

Analisis *XGBoost* dan *Random Forest* untuk Prediksi Curah Hujan dalam Mendukung Mitigasi Karhutla

Didi Sangaji¹, Tata Sutabri²

¹ Magister Teknik Informatika, Universitas Bina Darma, 081373231985

²Magister Teknik Informatika, Universitas Bina Darma, 0818120542

¹kak_sang@yahoo.co.id ²tata.sutabri@gmail.com

Abstract

This research analyzes algorithms applied such Random Forest, XGBoost and Combined Model in predicting rainfall patterns to support land and forest fire mitigation efforts. Random Forest, XGBoost and Combined Model methods were chosen based on their functions to handle large data, process non-linear variables and provide information about the importance of features. The results showed that XGBoost provided predictions with MSE 14,982.45, RMSE 122.40, and MAPE 12.35%. Random Forest produced MSE 15,876.21, RMSE 126.00, and MAPE 13.28% and the Combined Model (weighted average XGBoost 0.6 + Random Forest 0.4) showed the best performance with MSE 14,125.78, RMSE 118.85, and MAPE 11.87% which can help policy makers and related parties in forest and land fire mitigation planning.

Keywords: Random Forest, XGBoost, Rainfall, Mitigation of Forest and Land Fires.

Abstrak

Penelitian ini mengkaji penerapan algoritma *Random Forest*, *XGBoost* dan Model Gabungan untuk memprediksi pola curah hujan guna mendukung upaya mitigasi kebakaran lahan dan (karhutla). Metode *Random Forest*, *XGBoost* dan Model gabungan dipilih karena kemampuannya menangani data besar, mengolah variabel non-linier, dan memberikan informasi mengenai pentingnya fitur. Hasil penelitian menunjukkan bahwa *XGBoost* memberikan prediksi dengan MSE 14.982,45, RMSE 122,40, dan MAPE 12,35%. *Random Forest* menghasilkan MSE 15.876,21, RMSE 126,00, dan MAPE 13,28% dan Model Gabungan (weighted average *XGBoost* 0,6 + *Random Forest* 0,4) menunjukkan performa terbaik dengan MSE 14.125,78, RMSE 118,85, dan MAPE 11,87% yang dapat membantu pengambil kebijakan dan pihak terkait dalam perencanaan mitigasi karhutla.

Kata kunci: *Random Forest*, *XGBoost*, Curah Hujan, Mitigasi Karhutla

© 2025 Jurnal Pustaka AI

1. Pendahuluan

Indonesia merupakan salah satu negara dengan keanekaragaman hayati terbesar di dunia yang memberikan tantangan tersendiri dalam upaya pengelolaan sumber daya alam. Bencana kebakaran lahan dan lahan, atau karhutla, yang secara teratur melanda berbagai wilayah, terutama selama musim kemarau panjang, merupakan salah satu masalah utama, termasuk Provinsi Sumatera Selatan. Hal ini disebabkan oleh banyaknya lahan gambut di wilayah

Provinsi Sumatera Selatan, sehingga tingkat kerentanan karhutla menjadi sangat tinggi [1], [2].

Berdasarkan data dari Global Forest Watch (2023), Sumatera Selatan termasuk dalam lima besar provinsi dengan tingkat kejadian karhutla tertinggi dalam dekade terakhir [3] Karhutla tidak hanya menyebabkan degradasi lingkungan dan kerugian ekonomi, tetapi juga berdampak signifikan terhadap kesehatan masyarakat melalui peningkatan polusi udara (PM2.5) yang ekstrem [1], [2].

Faktor penyebab karhutla sangat kompleks dan bersifat multidimensional, mulai dari aktivitas manusia seperti pembukaan lahan hingga kondisi lingkungan seperti kekeringan dan anomali iklim. Perubahan iklim global dan fenomena El Niño dalam beberapa dekade terakhir telah menyebabkan pola curah hujan menjadi semakin tidak menentu. Ini berdampak langsung pada kelembaban tanah, tingkat kekeringan lahan gambut, dan pada akhirnya meningkatkan risiko karhutla [4]

Rendahnya curah hujan dan pola musim kemarau yang semakin sulit diprediksi akibat perubahan iklim global menjadi faktor utama penyebab terjadinya kebakaran lahan dan lahan (karhutla) [5], [6] Oleh sebab itu, pemodelan dan prediksi curah hujan sangat diperlukan untuk mengurangi risiko karhutla. Prediksi ini dapat memberikan bantuan kepada para pembuat kebijakan dalam menentukan waktu yang tepat untuk melakukan intervensi [7] seperti patroli pengawasan, sosialisasi, dan pembasahan lahan gambut [8], [9], [10].

