

Implementasi *Decision Tree* Sistem *Monitoring* Medan Listrik Atmosfer Berbasis IoT Menggunakan Sensor EFM (*Electric Field Mill*)

Erlangga Keta Pratama¹, Masayu Anisah², Johansyah Al Rasyid³

Politeknik Negeri Sriwijaya, Palembang Indonesia

Erlangga.angga.keta@gmail.com

Abstrak: Tujuan dari penelitian ini adalah untuk menerapkan algoritma *decision tree* pada sistem *monitoring* medan listrik atmosfer yang berbasis *Internet of Things* (IoT) yang menggunakan sensor *Electric Field Mill* (EFM). Sistem ini terdiri dari sensor EFM, mikrokontroler ESP32, database *cloud Supabase*, dan dashboard *monitoring* web yang memungkinkan pengumpulan, penyimpanan, dan visualisasi data secara *real-time*. Data hasil pengukuran medan listrik atmosfer diproses melalui tahapan *preprocessing*. Tahapan ini termasuk transformasi fitur, normalisasi menggunakan skala Min-Max, dan penyeimbangan data menggunakan metode *Synthetic Minority Oversampling Technique* (SMOTE). Setelah proses SMOTE, dataset awal dengan distribusi kelas yang tidak seimbang meningkat menjadi 828 data. Selanjutnya, kondisi atmosfer dimasukkan ke dalam kategori AMAN, WASPADA, dan BAHAYA menggunakan algoritma *decision tree*. Hasil uji *5-Fold stratified cross validation* menunjukkan bahwa model menghasilkan nilai *accuracy*, *precision*, *recall*, dan skor F1 sebesar 100%. Selain itu, nilai rata-rata model sebesar 1,000 dengan standar deviasi 0,000, yang menunjukkan tingkat kestabilan model yang sangat baik. Menurut analisis nilai fitur, fitur Cuaca_PETIR dan kV_m_log adalah yang paling berpengaruh dalam proses klasifikasi. Hasil penelitian menunjukkan bahwa algoritma *decision tree* dapat diterapkan secara efektif pada sistem *monitoring* medan listrik atmosfer berbasis IoT untuk mendukung proses klasifikasi kondisi atmosfer secara otomatis dan *real-time*.

Kata kunci: *decision tree*, *electric field mill*, *internet of things*, *monitoring atmosfer*

Abstract: This study aims to implement the *decision tree* algorithm in an *Internet of Things* (IoT)-based atmospheric electric field monitoring system using an *Electric Field Mill* (EFM) sensor. The developed system consists of an EFM sensor, an ESP32 microcontroller, a *Supabase cloud database*, and a web-based monitoring dashboard that enables *real-time* data acquisition, storage, and visualization. Atmospheric electric field measurement data were processed through several preprocessing stages, including feature transformation, Min-Max scaling normalization, and data balancing using the *Synthetic Minority Oversampling Technique* (SMOTE). The initial dataset, which had an imbalanced class distribution, increased to 828 records after the SMOTE process. Subsequently, the *decision tree* algorithm was employed to classify atmospheric conditions into three categories: SAFE, ALERT, and DANGER. The evaluation results showed that the model achieved 100% accuracy, precision, recall, and F1-score. In addition, the *5-Fold Stratified Cross Validation* results produced a mean score of 1.000 with a standard deviation of 0.000, indicating excellent model stability. Feature importance analysis revealed that *Cuaca_PETIR* and *kV_m_log* were the most influential features in the classification process. The results demonstrate that the *decision tree* algorithm can be effectively applied to an IoT-based atmospheric electric field monitoring system to support automatic and *real-time* classification of atmospheric conditions.

