

ESTIMASI POTENSI PETIR BERBASIS POLA *ELECTRIC FIELD MILL* MENGGUNAKAN *XGBOOST* DAN *BAYESIAN UPDATE*

Ammar Jauhari^{1*}, Masayu Anisah², Johansyah Al Rasyid³

^{1,2,3}Politeknik Negeri Sriwijaya; Jl Srijaya Negara Bukit Besar Palembang Sumatera Selatan 30139,

Telpon : +620711353414

Keywords:

Electric Field Mill;

XGBoost;

Bayesian Update;

estimasi petir;

machine learning.

Correspondent Email:

msulthannr11@gmail.com

Abstrak. Petir merupakan fenomena atmosfer yang berisiko terhadap keselamatan manusia, sistem tenaga listrik, perangkat telekomunikasi, dan aktivitas luar ruang. Penelitian ini bertujuan mengembangkan model estimasi potensi petir berbasis pola *Electric Field Mill* (EFM) menggunakan *XGBoost* dan *Bayesian Update*. Data EFM diproses melalui tahapan prapemrosesan, ekstraksi fitur deret waktu, pembentukan skor potensi, pemodelan *XGBoost*, dan pembaruan probabilitas *Bayesian*. Fitur yang digunakan meliputi nilai medan listrik, perubahan medan listrik, rata-rata bergerak, simpangan baku, nilai maksimum absolut, dan kemiringan perubahan sinyal. Hasil pengujian menunjukkan bahwa *XGBoost* memperoleh MAE sebesar 1,673, RMSE sebesar 2,108, dan R^2 sebesar 0,990. Setelah dilakukan *Bayesian Update*, diperoleh MAE sebesar 5,846, RMSE sebesar 7,313, dan R^2 sebesar 0,882. Hasil tersebut menunjukkan bahwa *XGBoost* memberikan performa estimasi terbaik secara numerik, sedangkan *Bayesian Update* berperan sebagai mekanisme pembaruan probabilitas *posterior* yang lebih konservatif dan stabil. Penelitian ini dapat menjadi dasar awal pengembangan sistem peringatan dini petir berbasis EFM.



Copyright © 2026 The Author(s).
Published by Jurnal Informatika dan
Teknik Elektro Terapan. This is an
open-access article distributed under
the terms of the Creative Commons
Attribution-NonCommercial 4.0
International License (CC BY-NC
4.0).

Abstract. Lightning is an atmospheric phenomenon that poses risks to human safety, power systems, telecommunication devices, and outdoor activities. This study aims to develop a lightning potential estimation model based on Electric Field Mill (EFM) patterns using XGBoost and Bayesian Update. The EFM data were processed through preprocessing, time-series feature extraction, potential score generation, XGBoost modeling, and Bayesian probability updating. The features used in this study include electric field value, electric field variation, moving average, standard deviation, maximum absolute value, and signal slope. The experimental results show that XGBoost achieved an MAE of 1.673, RMSE of 2.108, and R^2 of 0.990. After applying Bayesian Update, the model obtained an MAE of 5.846, RMSE of 7.313, and R^2 of 0.882. These results indicate that XGBoost provides the best numerical estimation performance, while Bayesian Update functions as a more conservative and stable posterior probability updating mechanism. This study can serve as an initial basis for developing an EFM-based lightning early warning system.

1. PENDAHULUAN

Petir merupakan fenomena atmosfer yang terjadi akibat pelepasan muatan listrik, baik di dalam awan, antarawan, maupun antara awan dan permukaan tanah. Fenomena ini memiliki risiko tinggi terhadap keselamatan manusia, sistem tenaga listrik, perangkat telekomunikasi, peralatan elektronik, serta aktivitas luar ruang

[1], [2]. Sambaran petir jenis *cloud to ground* menjadi salah satu jenis yang paling berbahaya karena berhubungan langsung dengan objek di permukaan tanah. Oleh karena itu, sistem estimasi potensi petir yang mampu memberikan informasi awal sebelum terjadinya sambaran diperlukan sebagai bagian dari upaya mitigasi dan peringatan dini, terutama pada area lokal

seperti lingkungan kampus, kawasan industri, fasilitas kelistrikan, dan area terbuka.

Salah satu parameter yang dapat digunakan untuk mengamati indikasi awal peningkatan potensi petir adalah perubahan medan listrik atmosfer. Perubahan medan listrik berkaitan dengan proses pemisahan dan akumulasi muatan listrik di dalam awan konvektif. Instrumen yang umum digunakan untuk mengukur medan listrik atmosfer di permukaan tanah adalah *Electric Field Mill* (EFM). EFM bekerja dengan mengamati perubahan medan listrik secara kontinu sehingga pola peningkatan, penurunan, fluktuasi, dan perubahan tren medan listrik dapat dianalisis sebagai indikator awal aktivitas kelistrikan atmosfer [3], [4]. Dengan demikian, data EFM berpotensi digunakan sebagai dasar dalam pengembangan sistem estimasi potensi petir berbasis data.

