

## Deteksi Emisi Metana dari Pabrik Kelapa Sawit di Indonesia Menggunakan Data Satelit Dan Menggunakan Metode *Machine Learning*

Iin Darmiyati<sup>1\*</sup>, Ranjiv Maulana<sup>2</sup>

<sup>1</sup>D3 Teknik Instrumentasi dan Elektronika Migas, Sekolah Tinggi Teknologi Migas

\*E-mail: iin.darmiyati@sttmigas.ac.id

### ABSTRACT

*Methane (CH<sub>4</sub>) emissions from palm oil mills Palm Oil Mill (POM) in Indonesia are a major contributor to greenhouse gas accumulation and climate change. To address this issue, this study applies machine learning with satellite data to automatically and efficiently detect and analyze methane emission patterns. The dataset is obtained from GHGSat, Sentinel-5P TROPOMI, PRISMA, EnMAP, and EMIT, which provide spatial and temporal information on methane distribution in the atmosphere. The data is processed using Google Colab, including data cleaning, normalization, variable transformation, and feature selection, before being trained using several machine learning models, namely Logistic Regression, XGBoost, Gradient Boosting, Decision Tree, and K-Nearest Neighbors (KNN). The evaluation results show that XGBoost performs the best, achieving 73.53% accuracy and an F1-score of 52.28% for high-emission areas, followed by Decision Tree with 73.44% accuracy and 54.90% recall. This method enables faster, more accurate, and large-scale methane emission detection, supporting climate change mitigation strategies and the sustainability of the palm oil industry in Indonesia.*

**Keywords:** *Methane Emissions, Machine Learning, Satellite Data, XGBoost, Palm Oil, Greenhouse Gases, Climate Change.*

### ABSTRAK

Faktor emisi metana (CH<sub>4</sub>) dari pabrik kelapa sawit *Palm Oil Mill (POM)* di Indonesia merupakan salah satu penyebab utama peningkatan gas rumah kaca yang berkontribusi terhadap perubahan iklim. Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan *machine learning* berbasis data satelit guna mendeteksi dan menganalisis pola emisi metana secara otomatis dan efisien. Data yang digunakan diperoleh dari GHGSat, Sentinel-5P TROPOMI, PRISMA, EnMAP, dan EMIT, yang menyediakan informasi spasial dan temporal mengenai distribusi metana di atmosfer. Data ini diproses menggunakan Google Colab, dengan tahapan pembersihan, normalisasi, transformasi variabel, dan seleksi fitur sebelum dilatih menggunakan beberapa model *machine learning*, yaitu Logistic Regression, XGBoost, Gradient Boosting, Decision Tree, dan K-Nearest Neighbors (KNN). Hasil evaluasi menunjukkan bahwa XGBoost memiliki performa terbaik, dengan akurasi 73.53% dan F1-score 52.28% untuk wilayah dengan emisi tinggi, diikuti oleh Decision Tree dengan akurasi 73.44% dan recall 54.90%. Dengan metode ini, deteksi emisi metana dapat dilakukan lebih cepat, akurat, dan dalam skala luas, sehingga mendukung strategi mitigasi perubahan iklim serta keberlanjutan industri kelapa sawit di Indonesia.

**Kata kunci:** *Emisi Metana, Machine Learning, Data Satelit, XGBoost, Kelapa Sawit, Gas Rumah Kaca, Perubahan Iklim.*

## PENDAHULUAN

Perubahan iklim merupakan salah satu tantangan terbesar yang dihadapi dunia saat ini, dengan emisi gas rumah kaca sebagai faktor utama yang berkontribusi terhadap pemanasan global. Salah satu gas rumah kaca yang memiliki dampak signifikan adalah metana ( $\text{CH}_4$ ), yang memiliki potensi pemanasan global sekitar 25 kali lebih besar dibandingkan karbon dioksida ( $\text{CO}_2$ ) dalam jangka waktu 100 tahun (Farah & Shahrour, 2024). Emisi metana berasal dari berbagai sumber baik alami maupun antropogenik, termasuk sektor energi, pertanian, dan pengelolaan limbah. Di Indonesia, salah satu kontributor utama emisi metana adalah pabrik kelapa sawit (*Palm Oil Mills* – POM), yang menghasilkan *Palm Oil Mill Effluent* (POME), limbah cair dengan kandungan bahan organik tinggi (Vollmer, 2024). Jika tidak dikelola dengan baik, POME akan mengalami dekomposisi anaerobik dan menghasilkan metana dalam jumlah besar. Metode konvensional dalam pengelolaan POME, seperti *open ponding system*, dinilai tidak ramah lingkungan karena berkontribusi terhadap pelepasan emisi metana yang signifikan (Kumar, 2023). Oleh karena itu diperlukan pendekatan yang lebih efektif dalam memantau, mengukur, dan mengelola emisi metana dari industri kelapa sawit (Gemeinhardt & Sharma, 2024).