Keywords: *decision tree*, *electric field mill*, *internet of things*, *atmospheric electric field monitoring*

Pendahuluan

Salah satu fenomena atmosfer yang paling umum di daerah tropis adalah petir. Ini dapat membahayakan sistem tenaga listrik, peralatan elektronik, dan keselamatan manusia. Nilai medan listrik atmosfer yang besar biasanya menunjukkan perubahan kondisi atmosfer sebelum aktivitas petir. Sebagaimana ditunjukkan oleh (Li et al., 2024), variasi medan listrik atmosfer terkait erat dengan cuaca dan aktivitas kelistrikan di atmosfer. Oleh karena itu, dapat digunakan sebagai indikator dalam sistem pemantauan lingkungan. Selain itu, seperti yang ditunjukkan oleh (Kiouvrekis et al., 2025), pemetaan medan listrik berbasis *machine learning* dapat memberikan

informasi yang lebih akurat selama proses pengamatan kondisi lingkungan. Oleh karena itu, salah satu cara yang dapat digunakan untuk membantu mengurangi bahaya yang disebabkan oleh petir adalah dengan memantau medan listrik atmosfer.

Menurut (Bazhenov, 2023), *Electric Field Mill* (EFM) adalah salah satu teknologi yang paling populer untuk mengukur medan listrik atmosfer karena dapat mendeteksi perubahan medan listrik di lingkungan sekitar dan menghasilkan data yang dapat digunakan untuk menggambarkan kondisi atmosfer secara kontinu. Data medan listrik dapat digunakan untuk mendukung sistem deteksi dan peringatan dini petir, selain digunakan untuk mengukur kondisi medan listrik atmosfer (Teknikal et al., 2024), mengembangkan sistem deteksi petir dengan analisis gelombang medan listrik atmosfer yang dapat memberikan informasi peringatan dini dengan cara yang efisien dan sederhana. Hasil penelitian menunjukkan bahwa pemantauan medan listrik atmosfer memiliki potensi yang sangat besar untuk mendukung pengembangan sistem untuk memantau dan mengurangi risiko petir.

Cara sistem pemantauan lingkungan bekerja telah berubah karena teknologi *Internet of Things* (IoT). Data hasil pengukuran dapat dikirim, disimpan, dan ditampilkan secara *real-time* melalui internet berkat integrasi sensor, mikrokontroler, jaringan komunikasi, dan platform cloud. (Waworundeng, 2024) mengatakan bahwa menambahkan IoT ke sistem monitoring lingkungan dapat membuat pengumpulan data lebih efisien dan membuat proses melihat data secara online lebih mudah. Selain itu, (Narayana et al., 2024) menyatakan bahwa sistem *monitoring* berbasis IoT memungkinkan pengawasan berkelanjutan dan otomatis atas parameter lingkungan. Selain itu, penelitian (Adeagbo, 2024) menemukan bahwa menggunakan ESP32 sebagai komponen utama sistem monitoring dapat menawarkan solusi yang fleksibel dan murah untuk berbagai kebutuhan pemantauan lingkungan.

Teknologi kecerdasan buatan (AI) dan *machine learning* semakin digunakan untuk meningkatkan analisis data seiring dengan perkembangan IoT. (Garcia et al., 2025) mengatakan bahwa dengan menggabungkan AI dan IoT, proses analisis data dapat dibantu dengan lebih cepat dan akurat. Menurut penelitian (Gryech et al., 2024), gabungan AI dan IoT dapat meningkatkan prediksi dan klasifikasi kondisi lingkungan dengan data sensor. Selain itu, melalui penyediaan data yang cepat dan akurat, (Fahmi & Zuhair, 2025) menemukan bahwa sistem pemantauan berbasis IoT dapat meningkatkan efisiensi pengambilan keputusan.

Machine learning banyak digunakan untuk mengubah data hasil *monitoring* menjadi informasi yang lebih mudah dipahami dan digunakan dalam proses pengambilan keputusan. Menurut (Laha et al., 2022), pembelajaran mesin dapat meningkatkan kemampuan analisis data dan membantu proses identifikasi pola otomatis. Selain itu, (Alotaibi & Nassif, 2024) menunjukkan bahwa,

dibandingkan dengan metode konvensional, algoritma *machine learning* dapat membantu proses prediksi dan pengambilan keputusan serta meningkatkan analisis data dan identifikasi pola.

