

Analisis Kontribusi Sensor IoT pada Deteksi Kebakaran Lahan Gambut Menggunakan Random Forest dan SHAP

Hirzen Hasfani*, Kartika Sari, Rahmi Hidayati

Fakultas Matematika dan Ilmu Pengetahuan Alam, Rekayasa Sistem Komputer, Universitas Tanjungpura, Pontianak
Jl. Profesor Dokter H. Hadari Nawawi, Bansir Laut, Kec. Pontianak Tenggara, Kota Pontianak, Kalimantan Barat, Indonesia
Email: ^{1,*}hirzen.hasfani@siskom.untan.ac.id, ²kartika.sari@siskom.untan.ac.id, ³rahmihidayati@siskom.untan.ac.id

Email Penulis Korespondensi: hirzen.hasfani@siskom.untan.ac.id

Submitted: 29/06/2026; Accepted: 18/07/2026; Published: 20/07/2026

Abstrak—Kebakaran lahan gambut merupakan bencana yang berdampak terhadap lingkungan, kesehatan, dan aktivitas sosial ekonomi. Deteksi dini berbasis Internet of Things (IoT) menjadi salah satu solusi untuk memantau kondisi lingkungan secara real-time menggunakan berbagai sensor. Namun, kontribusi setiap sensor terhadap proses deteksi belum diketahui secara jelas. Penelitian ini bertujuan menganalisis kontribusi multi sensor pada sistem deteksi kebakaran lahan gambut berbasis IoT menggunakan algoritma Random Forest (RF). Dataset terdiri atas 2.000 data primer yang diperoleh dari sensor AMG8833, MAX6677, MQ-2, DHT22, dan Water Float. Model dilatih menggunakan data primer dan diuji menggunakan data uji yang merepresentasikan kondisi transisi (overlap) antara keadaan normal dan kebakaran. Kinerja model dievaluasi menggunakan accuracy, precision, recall, F1-score, dan confusion matrix, sedangkan kontribusi setiap sensor dianalisis menggunakan Feature Importance dan divalidasi dengan SHapley Additive exPlanations (SHAP). Hasil penelitian menunjukkan model RF memperoleh accuracy 87,50%, precision 100,00%, recall 75,00%, dan F1-score 85,71%. Analisis Feature Importance dan SHAP menunjukkan bahwa DHT22 (kelembapan dan suhu) merupakan sensor dengan kontribusi terbesar, diikuti MAX6677, MQ-2, AMG8833, dan Water Float. Hasil ini menunjukkan bahwa parameter suhu dan kelembapan menjadi indikator utama dalam deteksi kebakaran lahan gambut serta dapat menjadi dasar dalam pengembangan sistem deteksi berbasis IoT.

Kata Kunci: Internet of Things; Kebakaran Lahan Gambut; Random Forest; Feature Importance; SHAP

Abstract—Peatland fires are disasters that impact the environment, health, and socio economic activities. Internet of Things (IoT) based early detection enables real-time monitoring of environmental conditions through various sensors. However, the specific contribution of each sensor to the detection process remains unclear. This study aims to analyze the contribution of multiple sensors within an IoT-based peatland fire detection system using the Random Forest (RF) algorithm. The dataset comprises 2,000 primary data points obtained from AMG8833, MAX6677, MQ-2, DHT22, and Water Float sensors. The model was trained on the primary data and tested against data representing transitional (overlapping) conditions between normal states and fire events. Model performance was evaluated using accuracy, precision, recall, F1-score, and a confusion matrix, while sensor contributions were analyzed via Feature Importance and validated using SHapley Additive exPlanations (SHAP). The results indicate that the RF model achieved an accuracy of 87.50%, precision of 100.00%, recall of 75.00%, and an F1-score of 85.71%. Feature Importance and SHAP analyses revealed that the DHT22 sensor (measuring humidity and temperature) made the most significant contribution, followed by the MAX6677, MQ-2, AMG8833, and Water Float sensors. These findings demonstrate that temperature and humidity serve as key indicators for peatland fire detection and provide a foundation for developing IoT-based detection systems.

Keywords: Internet of Things; Peatland Fires; Random Forest; Feature Importance; SHAP

1. PENDAHULUAN

Lahan gambut merupakan salah satu ekosistem penting yang memiliki fungsi ekologis sebagai penyimpan karbon, pengatur tata air, serta habitat bagi berbagai jenis flora dan fauna [1]-[3]. Indonesia memiliki kawasan lahan gambut yang cukup luas sehingga keberadaannya berperan penting dalam menjaga keseimbangan lingkungan [4]. Namun, pada musim kemarau atau ketika muka air tanah mengalami penurunan, lahan gambut menjadi sangat rentan terhadap kebakaran [5]-[7]. Berbeda dengan kebakaran pada lahan mineral, kebakaran lahan gambut dapat merambat hingga ke lapisan bawah permukaan (ground fire), sehingga lebih sulit dideteksi, dipadamkan, dan berpotensi berlangsung dalam waktu yang lama [8]-[10]. Kondisi tersebut menyebabkan kebakaran lahan gambut sering menimbulkan kabut asap yang berdampak terhadap kualitas udara, kesehatan masyarakat, aktivitas ekonomi, serta kerusakan ekosistem [11]-[13]. Oleh karena itu, sistem deteksi dini yang mampu mengidentifikasi perubahan kondisi lingkungan sebelum kebakaran berkembang menjadi sangat penting untuk mendukung upaya mitigasi bencana.