Salah satu solusi yang semakin berkembang dalam pemantauan emisi metana adalah penggunaan data satelit, yang memungkinkan pemantauan luas, berkelanjutan, dan lebih akurat dibandingkan metode tradisional (Kaharuddin et al., 2020). Teknologi satelit seperti GHGSat dan AVIRIS-NG telah digunakan untuk mendeteksi *plume* metana, sehingga memungkinkan identifikasi sumber emisi dengan lebih akurat (Valverde, 2024). Namun, penggunaan pencitraan satelit masih memiliki keterbatasan dalam resolusi spasial dan temporal, sehingga memerlukan pendekatan tambahan untuk meningkatkan akurasi deteksi. Dalam hal ini *machine learning* menjadi solusi yang menjanjikan untuk mengoptimalkan analisis data satelit, dengan kemampuannya dalam mengenali pola emisi metana yang kompleks dan meningkatkan akurasi prediksi (Sharma, 2024)

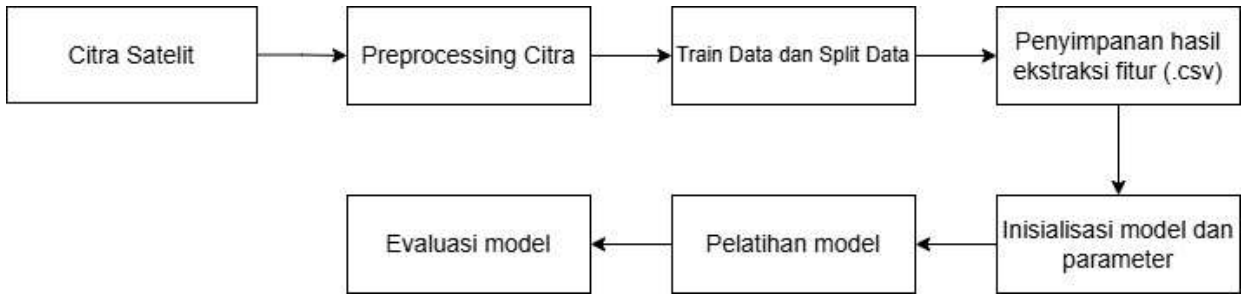
Dalam penelitian yang dilakukan beberapa model *machine learning* diterapkan untuk mendeteksi dan menganalisis emisi metana dari pabrik kelapa sawit, antara lain *Logistic Regression*, *XGBoost*, *Gradient Boosting*, *Decision Tree*, dan *K-Nearest Neighbors* (KNN). Penelitian ini bertujuan untuk mengeksplorasi efektivitas data satelit dan metode *machine learning* dalam mendeteksi emisi metana dari pabrik kelapa sawit di Indonesia. Studi ini akan menganalisis performa berbagai model *machine learning* dalam mengolah data satelit, mengidentifikasi pola emisi metana, serta mengevaluasi tantangan dan peluang implementasi teknologi ini dalam pemantauan lingkungan. Dengan hasil penelitian ini, diharapkan dapat memberikan kontribusi terhadap strategi mitigasi gas rumah kaca serta mendukung kebijakan yang lebih berkelanjutan dalam pengelolaan industri kelapa

sawit dan perlindungan lingkungan.