Decision Tree adalah salah satu algoritma *machine learning* yang paling banyak digunakan untuk proses klasifikasi karena memiliki struktur yang mirip dengan pohon keputusan dan mampu menghasilkan aturan klasifikasi yang mudah dipahami. *decision tree* mampu menghasilkan kinerja klasifikasi yang baik pada data kualitas udara, menurut (Sudipa et al., 2024). Selain itu, (Mariano et al., 2024) menunjukkan bahwa algoritma ini memiliki tingkat akurasi yang tinggi dalam proses klasifikasi kondisi lingkungan. Dengan keuntungan ini, *decision tree* dianggap sesuai untuk digunakan dalam sistem monitoring berbasis IoT.

Namun, penelitian yang dilakukan masih sangat terbatas dalam mengintegrasikan sensor EFM, teknologi Internet of Things, metode penyeimbangan data *Synthetic Minority Oversampling Technique* (SMOTE), dan algoritma *decision tree* dalam satu sistem pemantauan medan listrik atmosfer. Tahap *preprocessing* data, normalisasi dengan *min-max Scaling*, dan penyeimbangan data dengan metode *Synthetic Minority Oversampling Technique* (SMOTE) digunakan dalam penelitian ini untuk meningkatkan kualitas klasifikasi. SMOTE diperkenalkan oleh (Chawla et al., 2002) untuk mengatasi ketidak seimbangan kelas pada dataset sehingga model dapat belajar secara optimal.

Selanjutnya, proses klasifikasi dilakukan dengan algoritma *Decision tree*. Metode *5-fold stratified cross validation*, metrik *accuracy*, *precision*, *recall*, F1-score, digunakan untuk mengevaluasi performa dan stabilitas model yang dihasilkan. Jumlah data kategori WASPADA dan terutama BAHAYA lebih sedikit daripada kategori AMAN. Kejadian ekstrem atmosfer yang tidak terjadi secara terus-menerus selama periode pengambilan data menyebabkan kondisi ini. Jika kondisi ini tidak ditangani, model cenderung mempelajari lebih banyak karakteristik kelas mayoritas. Akibatnya, kemampuan mereka untuk membedakan kelas minoritas akan berkurang. Sampel sintetis dibuat pada kelas minoritas dengan menggunakan metode SMOTE. Ini dilakukan sehingga distribusi data menjadi lebih seimbang dan proses pelatihan model dapat dilakukan dengan lebih baik (Chawla et al., 2002).

Metode

Metode kuantitatif digunakan dalam penelitian ini untuk menerapkan algoritma *decision tree* pada sistem *monitoring* medan listrik atmosfer berbasis *Internet of Things* (IoT). Sistem yang dikembangkan terdiri atas sensor *Electric Field Mill* (EFM), *mikrokontroler* ESP32, *database cloud* *Supabase*, dan *dashboard web monitoring*. Sensor EFM digunakan untuk mengukur medan listrik atmosfer secara kontinu. Data hasil pengukuran kemudian diproses oleh ESP32 dan dikirim melalui

jaringan internet ke *database Supabase* untuk disimpan. Selanjutnya, data yang tersimpan ditampilkan pada *dashboard web monitoring* sehingga kondisi atmosfer dapat dipantau secara *real-time*.