Pemanfaatan EFM dalam sistem peringatan dini petir memiliki keunggulan karena pengamatan dilakukan terhadap perubahan medan listrik lokal sebelum sambaran terjadi. Berbeda dengan sistem deteksi petir yang umumnya merekam kejadian setelah pelepasan muatan terjadi, EFM dapat digunakan untuk membaca pola medan listrik yang muncul sebelum kondisi atmosfer mencapai tingkat risiko tertentu. Beberapa penelitian menunjukkan bahwa fitur berbasis medan listrik atmosfer dapat digunakan dalam metode peringatan risiko petir melalui proses pengolahan sinyal dan ekstraksi fitur deret waktu [5], [6]. Fitur seperti nilai medan listrik, perubahan nilai antarwaktu, rata-rata bergerak, simpangan baku, nilai maksimum, dan kemiringan perubahan sinyal dapat menggambarkan dinamika medan listrik atmosfer yang relevan untuk proses estimasi potensi petir.

Seiring berkembangnya teknologi komputasi, metode *machine learning* mulai banyak digunakan dalam sistem prediksi kejadian atmosfer. Mostajabi dkk. menunjukkan bahwa pendekatan *machine learning* dapat digunakan untuk melakukan *nowcasting* kejadian petir berdasarkan parameter meteorologi permukaan [7]. Selain itu, penelitian terkait prediksi kondisi atmosfer menggunakan model *machine learning* juga telah dilakukan pada data suhu dan parameter cuaca, yang menunjukkan bahwa pendekatan berbasis data dapat digunakan

untuk mempelajari pola nonlinier pada fenomena atmosfer [13]. Namun, sebagian besar penelitian masih berfokus pada parameter meteorologi umum, radar, satelit, atau deteksi kejadian petir, sementara pemanfaatan pola EFM sebagai sumber utama untuk estimasi potensi petir berbasis probabilitas masih perlu dikembangkan lebih lanjut.

Pada penelitian ini, algoritma *Extreme Gradient Boosting* (*XGBoost*) digunakan sebagai model utama untuk mempelajari hubungan antara fitur pola EFM dan tingkat potensi petir. *XGBoost* merupakan algoritma berbasis *gradient boosting decision tree* yang dirancang untuk menghasilkan model prediktif yang efisien, skalabel, dan mampu menangani data tabular [10], [11]. Penerapan *XGBoost* dalam tugas prediksi juga telah digunakan pada penelitian yang terbit di JITET, sehingga pendekatan ini relevan dalam konteks pengembangan sistem prediksi berbasis informatika dan teknik elektro [14].

Meskipun *XGBoost* mampu menghasilkan estimasi awal, kondisi atmosfer bersifat dinamis dan memiliki tingkat ketidakpastian yang tinggi. Oleh karena itu, keluaran model perlu diperkuat dengan pendekatan probabilistik agar hasil estimasi tidak hanya berupa nilai prediksi, tetapi juga dapat diperbarui berdasarkan bukti baru dari data EFM. *Bayesian Update* digunakan sebagai metode pembaruan probabilitas dengan menggabungkan probabilitas awal atau prior dan informasi baru atau *likelihood* untuk menghasilkan probabilitas *posterior* [15], [16]. Dalam penelitian ini, *Bayesian Update* tidak digunakan untuk menggantikan *XGBoost*, melainkan sebagai tahap lanjutan untuk memperbarui probabilitas hasil prediksi agar estimasi potensi petir menjadi lebih adaptif terhadap perubahan pola medan listrik atmosfer.

Berdasarkan uraian tersebut, penelitian ini mengusulkan model estimasi potensi petir berbasis pola *Electric Field Mill* menggunakan kombinasi *XGBoost* dan *Bayesian Update*. Data EFM diproses melalui tahapan prapemrosesan, ekstraksi fitur deret waktu, pembentukan target potensi, pemodelan menggunakan *XGBoost*, serta pembaruan probabilitas menggunakan *Bayesian Update*. Kontribusi utama penelitian ini adalah pengembangan kerangka estimasi potensi petir yang menggabungkan fitur pola medan listrik atmosfer, model prediksi berbasis

XGBoost, dan pembaruan probabilitas *Bayesian* dalam satu alur analisis. Hasil penelitian ini diharapkan dapat menjadi dasar awal bagi pengembangan sistem peringatan dini petir berbasis EFM yang lebih sederhana, adaptif, dan sesuai untuk pemantauan lokal.

2. TINJAUAN PUSTAKA

2.1 Electric Field Mill

Electric Field Mill (EFM) merupakan instrumen yang digunakan untuk mengukur kuat medan listrik atmosfer di permukaan tanah. Prinsip kerja EFM didasarkan pada perubahan fluks medan listrik yang diterima oleh elektroda sensor akibat proses pembukaan dan penutupan secara periodik menggunakan rotor atau elektroda berputar. Perubahan fluks tersebut menghasilkan sinyal listrik yang dapat diolah untuk memperoleh nilai medan listrik atmosfer dalam satuan kV/m [3], [4]. Pada kondisi cuaca normal, nilai medan listrik atmosfer relatif rendah dan stabil. Namun, ketika terjadi pembentukan awan konvektif dan proses pemisahan muatan di dalam awan, nilai medan listrik dapat berubah secara signifikan.

