.v4i4.1681>.
- [15] M. Fahmi and I. K. G. Suhartana, "Perbandingan Algoritma Decision Tree Dan Support Vector Machine Dalam Prediksi Kualitas Udara," vol. 1, no. November, pp. 21–30, 2022.
- [16] G. E. Saputra, M. Hanindia, P. Swari, and A. L. Nurlaili, "Implementasi Algoritma XGBoost , CatBoost , dan LGBM untuk Klasifikasi Pencemaran Udara," vol. 8, pp. 14135–14139, 2025, doi: <https://doi.org/10.54371/jiip.v8i12.10102>