

Rekayasa Fitur Multi-Sensor untuk Deteksi Anomali Telemetri UAV Berbasis Machine Learning pada Industri Kreatif Digital

Surya Hanjaya*¹

¹ Teknik Informatika, Universitas Negeri Surabaya, Indonesia
Email: ¹ surya.23007@mhs.unesa.ac.id

Abstrak

Kegagalan sistem *Unmanned Aerial Vehicle* (UAV) secara tiba-tiba merupakan tantangan kritis dalam operasional industri kreatif digital, khususnya pada aplikasi sinematografi udara dan dokumentasi budaya, karena dampaknya langsung terhadap keselamatan dan kontinuitas produksi. Metode pemantauan konvensional yang bersifat reaktif tidak mampu mendeteksi anomali secara dini sebelum kegagalan terjadi. Penelitian ini mengembangkan sistem deteksi anomali *real-time* berbasis *machine learning* dengan pendekatan rekayasa fitur multi-sensor pada data telemetri UAV. Metode yang digunakan adalah *Local Outlier Factor* (LOF) dengan konfigurasi 20 tetangga terdekat dan tingkat kontaminasi 0,2, diterapkan pada 42 fitur yang terdiri dari 36 fitur sensor mentah dan 6 fitur rekayasa meliputi standar deviasi putaran motor, ketidaksepakatan sensor ketinggian, konsumsi daya, serta statistik bergulir getaran dan giroskop. Model dilatih menggunakan 17.970 sampel data telemetri dengan rasio anomali 20,02%. Sistem mampu mendeteksi tiga jenis anomali, yaitu kegagalan motor, gangguan sensor, dan penurunan baterai mendadak. Hasil evaluasi menunjukkan *ROC-AUC* sebesar 88,73%, presisi 84,86%, *recall* 80,09%, dan *F1-Score* 82,41%. Sistem diimplementasikan dalam arsitektur *full-stack* dengan dasbor pemantauan berbasis React dan *backend* Flask yang memperbarui data setiap satu detik. Pendekatan ini menunjukkan performa yang cukup baik dalam mendukung keandalan operasional UAV pada industri kreatif digital Indonesia.

Kata kunci: Deteksi Anomali, Industri Kreatif Digital, Local Outlier Factor, Rekayasa Fitur, Telemetri UAV

Abstract

Sudden failures in *Unmanned Aerial Vehicle* (UAV) systems present a critical challenge in digital creative industry operations, particularly in aerial cinematography and cultural documentation applications, due to their direct impact on operational safety and production continuity. Conventional reactive monitoring approaches are unable to detect anomalies at an early stage before system failures occur. This study develops a *real-time* anomaly detection system based on machine learning using a multi-sensor feature engineering approach on UAV telemetry data. The proposed method employs the *Local Outlier Factor* (LOF) algorithm with 20 nearest neighbors and a contamination rate of 0.2, applied to 42 features consisting of 36 raw sensor features and 6 engineered features, including motor rotation standard deviation, altitude sensor disagreement, power consumption, and rolling vibration and gyroscope statistics. The model was trained using 17,970 telemetry data samples with an anomaly ratio of 20.02%. The system successfully detected three anomaly types, namely motor failure, sensor glitches, and sudden battery drops. Evaluation results achieved a *ROC-AUC* score of 88.73%, precision of 84.86%, *recall* of 80.09%, and *F1-Score* of 82.41%. The system was implemented using a *full-stack* architecture with a React-based monitoring dashboard and a Flask backend updating telemetry data every second. The proposed approach showed promising performance in supporting reliable UAV operations within Indonesia's digital creative industry.