## METODE PENELITIAN

Penelitian ini menggunakan pendekatan analisis data satelit dan *machine learning* untuk mendeteksi serta menganalisis emisi metana dari pabrik kelapa sawit *Palm Oil Mill Effluent* (POM) di Indonesia. Data yang digunakan diperoleh dari dataset satelit di Kaggle, yang mencakup informasi mengenai konsentrasi metana ( $\Delta X$  CH<sub>4</sub>), lokasi geografis (latitude, *longitude*), suhu, kelembaban, dan kondisi atmosfer lainnya. Pemrosesan data dilakukan menggunakan Google Colab, yang mendukung pemrograman berbasis cloud serta integrasi dengan pustaka Python seperti *Pandas*, *Scikit-Learn*, *TensorFlow*, dan *Matplotlib*. Tahapan penelitian ini mencakup pengumpulan data, pra-pemrosesan, pembangunan model *machine learning*, evaluasi model serta visualisasi hasil. Pada tahap pengumpulan data, penelitian ini memanfaatkan berbagai sumber pencitraan satelit yang tersedia di dataset Kaggle, termasuk GHGSat, Sentinel-5P TROPOMI, PRISMA, EnMAP, dan EMIT, yang memiliki sensitivitas tinggi terhadap emisi metana (Sarker, 2024). Dataset ini berisi data spasial dan temporal, sehingga memungkinkan analisis pola emisi dari pabrik kelapa sawit di Indonesia berdasarkan waktu dan lokasi. Data ini dipadukan dengan informasi lokasi POM yang diperoleh dari sumber terbuka seperti Kementerian Pertanian Indonesia dan platform GIS, untuk memastikan akurasi deteksi sumber emisi metana (Tiemann, 2024).

Untuk meningkatkan kualitas dataset sebelum pemodelan *machine learning*, dilakukan pra-pemrosesan data yang mencakup pembersihan missing values, deteksi outlier (z-score & IQR), normalisasi, serta transformasi variabel kategorikal menggunakan one-hot encoding atau label encoding (Islam dkk, 2024). *Feature selection* dilakukan dengan correlation matrix dan PCA untuk memilih variabel paling relevan. Dataset dibagi menjadi 80% training set dan 20% testing set menggunakan train-test split, serta diterapkan K-fold cross-validation (K=5) untuk menghindari overfitting. Penelitian ini diharapkan dapat menghasilkan sistem deteksi emisi metana berbasis *machine learning* yang lebih akurat dan efisien menggunakan data satelit. Adapun dalam penelitian ini menggunakan *machine learning* sebagai solusi cerdas untuk melakukan proses deteksi metana menggunakan citra satelit. Adapun langkah kerja yang dilakukan terdapat dalam Gambar 1.



**Gambar 1.** Flowchart penelitian

Model yang digunakan dalam penelitian ini meliputi *Linear Regression*, *XGBoost*, *Gradient Boosting*, *Decision Tree*, dan *K-Nearest Neighbors (KNN)*. *XGBoost* dan *Gradient Boosting* digunakan untuk menangani pola kompleks, *Decision Tree* untuk klasifikasi non-linear, serta *KNN* untuk deteksi pola spasial-temporal (Islam dkk, 2022). Evaluasi model dilakukan menggunakan *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, dan *R<sup>2</sup> Score* untuk regresi, serta *Accuracy*, *Precision*, *Recall*, dan *F1-score* untuk klasifikasi. Setelah pemodelan dan evaluasi, hasil analisis akan divisualisasikan dalam bentuk peta sebaran emisi metana, grafik tren emisi, serta *heatmap* korelasi guna memahami pola emisi berdasarkan lokasi dan kondisi lingkungan. Untuk perhitungan akurasi dalam metode *machine learning* menggunakan rumus presisi, recall dan *F1-score* (Jasmine, 2016):

$$Precision (P) = \frac{TP}{TP+FP} \quad (1)$$

$$Recall (R) = \frac{TP}{TP+FN} \quad (2)$$

$$F1 - Score = 2 \times \frac{P \times R}{P+R} \quad (3)$$

## HASIL PENELITIAN DAN PEMBAHASAN

Penelitian ini mengimplementasikan *machine learning* untuk mendeteksi emisi metana menggunakan dataset dari Kaggle yang diproses di Google Colab. Tahapan penelitian dimulai dari pra-pemrosesan data, yang mencakup pembersihan data, normalisasi, serta seleksi fitur untuk memastikan model hanya menggunakan variabel yang paling relevan. Eksplorasi data menunjukkan bahwa emisi metana memiliki korelasi dengan faktor lingkungan seperti suhu dan kelembaban, serta konsentrasi tinggi ditemukan di wilayah dengan aktivitas industri dan pertanian.