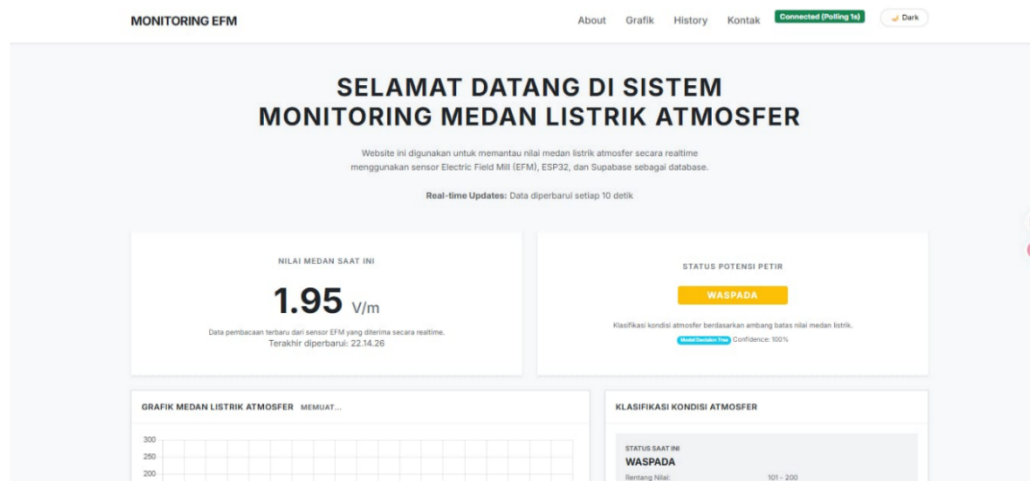
Dalam penelitian ini, data medan listrik atmosfer dikategorikan ke dalam tiga kelas: AMAN, WASPADA, dan BAHAYA. *Preprocessing* digunakan untuk memulai tahap awal pengolahan data. Proses ini mencakup transformasi waktu menjadi fitur siklik menggunakan fungsi sinus dan cosinus, transformasi logaritmik pada nilai medan listrik atmosfer (kV/m), dan normalisasi menggunakan metode skala *min-max*. Selain itu, metode *one-hot encoding* digunakan untuk mengubah variabel cuaca menjadi data numerik sehingga dapat digunakan dalam proses pelatihan model *machine learning*.

Synthetic Minority Oversampling Technique (SMOTE) menghasilkan sampel sintesis pada kelas minoritas untuk meningkatkan keseimbangan distribusi data. Selanjutnya, model *decision tree* dilatih untuk membagi kondisi atmosfer ke dalam kategori AMAN, WASPADA, dan BAHAYA berdasarkan data *preprocessing* dan SMOTE. Untuk mengetahui tingkat performa dan stabilitas model yang dihasilkan, kinerja model dinilai menggunakan metode *5-Fold Stratified Cross Validation* dan metrik *accuracy, precision, recall*, dan skor F1.

Hasil dan Pembahasan

Implementasi Sistem *Monitoring* Medan Listrik Atmosfer

Mikrokontroler ESP32, *database cloud* Supabase, dan antarmuka *web monitoring* adalah komponen yang berhasil digunakan untuk menerapkan sistem *monitoring* medan listrik atmosfer berbasis *Internet of Things* (IoT). Sistem ini dirancang untuk mengumpulkan dan mengirimkan data dari sensor *Electric Field Mill* (EFM) ke *database cloud* secara *real-time* melalui jaringan internet. Pengguna dapat melihat data yang tersimpan di *dashboard monitoring* dari berbagai tempat.



Gambar 1. Dashboard monitoring

Berdasarkan **Gambar 1**, *dashboard monitoring* mampu menampilkan informasi utama yang terdiri dari nilai medan listrik atmosfer saat ini, status kondisi atmosfer, grafik perubahan data pengukuran, serta informasi klasifikasi kondisi atmosfer. Nilai medan listrik atmosfer ditampilkan dalam satuan volt per meter (V/m) dan diperbarui secara berkala sesuai data yang diterima dari sistem *monitoring*. Selain itu, *dashboard* juga menampilkan status kondisi atmosfer yang diklasifikasikan ke dalam kategori AMAN, WASPADA, dan BAHAYA berdasarkan hasil pengolahan data menggunakan algoritma *decision tree*.

Hasil Pengolahan Data dan SMOTE

Penelitian ini masih memiliki keterbatasan karena jumlah data kategori BAHAYA relatif sedikit dibandingkan dengan kategori lainnya. Untuk mengatasi keterbatasan ini, metode SMOTE digunakan untuk menghasilkan distribusi data yang lebih seimbang. Penelitian selanjutnya dapat dilakukan dengan menambah jumlah data pengamatan aktual sehingga model dapat diuji pada kondisi yang lebih beragam.