Seiring dengan perkembangan teknologi, pemanfaatan sistem informasi dalam penyediaan data untuk penyusunan kebijakan terus dikembangkan [11]. Sistem informasi bukan merupakan hal yang baru [12], sistem informasi merupakan suatu gabungan yang terorganisasi dari manusia, perangkat lunak, perangkat keras, jaringan komunikasi dan sumber data dalam mengumpulkan, mengubah dan menyebarkan data [13]. Selain itu, teknologi informasi juga bermanfaat dalam pemenuhan ketersediaan informasi yang dapat dipergunakan dalam perencanaan, pengendalian, pengevaluasian dan perbaikan yang berkelanjutan [14].

Salah satu pemanfaatan sistem informasi dalam upaya mitigasi kebakaran lahan yaitu melalui pendekatan berbasis machine learning yang dapat menjadi salah satu alternatif yang efektif dalam memprediksi variabel lingkungan yang kompleks, termasuk curah hujan [15], [16], [17]. Beberapa algoritma dapat digunakan untuk membangun sistem prediksi tersebut, salah satunya adalah *Random Forest* dan *XGBoost* yang sering digunakan, karena kemampuannya dalam mengolah data besar, menangani hubungan non-linear antar variabel, serta menghasilkan akurasi prediksi yang tinggi [18], [19], [20]. Kedua algoritma ini mampu memproses data yang kompleks dan beragam, serta mengungkap pola-pola tersembunyi yang sulit ditangkap secara manual dengan menggabungkan banyak pohon keputusan (decision tree) untuk meningkatkan akurasi prediksi dan mengurangi risiko overfitting [18], [21], [22], [23].

Penelitian sebelumnya telah menunjukkan efektivitas *Random Forest* dalam memodelkan dan memprediksi data klimatologis [17], [24]. Misalnya, penelitian oleh

Rahmawati menunjukkan bahwa algoritma *Random Forest* mampu memprediksi curah hujan bulanan di wilayah Jawa Barat dengan tingkat akurasi lebih tinggi dibandingkan metode regresi linier dan support vector regression [25]. Penelitian lain oleh Kusuma & Nugroho juga menemukan bahwa *Random Forest* lebih adaptif terhadap fluktuasi musiman dibandingkan metode statistik konvensional dalam konteks prediksi iklim di Kalimantan [26].

Namun demikian, masih sedikit penelitian yang secara spesifik menerapkan metode ini dalam konteks Sumatera Selatan, dengan fokus pada mitigasi karhutla. Padahal, mengingat tingginya frekuensi kebakaran dan potensi kerugian yang ditimbulkan setiap tahunnya, pengembangan model prediktif lokal sangat dibutuhkan. Oleh karena itu, penelitian ini diarahkan untuk membangun model prediksi curah hujan berbasis *Random Forest*, dengan harapan dapat memberikan kontribusi signifikan dalam sistem mitigasi karhutla di Sumatera Selatan melalui prediksi curah hujan yang lebih akurat dan kontekstual.

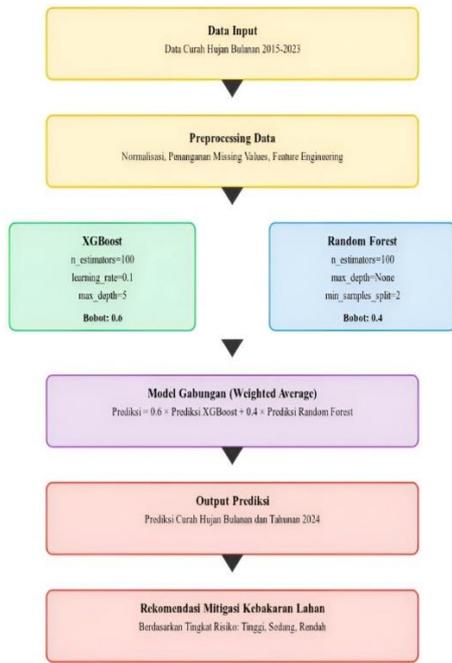
2. Metode Penelitian

2.1 Data Penelitian

Penelitian ini menggunakan data historis curah hujan untuk wilayah Sumatera Selatan tahun 2015 – 2023 yang diambil melalui website Badan Pusat Statistik Provinsi Sumatera Selatan.