### Tahap Pra Pemrosesan Data (*Preprocessing*)

Pada penelitian ini, pra-pemrosesan data dilakukan untuk memastikan kualitas dataset sebelum digunakan dalam model machine learning. Langkah pertama adalah pembersihan data (*data cleaning*), yang mencakup penghapusan *missing values* dan deteksi outlier menggunakan metode z-score dan IQR (*Interquartile Range*) guna menghindari bias dalam model. Transformasi data dilakukan dengan mengonversi variabel kategorikal menggunakan label *encoding* atau *one-hot encoding*. Selanjutnya, dilakukan normalisasi dan standarisasi agar fitur berada dalam skala yang sama, menggunakan *MinMaxScaler* untuk KNN dan *Gradient Boosting*, serta *StandardScaler* untuk *Linear Regression*. Reduksi dimensi dengan *Principal Component Analysis* (PCA) diterapkan untuk meningkatkan efisiensi model. Setelah itu, dilakukan *feature selection* menggunakan *correlation matrix*, serta pembagian data dengan *train-test split* (80% training, 20% testing). Untuk meningkatkan keakuratan dan menghindari overfitting, diterapkan K-fold cross-validation (K=5).

Untuk dataset citra satelit, dilakukan ekstraksi fitur spektral, di mana data dalam format GeoTIFF atau NetCDF diubah menjadi array numerik menggunakan GDAL, Rasterio, dan NumPy. Resolusi citra diseragamkan melalui *downscaling* dan *resampling*, serta dilakukan normalisasi spektral untuk memastikan perbandingan intensitas metana yang lebih akurat. Setelah semua tahapan pra-pemrosesan selesai, dataset yang telah dibersihkan siap digunakan dalam pelatihan model *machine learning* untuk mendeteksi dan memprediksi emisi metana dari pabrik kelapa sawit di Indonesia.

### Pembangunan Model Machine Learning

Setelah melalui tahapan pra-pemrosesan, dataset citra satelit digunakan untuk melatih beberapa model machine learning guna mendeteksi dan memprediksi emisi metana dari pabrik kelapa sawit di Indonesia. Model yang diterapkan dalam penelitian ini meliputi *Linear Regression* (LR), *Extreme Gradient Boosting* (XGB), *Gradient Boosting* (GB), *Decision Tree* (DT), dan *K-Nearest Neighbors* (KNN), yang masing-masing memiliki pendekatan berbeda dalam menganalisis data. *Linear Regression* digunakan sebagai baseline model untuk memahami hubungan linear antara variabel lingkungan dan tingkat emisi metana, sementara XGBoost dan *Gradient Boosting* diterapkan untuk menangani pola non-linear dengan teknik *boosting*. *Decision Tree* digunakan untuk mengklasifikasikan tingkat emisi berdasarkan karakteristik lingkungan, sedangkan KNN memprediksi emisi berdasarkan kemiripan spasial-temporal antar titik data. Dataset dibagi menggunakan *train-test split* (80% training, 20% testing) serta K-fold cross-validation (K=5) untuk menghindari *overfitting* dan meningkatkan akurasi model. Selain itu, dilakukan *hyperparameter*

Artikel diterima 28 Februari 2025. Online 30 Maret 2025.

*tuning* pada model berbasis boosting untuk mengoptimalkan parameter seperti *learning rate*, *depth of trees*, dan *number of estimators* guna mendapatkan keseimbangan antara bias dan varians model (Yussof, 2022).

Untuk menangani dataset citra satelit, dilakukan ekstraksi fitur spektral dengan mengonversi citra menjadi data numerik menggunakan GDAL, Rasterio, dan NumPy. Resolusi spasial diseragamkan melalui *downscaling* dan *resampling*, serta dilakukan normalisasi spektral untuk menyesuaikan skala intensitas metana pada setiap piksel (Kumar, 2020). Data kemudian dikodekan dalam bentuk *time-series* atau *grid-based features* dan diolah dalam Google Colab menggunakan *pipeline machine learning* untuk mengotomatisasi transformasi, normalisasi, feature selection, dan training model. Evaluasi model dilakukan menggunakan *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan  $R^2$  Score untuk model regresi, serta *Accuracy*, *Precision*, *Recall*, dan F1-score untuk model klasifikasi (Hossain dkk, 2020). Hasil analisis divisualisasikan dalam bentuk peta sebaran emisi metana, grafik tren emisi, dan heatmap korelasi guna memahami pola distribusi dan faktor lingkungan yang berkontribusi terhadap emisi metana. Penelitian ini diharapkan dapat memberikan wawasan lebih dalam mengenai pola emisi metana dari pabrik kelapa sawit di Indonesia, serta mengidentifikasi metode machine learning yang paling efektif dalam mendeteksi dan memprediksi emisi berbasis data satelit.