Tabel 1. Distribusi dataset sebelum dan sesudah SMOTE

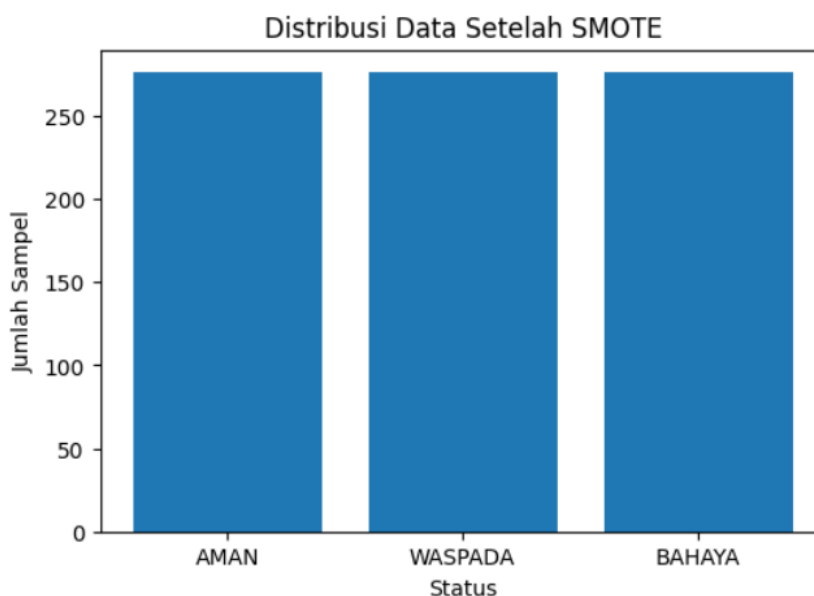
STATUS	SEBELUM SMOTE	SESUDAH SMOTE
Aman	276	276
Waspada	36	276
Bahaya	4	276
Total	316	828

Sebelum digunakan dalam proses klasifikasi, data yang diperoleh dari sistem *monitoring* medan listrik atmosfer diproses melalui tahap *preprocessing*. Tahap *preprocessing* dilakukan untuk meningkatkan kualitas data dan memastikan bahwa algoritma *machine learning* dapat memproses semua variabel. *Preprocessing* mencakup transformasi karakteristik waktu menjadi representasi

siklik dengan menggunakan fungsi sinus dan cosinus, transformasi logaritmik pada nilai medan listrik atmosfer (kV/m), dan normalisasi dengan menggunakan metode pengukuran Min-Max.

Hasil analisis awal menunjukkan bahwa data masih didistribusikan secara tidak seimbang di setiap kelas. Menurut Tabel 1, dataset terdiri dari 316 data, dengan 276 data dalam kategori AMAN, 36 data dalam kategori WASPADA, dan hanya 4 data dalam kategori BAHAYA. Ketidakseimbangan jumlah data dapat menyebabkan model klasifikasi menjadi lebih dominan dalam mempelajari karakteristik kelas mayoritas.

Penelitian ini menggunakan metode *Synthetic Minority Oversampling Technique* (SMOTE) untuk menyelesaikan masalah tersebut. Metode ini mencapai distribusi data yang lebih seimbang dengan menghasilkan sampel sintetis pada kelas minoritas berdasarkan karakteristik data yang sudah ada. Oleh karena itu, dataset secara keseluruhan meningkat dari 316 menjadi 828 data, yang terdiri dari 276 data kategori AMAN, 276 data kategori WASPADA, dan 276 data kategori BAHAYA. Distribusi data setelah penerapan SMOTE ditunjukkan pada Gambar 2. Diharapkan distribusi data yang lebih seimbang ini akan membantu algoritma *decision tree* mempelajari pola pada setiap kelas, sehingga meningkatkan kemampuan model untuk melakukan klasifikasi kondisi atmosfer yang lebih akurat.