Keywords: Anomaly Detection, Digital Creative Industry, Local Outlier Factor, Feature Engineering, UAV Telemetry

I. PENDAHULUAN

Penggunaan *Unmanned Aerial Vehicle* (UAV) pada industri kreatif digital Indonesia terus berkembang, khususnya pada sinematografi udara, dokumentasi budaya, promosi pariwisata, dan produksi konten visual berbasis drone. Pemanfaatan UAV pada sektor tersebut menuntut sistem operasional yang andal karena gangguan penerbangan dapat memengaruhi keselamatan, kontinuitas produksi, serta kualitas hasil visual [1], [2]. Kegagalan sistem UAV umumnya dipengaruhi oleh kerusakan motor, gangguan sensor navigasi, penurunan performa baterai, maupun ketidaksesuaian data telemetri antar sensor [3]. Pendekatan pemantauan konvensional yang bersifat reaktif umumnya hanya mendeteksi gangguan setelah kegagalan terjadi, sehingga dibutuhkan pendekatan deteksi dini berbasis data telemetri secara *real-time* [4].

Perkembangan machine learning telah mendorong implementasi deteksi anomali pada berbagai sistem siber-fisik, termasuk UAV dan *Internet of Things* (IoT) [5]. Pendekatan deteksi anomali berbasis machine learning mampu mengidentifikasi pola penyimpangan pada data multivariat tanpa memerlukan aturan ambang batas statis [6]. Salah satu metode yang banyak digunakan adalah *Local Outlier Factor* (LOF), yaitu algoritma berbasis kepadatan lokal yang mendeteksi data menyimpang berdasarkan karakteristik lingkungan tetangga terdekat [7]. LOF dinilai efektif pada data multidimensi karena mampu mendeteksi anomali lokal yang sulit diidentifikasi menggunakan metode statistik konvensional [8].

Beberapa penelitian sebelumnya telah menerapkan machine learning untuk deteksi anomali UAV. Reis dan Reis [1] mengembangkan sistem deteksi gangguan UAV berbasis edge computing menggunakan kombinasi *Isolation Forest* dan *LSTM autoencoder* untuk data telemetri real-time. Bell et al. [9] menggunakan *stacked recurrent autoencoder* untuk mendeteksi anomali sensor UAV berbasis data deret waktu. Jiang et al. [10] menerapkan *Isolation Forest* pada data penerbangan UAV untuk mendeteksi penyimpangan operasional. Selain itu, Zhou et al. [11] mengembangkan model deteksi intrusi UAV berbasis *feature fusion* menggunakan CNN dan LSTM untuk meningkatkan kualitas representasi data sensor.

Meskipun berbagai pendekatan telah dikembangkan, penerapan deteksi anomali pada telemetri UAV masih menghadapi beberapa tantangan. Data telemetri UAV bersifat multivariat dan berasal dari berbagai sensor seperti GPS, IMU, sensor ketinggian, motor, dan sistem daya yang saling berinteraksi [12]. Penggunaan fitur sensor mentah saja sering kali belum mampu merepresentasikan kondisi kegagalan sistem secara optimal. Oleh karena itu, rekayasa fitur multi-sensor diperlukan untuk menangkap hubungan antar komponen UAV dan meningkatkan representasi pola anomali [13].

Penelitian ini mengembangkan sistem deteksi anomali telemetri UAV berbasis machine learning menggunakan pendekatan rekayasa fitur multi-sensor dan algoritma *Local Outlier Factor*. Sistem memanfaatkan 42 fitur yang terdiri atas 36 fitur sensor mentah dan 6 fitur hasil rekayasa, meliputi standar deviasi putaran motor, ketidaksepakatan sensor ketinggian, konsumsi daya, serta statistik bergulir data getaran dan giroskop. Sistem diimplementasikan pada arsitektur sistem berbasis Flask dan React untuk mendukung pemantauan real-time pada operasional UAV di industri kreatif digital. Kontribusi utama penelitian ini meliputi:


1. Pengembangan pipeline rekayasa fitur multi-sensor untuk data telemetri UAV.
2. Implementasi deteksi anomali real-time berbasis *Local Outlier Factor* pada data multivariat UAV.
3. Pengembangan sistem pemantauan berbasis web untuk mendukung keandalan operasional UAV pada industri kreatif digital.

II. METODE PENELITIAN

Penelitian ini mengembangkan sistem deteksi anomali telemetri Unmanned Aerial Vehicle (UAV) berbasis machine learning menggunakan pendekatan rekayasa fitur multi-sensor dan algoritma *Local Outlier Factor* (LOF). Sistem dirancang untuk melakukan pemantauan telemetri secara real-time melalui integrasi pipeline machine learning dengan arsitektur sistem berbasis Flask dan React. Tahapan penelitian meliputi pengumpulan data telemetri, rekayasa fitur multi-sensor, pelatihan model deteksi anomali, evaluasi performa model, dan implementasi sistem pemantauan real-time.