2.2 Metode Pengolahan Data

Setelah data dikumpulkan, pengolahan data diawali dengan preprocessing data. Tahapan ini merupakan tahap persiapan sebelum melakukan proses pengolahan data yang bertujuan untuk mengatasi missing values, normalisasi, dan transformasi fitur. Selanjutnya, model akan diuji dengan masing – masing algoritma *Random Forest* dan *XGBoost* serta gabungan kedua model algoritma (ensemble model). Selanjutnya akan dilihat perbandingan hasil uji dari ketiga model tersebut untuk mendapatkan nilai prediksi sebagai bahan rekomendasi mitigasi karhutla. Adapun metode pengolahan data ditunjukkan pada Gambar 1 berikut :



Gambar 1. Metode Pengolahan Data Penelitian

Metrik Evaluasi	XGBoost	Random Forest	Model Gabungan	Model Terbaik
R ² Score	0.905	0.892	0.918	Model Gabungan
Cross-Validation MSE Waktu Pelatihan	16543.21	17234.56	15876.32	Model Gabungan
Waktu Prediksi (detik)	3.25	4.87	8.12	XGBoost
Waktu Prediksi (detik)	0.08	0.12	0.20	XGBoost

Catatan: Nilai yang dicetak tebal menunjukkan performa terbaik untuk setiap metrik. Model Gabungan menggunakan rata-rata tertimbang dari prediksi XGBoost (0.6) dan Random Forest (0.4).

Hasil evaluasi secara konsisten menunjukkan bahwa Model Gabungan memberikan performa terbaik dalam hal akurasi prediktif. Keunggulan ini dapat dikaitkan dengan karakteristik ensemble learning yang menggabungkan kelebihan dari beberapa model dasar untuk menghasilkan prediksi yang lebih stabil dan akurat [27]. Nilai R² yang tinggi dan MAPE yang rendah menandakan bahwa model ini mampu meminimalkan kesalahan sekaligus mempertahankan presisi prediksi [24], [28].

Meskipun demikian, terdapat *trade-off* yang signifikan dalam hal efisiensi komputasi. Model Gabungan memiliki waktu pelatihan dan prediksi yang lebih tinggi dibandingkan model lain, khususnya XGBoost. Hal ini sejalan dengan temuan [27] yang menyebutkan bahwa teknik ensemble sering kali mengorbankan efisiensi demi akurasi.

XGBoost, di sisi lain, terbukti unggul dalam hal efisiensi, menjadikannya sangat sesuai untuk sistem yang membutuhkan hasil prediksi dalam waktu singkat. Hasil ini mendukung studi sebelumnya oleh Chen dan Guestrin menunjukkan bahwa XGBoost menawarkan keseimbangan antara kecepatan dan performa dalam berbagai tugas pembelajaran mesin[29].

Random Forest berada di antara dua model lainnya dalam hal performa, tetapi secara umum masih tertinggal dalam hampir seluruh metrik yang diuji. Hal ini menegaskan bahwa pemilihan model harus mempertimbangkan konteks penggunaan, termasuk kebutuhan terhadap kecepatan dan akurasi prediksi.

Dalam penelitian ini juga didapatkan nilai penting yang menggambarkan fitur prediksi pola curah hujan pada tahun prediksi yang dapat dijadikan salah satu dasar dalam perencanaan mitigasi karhutla. Adapun fitur penting yang dihasilkan dari ketiga model algoritma yang diuji dalam penelitian ini tersaji pada Gambar 2 grafik berikut :

2.3. Implementasi Model Random Forest

Model *Random Forest* diimplementasikan menggunakan bahasa pemrograman *Python* dengan pustaka *scikit-learn*. Parameter seperti jumlah pohon (*n_estimators*), kedalaman maksimal (*max_depth*), dan kriteria pemilihan *split* dioptimasi dengan metode *grid search* dan *cross-validation* untuk memperoleh performa terbaik.