Dalam konteks peringatan dini petir, EFM berperan sebagai sensor yang dapat mengamati perubahan medan listrik sebelum terjadinya sambaran petir. Data EFM memiliki karakteristik deret waktu karena nilai medan listrik dicatat secara berurutan berdasarkan waktu pengamatan. Pola peningkatan, penurunan, fluktuasi, dan perubahan gradien sinyal EFM dapat digunakan sebagai indikator adanya peningkatan aktivitas kelistrikan atmosfer [5], [6].

2.2 Ekstraksi Fitur Deret Waktu EFM

Data EFM mentah umumnya belum dapat langsung digunakan sebagai masukan model prediksi karena masih berupa deret nilai medan listrik terhadap waktu. Oleh sebab itu, diperlukan proses ekstraksi fitur untuk mengubah sinyal EFM menjadi variabel numerik yang lebih informatif. Fitur yang digunakan antara lain nilai medan listrik aktual, perubahan nilai medan listrik antarwaktu, rata-rata bergerak, simpangan baku, nilai maksimum absolut, dan kemiringan perubahan sinyal dalam rentang waktu tertentu.

Perubahan medan listrik antarwaktu dapat digunakan untuk melihat arah dan kecepatan perubahan sinyal. Rata-rata bergerak digunakan untuk menghaluskan fluktuasi sinyal, sedangkan simpangan baku menggambarkan

variasi medan listrik dalam jendela waktu tertentu. Selain itu, fitur kemiringan atau *slope* dapat digunakan untuk mengidentifikasi tren peningkatan atau penurunan medan listrik.

2.3 Extreme Gradient Boosting

Extreme Gradient Boosting atau *XGBoost* merupakan algoritma *machine learning* berbasis *gradient boosting decision tree*. Algoritma ini bekerja dengan membangun sejumlah pohon keputusan secara bertahap, di mana setiap pohon baru berusaha memperbaiki kesalahan prediksi dari pohon sebelumnya [10]. *XGBoost* dirancang untuk menghasilkan model yang efisien, skalabel, dan memiliki kemampuan generalisasi yang baik pada data tabular [11].

Keunggulan *XGBoost* terletak pada penggunaan fungsi objektif yang terdiri atas fungsi kerugian dan komponen regularisasi. Regularisasi digunakan untuk mengendalikan kompleksitas model sehingga risiko *overfitting* dapat dikurangi. Dalam penelitian ini, *XGBoost* digunakan untuk memetakan fitur hasil ekstraksi dari data EFM terhadap estimasi awal potensi petir.

$$\text{Obj} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (1)$$

Pada Persamaan (1), $l(y_i, \hat{y}_i)$ merupakan fungsi kerugian antara nilai aktual dan nilai prediksi pada data ke- i , sedangkan $\Omega(f_k)$ merupakan komponen regularisasi pada pohon ke- k untuk mengendalikan kompleksitas model. Secara umum, regularisasi *XGBoost* dapat dinyatakan sebagai $\Omega(f) = \gamma T + (1/2) \lambda \sum_{j=1}^T w_j^2$, dengan T sebagai jumlah daun dan w_j sebagai bobot daun [10].

2.4 Bayesian Update

Bayesian Update merupakan pendekatan probabilistik yang digunakan untuk memperbarui suatu probabilitas berdasarkan informasi atau bukti baru. Konsep utama dalam metode *Bayesian* terdiri atas prior, *likelihood*, dan *posterior*. Prior merupakan probabilitas awal sebelum adanya bukti baru, *likelihood* menunjukkan peluang munculnya bukti terhadap suatu kondisi, sedangkan *posterior* merupakan probabilitas akhir setelah informasi baru diperhitungkan [15], [16].

$$\begin{aligned} & \frac{P(H | E)}{P(E | H)P(H)} \\ &= \frac{P(H | E)}{P(E | H)P(H) + P(E | \neg H)P(\neg H)} \quad (2) \end{aligned}$$

Pada Persamaan (2), $P(H|E)$ merupakan probabilitas *posterior*, $P(H)$ merupakan probabilitas awal atau prior, $P(E|H)$ merupakan *likelihood*, $P(\neg H)$ merupakan komplemen prior, dan $P(E|\neg H)$ merupakan peluang bukti ketika hipotesis tidak terpenuhi. Bentuk penyebut tersebut digunakan sebagai faktor normalisasi agar probabilitas *posterior* tetap berada pada rentang 0 sampai 1. Dalam penelitian ini, *Bayesian Update* digunakan untuk memperbarui probabilitas estimasi potensi petir berdasarkan keluaran *XGBoost* dan pola fitur EFM.