Perkembangan teknologi Internet of Things (IoT) telah memberikan peluang dalam membangun sistem pemantauan lingkungan secara real-time [14]. Melalui teknologi IoT, berbagai sensor dapat diintegrasikan untuk mengamati kondisi lingkungan secara berkelanjutan dan mengirimkan data secara otomatis ke pusat pemrosesan [15]. Pada sistem deteksi kebakaran lahan gambut, penggunaan pendekatan multi sensor mampu memberikan informasi yang lebih komprehensif dibandingkan penggunaan satu sensor saja. Sensor suhu dapat mendeteksi peningkatan temperatur, sensor gas mampu mengidentifikasi gas hasil pembakaran, sensor kelembapan memberikan informasi mengenai kondisi udara, sedangkan sensor tinggi muka air digunakan untuk memantau kondisi hidrologi lahan gambut [16]-[19]. Integrasi berbagai parameter tersebut memungkinkan sistem memperoleh gambaran kondisi lingkungan secara lebih menyeluruh sehingga meningkatkan kemampuan dalam mendeteksi potensi kebakaran. Salah satu parameter yang memiliki peranan penting pada lahan gambut adalah

tinggi muka air tanah (groundwater level) [20]. Penurunan muka air tanah menyebabkan lapisan gambut kehilangan kelembapan sehingga lebih mudah mengering dan terbakar. Oleh karena itu, pada penelitian ini digunakan sensor Water Float yang ditempatkan pada sumur resapan untuk memantau perubahan tinggi muka air sebagai indikator kondisi hidrologi lahan gambut. Informasi tersebut digunakan sebagai parameter pendukung bersama sensor termal AMG8833, sensor suhu MAX6677, sensor gas MQ-2, serta sensor suhu dan kelembapan DHT22. Kombinasi kelima sensor diharapkan mampu memberikan informasi yang lebih representatif mengenai kondisi lingkungan dibandingkan apabila hanya mengandalkan satu jenis sensor.

Seiring berkembangnya teknologi IoT, penerapan Machine Learning pada sistem deteksi kebakaran juga semakin banyak dilakukan. Machine Learning memungkinkan komputer mempelajari pola hubungan antarparameter sensor sehingga mampu membedakan kondisi normal dan kondisi kebakaran secara otomatis [21]. Berbagai algoritma telah digunakan pada penelitian sebelumnya, seperti Decision Tree, Support Vector Machine, K-Nearest Neighbor, Naive Bayes, dan Random Forest. Sebagian besar penelitian menunjukkan bahwa algoritma Machine Learning mampu meningkatkan akurasi deteksi dibandingkan metode konvensional berbasis nilai ambang (threshold). Namun demikian, fokus penelitian umumnya masih terbatas pada peningkatan performa klasifikasi melalui pengukuran accuracy, precision, recall, dan F1-score, sedangkan analisis mengenai kontribusi masing-masing sensor terhadap performa model masih relatif terbatas.

Padahal, pada sistem berbasis multi sensor, setiap sensor memiliki karakteristik dan sensitivitas yang berbeda terhadap perubahan kondisi lingkungan. Sensor tertentu mungkin memberikan kontribusi yang sangat besar terhadap proses klasifikasi, sedangkan sensor lainnya hanya memberikan tambahan informasi yang relatif kecil. Penggunaan seluruh sensor secara bersamaan belum tentu menghasilkan konfigurasi sistem yang paling efisien karena adanya kemungkinan informasi yang bersifat redundan. Analisis kontribusi sensor menjadi penting untuk mengetahui sensor mana yang benar-benar memberikan pengaruh terhadap performa model. Informasi tersebut dapat digunakan sebagai dasar dalam merancang sistem deteksi kebakaran yang lebih sederhana, hemat biaya, memiliki konsumsi daya yang lebih rendah, namun tetap mempertahankan tingkat akurasi yang tinggi.

Analisis kontribusi sensor menjadi salah satu aspek penting dalam pengembangan sistem deteksi kebakaran lahan gambut berbasis Internet of Things. Informasi mengenai tingkat kepentingan masing-masing sensor dapat digunakan sebagai dasar dalam menentukan konfigurasi sensor yang lebih efisien sehingga mampu menekan biaya implementasi, mengurangi konsumsi daya, serta menyederhanakan kompleksitas sistem tanpa menurunkan kemampuan deteksi secara signifikan. Salah satu pendekatan yang umum digunakan untuk mengukur kontribusi fitur pada model berbasis pohon keputusan adalah Feature Importance pada algoritma Random Forest. Random Forest dipilih karena mampu menghasilkan performa klasifikasi yang stabil pada dataset multisensor berukuran kecil. Pada penelitian ini, algoritma Random Forest juga tidak memerlukan hyperparameter tuning, dikarenakan tidak efektif untuk situasi dataset yang kecil [22]. Algoritma ini menghitung tingkat kepentingan setiap fitur berdasarkan besarnya penurunan nilai Gini Impurity selama proses pembentukan pohon keputusan. Semakin besar nilai Feature Importance, semakin besar pula kontribusi sensor terhadap proses klasifikasi [23].

Meskipun demikian, hasil Feature Importance masih perlu divalidasi untuk memastikan bahwa peringkat kontribusi yang diperoleh benar-benar mencerminkan pengaruh masing-masing sensor terhadap keputusan model. Oleh karena itu, penelitian ini menggunakan SHapley Additive exPlanations (SHAP) sebagai metode validasi. SHAP merupakan salah satu metode dalam Explainable Artificial Intelligence (XAI) yang mampu menjelaskan kontribusi setiap fitur terhadap keputusan model berdasarkan konsep nilai Shapley dalam teori permainan [24]. Dengan membandingkan hasil Feature Importance dan SHAP, penelitian ini dapat mengevaluasi konsistensi tingkat kepentingan setiap sensor sehingga interpretasi yang dihasilkan menjadi lebih dapat dipercaya.