Desain Sistem

Sistem terdiri atas tiga komponen utama, yaitu simulator telemetri UAV, backend machine learning, dan dashboard pemantauan berbasis web. Simulator telemetri menghasilkan data penerbangan UAV secara kontinu dan menyimpannya ke basis data SQLite menggunakan mode *Write-Ahead Logging* (WAL) untuk mendukung proses baca dan tulis secara bersamaan. Backend Flask melakukan pengambilan data telemetri, rekayasa fitur, prediksi anomali, dan penyediaan API. Dashboard React digunakan untuk menampilkan status UAV dan hasil deteksi anomali secara real-time. Arsitektur sistem secara keseluruhan dapat dilihat pada Gambar 1.



Gambar 1 Arsitektur Sistem Deteksi Anomali UAV

Dataset dan Pengumpulan Data

Dataset telemetri UAV terdiri atas 17.970 sampel data dengan rasio anomali sebesar 20,02%. Data diperoleh melalui simulasi penerbangan UAV menggunakan skenario penerbangan bertahap meliputi fase *takeoff*, *climb*, *cruise*, *descent*, dan *landing*. Data telemetri mencakup sensor navigasi, sistem daya, sensor inersial, dan sistem motor. Tabel 1 menunjukkan kategori fitur telemetri yang digunakan dalam penelitian.

Tabel 1 Kategori Fitur Telemetri UAV

Kategori	Fitur
Navigasi	<i>altitude, gps alt, lidar altitude, gps lat, gps lon</i>
Orientasi	<i>pitch, roll, yaw, heading</i>
Sistem Motor	<i>motor rpm 1 hingga motor rpm 4</i>
Temperatur Motor	<i>motor temp 1 hingga motor temp 4</i>
Sistem Daya	<i>battery level, battery voltage, battery current</i>
Sensor Inersial	<i>accel x, accel y, accel z, gyro x, gyro y, gyro z</i>
Komunikasi	<i>sat count, signal strength, link quality</i>

Tabel menunjukkan fitur utama yang digunakan sebagai masukan model machine learning untuk mendeteksi kondisi abnormal UAV.

Rekayasa Fitur Multi-Sensor

Penelitian ini menggunakan pendekatan rekayasa fitur untuk meningkatkan representasi pola anomali pada data telemetri multivariat. Sebanyak 36 fitur sensor mentah ditransformasikan menjadi 42 fitur melalui penambahan fitur statistik dan fitur berbasis hubungan antar sensor. Fitur rekayasa yang digunakan ditunjukkan pada Tabel 2.

Tabel 2 Fitur Rekayasa Multi-Sensor

Fitur Rekayasa	Deskripsi
<i>motor rpm std</i>	Standar deviasi putaran motor
<i>motor temp std</i>	Variasi temperatur motor
<i>alt disagreement std</i>	Ketidaksesuaian sensor ketinggian
<i>power draw</i>	Konsumsi daya baterai
<i>roll accel z std</i>	Statistik getaran vertikal
<i>roll gyro x std</i>	Variasi rotasi giroskop

Fitur konsumsi daya dihitung menggunakan Persamaan [1].

$$Power_Draw = V \times I$$

[1]

dengan:

- V adalah tegangan baterai
- I adalah arus baterai


Standar deviasi putaran motor dihitung menggunakan Persamaan [2].

$$\sigma_{rpm} = \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}} \quad [2]$$

dengan:

- x_i adalah nilai RPM motor
- μ adalah rata-rata RPM
- n adalah jumlah motor

Fitur statistik digunakan untuk menangkap ketidakseimbangan motor dan perbedaan perilaku sensor yang tidak terlihat pada fitur mentah.