2.5 Integrasi *XGBoost* dan *Bayesian Update*

Integrasi *XGBoost* dan *Bayesian Update* dilakukan untuk memperoleh estimasi potensi petir yang tidak hanya berbasis prediksi model, tetapi juga mempertimbangkan pembaruan probabilitas. *XGBoost* digunakan untuk mempelajari hubungan antara fitur EFM dan tingkat potensi petir, sedangkan *Bayesian Update* digunakan untuk memperbarui probabilitas berdasarkan bukti baru dari pola data. Dengan demikian, keluaran akhir model berupa nilai probabilitas *posterior* yang dapat dikategorikan menjadi tingkat potensi tertentu, seperti rendah, sedang, tinggi, atau ekstrem.

3. METODE PENELITIAN

3.1 Rancangan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif berbasis pemodelan data untuk mengestimasi potensi petir berdasarkan pola perubahan medan listrik atmosfer yang direpresentasikan melalui data *Electric Field Mill* (EFM). Model yang diusulkan menggabungkan algoritma *XGBoost* sebagai model prediksi awal dan *Bayesian Update* sebagai metode pembaruan probabilitas. Tahapan penelitian terdiri atas pembentukan *dataset* EFM, prapemrosesan data, ekstraksi fitur deret waktu, pembentukan target potensi petir, pelatihan model *XGBoost*, pembaruan probabilitas menggunakan *Bayesian Update*, serta evaluasi kinerja model.

Alur penelitian dimulai dari data EFM yang berisi nilai medan listrik atmosfer terhadap waktu. Data tersebut diproses untuk memperoleh fitur turunan yang menggambarkan karakteristik perubahan sinyal, seperti perubahan medan listrik antarwaktu, rata-rata bergerak, simpangan baku, nilai maksimum absolut, dan kemiringan

perubahan sinyal. Fitur hasil ekstraksi digunakan sebagai masukan model *XGBoost* untuk menghasilkan estimasi awal potensi petir. Selanjutnya, probabilitas keluaran model diperbarui menggunakan *Bayesian Update* sehingga diperoleh probabilitas *posterior* sebagai estimasi akhir.

3.2 Dataset Penelitian

Dataset yang digunakan pada penelitian ini merupakan *dataset* uji berbasis karakteristik sinyal EFM. Data disusun dalam bentuk deret waktu dengan interval pengamatan satu menit. *Dataset* terdiri atas data pembacaan sensor dan fitur hasil pengolahan, meliputi waktu pengamatan, nilai ADC 12-bit, tegangan mentah, tegangan hasil penyaringan, nilai medan listrik dalam satuan kV/m, perubahan medan listrik, rata-rata bergerak, simpangan baku, nilai maksimum absolut, kemiringan perubahan sinyal, skor potensi, probabilitas awal *XGBoost*, probabilitas *posterior Bayesian*, dan kategori potensi petir.

Data yang digunakan dalam penelitian ini tidak dinyatakan sebagai data pengukuran lapangan aktual, melainkan sebagai *dataset* uji terstruktur untuk validasi alur prapemrosesan, ekstraksi fitur, pemodelan *XGBoost*, dan pembaruan probabilitas *Bayesian*. Kategori potensi pada *dataset* digunakan sebagai *target proxy* untuk menguji performa metode, bukan sebagai label absolut kejadian petir di lapangan.

3.3 Prapemrosesan Data

Prapemrosesan dilakukan untuk memastikan data siap digunakan dalam proses pemodelan. Tahapan prapemrosesan meliputi pemeriksaan data kosong, pemeriksaan format waktu, penyusunan urutan data berdasarkan waktu, serta penyesuaian fitur numerik. Kolom waktu digunakan untuk mempertahankan urutan deret waktu, sedangkan fitur numerik digunakan sebagai variabel masukan model. Untuk mengurangi pengaruh perbedaan skala antarfitur, beberapa fitur turunan dinormalisasi menggunakan pendekatan Min-Max sehingga berada pada rentang 0 sampai 1.

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}, \quad X_{\max} \neq X_{\min} \quad (3)$$

Pada Persamaan (3), X_{norm} merupakan nilai hasil normalisasi, X merupakan nilai asli, $X_{\min}$ merupakan nilai minimum pada fitur tersebut, dan $X_{\max}$ merupakan nilai maksimum pada fitur tersebut. Persamaan ini

digunakan jika $X_{\max}$ tidak sama dengan $X_{\min}$ agar tidak terjadi pembagian dengan nol.

3.4 Ekstraksi Fitur EFM

Ekstraksi fitur dilakukan untuk mengubah data EFM dalam bentuk deret waktu menjadi variabel numerik yang dapat digunakan oleh model prediksi. Fitur utama yang digunakan adalah nilai medan listrik atmosfer dalam satuan kV/m. Selain itu, digunakan fitur perubahan nilai medan listrik antarwaktu untuk melihat selisih antara nilai medan listrik pada waktu tertentu dengan waktu sebelumnya.

$$\Delta E_t = E_t - E_{t-1} \quad (4)$$

Pada Persamaan (4), ΔE_t merupakan perubahan medan listrik pada waktu ke- t , E_t merupakan nilai medan listrik pada waktu ke- t , dan E_{t-1} merupakan nilai medan listrik pada waktu sebelumnya. Selain perubahan antarwaktu, penelitian ini menggunakan fitur rata-rata bergerak 5 menit dan 10 menit, simpangan baku 5 menit, nilai maksimum absolut 10 menit, serta *slope* 10 menit.