## Evaluasi Model

Pada Tabel 1. terdapat lima model machine learning telah diuji untuk mendeteksi emisi metana dari pabrik kelapa sawit di Indonesia, yaitu *Logistic Regression* (LR), *XGBoost*, *Gradient Boosting* (GB), *Decision Tree* (DT), dan *K-Nearest Neighbors* (KNN). Evaluasi dilakukan berdasarkan akurasi (*accuracy*), presisi (*precision*), *recall*, dan F1-score untuk masing-masing kelas, di mana *Class 0* mewakili area dengan emisi metana rendah, sedangkan *Class 1* mewakili area dengan emisi metana tinggi. Berikut adalah analisis performa dari masing-masing model.

### 1. *Logistic Regression* (LR)

Model *Logistic Regression* menunjukkan akurasi sebesar 68.12%, yang merupakan nilai terendah kedua dibandingkan model lainnya. Model ini memiliki presisi tinggi untuk *Class 0* (0.6878), tetapi sangat rendah untuk *Class 1* (0.4227), menunjukkan bahwa model lebih cenderung memprediksi wilayah sebagai non-emitter. *Recall* untuk *Class 0* mencapai 97.90%, menandakan bahwa hampir semua wilayah dengan emisi rendah diklasifikasikan dengan benar. Namun, *recall* untuk *Class 1* sangat rendah, hanya 3.33%, yang berarti model gagal mendeteksi sebagian besar area dengan emisi tinggi. Dengan F1-score yang rendah untuk *Class 1* (0.0618), dapat disimpulkan bahwa

*Logistic Regression* kurang cocok untuk tugas ini karena bias yang kuat terhadap kelas mayoritas (*Class 0*).

## 2. XGBoost

Dari semua model yang diuji, XGBoost menunjukkan performa terbaik dengan akurasi 73.53%. Model ini memiliki presisi tinggi pada *Class 0* (0.7764) dan lebih baik dalam mendeteksi *Class 1* dengan presisi 0.6046 dibandingkan model lainnya. *Recall* untuk *Class 1* sebesar 46.05%, menunjukkan bahwa model cukup mampu mengenali area dengan emisi metana tinggi dibandingkan metode lainnya. *F1-score* untuk *Class 1* mencapai 0.5228, yang merupakan nilai tertinggi dibandingkan model lainnya, mengindikasikan keseimbangan yang baik antara presisi dan *recall*. Secara keseluruhan, XGBoost adalah model yang paling efektif dalam mendeteksi emisi metana, terutama dalam menangani ketidakseimbangan kelas.

## 3. Gradient Boosting (GB)

Model *Gradient Boosting* memiliki akurasi 72.53%, sedikit lebih rendah dari XGBoost. Presisi untuk *Class 0* cukup baik di angka 0.7488, tetapi *recall* untuk *Class 1* hanya 34.25%, yang lebih rendah dari XGBoost dan *Decision Tree*. Meskipun presisi untuk *Class 1* mencapai 0.6148, nilai *recall* yang rendah menyebabkan *F1-score* untuk *Class 1* turun menjadi 0.4399, yang lebih rendah dari XGBoost dan *Decision Tree*. Ini menunjukkan bahwa *Gradient Boosting* memiliki performa yang baik secara keseluruhan, tetapi kurang dalam mendeteksi wilayah dengan emisi tinggi dibandingkan XGBoost.

## 4. Decision Tree (DT)

*Decision Tree* menunjukkan akurasi yang hampir setara dengan XGBoost, yaitu 73.44%, menjadikannya salah satu model dengan performa terbaik dalam tugas ini. Model ini memiliki presisi tertinggi untuk *Class 0* (0.7981), menunjukkan bahwa model sangat akurat dalam mengklasifikasikan wilayah tanpa emisi metana tinggi. *Recall* untuk *Class 1* mencapai 54.90%, yang lebih tinggi dibandingkan *Logistic Regression*, *Gradient Boosting*, dan KNN, tetapi masih lebih rendah dari XGBoost. *F1-score* untuk *Class 1* adalah 0.5656, yang merupakan nilai tertinggi kedua setelah XGBoost. Berdasarkan hasil ini, *Decision Tree* adalah model yang cukup baik dalam mendeteksi emisi metana tinggi, tetapi masih rentan terhadap *overfitting* dibandingkan metode boosting seperti XGBoost

## 5. K-Nearest Neighbors (KNN)


Dari semua model yang diuji, KNN memiliki performa terburuk dengan akurasi hanya 63.26%. Model ini memiliki presisi rendah untuk *Class 1* (0.3447) dan *recall* yang sangat rendah (18.47%), yang berarti model ini gagal mendeteksi sebagian besar wilayah dengan emisi tinggi. *F1-score* untuk *Class 1* hanya 0.2405, menunjukkan bahwa model ini kurang efektif dalam tugas ini. KNN memiliki

keterbatasan dalam menangani dataset yang besar dan kompleks, terutama yang memiliki banyak fitur numerik dan hubungan non-linear. Dengan hasil ini, KNN tidak direkomendasikan untuk mendeteksi emisi metana dari data satelit. Tabel 1 menunjukkan hasil keseluruhan metode *machine learning*.