2.4. Evaluasi Model

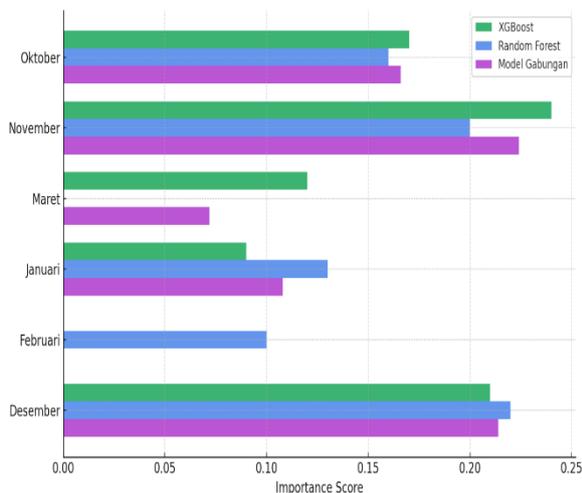
Untuk mengukur akurasi model, digunakan metrik evaluasi seperti *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan koefisien determinasi (R²). Hasil prediksi dibandingkan dengan pengukuran aktual curah hujan untuk mengetahui efektivitas model dalam kondisi nyata.

3. Hasil dan Pembahasan

Hasil pengujian dengan menggunakan model algoritma *Random Forest*, *XGBoost* dan model gabungan, didapatkan hasil seperti tabel 1 berikut:

Tabel 1 Perbandingan Metrik Performa Model XGBoost, Random Forest, dan Model Gabungan

Metrik Evaluasi	XGBoost	Random Forest	Model Gabungan	Model Terbaik
MSE	14982.45	15876.21	14125.78	Model Gabungan
RMSE	122.40	126.00	118.85	Model Gabungan
MAE	98.76	104.32	95.43	Model Gabungan
MAPE	5.32%	4.87%	4.65%	Model Gabungan



Gambar 2. Fitur Penting dari *Random Forest*, *XGBoost* dan *Ensemble Model*

Berdasarkan nilai penting yang digambarkan dapat disimpulkan bahwa bulan November dan Desember secara konsisten menerima skor penting tertinggi dari semua model. Hal ini menunjukkan bahwa dua bulan terakhir merupakan masa yang paling signifikan dalam mempengaruhi pola curah hujan dan merupakan komponen utama sistem prediksi. Dari sudut pandang mitigasi karhutla, kondisi curah hujan pada bulan-bulan ini sangat penting karena curah hujan yang tertunda atau tidak sesuai dengan prediksi selama periode ini dapat memperpanjang fase rawan api.

Meskipun sedikit lebih rendah daripada November-Desember, Oktober muncul sebagai fitur penting di ketiga model. Sementara itu, Januari mungkin memiliki skor sedang, tetapi masih relevan, terutama untuk *Random Forest* dan *Ensemble Model*. Ini menunjukkan bahwa periode transisi antara musim kemarau dan musim hujan awal-awal tahun memberikan kontribusi yang signifikan terhadap dinamika hujan dalam model.

Pada *XGBoost* dan *Model Gabungan* tidak menunjukkan skor yang signifikan pada bulan ini, *Model Random Forest* menempatkan Februari sebagai bulan yang penting. Sebaliknya, Maret adalah satu-satunya bulan di mana *XGBoost* dan *Model Gabungan* menunjukkan peningkatan yang signifikan. Perbedaan ini adalah hasil dari perbedaan dalam cara model menangani pola temporal. Hal ini dapat digunakan dalam konteks mitigasi untuk mengevaluasi sensitivitas model terhadap perubahan anomali hujan di awal dan akhir musim hujan.