Fitur-fitur yang digunakan dalam penelitian ini meliputi kV_m, Delta_kV_m, MA_5menit, MA_10menit, STD_5menit, MAXABS_10menit, Slope_10menit, Scaled_abs_kV_m, Scaled_abs_Delta, dan Scaled_STD_5. Kombinasi fitur tersebut digunakan karena mampu merepresentasikan besar medan listrik, perubahan mendadak, fluktuasi, puncak sinyal, dan tren perubahan sinyal EFM.

3.5 Pembentukan Target Potensi Petir

Target potensi petir pada penelitian ini dibentuk dalam bentuk skor potensi dengan rentang 0 sampai 100. Skor ini merupakan indeks *proxy* yang dihitung berdasarkan kombinasi beberapa fitur utama hasil normalisasi. Fitur yang digunakan dalam pembentukan skor meliputi nilai absolut medan listrik, nilai absolut perubahan medan listrik, simpangan baku 5 menit, nilai maksimum absolut 10 menit, dan nilai absolut kemiringan 10 menit.

$$\begin{aligned} \text{Indeks} = & 0,42N(|E|) + 0,18N(|\Delta E|) + \\ & 0,15N(\text{STD}_5) \\ & + 0,18N(\text{MAXABS}_{10}) + 0,07N(|\text{Slope}_{10}|) \end{aligned} \quad (5)$$

$$\text{Potensi_Skor} = 100 \times \text{Indeks} \quad (6)$$

Pada Persamaan (5), $N(\cdot)$ menyatakan fungsi normalisasi. Persamaan (6) digunakan untuk

mengonversi nilai indeks menjadi skor potensi pada rentang 0 sampai 100. Skor potensi digunakan untuk membentuk kategori potensi petir, yaitu rendah, sedang, tinggi, dan ekstrem. Bobot pada Persamaan (5) digunakan sebagai skema pembentukan *target proxy* berdasarkan karakteristik fitur EFM, bukan sebagai formula baku potensi petir. Karena target yang digunakan merupakan *target proxy*, kategori tersebut tidak dipahami sebagai status resmi kejadian petir, melainkan sebagai tingkat potensi berdasarkan pola data EFM.

3.6 Pemodelan Menggunakan XGBoost

Model *XGBoost* digunakan untuk mempelajari hubungan antara fitur EFM dan skor potensi petir. Fitur hasil ekstraksi digunakan sebagai variabel masukan, sedangkan skor potensi digunakan sebagai target prediksi. Data dibagi menjadi data latih dan data uji. Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk mengevaluasi kemampuan model pada data yang tidak digunakan saat pelatihan. Model *XGBoost* menghasilkan nilai estimasi awal yang kemudian dikonversi menjadi probabilitas potensi petir.

3.7 Bayesian Update

Bayesian Update digunakan untuk memperbarui probabilitas potensi petir berdasarkan probabilitas awal dan bukti baru dari pola EFM. Dalam penelitian ini, probabilitas awal berasal dari keluaran model *XGBoost*, sedangkan bukti baru direpresentasikan oleh fitur atau skor potensi yang menunjukkan peningkatan aktivitas medan listrik atmosfer. Hasil akhir *Bayesian Update* berupa probabilitas *posterior* yang digunakan sebagai estimasi akhir potensi petir.

3.8 Evaluasi Model

Evaluasi dilakukan untuk mengetahui kinerja model dalam mengestimasi skor potensi petir. Metrik evaluasi yang digunakan adalah *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi R^2 . MAE digunakan untuk mengukur rata-rata besar kesalahan absolut antara nilai aktual dan nilai prediksi. RMSE mengukur besar kesalahan prediksi dengan penalti lebih besar terhadap kesalahan yang tinggi. R^2 digunakan untuk mengetahui seberapa besar variasi target yang dapat dijelaskan oleh model [17].

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

4. HASIL DAN PEMBAHASAN

4.1 Deskripsi Dataset

Dataset yang digunakan dalam penelitian ini terdiri atas 1000 data deret waktu dengan interval *sampling* satu menit. Data dimulai pada 1 April 2026 pukul 00:00 sampai 16:39. Setiap data merepresentasikan pembacaan dan hasil pengolahan sinyal EFM, meliputi nilai ADC 12-bit, tegangan mentah, tegangan hasil penyaringan, nilai medan listrik dalam satuan kV/m, perubahan medan listrik, rata-rata bergerak, simpangan baku, nilai maksimum absolut, kemiringan perubahan sinyal, skor potensi, probabilitas *XGBoost*, probabilitas *posterior Bayesian*, dan kategori potensi petir.