Berdasarkan permasalahan tersebut, penelitian ini mengusulkan Analisis Kontribusi Multi Sensor pada Sistem Deteksi Kebakaran Lahan Gambut Berbasis Internet of Things Menggunakan Random Forest. Penelitian menggunakan dataset primer sebanyak 2.000 data yang diperoleh dari lima sensor, yaitu AMG8833, MAX6677, MQ-2, DHT22, dan Water Float. Random Forest digunakan sebagai model Machine Learning untuk membangun sistem deteksi kebakaran, sedangkan Permutation Importance digunakan untuk menghitung tingkat kontribusi masing-masing sensor. Selanjutnya, hasil analisis divalidasi menggunakan SHAP untuk memvalidasi model Importance Feature. Kontribusi utama penelitian ini adalah menyajikan analisis komprehensif mengenai kontribusi setiap sensor terhadap sistem deteksi kebakaran lahan gambut berbasis IoT. Selain mengevaluasi performa model Random Forest, penelitian ini menghasilkan peringkat kontribusi sensor serta rekomendasi konfigurasi sensor yang lebih efisien untuk mendukung pengembangan sistem deteksi kebakaran lahan gambut yang memiliki akurasi tinggi, konsumsi daya rendah, dan biaya implementasi yang lebih optimal.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan yang sistematis, dimulai dari proses pengumpulan data, preprocessing, pembangunan model menggunakan algoritma Random Forest, evaluasi performa model, analisis kontribusi sensor menggunakan Feature Importance Random Forest, hingga validasi hasil melalui Metode SHAP. Tahapan penelitian bertujuan untuk mengetahui kontribusi masing-masing sensor terhadap performa sistem

deteksi kebakaran lahan gambut berbasis Internet of Things (IoT). Tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alir Tahapan Penelitian

2.2 Pengumpulan Data

Data primer dikumpulkan secara langsung pada lahan gambut selama tiga hari pengamatan pada musim kemarau dengan kondisi cuaca cerah hingga sesekali hujan. Selama periode pengambilan data, tinggi muka air tanah (groundwater level) berada pada kondisi lebih dari 80 cm di bawah permukaan tanah, sehingga kondisi lahan relatif stabil dan tidak menunjukkan variasi parameter lingkungan yang signifikan. Pengukuran dilakukan menggunakan lima sensor, yaitu AMG8833, MAX6677, MQ-2, DHT22, dan Water Float, yang merekam parameter suhu, kelembapan, konsentrasi gas, serta kondisi muka air tanah secara berkala. Dari proses tersebut diperoleh 2.000 data primer yang terdiri atas kondisi tidak terjadi kebakaran dan terjadi kebakaran.

Untuk memperoleh variasi data yang lebih representatif terhadap berbagai kondisi operasional di lapangan, pengambilan data dilakukan melalui skenario pengujian terkontrol. Selain kondisi normal, dilakukan simulasi peningkatan temperatur menggunakan sumber panas, simulasi keberadaan api sebagai representasi kejadian kebakaran, serta simulasi perubahan tinggi muka air tanah untuk menggambarkan perubahan kondisi hidrologi lahan gambut. Skenario tersebut bertujuan menghasilkan variasi data yang mencerminkan perubahan lingkungan secara bertahap sehingga model mampu mempelajari karakteristik kondisi normal maupun kebakaran secara lebih komprehensif.

2.3 Preprocessing Data

Tahap preprocessing bertujuan untuk meningkatkan kualitas dataset sebelum digunakan dalam proses pembelajaran model. Tahapan preprocessing meliputi:

- pemeriksaan data kosong (missing value);
- pemeriksaan nilai yang tidak valid (invalid value);
- penghapusan data duplikat apabila ditemukan;
- pelabelan kelas menjadi 0 (Tidak Ada Api) dan 1 (Ada Api);
- penyusunan dataset ke dalam format numerik.

Selanjutnya dilakukan pembagian dataset menjadi data latih dan data uji dengan komposisi 70% data latih dan 30% data uji.

2.4 Random Forest

Model klasifikasi dibangun menggunakan algoritma Random Forest, yaitu metode ensemble learning yang membentuk sejumlah pohon keputusan (decision tree) kemudian menggabungkan hasil prediksi setiap pohon menggunakan mekanisme majority voting [25]. Pada Random Forest, pemilihan atribut terbaik dilakukan menggunakan nilai Gini Impurity yang dirumuskan sebagai [26]:

$$\text{Gini}(N) = 1 - \sum_{i=1}^K p_i^2 \quad (1)$$

Gini merupakan nilai Gini Impurity adalah nilai Pemisahan Node pada setiap Pohon Keputusan. Simbol N menyatakan jumlah observasi atau sampel yang terdapat pada suatu node, K menyatakan jumlah kelas yang digunakan dalam proses klasifikasi, sedangkan p_i merupakan proporsi data yang termasuk ke dalam kelas ke- i pada node tersebut. Nilai-nilai tersebut digunakan untuk menghitung Gini Impurity sebagai dasar dalam menentukan pemisahan node terbaik selama proses pembentukan pohon keputusan pada algoritma Random Forest. Nilai Gini digunakan sebagai dasar dalam menentukan pemisahan node pada setiap pohon keputusan. Semakin kecil nilai Gini, semakin baik atribut tersebut dalam memisahkan kelas. Setelah seluruh pohon terbentuk, hasil prediksi akhir diperoleh berdasarkan kelas yang paling banyak dipilih oleh seluruh pohon keputusan.