**Tabel 1.** Hasil Metode *Machine Learning*

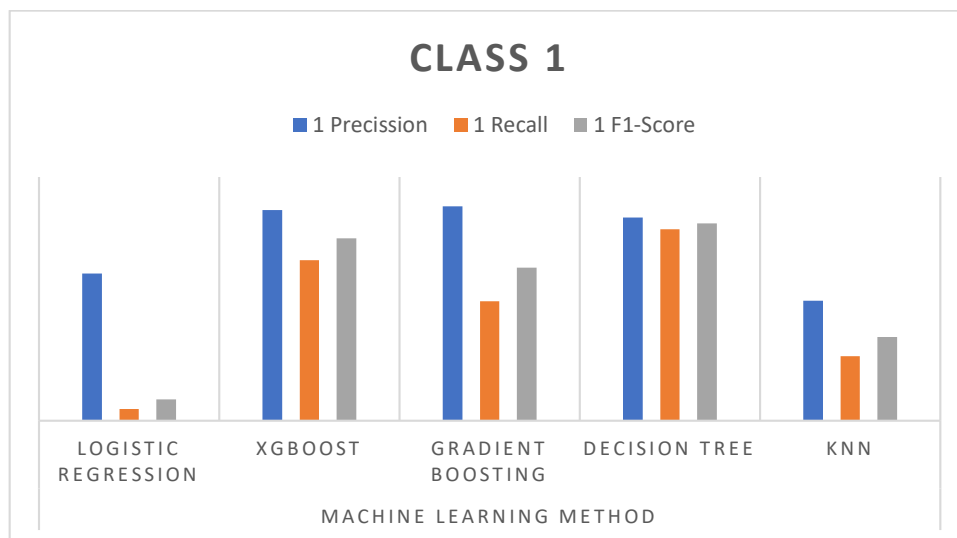
Class	Evaluation Method	Machine Learning Method				
		Logistic Regression	XGBoost	Gradient Boosting	Decision Tree	KNN
0	Precision	0.6877	0.7764	0.7488	0.7981	0.6911
	Recall	0.9791	0.8615	0.9013	0.8196	0.8385
	F1-Score	0.8079	0.8168	0.8181	0.8087	0.7577
1	Precision	0.4227	0.6046	0.6148	0.5833	0.3447
	Recall	0.033	0.4605	0.3425	0.5491	0.1847
	F1-Score	0.0618	0.5228	0.4399	0.5656	0.2405
Accuracy		0.6812	0.7352	0.7253	0.73444	0.6326

Dataset yang digunakan dalam penelitian ini memiliki hubungan erat dengan *machine learning* karena berisi informasi hasil klasifikasi model dalam mendeteksi emisi metana dari pabrik kelapa sawit (POM) di Indonesia berdasarkan data satelit. Dataset ini mencakup berbagai metrik evaluasi, seperti akurasi, presisi, recall, dan F1-score, yang digunakan untuk mengukur efektivitas model dalam membedakan wilayah dengan dan tanpa emisi metana tinggi. Dalam konteks ini, machine learning memungkinkan model untuk belajar dari pola dalam data satelit dan membuat prediksi berdasarkan informasi lingkungan yang terdeteksi dari sensor satelit. Model yang digunakan, seperti *Logistic Regression*, *XGBoost*, *Gradient Boosting*, *Decision Tree*, dan KNN, dilatih untuk mengenali hubungan kompleks antara variabel-variabel ini dan menentukan apakah suatu wilayah merupakan sumber emisi metana atau bukan. Proses deteksi dimulai dengan pengumpulan dan pemrosesan data satelit yang mencakup peta distribusi metana dari berbagai instrumen satelit, seperti GHGSat, Sentinel-5P TROPOMI, PRISMA, EnMAP, dan EMIT. Data ini kemudian diproses melalui pembersihan data (*data cleaning*), normalisasi, dan transformasi agar dapat digunakan dalam *model machine learning*. Gambar 2 menunjukkan hasil perbandingan tiap metode *machine learning* untuk kelas 0 yang mewakili area dengan emisi metana rendah.