Gambar 2 Pipeline Rekayasa Fitur Multi-Sensor

Deteksi Anomali Menggunakan Local Outlier Factor

Metode deteksi anomali menggunakan algoritma *Local Outlier Factor* (LOF). LOF merupakan metode *unsupervised learning* berbasis kepadatan lokal yang mengukur tingkat penyimpangan data terhadap tetangga terdekatnya. Model dikonfigurasi menggunakan 20 *nearest neighbors* dan *contamination* sebesar 0,2.

Skor LOF dihitung berdasarkan *local reachability density* sebagaimana ditunjukkan pada Persamaan [3].

$$LOF_k(A) = \frac{\sum_{B \in N_k(A)} \frac{lrd(B)}{lrd(A)}}{|N_k(A)|} \quad [3]$$

dengan:

- $LOF_k(A)$ adalah skor outlier titik data A
- $lrd(A)$ adalah *local reachability density*
- $N_k(A)$ adalah himpunan tetangga terdekat

Nilai LOF mendekati 1 menunjukkan kondisi normal, sedangkan nilai yang lebih tinggi menunjukkan indikasi anomali. Konfigurasi parameter digunakan untuk menyesuaikan sensitivitas model terhadap pola anomali pada data telemetry UAV.

Tabel 3 Konfigurasi Model LOF

Parameter	Nilai
<i>n_neighbors</i>	20
<i>contamination</i>	0,2
<i>metric</i>	Euclidean
<i>novelty</i>	True

Simulasi Anomali

Penelitian ini mensimulasikan tiga jenis anomali utama yang umum terjadi pada sistem UAV, yaitu:

1. Kegagalan motor
2. Gangguan sensor ketinggian
3. Penurunan baterai mendadak

Distribusi simulasi anomali ditunjukkan pada Tabel 4.

Tabel 4 Jenis Simulasi Anomali

Jenis Anomali	Deskripsi
Motor Failure	RPM motor menjadi 0 dan temperatur meningkat
Sensor Glitch	Nilai sensor ketinggian mengalami lonjakan
Battery Drop	Penurunan kapasitas baterai secara mendadak

Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan algoritma Local Outlier Factor dalam mendeteksi anomali pada data telemetri UAV. Dataset dibagi menggunakan metode *stratified split* dengan proporsi 65% data pelatihan dan 35% data pengujian untuk menjaga distribusi data normal dan anomali tetap seimbang. Model dievaluasi menggunakan metrik ROC-AUC, precision, recall, dan F1-Score karena metrik tersebut umum digunakan pada kasus deteksi anomali berbasis machine learning [11], [12].

Precision digunakan untuk mengukur ketepatan model dalam memprediksi data anomali dan dihitung menggunakan Persamaan [4].

$$Precision = \frac{TP}{TP+FP} \quad [4]$$

Recall digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh data anomali sebagaimana ditunjukkan pada Persamaan [5].

$$Recall = \frac{TP}{TP+FN} \quad [5]$$

F1-Score digunakan untuk mengevaluasi keseimbangan antara precision dan recall yang dihitung menggunakan Persamaan [6].

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad [6]$$

dengan:

- *TP* merupakan true positive
- *FP* merupakan false positive
- *FN* merupakan false negative

III. HASIL DAN PEMBAHASAN

3.1 Hasil Rekayasa Fitur Multi-Sensor

Pendekatan rekayasa fitur multi-sensor menghasilkan total 42 fitur yang terdiri atas 36 fitur sensor mentah dan 6 fitur hasil transformasi statistik. Penambahan fitur rekayasa dilakukan untuk meningkatkan representasi pola anomali pada sistem UAV, khususnya pada interaksi antar sensor dan sistem motor. Fitur tambahan meliputi standar deviasi putaran motor, ketidaksesuaian sensor ketinggian, konsumsi daya, serta statistik bergulir sensor getaran dan giroskop.

Data anomali memiliki distribusi fitur yang lebih menyebar dibanding data normal. Nilai *motor_rpm_std* meningkat signifikan saat terjadi kegagalan motor, sedangkan *alt_disagreement_std* meningkat ketika sensor ketinggian mengalami gangguan. Hal ini menunjukkan bahwa rekayasa fitur mampu memperkuat representasi pola kegagalan UAV. Tabel 5 menunjukkan ringkasan statistik beberapa fitur rekayasa utama.