2.5 Evaluasi Model

Evaluasi model dilakukan menggunakan data uji untuk mengetahui tingkat keberhasilan model dalam mendeteksi kondisi kebakaran. Parameter evaluasi yang digunakan meliputi accuracy, precision, recall, dan F1-score. Accuracy digunakan untuk mengukur persentase prediksi yang benar terhadap seluruh data uji, sedangkan precision menunjukkan ketepatan model. Recall digunakan untuk mengukur kemampuan model mendeteksi seluruh kejadian kebakaran yang sebenarnya, sementara F1-score memberikan nilai keseimbangan antara precision dan recall [27]. Selain itu, digunakan confusion matrix untuk mengetahui jumlah prediksi benar maupun salah pada masing-masing kelas, sehingga dapat dianalisis tingkat kesalahan klasifikasi yang dihasilkan.

2.6 Analisis Kontribusi Sensor menggunakan Random Forest Feature Importance

Analisis kontribusi sensor pada penelitian ini dilakukan menggunakan Feature Importance yang merupakan metode bawaan dari algoritma Random Forest. Metode ini mengukur tingkat kepentingan setiap sensor berdasarkan besarnya penurunan nilai Gini Impurity yang dihasilkan ketika suatu fitur digunakan sebagai pemisah (split) pada seluruh pohon keputusan. Sensor yang menghasilkan penurunan impurity lebih besar akan memperoleh nilai Feature Importance yang lebih tinggi sehingga dianggap memiliki kontribusi yang lebih besar terhadap proses klasifikasi. Nilai Feature Importance dihitung menggunakan persamaan berikut [28] :

$$\text{MDI}(k, F) = \frac{1}{|F|} \sum_{T \in F} \text{MDI}(k, T) \quad (2)$$

$\text{MDI}(k, F)$ adalah nilai Feature Importance (Mean Decrease Impurity) fitur ke- k pada seluruh Random Forest. Kemudian nilai $|F|$ merupakan Jumlah pohon (decision tree) dalam Random Forest. Sedangkan T = Jumlah pohon keputusan (decision tree). $\text{MDI}(k, T)$ = nilai Feature Importance fitur ke- k pada satu pohon keputusan. Semakin besar nilai Feature Importance, semakin besar kontribusi sensor terhadap proses klasifikasi. Selanjutnya, seluruh sensor diurutkan berdasarkan nilai Feature Importance untuk memperoleh peringkat kontribusi masing-masing sensor.

2.7 Validasi Menggunakan SHAP

Analisis kontribusi sensor pada penelitian ini dilakukan menggunakan SHapley Additive exPlanations (SHAP). SHAP merupakan metode interpretasi model Machine Learning yang didasarkan pada konsep Shapley Value dalam teori permainan (cooperative game theory). Setiap sensor diperlakukan sebagai "pemain" yang memberikan kontribusi terhadap keputusan model Random Forest. Nilai SHAP menunjukkan besarnya pengaruh masing-masing sensor terhadap hasil prediksi sehingga dapat diketahui sensor mana yang memiliki kontribusi terbesar maupun terkecil dalam proses deteksi kebakaran lahan gambut. Setelah model Random Forest selesai dilatih menggunakan seluruh data latih, dilakukan proses interpretasi menggunakan TreeExplainer, yaitu algoritma SHAP yang dirancang khusus untuk model berbasis pohon keputusan. Nilai SHAP dihitung untuk setiap fitur pada seluruh data uji, kemudian dirata-ratakan menggunakan nilai absolut (Mean Absolute SHAP Value) sehingga diperoleh tingkat kepentingan masing-masing sensor [29]. Nilai rata-rata SHAP dihitung menggunakan persamaan berikut [30] :

$$\text{Importance}_j = \frac{1}{N} \sum_{i=1}^N |\phi_{i,j}| \quad (3)$$

Nilai Importance_j adalah kontribusi rata-rata sensor ke- j . Kemudian nilai N merupakan jumlah data yang akan diuji. Nilai $\phi_{i,j}$ merupakan nilai SHAP sensor ke- j pada data ke- i . Semakin besar nilai Mean Absolute SHAP, semakin besar kontribusi sensor tersebut terhadap keputusan model Random Forest.

3. HASIL DAN PEMBAHASAN

3.1 Dataset

Dataset yang digunakan merupakan data primer yang diperoleh dari sistem deteksi kebakaran lahan gambut berbasis Internet of Things. Pengambilan data dilakukan pada area penelitian yang dilengkapi dengan sumur resapan sebagai lokasi pemantauan tinggi muka air tanah gambut. Sistem terdiri atas lima sensor yaitu sensor AMG8833, MAX6677, MQ-2, DHT22, dan Water Float.

Sensor AMG8833 digunakan sebagai sensor termal untuk mendeteksi distribusi suhu permukaan sehingga dapat mengidentifikasi adanya area dengan temperatur yang lebih tinggi. Sensor MAX6677 digunakan sebagai sensor suhu untuk mengukur temperatur lingkungan. Sensor MQ-2 sebagai sensor gas yang mendeteksi gas hasil pembakaran. Selain itu, sensor DHT22 sebagai sensor suhu dan kelembapan udara di sekitar area pemantauan. Sementara itu, sensor Water Float sebagai sensor tinggi muka air pada sumur resapan yang digunakan untuk memantau kondisi hidrologi lahan gambut.

Dataset yang telah diperoleh selanjutnya dibagi menjadi 1.400 data latih (70%) dan 600 data uji (30%) Proporsi 70:30 dipilih untuk memberikan jumlah data yang memadai pada proses pelatihan sekaligus menyediakan data uji yang cukup untuk mengevaluasi kemampuan generalisasi model.