Berdasarkan hasil pengolahan *dataset*, nilai medan listrik memiliki rentang dari -47,375 kV/m sampai 68,521 kV/m, dengan rata-rata 9,263 kV/m. Nilai skor potensi berada pada rentang 0 sampai 92,890, dengan rata-rata 21,573. Hal ini menunjukkan bahwa mayoritas data berada pada kondisi potensi rendah, tetapi terdapat beberapa periode dengan peningkatan medan listrik yang cukup signifikan hingga mencapai kategori ekstrem.

Tabel 1. Distribusi kategori potensi petir

Kategori	Jumlah	Persentase
Rendah	647	64,7%
Sedang	252	25,2%
Tinggi	71	7,1%
Ekstrem	30	3,0%
Total	1000	100%

Berdasarkan Tabel 1, kategori rendah merupakan kategori paling dominan dengan jumlah 647 data atau 64,7% dari keseluruhan data. Kategori sedang berjumlah 252 data atau 25,2%, sedangkan kategori tinggi dan ekstrem masing-masing berjumlah 71 data dan 30 data. Distribusi ini menunjukkan bahwa kejadian dengan potensi tinggi dan ekstrem memiliki jumlah lebih sedikit dibandingkan kondisi rendah dan sedang.

4.2 Karakteristik Fitur EFM

Fitur utama dalam penelitian ini adalah nilai medan listrik atmosfer dalam satuan kV/m. Selain itu, beberapa fitur turunan digunakan untuk menggambarkan perubahan sinyal EFM, seperti perubahan medan listrik antarwaktu, rata-rata bergerak, simpangan baku, nilai maksimum absolut, dan kemiringan perubahan sinyal. Fitur-fitur tersebut digunakan karena potensi petir tidak hanya dipengaruhi oleh besar medan listrik sesaat, tetapi juga oleh pola perubahan dan kestabilan sinyal dalam rentang waktu tertentu.

Tabel 2. Ringkasan statistik fitur EFM

Fitur	Min.	Maks.	Rata-rata
kV/m	-47,375	68,521	9,263
Delta kV/m	-7,544	8,811	0,001
MA 5 menit	-46,015	66,619	9,259
MA 10 menit	-45,176	63,564	9,251
STD 5 menit	0,000	4,296	1,199
MAXABS 10 menit	0,229	68,521	18,635
Slope 10 menit	-1,613	1,600	0,003
Skor Potensi	0,000	92,890	21,573

Berdasarkan Tabel 2, nilai maksimum absolut medan listrik dalam jendela 10 menit mencapai 68,521 kV/m. Nilai ini menunjukkan adanya periode dengan peningkatan medan listrik yang kuat. Sementara itu, nilai simpangan baku 5 menit memiliki rata-rata 1,199, yang menunjukkan adanya variasi sinyal dalam jendela waktu pendek.

4.3 Hasil Estimasi Menggunakan *XGBoost*

Model *XGBoost* digunakan untuk memetakan fitur hasil ekstraksi EFM terhadap skor potensi petir. Keluaran model berupa probabilitas awal yang menunjukkan tingkat potensi petir berdasarkan pola data. Dalam evaluasi ini, probabilitas *XGBoost* dikalikan 100 agar memiliki skala yang sama dengan skor potensi 0 sampai 100.

Tabel 3. Hasil evaluasi *XGBoost*

Metrik	Nilai
MAE	1,673
RMSE	2,108
R ²	0,990

Berdasarkan Tabel 3, model *XGBoost* memperoleh nilai MAE sebesar 1,673 dan

RMSE sebesar 2,108. Nilai kesalahan yang rendah menunjukkan bahwa prediksi *XGBoost* memiliki kedekatan yang tinggi terhadap skor potensi. Selain itu, nilai R^2 sebesar 0,990 menunjukkan bahwa model mampu menjelaskan sebagian besar variasi skor potensi pada *dataset* uji.

4.4 Hasil Pembaruan Probabilitas

Menggunakan *Bayesian Update*

Bayesian Update digunakan untuk memperbarui probabilitas awal berdasarkan informasi tambahan dari pola EFM. Keluaran akhir metode ini berupa probabilitas *posterior*. Dalam evaluasi ini, probabilitas *posterior Bayesian* juga dikalikan 100 agar dapat dibandingkan dengan skor potensi 0 sampai 100.

Tabel 4. Hasil evaluasi *Bayesian Update*

Metrik	Nilai
MAE	5,846
RMSE	7,313
R^2	0,882

Berdasarkan Tabel 4, hasil *Bayesian Update* memperoleh MAE sebesar 5,846, RMSE sebesar 7,313, dan R^2 sebesar 0,882. Nilai ini menunjukkan bahwa hasil *Bayesian Update* masih mampu mengikuti pola skor potensi, tetapi tingkat kesalahannya lebih besar dibandingkan *XGBoost*. Kondisi ini terjadi karena *Bayesian Update* menghasilkan probabilitas *posterior* yang lebih konservatif.