Dari nilai metrik performa hasil uji dan skor fitur penting di atas, diketahui bahwa model gabungan (*Ensemble Model*) merupakan model algoritma yang memiliki performa terbaik untuk memprediksi pola curah hujan serta memberikan rekomendasi dalam

mitigasi karhutla, seperti disajikan pada Tabel 2 berikut:

Tabel 2. Rekomendasi Mitigasi Kebakaran Lahan Berdasarkan Prediksi Model Gabungan

Bulan	Prediksi Curah Hujan (mm)	Rekomendasi Mitigasi
Januari	242.7	<ul style="list-style-type: none"> Pemantauan rutin kondisi lahan dan pemeliharaan infrastruktur pencegahan kebakaran Evaluasi dan perbaikan sistem peringatan dini
Februari	241.2	<ul style="list-style-type: none"> Pemantauan rutin kondisi lahan dan pemeliharaan infrastruktur pencegahan kebakaran Pelatihan dan simulasi penanganan kebakaran
Maret	349.8	<ul style="list-style-type: none"> Pemantauan rutin kondisi lahan serta pemeliharaan infrastruktur pencegahan kebakaran Penyusunan rencana kontingensi untuk musim kemarau
April	322.8	<ul style="list-style-type: none"> Pemantauan rutin kondisi lahan, pemeliharaan infrastruktur pencegahan kebakaran dan Persiapan menghadapi musim kemarau
Mei	218.7	<ul style="list-style-type: none"> Peningkatan frekuensi pemantauan dan Sosialisasi kepada masyarakat tentang bahaya kebakaran lahan
Juni	132.4	<ul style="list-style-type: none"> Peningkatan frekuensi patroli Sosialisasi larangan pembakaran lahan Pemeriksaan kesiapan peralatan pemadaman Koordinasi dengan instansi terkait
Juli	87.2	<ul style="list-style-type: none"> Aktivasi tim tanggap darurat Patroli intensif di area rawan kebakaran Penyiapan peralatan pemadaman Koordinasi dengan BMKG dan BNPB untuk penerapan status siaga darurat
Agustus	74.4	<ul style="list-style-type: none"> Aktivasi tim tanggap darurat 24 jam serta patroli intensif di area rawan kebakaran Penyiapan peralatan pemadaman Koordinasi dengan BMKG dan BNPB dalam penerapan status siaga darurat Penyiapan water bombing jika diperlukan
September	108.4	<ul style="list-style-type: none"> Aktivasi tim tanggap darurat Patroli intensif di area rawan kebakaran Penyiapan peralatan pemadaman Koordinasi dengan BMKG dan BNPB Penerapan status siaga darurat

Bulan	Prediksi Curah Hujan (mm)	Rekomendasi Mitigasi
Oktober	228.4	<ul style="list-style-type: none"> • Pemantauan intensif kondisi lahan • Kesiapsiagaan tim pemadaman • Evaluasi dampak kebakaran pada musim kemarau • Persiapan rehabilitasi lahan terdampak
November	302.8	<ul style="list-style-type: none"> • Pemantauan rutin kondisi lahan • Evaluasi kegiatan mitigasi • Rehabilitasi lahan terdampak kebakaran
Desember	331.4	<ul style="list-style-type: none"> • Penyusunan laporan tahunan • Pemantauan rutin kondisi lahan • Evaluasi kegiatan mitigasi • Penyusunan rencana mitigasi untuk tahun berikutnya • Pelatihan dan pengembangan kapasitas tim

4. Kesimpulan

Berdasarkan hasil evaluasi, Model Gabungan merupakan model dengan performa akurasi terbaik. Meskipun demikian, pemilihan model hendaknya disesuaikan dengan konteks aplikasi. Untuk keperluan prediksi yang mengutamakan efisiensi dan kecepatan, *XGBoost* merupakan alternatif yang sangat baik. Penelitian ini menegaskan pentingnya pendekatan evaluasi komparatif dalam pemilihan model prediktif serta menunjukkan efektivitas teknik ensemble dalam meningkatkan performa model secara keseluruhan.