3.2 Performa Random Forest

Model Random Forest yang dibangun menggunakan data hasil pembacaan lima sensor, yaitu AMG8833, MAX6677, MQ-2, DHT22, dan Water Float, dievaluasi menggunakan empat parameter utama, yaitu accuracy, precision, recall, dan F1-score. Hasil evaluasi model disajikan pada Tabel 1.

Tabel 1. Performa Random Forest

Metric	Nilai (%)
Accuracy	87,5
Precision	100
Recall	75
F1-Score	85,71

Berdasarkan Tabel 1, model Random Forest memperoleh nilai accuracy sebesar 100,00%, yang menunjukkan bahwa seluruh data uji berhasil diklasifikasikan dengan benar ke dalam kelas Ada Api maupun Tidak Ada Api. Hasil ini menunjukkan bahwa model mampu mengenali pola yang terbentuk dari kombinasi data multi sensor secara sangat baik sehingga tidak ditemukan kesalahan klasifikasi pada data pengujian. Hasil tersebut menunjukkan bahwa kombinasi data yang diperoleh dari sensor AMG8833, MAX6677, MQ-2, DHT22, dan Water Float mampu membentuk karakteristik yang jelas antara kondisi Ada Api dan Tidak Ada Api. Random Forest dapat memanfaatkan hubungan antarparameter sensor untuk menghasilkan batas keputusan (decision boundary) yang mampu memisahkan kedua kelas secara sempurna pada dataset penelitian ini.



Gambar 2. Confusion Matriks

Berdasarkan Gambar 2, model Random Forest berhasil mengklasifikasikan seluruh data uji dengan benar. Sebanyak 300 data pada kelas Tidak Ada Api berhasil dikenali dengan tepat sebagai kondisi Tidak Ada Api (True Negative), sedangkan 225 data pada kelas Ada Api berhasil diprediksi dengan benar sebagai kondisi Ada Api (True Positive). Selain itu, tidak ditemukan data yang salah diklasifikasikan ke kelas lain, sehingga nilai False Positive (FP) dan False Negative (FN) sama-sama bernilai 0.

3.3 Hasil Penggunaan Feature Importance Random Forest

Untuk mengetahui tingkat kontribusi masing-masing sensor terhadap proses deteksi kebakaran lahan gambut, penelitian ini menggunakan Feature Importance yang merupakan metode bawaan dari algoritma Random Forest. Nilai Feature Importance dihitung berdasarkan besarnya penurunan Gini Impurity yang dihasilkan oleh setiap sensor selama proses pembentukan pohon keputusan. Semakin besar nilai Feature Importance, semakin besar kontribusi sensor tersebut dalam membedakan kondisi Ada Api dan Tidak Ada Api. Tabel ranking analisis penggunaan sensor dapat dilihat pada Tabel 2.

Tabel 2. Penggunaan Feature Importance Random Forest

Ranking	Sensor	Feature Importance
1	DHT22 (Kelembapan)	0,3155
2	DHT22 (Suhu)	0,2903
3	MAX6677	0,2617
4	MQ-2	0,1171
5	AMG8833	0,0154
6	Water Float	0,0000

Berdasarkan Tabel 2, sensor DHT22 memiliki kontribusi terbesar terhadap model Random Forest, baik pada parameter kelembapan maupun suhu. Hal ini menunjukkan bahwa perubahan suhu dan kelembapan merupakan indikator utama yang digunakan model dalam membedakan kondisi Ada Api dan Tidak Ada Api. Sensor MAX6677 juga memberikan kontribusi yang tinggi karena mampu mendeteksi perubahan temperatur secara akurat.

Sensor MQ-2 berperan sebagai sensor pendukung melalui informasi konsentrasi gas hasil pembakaran, sedangkan AMG8833 memiliki kontribusi yang relatif kecil karena informasi suhu yang dihasilkan telah banyak direpresentasikan oleh sensor suhu lainnya. Sementara itu, Water Float memperoleh nilai Feature Importance paling rendah karena parameter tinggi muka air tanah tidak berpengaruh secara langsung terhadap klasifikasi kebakaran pada dataset penelitian, tetapi tetap bermanfaat untuk memantau kondisi hidrologi lahan gambut.

Secara keseluruhan, hasil Feature Importance menunjukkan bahwa sensor suhu dan kelembapan merupakan sensor yang paling berpengaruh dalam sistem deteksi kebakaran lahan gambut, sedangkan MQ-2, AMG8833, dan Water Float berfungsi sebagai sensor pendukung dengan tingkat kontribusi yang lebih rendah.

3.4 Hasil Validasi menggunakan Metode SHAP

Untuk mengetahui tingkat kontribusi masing-masing sensor terhadap keputusan model Random Forest, penelitian ini menggunakan metode SHapley Additive exPlanations (SHAP). Nilai SHAP dihitung menggunakan TreeExplainer, kemudian dirata-ratakan menggunakan Mean Absolute SHAP Value sehingga diperoleh tingkat kepentingan setiap sensor terhadap proses klasifikasi. Semakin besar nilai Mean Absolute SHAP, semakin besar kontribusi sensor tersebut dalam membantu model membedakan kondisi Ada Api dan Tidak Ada Api. Tabel validasi penggunaan metode SHAP dapat dilihat pada Tabel 3.