Gambar 2. Distribusi data setelah SMOTE

Hasil Klasifikasi Menggunakan decision tree

Tabel 2. Hasil evaluasi Model decision tree

Metrik	Nilai
Accuracy	100%
Precision	100%
Recall	100%
F1-Score	100%

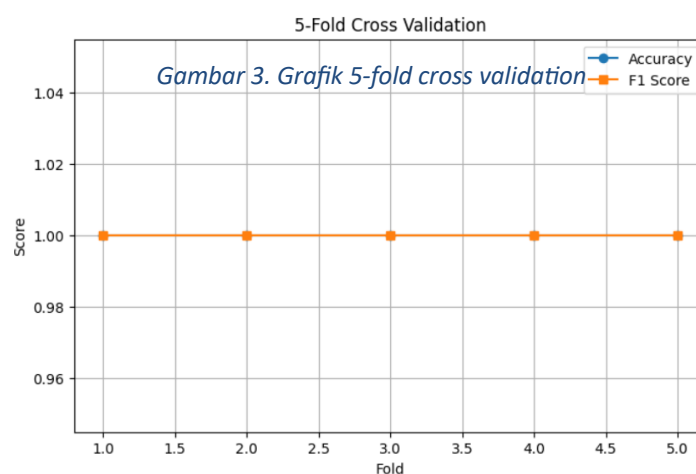
Tabel 3. Hasil 5-fold cross validation


Metrik	Mean	Std
Accuracy	1.000	0.000
Precision	1.000	0.000
Recall	1.000	0.000
F1-Score	1.000	0.000

Proses klasifikasi kondisi atmosfer menggunakan algoritma *decision tree* adalah langkah selanjutnya dalam penelitian ini. Model dibangun menggunakan dataset hasil *preprocessing* dan penyeimbangan data melalui metode SMOTE. Data uji yang diperoleh dari pembagian dataset digunakan untuk evaluasi model, dan metode *5-Fold Stratified Cross Validation* digunakan untuk menguji kestabilan model.

Berdasarkan hasil evaluasi yang ditunjukkan pada Tabel 2, model *decision tree* mampu menghasilkan nilai *accuracy*, *precision*, *recall*, dan *F1-score* sebesar 100%. Nilai *accuracy* dan *recall* sebesar 100% menunjukkan bahwa model mampu mengidentifikasi setiap kelas tanpa menghasilkan kesalahan klasifikasi atau kehilangan data yang seharusnya terdeteksi.

Untuk menguji konsistensi kinerja model, metode *5-Fold Stratified Cross Validation* digunakan. Hasil pengujian, yang ditunjukkan pada Tabel 3, menunjukkan bahwa metrik evaluasi secara keseluruhan memiliki nilai rata-rata 1,000 dengan standar deviasi 0,000, yang menunjukkan bahwa model memiliki tingkat kestabilan yang sangat tinggi pada setiap pembagian data dan tidak mengalami penurunan kinerja selama proses validasi silang.

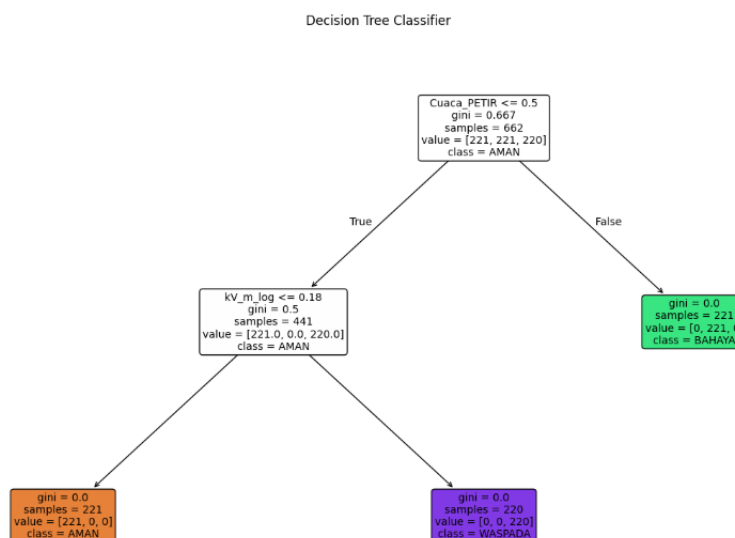




Gambar 4. Confusion matrix


Gambar 4 menunjukkan *confusion matrix*, yang menunjukkan keberhasilan proses klasifikasi. Semua data dalam kategori AMAN, WASPADA, dan BAHAYA ditempatkan dengan benar pada kelas yang tepat. Seluruh data berada pada diagonal utama *confusion matrix* karena tidak ditemukan nilai *false positive* maupun *false negative* pada hasil pengujian. Kondisi ini menunjukkan kemampuan model untuk mempelajari pola dataset dengan sangat baik. Hasil klasifikasi menunjukkan bahwa algoritma *decision tree* memiliki kemampuan yang luar biasa untuk membedakan kondisi atmosfer dengan parameter yang digunakan dalam penelitian ini.