Tabel 5 Statistik Fitur Rekayasa Multi-Sensor

Fitur	Kondisi Normal	Kondisi Anomali
<i>motor_rpm_std</i>	Rendah dan stabil	Meningkat signifikan
<i>alt_disagreement_std</i>	Mendekati nol	Fluktuatif
<i>power_draw</i>	Konsisten	Menurun drastis
<i>roll_accel_z_std</i>	Stabil	Variasi tinggi

Hasil tersebut menunjukkan bahwa fitur turunan berbasis hubungan antar sensor lebih sensitif dalam menangkap kondisi abnormal dibanding fitur sensor tunggal. Temuan ini sejalan dengan penelitian Zhou et al. [11] yang menyatakan bahwa *feature fusion* dapat meningkatkan representasi pola gangguan pada sistem UAV.


3.2 Hasil Deteksi Anomali Menggunakan Local Outlier Factor

Model Local Outlier Factor berhasil mendeteksi anomali telemetri UAV secara real-time menggunakan konfigurasi 20 *nearest neighbors* dan contamination sebesar 0,2. Evaluasi dilakukan menggunakan dataset pengujian dengan distribusi data normal dan anomali yang seimbang. Tabel 6 menunjukkan hasil evaluasi model LOF.

Tabel 6 Hasil Evaluasi Model LOF

Metrik	Nilai
ROC-AUC	88,73%
Precision	84,86%
Recall	80,09%
F1-Score	82,41%

Hasil evaluasi menunjukkan bahwa model memiliki kemampuan diskriminasi yang baik dengan nilai ROC-AUC sebesar 88,73%. Nilai precision sebesar 84,86% menunjukkan sebagian besar anomali yang diprediksi model merupakan kondisi abnormal yang valid. Nilai recall sebesar 80,09% menunjukkan model mampu mendeteksi sebagian besar gangguan yang terjadi pada sistem UAV.



Gambar 3 Kurva ROC Model Local Outlier Factor

Kurva ROC menunjukkan kemampuan model dalam membedakan data normal dan anomali. Nilai area under curve yang mendekati 1 menunjukkan performa klasifikasi yang baik pada data telemetri UAV.

Hasil penelitian menunjukkan bahwa pendekatan LOF cukup efektif untuk mendeteksi pola penyimpangan lokal pada data multivariat UAV. Temuan ini sejalan dengan penelitian Breunig dkk. [7] yang menyatakan bahwa LOF efektif dalam mendeteksi outlier berbasis kepadatan lokal pada data multidimensi.

3.3 Perbandingan Model Deteksi Anomali

Penelitian ini juga membandingkan performa LOF dengan *Isolation Forest* dan model ensemble sederhana untuk mengevaluasi efektivitas pendekatan yang digunakan.

Tabel 7 Perbandingan Performa Model


Model	ROC-AUC	Precision	Recall	F1-Score
LOF	88,73%	84,86%	80,09%	82,41%
Isolation Forest	65,03%	57,65%	96,83%	72,27%
Ensemble	70,94%	60,76%	91,58%	73,05%

Berdasarkan hasil evaluasi, LOF menghasilkan keseimbangan precision dan recall yang lebih baik dibandingkan model lainnya. *Isolation Forest* memiliki recall yang tinggi, namun menghasilkan precision yang rendah sehingga meningkatkan kemungkinan *false positive*. Pada sistem UAV, *false positive* yang terlalu tinggi dapat menyebabkan peringatan abnormal yang tidak diperlukan selama operasional penerbangan. LOF menghasilkan keseimbangan precision dan recall yang lebih baik pada dataset penelitian ini, khususnya pada precision dan F1-score. Hal ini menunjukkan bahwa pendekatan berbasis kepadatan lokal lebih sesuai untuk karakteristik data telemetri UAV pada penelitian ini.

Temuan tersebut konsisten dengan penelitian Khan dan Madden [4] yang menyatakan bahwa metode berbasis *local density* memiliki sensitivitas yang baik terhadap pola penyimpangan lokal pada data multivariat.