Tabel 3. Tabel Perankingan menggunakan Metode SHAP

Ranking	Sensor	Mean (SHAP)
1	DHT22 (Kelembapan)	0,1629
2	DHT22 (Suhu)	0,1472
3	MAX6677	0,1384
4	MQ-2	0,0461
5	AMG8833	0,0170
6	Water Float	0,0000

Berdasarkan Tabel 3, sensor DHT22 memiliki kontribusi terbesar terhadap keputusan model, baik pada parameter kelembapan maupun suhu. Hal ini menunjukkan bahwa perubahan suhu dan kelembapan merupakan indikator utama yang digunakan Random Forest dalam membedakan kondisi Ada Api dan Tidak Ada Api. Sensor MAX6677 juga memberikan kontribusi yang tinggi karena mampu mendeteksi perubahan temperatur secara akurat. Sensor MQ-2 memiliki kontribusi yang lebih rendah dibandingkan sensor suhu, namun tetap berperan dalam mendukung proses klasifikasi melalui informasi konsentrasi gas hasil pembakaran. Sementara itu, AMG8833 memberikan kontribusi yang relatif kecil karena informasi suhu yang dihasilkan memiliki kemiripan dengan sensor MAX6677.

Sensor Water Float memperoleh nilai SHAP paling rendah. Hal ini menunjukkan bahwa tinggi muka air tanah tidak berpengaruh langsung terhadap klasifikasi kondisi kebakaran pada dataset penelitian. Namun demikian, sensor ini tetap penting sebagai indikator kondisi hidrologi lahan gambut yang dapat digunakan untuk mendukung pemantauan tingkat kekeringan dan potensi kerawanan kebakaran. Secara keseluruhan, hasil SHAP menunjukkan bahwa sensor yang mengukur suhu dan kelembapan memberikan kontribusi terbesar terhadap model Random Forest, sedangkan sensor Water Float lebih berfungsi sebagai parameter pendukung dalam sistem pemantauan kebakaran lahan gambut.

3.5 Pembahasan

Hasil penelitian menunjukkan bahwa algoritma Random Forest mampu mengklasifikasikan kondisi Ada Api dan Tidak Ada Api dengan performa yang baik. Berdasarkan hasil pengujian, model memperoleh nilai accuracy sebesar 87,50%, precision sebesar 100,00%, recall sebesar 75,00%, dan F1-score sebesar 85,71%. Nilai accuracy menunjukkan bahwa sebagian besar data uji berhasil diklasifikasikan dengan benar, sedangkan nilai precision sebesar 100,00% mengindikasikan bahwa seluruh data yang diprediksi sebagai Ada Api merupakan kondisi

kebakaran yang benar. Sementara itu, nilai recall sebesar 75,00% menunjukkan bahwa masih terdapat sebagian kondisi kebakaran yang belum berhasil dikenali oleh model, terutama pada data yang memiliki karakteristik mendekati kondisi normal.

Hasil tersebut diperkuat oleh confusion matrix, yang menunjukkan bahwa seluruh 300 data Tidak Ada Api berhasil diklasifikasikan dengan benar sebagai True Negative, tanpa menghasilkan False Positive. Pada kelas Ada Api, sebanyak 225 data berhasil dikenali sebagai True Positive, sedangkan 75 data diklasifikasikan sebagai False Negative. Tidak ditemukannya False Positive menunjukkan bahwa model memiliki tingkat kepercayaan yang tinggi ketika mendeteksi kebakaran. Namun demikian, keberadaan False Negative mengindikasikan bahwa beberapa sampel kebakaran, khususnya yang berada pada kondisi transisi (overlap), masih memiliki karakteristik sensor yang menyerupai kondisi normal sehingga belum seluruhnya dapat dibedakan oleh model. Kondisi ini lebih mencerminkan situasi operasional di lapangan dibandingkan dataset dengan pemisahan kelas yang sempurna.

Analisis kontribusi sensor menggunakan Feature Importance Random Forest menunjukkan bahwa sensor DHT22 (kelembapan), DHT22 (suhu), dan MAX6677 merupakan sensor yang memiliki kontribusi terbesar terhadap proses klasifikasi. Hasil ini mengindikasikan bahwa perubahan suhu dan kelembapan merupakan indikator utama dalam mendeteksi kebakaran lahan gambut. Sebaliknya, sensor AMG8833 dan Water Float memiliki kontribusi yang relatif rendah karena informasi yang diberikan sebagian telah direpresentasikan oleh sensor lain atau berfungsi sebagai parameter pendukung.

Untuk memvalidasi hasil tersebut, dilakukan analisis menggunakan SHAP. Hasil SHAP menunjukkan urutan kontribusi sensor yang sama dengan Feature Importance Random Forest, yaitu DHT22, MAX6677, MQ-2, AMG8833, dan Water Float. Konsistensi kedua metode menunjukkan bahwa sensor dengan nilai Feature Importance tinggi juga memiliki kontribusi yang besar terhadap keputusan model. Dengan demikian, hasil analisis kontribusi sensor dapat dianggap konsisten dan dapat dipercaya, sehingga memberikan dasar yang kuat dalam menentukan konfigurasi sensor yang lebih efisien untuk sistem deteksi kebakaran lahan gambut berbasis Internet of Things. Hasil Perbandingan Feature Importance Random Forest dan SHAP dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan Feature Importance Random Forest dan SHAP


Ranking	Feature Importance	Nilai	Ranking	SHAP	Nilai	Hasil Ranking
1	DHT22 (Kelembapan)	0,3155	1	DHT22 (Kelembapan)	0,1629	Sama
2	DHT22 (Suhu)	0,2903	2	DHT22 (Suhu)	0,1472	Sama
3	MAX6677	0,2617	3	MAX6677	0,1384	Sama
4	MQ-2	0,1171	4	MQ-2	0,0461	Sama
5	AMG8833	0,0154	5	AMG8833	0,0170	Sama
6	Water Float	0,0000	6	Water Float	0,0000	Sama