Analisis Model



Gambar 5. Decision tree

Gambar 5 menunjukkan struktur *decision tree* yang dihasilkan, berdasarkan hasil pelatihan model, *decision tree* membentuk aturan klasifikasi dengan menggunakan kombinasi nilai medan listrik atmosfer dan parameter kondisi cuaca. Struktur pohon yang agak sederhana menunjukkan bahwa proses klasifikasi dapat dilakukan dengan aturan keputusan yang mudah dipahami dan diinterpretasikan. Pada penelitian ini, serangkaian aturan digunakan untuk mengkategorikan kondisi atmosfer ke dalam kategori AMAN, WASPADA, dan BAHAYA. Ini dilakukan berdasarkan karakteristik data yang dipelajari selama proses pelatihan. Analisis nilai fitur dilakukan, seperti yang ditunjukkan pada Gambar 6, untuk menentukan tingkat pengaruh masing-masing fitur terhadap model. Hasil analisis menunjukkan bahwa fitur Cuaca_PETIR memiliki nilai signifikansi 0,500379, sedangkan fitur kV_m_log memiliki nilai signifikansi 0,499621. Kedua sifat tersebut berkontribusi hampir sama dan keduanya menjadi komponen penting dalam proses klasifikasi kondisi atmosfer.



Gambar 7. Grafik feature importance

Hasil analisis menunjukkan bahwa model *decision tree* dapat mengidentifikasi hubungan yang signifikan antara kondisi cuaca dan medan listrik atmosfer terhadap kondisi-kondisi atmosfer. Ada hubungan yang kuat antara parameter cuaca dan nilai medan listrik atmosfer terhadap label klasifikasi yang digunakan, yang diduga menyebabkan kinerja model yang tinggi. Pemisahan antar kelas dapat dilakukan dengan mudah karena fitur Cuaca_PETIR dan kV_m_log mendominasi proses pengambilan keputusan, seperti yang ditunjukkan oleh hasil fitur penting.

Kesimpulan

Dalam penelitian ini, algoritma *decision tree* dan teknologi *Internet of Things* (IoT) telah diintegrasikan ke dalam sistem monitoring medan listrik atmosfer yang berbasis *Electric Field Mill* (EFM). Sistem ini memiliki kemampuan untuk melacak data secara *real-time*, menyimpan data di *cloud*, dan secara otomatis mengklasifikasikan kondisi atmosfer ke dalam kategori AMAN, WASPADA, dan BAHAYA. Hasil pengujian menunjukkan bahwa penerapan metode *Synthetic Minority Oversampling Technique* (SMOTE) dan *preprocessing* data dapat meningkatkan kualitas dataset, sehingga model *decision tree* menghasilkan performa klasifikasi yang luar biasa dengan nilai *accuracy*, *precision*, *recall*, dan skor F1 sebesar 100%. Selain itu, hasil validasi *cross – stratified* 5-fold menunjukkan kestabilan model yang sangat tinggi dengan nilai rata-rata 1,000. Hasilnya menunjukkan bahwa metode *decision tree* dapat digunakan pada sistem monitoring medan listrik atmosfer berbasis *Internet of Things* untuk membantu pengambilan keputusan dan pemantauan kondisi atmosfer secara *real-time*. Penelitian selanjutnya dapat berkonsentrasi pada penambahan jumlah data pengamatan aktual dan pengujian model menggunakan algoritma *machine learning* lainnya untuk meningkatkan representasi model.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Program Studi Teknik Elektro Politeknik Negeri Sriwijaya yang telah memberikan dukungan akademik untuk pelaksanaan penelitian ini. Penulis juga mengucapkan terima kasih kepada dosen pembimbing yang telah memberikan bimbingan, saran, dan inspirasi selama proses penyusunan penelitian hingga penulisan artikel ini. Selain itu, penghargaan diberikan kepada semua orang yang telah membantu dalam proses pengumpulan data, pembuatan sistem monitoring, dan penyelesaian penelitian ini.