3.4 Analisis Deteksi Anomali Real-Time


Sistem berhasil diimplementasikan menggunakan arsitektur sistem berbasis Flask dan React dengan interval pembaruan data setiap satu detik. Dashboard mampu menampilkan status sistem UAV, waktu pembaruan data, ketinggian penerbangan, kapasitas baterai, mode penerbangan, grafik skor anomali, metrik penerbangan, serta histori telemetri secara real-time. Gambar 4 menunjukkan implementasi dashboard pemantauan UAV yang dikembangkan pada penelitian ini.



Gambar 4 Dashboard Pemantauan UAV Real-Time

Dashboard digunakan untuk memvisualisasikan kondisi operasional UAV secara langsung melalui antarmuka berbasis web. Sistem menampilkan status UAV dalam bentuk indikator normal atau anomali, disertai skor deteksi anomali berbasis model Local Outlier Factor. Selain itu, dashboard juga menampilkan grafik timeline skor anomali untuk memantau perubahan pola telemetri selama proses penerbangan. Pada bagian *flight metrics*, sistem memvisualisasikan perubahan *altitude* dan *battery level* secara kontinu sehingga operator dapat memantau kondisi penerbangan dengan lebih mudah. Histori telemetri terbaru juga disajikan dalam bentuk tabel untuk mendukung proses monitoring dan analisis operasional.

Pengujian simulasi menunjukkan bahwa sistem mampu mendeteksi tiga jenis anomali utama, yaitu kegagalan motor, gangguan sensor ketinggian, dan penurunan baterai mendadak. Pada skenario kegagalan motor, nilai fitur *motor_rpm_std* meningkat akibat ketidakseimbangan putaran antar motor. Pada skenario gangguan sensor, nilai *alt_disagreement_std* meningkat karena terjadi perbedaan pembacaan antar sensor ketinggian. Sementara itu, anomali penurunan baterai menghasilkan perubahan pada fitur *power_draw* dan *battery_level*. Gambar 5 menunjukkan perubahan skor anomali pada data telemetri UAV selama simulasi berlangsung.



Gambar 5 Visualisasi Skor Anomali pada Data Telemetri UAV

Peningkatan skor anomali terlihat pada beberapa titik waktu ketika sistem mengalami gangguan operasional. Nilai skor anomali meningkat secara signifikan dibanding kondisi normal sehingga model mampu mengidentifikasi pola penyimpangan pada data telemetri secara real-time. Setelah kondisi sistem kembali stabil, skor anomali menurun mendekati kondisi normal.

Hasil implementasi menunjukkan bahwa pendekatan rekayasa fitur multi-sensor berbasis machine learning mampu mendukung pemantauan UAV secara real-time pada lingkungan industri kreatif digital. Namun demikian, penelitian ini masih menggunakan data simulasi dan belum diuji pada penerbangan UAV fisik secara langsung. Selain itu, model belum mempertimbangkan faktor lingkungan yang lebih kompleks seperti gangguan cuaca, perubahan beban dinamis, dan interferensi sinyal komunikasi.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem deteksi anomali telemetri UAV berbasis machine learning menggunakan pendekatan rekayasa fitur multi-sensor dan algoritma *Local Outlier Factor*. Sistem mampu melakukan pemantauan kondisi UAV secara real-time melalui integrasi backend Flask, basis data SQLite, dan dashboard berbasis React dengan interval pembaruan data setiap satu detik. Pendekatan rekayasa fitur menghasilkan total 42 fitur yang terdiri atas fitur sensor mentah dan fitur statistik turunan untuk meningkatkan representasi pola anomali pada sistem UAV.

Hasil evaluasi menunjukkan bahwa model LOF memperoleh performa yang cukup baik dengan nilai ROC-AUC sebesar 88,73%, *precision* 84,86%, *recall* 80,09%, dan F1-Score 82,41%. Sistem juga mampu mendeteksi tiga jenis anomali utama, yaitu kegagalan motor, gangguan sensor ketinggian, dan penurunan baterai mendadak. Hasil tersebut menunjukkan bahwa tujuan penelitian untuk mengembangkan sistem deteksi anomali telemetri UAV secara real-time berhasil dicapai dan telah dibuktikan melalui pengujian simulasi pada bab hasil dan pembahasan.