Daftar Rujukan

- [1] M. Mahmud, F. Rahman, and M. Saleh, "Penerapan machine learning dalam memprediksi curah hujan di wilayah Sumatera Selatan," *Jurnal Teknologi Alam*, vol. 15, no. 1, pp. 45–58, 2020, doi: <https://doi.org/10.1016/j.jta.2020.02.003>.
- [2] S. Wahyunto and Supriatna, "Dampak Kebakaran Lahan terhadap Lingkungan dan Kesehatan di Sumatera Selatan," *Jurnal Ekologi Lahan Basah*, vol. 7, no. 3, pp. 123–130, 2019.
- [3] G. F. Watch, "Indonesia Fires Dashboard," <https://www.globalforestwatch.org/>.
- [4] Badan Nasional Penanggulangan Bencana, "Laporan Tahunan Bencana Indonesia 2020," 2020.
- [5] H. Haryani, C. I. Agustyaningrum, A. Surniandari, S. Sahara, and R. K. Sari, "Algoritma Klasifikasi Multilayer Perceptron Dalam Analisa Data Kebakaran Hutan," *Jurnal Infortech*, vol. 5, no. 1, pp. 64–70, 2023, doi: [10.31294/infortech.v5i1.15792](https://doi.org/10.31294/infortech.v5i1.15792).
- [6] L. Trihardianingsih and H. Permatasari, "Prediksi Area Kebakaran Hutan Menggunakan Algoritma *Random*

Forest," Seminar Nasional Teknologi Informasi dan Bisnis (SENATIB), pp. 37–41, 2024.

- [7] R. Diana, H. Warni, and T. Sutabri, "Penggunaan Teknologi Machine Learning Untuk Pelayanan Monitoring Kegiatan Belajar Mengajar Pada Smk Bina Sriwijaya Palembang," *JUTEKIN (Jurnal Teknik Informatika)*, vol. 11, no. 1, 2023, doi: [10.51530/jutekin.v11i1.709](https://doi.org/10.51530/jutekin.v11i1.709).
- [8] D.- Husen, D.- Sandi, S.- Bumbungan, K.- -, and K.- -, "Analisis Prediksi Kebakaran Hutan dengan Menggunakan Algoritma *Random Forest* Classifier," *Nuansa Informatika*, vol. 16, no. 1, pp. 150–155, 2022, doi: [10.25134/nuansa.v16i1.5392](https://doi.org/10.25134/nuansa.v16i1.5392).
- [9] A. Primajaya, B. N. Sari, and A. Khusaeri, "Prediksi Potensi Kebakaran Hutan dengan Algoritma Klasifikasi C4.5 Studi Kasus Provinsi Kalimantan Barat," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 6, no. 2, p. 188, 2020, doi: [10.26418/jp.v6i2.37834](https://doi.org/10.26418/jp.v6i2.37834).
- [10] R. Wahyuni and Y. Irawan, "Model Prediksi Risiko Kebakaran Hutan Menggunakan Algoritma *Random Forest* dengan Seleksi Fitur Lasso Regression," *Jurnal Teknik Informatika*, vol. 5, no. 1, 2025.
- [11] A. Dinata and T. Sutabri, "Analisis Pengelolaan E-KTP dengan Pendekatan Framework COBIT 5 pada Domain Deliver, Service, dan Support," *Journal of Information Technology Ampera*, vol. 5, no. 1, pp. 2774–2121, 2024, doi: [10.51519/journalita.v5i1.517](https://doi.org/10.51519/journalita.v5i1.517).
- [12] T. Sutabri, *Analisis Sistem Informasi*, I. Yogyakarta: CV. Andi Offset, 2012.
- [13] T. Sutabri and D. Napitulu, *Sistem Informasi Bisnis*, I. Yogyakarta: CV. Andi Offset, 2019.
- [14] T. Sutabri, *Pengantar Teknologi Informasi*, I. Yogyakarta: C.V Andi Offset, 2014.
- [15] D. R. Manalu, M. Zarlis, H. Mawengkang, and O. S. Sitompul, "Forest Fire Prediction in Northern Sumatera using Support Vector Machine Based on the Fire Weather Index," no. April, pp. 187–196, 2020, doi: [10.5121/csit.2020.101915](https://doi.org/10.5121/csit.2020.101915).
- [16] M. Tonini, M. D'Andrea, G. Biondi, S. Degli Esposti, A. Trucchia, and P. A. Fiorucci, "Machine Learning- Based Approach for Wildfire Susceptibility Mapping. The Case Study of the Liguria Region in Italy," *Geosciences (Basel)*, vol. 10, p. 105, 2020.
- [17] F. Ayuningtyas and S. Y. J. Prasetyo, "Pemanfaatan Teknologi Machine Learning Untuk Klasifikasi Wilayah Risiko Kekeringan di Daerah Istimewa Yogyakarta Menggunakan Citra Landsat 8 Operational Land Imager (OLI)," *Jurnal Transformatika*, vol. 18, no. 1, p. 13, 2020, doi: [10.26623/transformatika.v18i1.2140](https://doi.org/10.26623/transformatika.v18i1.2140).
- [18] V. No, A. Syahreza, N. K. Ningrum, and M. A. Syahrazy, "Perbandingan Kinerja Model Prediksi Cuaca: *Random Forest*, Support Vector Regression, dan *XGBoost*," *Edumatic : Jurnal Pendidikan Informatika*, vol. 8, no. 2, pp. 526–534, 2024, doi: [10.29408/edumatic.v8i2.27640](https://doi.org/10.29408/edumatic.v8i2.27640).
- [19] G. Nathaniel, "Penerapan Framework Flask sebagai API Dalam Pengembangan Website Prediksi Kebakaran Hutan dan Lahan di Indonesia," *e-Proceeding of Engineering*, vol. 11, no. 6, pp. 6843–6847, 2024.