Referensi

- Adeagbo, A. A. (2024). *IOT Based Environment Monitoring System Using*.
- Alotaibi, E., & Nassif, N. (2024). Artificial intelligence in environmental monitoring : in - depth analysis. *Discover Artificial Intelligence, November*. <https://doi.org/10.1007/s44163-024-00198-1>
- Bazhenov, V. (2023). ANALYSIS OF MODERN ATMOSPHERIC ELECTROSTATIC FIELD MEASURING. *Technology Audit and Production Reserves, 1(72)*, 16–24. <https://doi.org/10.15587/2706-5448.2023.285963>
- Chawla, N. V, Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE : Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research, 16*, 321–357.
- Fahmi, M. H., & Zuhair, A. (2025). IOT-BASED MODEL FOR REAL-TIME MONITORING OF NEW AND RENEWABLE. *"EUREKA: Physics and Engineering," 3*, 36–48. <https://doi.org/10.21303/2461->

4262.2025.003471

- Garcia, A., Saez, Y., Harris, I., & Huang, X. (2025). Advancements in air quality monitoring : a systematic review of IoT-based air quality monitoring and AI technologies. *Artificial Intelligence Review*, *58*(275), 67.
- Gryech, I., Asaad, C., Ghogho, M., & Kobbane, A. (2024). Applications of machine learning & IoT for Outdoor Air Pollution Monitoring and Prediction : *Engineering Applications of Artificial Intelligence*, *137*(Part B), 1–24.
- Kiouvrekis, Y., Psomadakis, I., Vavouranakis, K., Zikas, S., & Katis, I. (2025). Explainable Machine Learning-Based Electric Field Strength Mapping for Urban Environmental Monitoring : A Case Study in Paris Integrating Geographical Features and Explainable AI. *Electronics*, *14*(2), 1–19.
- Laha, S. R., Pattanayak, B. K., & Pattnaik, S. (2022). Advancement of Environmental Monitoring System Using IoT and Sensor : A Comprehensive Analysis. *AIMS Environmental Science*, *9*(September), 771–800. <https://doi.org/10.3934/environsci.2022044>
- Li, W., Sun, Z., Yan, Z., & Ma, Z. (2024). Observations and Variability of Near-Surface Atmospheric Electric Fields across Multiple Stations. *Atmosphere*, *15*(1), 1–9.
- Mariano, K. D. P., Almada, F. L. N., & Dutra, M. A. (2024). *Smart Air Quality Monitoring for Automotive Workshop Environments*.
- Narayana, T. L., Venkatesh, C., Kiran, A., & J, C. B. (2024). Heliyon Advances in real time smart monitoring of environmental parameters using IoT and sensors. *Heliyon*, *10*(7), e28195. <https://doi.org/10.1016/j.heliyon.2024.e28195>
- Sudipa, I. G. I., Habibi, M., Setiyawa, E., Atmadji, J., & Arfiani, I. (2024). Predictive Modeling of Air Quality Levels Using Decision Tree Classification : Insights from Environmental and Demographic Factors. *Indonesian Journal of Data and Science Volume*, *4*(3), 251–258.
- Teknikal, U., Hang, J., Jaya, T., Studi, P., Elektro, T., Teknik, F., Sriwijaya, U., & Selatan, S. (2024). Design and Development of Lightning Detection System Utilizing Slow Atmospheric Electric Field Waveform at Legoland Malaysia. *Journal of Telecommunication, Electronic and Computer Engineering*, *16*(3), 27–33. <https://doi.org/https://doi.org/10.54554/jtec.2024.16.03.004>
- Waworundeng, J. (2024). IoT-based Environmental Monitoring with Data Analysis of Temperature , Humidity , and Air Quality. *COGITO Smart Journa*, *10*(1), 271–284.