4.5 Perbandingan *XGBoost* dan *XGBoost-Bayesian*

Tabel 5. Perbandingan hasil evaluasi model

Model	MAE	RMSE	R^2
<i>XGBoost</i>	1,673	2,108	0,990
<i>XGBoost-Bayesian</i>	5,846	7,313	0,882

Berdasarkan Tabel 5, *XGBoost* memiliki performa numerik yang lebih baik dibandingkan hasil setelah *Bayesian Update*. Hal ini terlihat dari nilai MAE dan RMSE yang lebih rendah serta nilai R^2 yang lebih tinggi. Namun, hasil ini tidak berarti bahwa *Bayesian Update* tidak bermanfaat. *Bayesian Update* memberikan karakteristik *posterior* yang lebih konservatif dan dapat digunakan sebagai tahap pembaruan probabilitas untuk mengurangi perubahan probabilitas yang terlalu ekstrem.

Tabel 6. Rata-rata probabilitas berdasarkan kategori potensi

Kategori	<i>XGBoost</i>	<i>Bayesian</i>
Rendah	0,085	0,123
Sedang	0,368	0,312
Tinggi	0,626	0,484
Ekstrem	0,836	0,624

Berdasarkan Tabel 6, *XGBoost* menghasilkan probabilitas yang lebih tinggi pada kategori tinggi dan ekstrem, sedangkan *Bayesian Update* menghasilkan nilai *posterior* yang lebih rendah dan stabil. Pada kategori rendah, *Bayesian* menghasilkan rata-rata probabilitas sedikit lebih tinggi dibandingkan *XGBoost*. Pola ini menunjukkan bahwa *Bayesian Update* berperan sebagai mekanisme penyeimbang probabilitas, terutama untuk mencegah prediksi terlalu ekstrem.

4.6 Pembahasan

Hasil penelitian menunjukkan bahwa fitur berbasis pola EFM dapat digunakan untuk membangun estimasi potensi petir. Nilai medan listrik, nilai maksimum absolut, simpangan baku, dan rata-rata bergerak memiliki hubungan kuat terhadap skor potensi. Ketika nilai medan listrik dan variasi sinyal meningkat, skor potensi juga cenderung meningkat. Hal ini sesuai dengan karakteristik EFM yang mengukur perubahan medan listrik atmosfer akibat akumulasi dan pemisahan muatan di dalam awan konvektif [3], [6].

Model *XGBoost* menunjukkan performa terbaik berdasarkan metrik MAE, RMSE, dan R^2 . Nilai R^2 sebesar 0,990 menunjukkan bahwa model sangat mampu memetakan hubungan antara fitur EFM dan skor potensi pada *dataset* uji. Namun, karena *dataset* yang digunakan merupakan *dataset* uji terstruktur berbasis karakteristik EFM, hasil ini belum dapat langsung digeneralisasi sebagai performa pada data lapangan nyata. Pengujian lebih lanjut menggunakan data pengukuran EFM aktual tetap diperlukan untuk menilai ketahanan model terhadap *noise*, variasi cuaca, gangguan sensor, dan kondisi atmosfer yang lebih kompleks.

Bayesian Update menghasilkan nilai evaluasi yang lebih rendah dibandingkan *XGBoost*, tetapi tetap memiliki fungsi penting dalam kerangka estimasi probabilistik. Dalam sistem peringatan dini, keluaran yang terlalu responsif

terhadap perubahan sesaat dapat menimbulkan peringatan palsu. *Bayesian Update* dapat digunakan untuk memperbarui dan menstabilkan probabilitas berdasarkan informasi sebelumnya dan bukti baru. Dengan demikian, pendekatan ini lebih tepat digunakan sebagai lapisan pembaruan probabilitas, bukan sebagai pengganti model prediksi utama [15], [16].

Secara keseluruhan, integrasi *XGBoost* dan *Bayesian Update* memberikan dua fungsi yang berbeda. *XGBoost* berperan sebagai model prediksi utama yang menghasilkan estimasi awal dengan akurasi tinggi terhadap skor potensi. Sementara itu, *Bayesian Update* berperan sebagai mekanisme pembaruan probabilitas yang menghasilkan estimasi lebih konservatif. Kombinasi ini dapat menjadi dasar awal untuk pengembangan sistem peringatan dini petir berbasis EFM, terutama pada area pemantauan lokal.

5. KESIMPULAN

1. Penelitian ini berhasil mengembangkan alur estimasi potensi petir berbasis pola *Electric Field Mill* (EFM) menggunakan kombinasi *XGBoost* dan *Bayesian Update*. Fitur EFM yang digunakan meliputi nilai medan listrik, perubahan medan listrik, rata-rata bergerak, simpangan baku, nilai maksimum absolut, dan kemiringan perubahan sinyal.

2. Model *XGBoost* menunjukkan performa terbaik dalam mengestimasi skor potensi petir pada *dataset* uji. Hasil evaluasi menunjukkan nilai MAE sebesar 1,673, RMSE sebesar 2,108, dan R^2 sebesar 0,990.

3. *Bayesian Update* menghasilkan nilai MAE sebesar 5,846, RMSE sebesar 7,313, dan R^2 sebesar 0,882. Hasil ini menunjukkan bahwa *Bayesian Update* belum meningkatkan performa numerik dibandingkan *XGBoost* secara langsung, tetapi tetap memiliki peran sebagai mekanisme pembaruan probabilitas *posterior* yang lebih konservatif dan stabil.