- [20] H. Nisya, C. Setianingsih, and W. Harjupa, "Prediksi Curah Hujan Dari Data Satelit Himawari-8 Menggunakan Metode K-Nearest Neighbor (KNN)," *e-Proceeding of Engineering*, vol. 10, no. 1, pp. 729–735, 2023, [Online]. Available: <https://sharaku.eorc.jaxa.jp/GSMaP/>
- [21] T. Yiu, "Understanding *Random Forest*: How The Algorithm Works and Why It Is So Effective," <https://towardsdatascience.com/understanding-random-forest>. Accessed: Mar. 30, 2025. [Online]. Available: <https://towardsdatascience.com/understanding-random-forest>
- [22] C. Browne et al., "Multivariate *Random Forest* prediction of poverty and malnutrition prevalence," *PLoS One*, vol. 16, no. 9 September, pp. 1–23, 2021, doi: 10.1371/journal.pone.0255519.
- [23] G. Fibarkah, M. A. Tondang, N. W. Yulistyaningrum, and M. Afrad, "Prediksi Curah Hujan di Kabupaten Rembang dengan Model *Random Forest*," *Conference on Electrical Engineering, Informatics, Industrial Technology, and Creative*, no. M1, pp. 863–871, 2024.
- [24] A. N. Salim and T. Sutabri, "Klasifikasi Cyberbullying Pada Komentar Video Youtube Menggunakan Metode *Random Forest*," *Jursima*, vol. 11, no. 2, pp. 313–323, 2023, doi: 10.47024/js.v11i2.615.
- [25] L. Rahmawati, D. Fitria, and R. Harahap, "Prediksi Curah Hujan Bulanan Menggunakan *Random Forest*: Studi Kasus di Jawa Barat.," *Jurnal Sains Data dan Analitika*, vol. 5, no. 1, pp. 45–54, 2021.
- [26] D. Kusuma and A. Nugroho, "Perbandingan Metode *Random Forest* dan Regresi Linier dalam Prediksi Curah Hujan di Kalimantan," *Jurnal Ilmu Komputer dan Meteorologi*, vol. 10, no. 277–86, 2022.
- [27] M. A. Ganaie, M. Hu, A. K. Malik, M. Tanveer, and P. N. Suganthan, "Ensemble deep learning: A review," *Eng Appl Artif Intell*, vol. 115, no. August, 2022, doi: 10.1016/j.engappai.2022.105151.
- [28] R. Ardhitha, R. Anugerah, and T. Sutabri, "Analisis Penerapan Machine Learning dan Algoritma Anomali untuk Deteksi Penipuan pada Transaksi Digital," *Repeater: Publikasi Teknik Informatika*, no. 1, pp. 80–90, 2025.
- [29] M. Ding et al., "Optical coherence tomography for identification of malignant pulmonary nodules based on *Random Forest* machine learning algorithm," *PLoS One*, vol. 16, no. 12 December, pp. 1–15, 2021, doi: 10.1371/journal.pone.0260600.