4. KESIMPULAN

Penelitian ini berhasil menganalisis kontribusi sensor pada sistem deteksi kebakaran lahan gambut berbasis Internet of Things (IoT) menggunakan algoritma Random Forest. Berdasarkan hasil pengujian, model memperoleh accuracy sebesar 87,50%, precision sebesar 100,00%, recall sebesar 75,00%, dan F1-score sebesar 85,71%, yang menunjukkan bahwa model mampu mengidentifikasi kondisi kebakaran dengan baik meskipun masih terdapat beberapa kondisi transisi yang diklasifikasikan sebagai False Negative. Analisis menggunakan Feature Importance yang divalidasi oleh SHAP menunjukkan hasil yang konsisten, yaitu sensor DHT22 (kelembapan), DHT22 (suhu), dan MAX6677 merupakan sensor yang memberikan kontribusi terbesar terhadap proses klasifikasi, diikuti oleh MQ-2, sedangkan AMG8833 dan Water Float memberikan kontribusi yang relatif rendah pada dataset penelitian ini. Berdasarkan hasil tersebut, konfigurasi sensor untuk sistem deteksi ini dapat diprioritaskan pada DHT22, MAX6677, dan MQ-2, karena ketiga sensor tersebut telah mampu merepresentasikan perubahan suhu, kelembapan, dan gas yang menjadi indikator utama kebakaran lahan gambut. Sementara itu, AMG8833 dan Water Float tetap direkomendasikan sebagai sensor pendukung pada implementasi lapangan, terutama untuk meningkatkan keandalan sistem pada kondisi lingkungan yang lebih kompleks atau untuk pemantauan hidrologi lahan gambut. Penelitian ini masih terbatas pada satu lokasi dan periode pengamatan, sehingga penelitian selanjutnya perlu melibatkan berbagai lokasi, musim, dan variasi kondisi lahan gambut, serta melakukan ablation study yaitu penelitian dengan mengurangkan sensor satu per satu untuk menentukan konfigurasi sensor minimum yang tetap mampu mempertahankan performa deteksi secara optimal.

REFERENCES

- [1] S. Tarigan, N. P. Zamani, D. Buchori, and R. Kinseng, "Peatlands Are More Beneficial if Conserved and Restored than Drained for Monoculture Crops," *Front. Environ. Sci.*, vol. 9, no. November, pp. 1–12, 2021, doi: 10.3389/fenvs.2021.749279.
- [2] J. Loisel and A. Gallego-sala, "Ecological resilience of restored peatlands to climate change," *Commun. Earth Environ.*, vol. 3, no. September, pp. 1–8, 2022, doi: 10.1038/s43247-022-00547-x.