Gambar 2. Hasil Perbandingan Untuk Kelas 0 (emisi metana rendah)

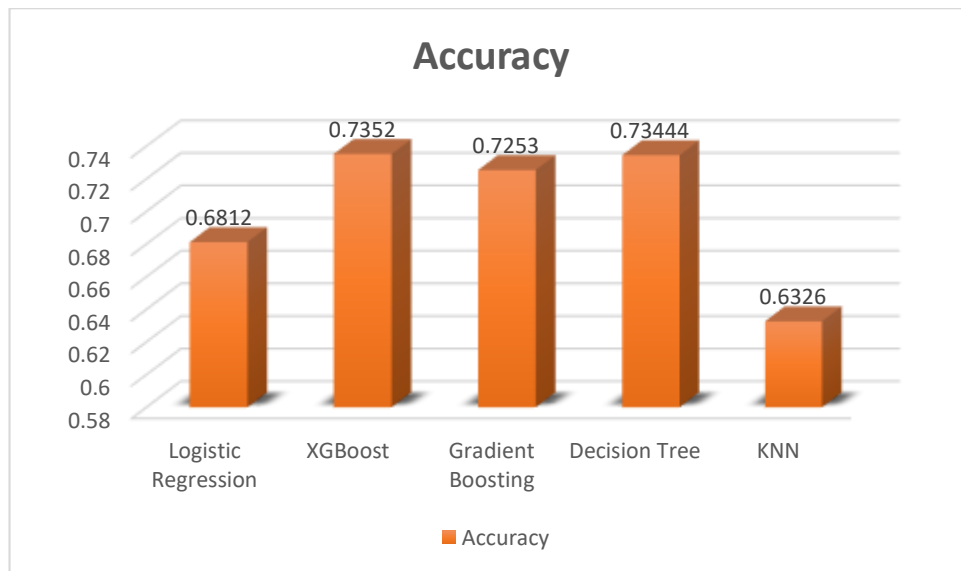
Setelah itu, data dilabeli dengan *Class 0* untuk wilayah dengan emisi metana rendah dan Gambar 3. adalah *Class 1* untuk wilayah dengan emisi tinggi yang mewakili area dengan emisi metana tinggi. Model *machine learning* kemudian dilatih menggunakan 80% dari dataset sebagai *training set* dan diuji menggunakan 20% data sisanya sebagai *testing set* untuk mengukur performa deteksinya. Dengan menggunakan algoritma seperti XGBoost dan *Decision Tree*, model mampu mengidentifikasi pola emisi metana berdasarkan informasi spektral dan kondisi lingkungan, yang memungkinkan deteksi otomatis dari sumber emisi metana dalam skala luas.



Gambar 3. Hasil Perbandingan Untuk Kelas 1(emisi metana tinggi)

Gambar 4. menjelaskan mengenai fungsi utama *machine learning* dalam penelitian ini adalah untuk mengotomatisasi dan meningkatkan akurasi proses deteksi emisi metana dari citra satelit. Dengan Artikel diterima 28 Februari 2025. Online 30 Maret 2025.

*machine learning*, sistem dapat memproses data dalam jumlah besar, mengenali pola emisi yang kompleks, dan melakukan prediksi secara *real-time*. Model seperti XGBoost dan *Gradient Boosting* memiliki keunggulan dalam menangkap hubungan non-linear dalam data, yang membuatnya lebih akurat dibandingkan metode konvensional.



**Gambar 4.** Hasil Perbandingan Akurasi Metode *Machine Learning*

Selain itu, hasil model ini dapat digunakan untuk mengidentifikasi wilayah dengan risiko emisi tinggi, sehingga memungkinkan pemerintah dan industri untuk mengambil langkah mitigasi lebih cepat dan efisien dalam mengurangi dampak perubahan iklim akibat emisi metana dari pabrik kelapa sawit. Dengan penerapan *machine learning*, deteksi emisi metana menjadi lebih cepat, akurat, dan efisien, serta dapat dilakukan dalam skala luas tanpa memerlukan pemantauan manual yang intensif. Hasil dari model *machine learning* ini juga dapat divisualisasikan dalam bentuk peta sebaran emisi metana, yang memberikan gambaran mengenai distribusi spasial emisi dan tren perubahan tingkat metana dari waktu ke waktu. Dengan demikian, *machine learning* tidak hanya meningkatkan efektivitas deteksi emisi metana tetapi juga memberikan wawasan yang berharga bagi kebijakan mitigasi perubahan iklim serta pengelolaan lingkungan yang lebih baik dalam industri kelapa sawit