Implementasi dashboard pemantauan berbasis web menunjukkan bahwa sistem dapat digunakan untuk membantu proses monitoring operasional UAV pada lingkungan industri kreatif digital, khususnya pada aplikasi sinematografi udara dan dokumentasi visual berbasis drone.

Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan masih berbasis simulasi sehingga belum sepenuhnya merepresentasikan kondisi penerbangan UAV di lingkungan nyata. Selain itu, model belum mempertimbangkan faktor eksternal seperti kondisi cuaca, interferensi sinyal komunikasi, dan perubahan beban operasional secara dinamis.

Pengembangan penelitian selanjutnya dapat dilakukan melalui pengujian langsung pada UAV fisik, penggunaan dataset telemetri nyata, serta eksplorasi metode *deep learning* berbasis temporal seperti *Long Short-Term Memory* dan *Autoencoder* untuk meningkatkan kemampuan deteksi pola anomali yang lebih kompleks. Selain itu, integrasi sistem peringatan otomatis dan *edge computing* juga berpotensi meningkatkan respons deteksi anomali pada operasional UAV real-time.

REFERENSI

- [1] M. J. C. S. Reis and A. J. D. Reis, "Edge-Based Real-Time Fault Detection in UAV Systems via B-Spline Telemetry Reconstruction and Lightweight Hybrid AI," pp. 1–19, 2025.
- [2] I. Bozcan and E. Kayacan, "UAV-AdNet : Unsupervised Anomaly Detection using Deep Neural Networks for Aerial Surveillance".
- [3] Y. Liu, L. Lee, and K. Yeh, "Enhancing UAV Security with GPS Spoofing and Jamming Anomaly Detection," pp. 54–67, 2025.
- [4] T. Knowledge and E. Review, "One-class classification : taxonomy of study and review of techniques," vol. 29, no. January, pp. 345–374, 2014, doi: 10.1017/S026988891300043X.
- [5] D. Li, D. Chen, L. Shi, B. Jin, J. Goh, and S. Ng, "MAD-GAN : Multivariate Anomaly Detection for Time Series Data with Generative Adversarial Networks," pp. 1–17.
- [6] F. T. Liu, K. M. Ting, and Z.-H. Zhou, "Isolation Forest," in *2008 Eighth IEEE International Conference on Data Mining*, 2008, pp. 413–422. doi: 10.1109/ICDM.2008.17.
- [7] M. M. Breunig, H. Kriegel, R. T. Ng, and J. Sander, "LOF : Identifying Density-Based Local Outliers," pp. 93–104, 2000.
- [8] D. M. J. TAX and R. P. W. DUIN, "Support Vector Data Description," *Mach. Learn.*, no. 54, pp. 45–66, 2004.
- [9] V. Bell, D. Rengasamy, B. Rothwell, and G. P. Figueredo, "Anomaly Detection for Unmanned Aerial Vehicle Sensor Data Using a Stacked Recurrent Autoencoder Method with Dynamic Thresholding".
- [10] J. Wang, Q. Liao, Z. Gu, and L. Nie, "Anomaly detection of UAV flight data based on spatiotemporal feature fusion," *Appl. Soft Comput.*, vol. 197, p. 115131, 2026, doi: <https://doi.org/10.1016/j.asoc.2026.115131>.
- [11] W. Zhou, B. Li, and X. Zeng, "Intrusion detection model of UAV system based on machine learning and neural network," *Front. Phys.*, vol. Volume 13-2025, 2026, doi: 10.3389/fphy.2025.1660104.
- [12] C. G. Gascón, J. B. Bolufer, P. Castelló, J. Antonio, and G. Manrique, "An open benchmark dataset for machine learning and intelligent trajectory optimization in fixed-wing unmanned aerial systems," pp. 1–18, 2026.
- [13] M. N. Mowla, D. Asadi, and F. Sohel, "Real-time fault detection in multirotor UAVs using lightweight deep learning and high-fidelity simulation data with single and double fault magnitudes," *Complex Intell. Syst.*, vol. 12, no. 2, p. 62, 2025, doi: 10.1007/s40747-025-02195-y.