4. Integrasi *XGBoost* dan *Bayesian Update* memberikan dua fungsi yang saling melengkapi. *XGBoost* berperan sebagai model prediksi utama, sedangkan *Bayesian Update* berperan sebagai tahap pembaruan probabilitas agar estimasi potensi petir tidak hanya bergantung pada prediksi awal model.

5. Keterbatasan penelitian ini adalah *dataset* yang digunakan masih berupa *dataset* uji

terstruktur berbasis karakteristik sinyal EFM, sehingga hasilnya belum dapat langsung digeneralisasi sebagai performa pada data pengukuran lapangan aktual. Pengembangan selanjutnya perlu menggunakan data EFM hasil pengukuran langsung dan data kejadian petir aktual sebagai label validasi.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada pihak-pihak yang telah memberikan dukungan dalam penyusunan penelitian ini. Ucapan terima kasih juga disampaikan kepada pihak yang telah membantu dalam penyediaan referensi, pengolahan data, serta pengembangan metode estimasi potensi petir berbasis *Electric Field Mill*, *XGBoost*, dan *Bayesian Update*.

DAFTAR PUSTAKA

- [1] National Weather Service, "Understanding Lightning Science," National Oceanic and Atmospheric Administration, 2026.
- [2] Badan Meteorologi, Klimatologi, dan Geofisika, "Sambaran Petir Real-time," BMKG, 2026.
- [3] M. A. B. Sidik, Z. Nawawi, M. I. Jambak, and Y. Z. Arief, "Development of Wireless Electric Field Mill for Atmospheric Electric Field Observation," TELKOMNIKA, vol. 12, no. 4, pp. 1113–1122, 2014.
- [4] H. Shahroom, Z. Buntat, M. A. B. Sidik, Z. Nawawi, and M. I. Jambak, "Atmospheric Electric Field Measurement Advances in Southern Peninsular Malaysia," in 2015 IEEE Conference on Energy Conversion (CENCON), 2015, pp. 116–121, doi: 10.1109/CENCON.2015.7409524.
- [5] M. A. da S. Ferro, J. Yamasaki, D. R. M. Pimentel, K. P. Naccarato, and M. M. F. Saba, "Lightning Risk Warnings Based on Atmospheric Electric Field Measurements in Brazil," Journal of Aerospace Technology and Management, vol. 3, no. 3, pp. 301–310, 2011, doi: 10.5028/jatm.v3i3.120.
- [6] X. Li, Y. Zhang, L. Wang, and Y. Liu, "Lightning Risk Warning Method Using Atmospheric Electric Field," Atmosphere, vol. 14, no. 6, 2023, doi: 10.3390/atmos14061002.
- [7] A. Mostajabi, D. L. Finney, M. Rubinstein, and F. Rachidi, "Nowcasting Lightning Occurrence from Commonly Available Meteorological Parameters Using Machine Learning Techniques," npj Climate and Atmospheric Science, vol. 2, no. 41, 2019, doi: 10.1038/s41612-019-0098-0.
- [8] J. Leinonen, U. Hamann, D. Nerini, U. Germann, and G. Franch, "Seamless Lightning

- Nowcasting with Recurrent-Convolutional Deep Learning,” *Artificial Intelligence for the Earth Systems*, vol. 1, no. 4, 2022, doi: 10.1175/AIES-D-22-0043.1.
- [9] G. Ehrensperger, T. Simon, G. J. Mayr, and T. Hell, “Identifying Lightning Processes in ERA5 Soundings with Deep Learning,” 2022.
- [10] T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794, doi: 10.1145/2939672.2939785.
- [11] R. Mitchell and E. Frank, “Accelerating the XGBoost Algorithm Using GPU Computing,” *PeerJ Computer Science*, vol. 3, 2017, doi: 10.7717/peerj-cs.127.
- [12] XGBoost Developers, “XGBoost Documentation,” 2026.
- [13] A. Sutaryani, S. Sunarno, and D. Djuniadi, “Perbandingan Performa Model Machine Learning dalam Prediksi Suhu di Semarang,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, 2024, doi: 10.23960/jitet.v12i3.4884.
- [14] F. H. Syahadah, R. T. Subagio, and P. Rizqiyah, “Penerapan XGBoost dalam Prediksi Pendaftaran Siswa Baru Bimbingan Belajar QSC di Kota Cirebon,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 3S1, 2025, doi: 10.23960/jitet.v13i3S1.7998.
- [15] R. van de Schoot et al., “Bayesian Statistics and Modelling,” *Nature Reviews Methods Primers*, vol. 1, no. 1, 2021, doi: 10.1038/s43586-020-00001-2.
- [16] A. Gelman, J. B. Carlin, H. S. Stern, D. B. Dunson, A. Vehtari, and D. B. Rubin, *Bayesian Data Analysis*, 3rd ed. Boca Raton, FL, USA: CRC Press, 2013.
- [17] F. Pedregosa et al., “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.