## Kesimpulan

Penelitian ini membuktikan bahwa metode XGBoost adalah model terbaik dalam mendeteksi emisi metana dari pabrik kelapa sawit di Indonesia berbasis citra satelit, dengan akurasi tertinggi (73.53%) dan keseimbangan terbaik antara *presisi* dan *recall*. *Decision Tree* juga menunjukkan performa yang kompetitif tetapi lebih rentan terhadap *overfitting*. *Gradient Boosting* memiliki akurasi yang baik tetapi kurang efektif dalam mendeteksi wilayah dengan emisi tinggi, sementara

*Logistic Regression* dan KNN gagal menangani ketidakseimbangan kelas dan memiliki *recall* yang sangat rendah untuk area dengan emisi tinggi.

Untuk penelitian selanjutnya dapat dikembangkan dengan menggunakan dataset beresolusi lebih tinggi, integrasi dengan teknik *Deep Learning* untuk analisis pola spasial temporal yang lebih kompleks, serta peningkatan strategi *balancing* data agar model lebih akurat dalam mendeteksi area dengan emisi tinggi. Selain itu penggunaan multi sumber data satelit serta integrasi dengan data cuaca dan lingkungan *real time* dapat meningkatkan prediksi dan mendukung kebijakan mitigasi perubahan iklim yang lebih efektif.

### **PENGAKUAN DAN UCAPAN TERIMA KASIH**

Kami bersyukur penelitian dan paper ini dapat dituntaskan dengan tepat waktu, hal ini tidak lepas dari dukungan Lembaga dalam memberikan kesempatan untuk mengambil dan mnegolah data di Laboratorium STT Migas Balikpapan.

### **DAFTAR PUSTAKA**

- Farah, E. & Shahrour, I. (2024). Water Leak Detection: A Comprehensive Review of Methods, Challenges, and Future Directions. *Water (Switzerland)*, 16(20), 12446.
- Gemeinhardt, H. & Sharma, J. (2024). Machine-Learning-Assisted Leak Detection Using Distributed Temperature and Acoustic Sensors. *IEEE Sensors Journal*, 24(2), с-ци 1520–1531.
- Hossain, K., Villebro, F. Forchhammer, S. (2020). UAV image analysis for leakage detection in district heating systems using machine learning. *Pattern Recognition Letters*, 140, с-ци 158–164. doi: 10.1016/j.patrec.2020.05.024.
- Islam, M. R., Azam, S., Shanmugam, B., & Mathur, D. (2022). A review on current technologies and future direction of water leakage detection in water distribution network. *IEEE Access*, 10, 107177-107201.
- Islam, M. R., Azam, S., Shanmugam, B., & Mathur, D. (2024). Leak detection and localization in underground water supply system using thermal imaging and geophone signals through machine learning. *Intelligent Systems with Applications*, 23, 200404.
- Jasmine, K. (2016). *Penambahan natrium benzoat dan kalium sorbat (antiinversi) dan kecepatan pengadukan sebagai upaya penghambatan reaksi inversi pada nira tebu* (Doctoral

dissertation, Universitas Brawijaya).

- Kumar, S.(2020). Deep remote sensing methods for methane detection in overhead hyperspectral imagery. *Proceedings - 2020 IEEE Winter Conference on Applications of Computer Vision, WACV 2020*, 1765–1774. doi: 10.1109/WACV45572.2020.9093600.
- Kumar, S. (2023). MethaneMapper: Spectral Absorption Aware Hyperspectral Transformer for Methane Detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2023-June, c-ци 17609–17618. doi: 10.1109/CVPR52729.2023.01689.
- Sarker, T. T. (2024). Gasformer: A Transformer-based Architecture for Segmenting Methane Emissions from Livestock in Optical Gas Imaging. doi: 10.1109/CVPRW63382.2024.00558.
- Tiemann, E.(2024). Machine Learning for Methane Detection and Quantification from Space - A survey. Available at: <http://arxiv.org/abs/2408.15122>.
- Vollmer, E.(2024). Detecting district heating leaks in thermal imagery: Comparison of anomaly detection methods. *Automation in Construction*, 168(PA), c 105709. doi: 10.1016/j.autcon.2024.105709.
- Yussof, N. A. M.Ho, H. W. (2022). Review of Water Leak Detection Methods in Smart Building Applications. *Buildings*, 12(10). doi: 10.3390/buildings12101535.