- [3] A. P. G. Hognogi and E. Hada, "Bridging Stakeholder Narratives for Sustainable Peatland Conservation," *Earth Syst. Environ.*, pp. 5–7, 2026, doi: <https://doi.org/10.1007/s41748-026-01141-3>.
- [4] M. Yunus, "A critical review of peatland ecosystem services research in Indonesia : Uncovering knowledge gaps and research needs," *J. Bulg. Geogr. Soc.*, vol. 50, pp. 169–190, 2024, doi: 10.3897/jbgs.e117635.
- [5] M. Osaki, N. Tsuji, N. Foad, and J. Rieley, *Tropical Peatland Eco-management*. Singapore: Springer, 2021. doi: <https://doi.org/10.1007/978-981-33-4654-3>.
- [6] B. Kartiwa et al., "Peat Hydrological Properties and Vulnerability to Fire Risk," *MDPI*, vol. 9, no. 1, pp. 1–18, 2026, doi: <https://doi.org/10.3390/fire9010024>.
- [7] J. le Roux et al., *Development Of Management And Rehabilitation Protocols For Peatlands In South Africa : Case Studies Of Peat Fires*. Pretoria: Water Research Commision, 2023.
- [8] M. B. R. Prayoga, M. Karuniasa, and E. Frimawaty, "Peatland wetness as an indicator of fire occurrence in Forest and Land Fires (FLFs)," *J. Earth Kingdom*, vol. 2, no. 1, pp. 62–78, 2024, doi: doi.org/10.61511/jek.v2i1.2024.873.
- [9] S. L. A, Y. L. A, and X. H. A, "How to Build a Firebreak to Stop Smouldering Peat Fire : Insights from a Laboratory-Scale Study," *Int. J. Wildl. Fire*, vol. 30, no. 6, pp. 454–461, 2021, doi: <https://doi.org/10.1071/WF20155>.
- [10] G. Rein and X. Huang, "ScienceDirect Smouldering wildfires in peatlands , forests and the arctic : Challenges and perspectives," *Curr. Opin. Environ. Sci. Heal.*, vol. 24, no. 100296, pp. 1–10, 2021, doi: 10.1016/j.coesh.2021.100296.
- [11] Rosyida and Y. Sopiana, "Dampak Kebakaran Lahan Gambut terhadap Perekonomian Masyarakat di Kecamatan Gambut Kabupaten Banjar," *JIEP J. Ilmu Ekon. dan Pembang.*, vol. 4, no. 2, pp. 463–475, 2021.
- [12] I. P. Anhar, R. Mardiana, and R. Sita, "Dampak Kebakaran Hutan dan Lahan Gambut terhadap Manusia dan Lingkungan Hidup (Studi Kasus : Desa Bunsur , Kecamatan Sungai Apit , Kabupaten Siak , Provinsi Riau) The Impact of Forest and Peatland Fires on Humans and The Environment (Case Study : Villa," *J. Sains Komun. dan Pengemb. Masy.*, vol. 6, no. 1, pp. 75–85, 2022, doi: doi.org/10.29244/jskpm.v6i1.967.
- [13] J. Listari, P. Sudira, R. Ananda, R. F. Saputra, and Fatmawati, "Efek Kebakaran Hutan Terhadap Lingkungan Hidup Dan Sumber Daya Alam Di Pekanbaru," *Sci. J. Ilm. Sains dan Teknol.*, vol. 3, no. 1, pp. 658–671, 2024, [Online]. Available: <https://jurnal.kolibi.org/index.php/scientica/article/view/3896>
- [14] B. Sudrajat, F. R. Doni, and A. M. Lukman, "Pemanfaatan Internet of Things (IoT) dalam Sistem Pemantauan Prediktif Peralatan Industri," *REMIK Ris. Dan E-Jurnal Manaj. Inform. Komput.*, vol. 9, no. 4, pp. 1233–1240, 2025, doi: 10.33395/remik.v9i4.15319.
- [15] D. N. Azizah, S. Heranurweni, L. Ode, and M. Idris, "Internet of Things Based Air Quality Monitoring System with Automatic Notification," *Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 3, pp. 776–787, 2025, doi: <https://doi.org/10.57152/malcom.v5i3.1945>.
- [16] G. Deshpande et al., "IoT- Based Low-Cost Soil Moisture and Soil Temperature Monitoring System," in *ICCUBEA*, 2022, p. 8. doi: <https://doi.org/10.48550/arXiv.2206.07488>.
- [17] H. Liu, R. Y. Chang, Y. Chen, and I. Fu, "Sensor-Based Satellite IoT for Early Wildfire Detection," in *IEEE Globecom Workshops*, Madrid, Spain: IEEE, 2021. doi: 10.1109/GCWkshps52748.2021.9682098.
- [18] J. Waworundeng, "IoT-based Environmental Monitoring with Data Analysis of Temperature , Humidity , and Air Quality," *CogITo Smart J.*, vol. 10, no. 1, pp. 271–284, 2024, [Online]. Available: https://www.researchgate.net/publication/383009320_IoT-based_Environmental_Monitoring_with_Data_Analysis_of_Temperature_Humidity_and_Air_Quality
- [19] S. Usman, R. L. Atimi, M. Anhar, and A. Susanto, "Low-Cost LoRaWAN Solution for Groundwater Monitoring in Peatlands," *J. Inf. Syst. Informatics*, vol. 6, no. 4, pp. 2777–2793, 2024, doi: 10.51519/journalisi.v6i4.923.
- [20] M. Irfan et al., "Peatland Hydro-Climatological Parameters Variability in Response to 2019 – 2022 Climate Anomalies in the OKI Regency," *Atmos. MDPI*, vol. 16, no. 81, pp. 1–15, 2025, doi: <https://doi.org/10.3390/atmos16010081>.
- [21] K. Exaudi et al., "An Improved Forest Fire Detection Model Using Audio Classification and Machine Learning," *Comput. Mater.*, vol. 86, no. 1, pp. 1–24, 2026, doi: 10.32604/cmc.2025.069377.
- [22] S. Han, B. D. Williamson, and Y. Fong, "Improving Random Forest Predictions in Small Datasets From Two-Phase Sampling Designs," *BMC Med. Inform. Decis. Mak.*, vol. 21, no. 322, pp. 1–9, 2021, doi: <https://doi.org/10.1186/s12911-021-01688-3>.
- [23] E. Scornet, Trees, forests, and impurity-based variable importance. *HAL Open Science*, 2021, pp. 1–40. doi: <https://doi.org/10.48550/arXiv.2001.04295>.
- [24] M. Li, H. Sun, Y. Huang, and H. Chen, "Shapley Value: From Cooperative Game to Explainable Artificial Intelligence," *Auton. Intell. Syst.*, vol. 4, no. 2, pp. 1–12, 2025, doi: <https://doi.org/10.1007/s43684-023-00060-8>.
- [25] S. Moslehi, N. Rabiei, A. R. Soltanian, and M. Mamani, "Forest Fire Prediction using Random Forest Shahwan," *Eng. Technol. J.*, vol. 10, no. 5, pp. 5159–5164, 2022, doi: 10.1186/s12911-022-01939-x.
- [26] R. A. Disha and S. Waheed, "Application of machine learning models based on decision trees in classifying the factors affecting mortality of COVID-19 patients in Hamadan, Iran," *BMC Med. Inform. Decis. Mak.*, vol. 22, no. 192, pp. 1–12, 2022.
- [27] R. A. Disha and S. Waheed, "Performance Analysis Of Machine Learning Models For Intrusion Detection System Using Gini Impurity-Based Weighted Random Forest (GIWRF) Feature Selection Technique," *Disha and Waheed Cybersecurity*, vol. 5, no. 1, pp. 1–22, 2022, doi: <https://doi.org/10.1186/s42400-021-00103-8>.
- [28] H. Yi-Xiao, S.-H. Lyu, and Y. Jiang, "Interpreting Deep Forest through Feature Contribution and MDI Feature Importance," *ACM J.*, vol. 20, no. 1, pp. 1–21, 2025, doi: <https://doi.org/10.1145/3641108>.
- [29] A. V. Ponce-Bobadilla, V. Schmitt, C. S. Maier, S. Mensing, and S. Stodtman, "Practical Guide To SHAP Analysis: Explaining Supervised Machine Learning Model Predictions In Drug Development," *Clin. Transl. Sci. Publ.*, vol. 17, no. e70056, pp. 1–15, 2024, doi: 10.1111/cts.70056.
- [30] C. Molnar, *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*, 3rd ed. 2025. [Online]. Available: <https://christophm.github.io/interpretable-ml-book>