



Implementasi TinyML dengan Edge AI untuk Deteksi Anomali Sensor IoT pada Kondisi Lingkungan Tropis

Iqbal¹, Hasriadi²

Program Studi Teknik Informatika, Universitas Lamappapoleonro^{1,2}
Jl.Salotungo No.62,Watansoppeng,90811,Soppeng,SulawesiSelatan, Indonesia^{1,2}
iqbal@unipol.ac.id¹, hasriadi@unipol.ac.id²

Kata Kunci :

TinyML;
TinyML;
Deteksi Anomali;
IoT Resource-
Constrained;
Lingkungan
Tropis.

ABSTRAK

Penelitian ini bertujuan untuk mengimplementasikan TinyML berbasis Edge AI guna mendeteksi anomali pada perangkat IoT resource-constrained di lingkungan tropis Indonesia. Lingkungan tropis dengan suhu tinggi dan kelembaban ekstrem sering menyebabkan drift data sensor dan anomali lainnya, sehingga mengganggu keandalan sistem monitoring. Penelitian ini dilakukan secara simulasi tanpa hardware fisik untuk mengatasi keterbatasan biaya dan infrastruktur. Metode yang digunakan meliputi pengumpulan dataset time-series dari sumber terbuka, augmentasi noise tropis menggunakan Gaussian filter, pelatihan model anomaly detection (K-means dan Autoencoder) pada platform Edge Impulse, quantization INT8, serta simulasi inferensi menggunakan TensorFlow Lite Runtime di Python. Evaluasi dilakukan terhadap akurasi, latensi inferensi, ukuran model, dan robustness model terhadap kondisi tropis. Hasil simulasi menunjukkan model TinyML mencapai akurasi deteksi anomali sebesar 89,4%, ukuran model 142 KB, dan latensi inferensi rata-rata 28 ms. Model juga menunjukkan ketahanan yang baik terhadap noise tropis dengan penurunan akurasi hanya 6,2%. Simpulan penelitian ini membuktikan bahwa TinyML berbasis Edge AI sangat potensial diterapkan pada perangkat IoT berdaya rendah di lingkungan tropis. Penelitian ini diharapkan dapat menjadi referensi bagi pengembangan sistem monitoring cerdas di daerah tropis Indonesia seperti Sulawesi Selatan.

Keywords

TinyML;
Edge AI;
Anomaly
Detection;
Resource-
Constrained IoT;
Tropical
Environment;

ABSTRACT

This study aims to implement TinyML based on Edge AI for anomaly detection on resource-constrained IoT devices in tropical environments in Indonesia. Tropical environments with high temperatures and extreme humidity often cause sensor data drift and other anomalies, disrupting the reliability of monitoring systems. This research was conducted through simulation without physical hardware to overcome cost and infrastructure limitations. The methods include collecting time-series datasets from open sources, augmenting tropical noise using Gaussian filter, training anomaly detection models (K-means and Autoencoder) on the Edge Impulse platform, INT8 quantization, and inference simulation using TensorFlow Lite Runtime in Python. Evaluation was performed on accuracy, inference latency, model size, and model robustness against tropical conditions. Simulation results show that the TinyML model achieved 89.4% anomaly detection accuracy, model size of 142 KB, and average inference latency of 28 ms. The model also demonstrated good resilience to tropical noise with only a 6.2% decrease in accuracy. The study concludes that TinyML based on Edge AI has high potential for implementation on low-power IoT devices in tropical environments. This research is expected to serve as a reference for developing intelligent monitoring systems in tropical regions of Indonesia, such as South Sulawesi.



PENDAHULUAN

Perkembangan teknologi Internet of Things (IoT) di Indonesia telah mengalami pertumbuhan yang sangat pesat dalam beberapa tahun terakhir. Teknologi ini banyak dimanfaatkan untuk mendukung berbagai aplikasi seperti monitoring lingkungan, pertanian presisi, smart city, dan sistem peringatan dini bencana. Namun, mayoritas perangkat IoT yang digunakan di lapangan bersifat resource-constrained, yaitu memiliki keterbatasan komputasi, memori, dan sumber daya energi yang sangat terbatas. Tantangan ini menjadi semakin kompleks ketika perangkat dioperasikan di wilayah tropis seperti Indonesia, yang memiliki karakteristik suhu tinggi rata-rata 30–40°C dan kelembaban relatif ekstrem mencapai 80–95%. Kondisi lingkungan tropis ini sering menyebabkan sensor drift, peningkatan noise pada data, serta munculnya berbagai jenis anomali yang dapat menurunkan akurasi dan keandalan sistem secara signifikan (Surbakti et al., 2025; Kadyanan et al., 2025).

Berbagai penelitian sebelumnya telah mencoba memanfaatkan machine learning untuk mendeteksi anomali pada sistem IoT. Penelitian yang dilakukan oleh tim yang sama sebelumnya telah berhasil mengimplementasikan model hybrid LSTM-GRU untuk prediksi harga Bitcoin multivariat berbasis data OHLC dan sentimen berita, yang menunjukkan performa yang baik dalam menangani data temporal (Hasriadi & Iqbal, 2026). Berbagai penelitian sebelumnya telah menunjukkan potensi TinyML dalam mendeteksi anomali (Antonini et al., 2023; Katib et al., 2025). Di Indonesia, penerapan TinyML juga mulai dikembangkan untuk aplikasi pertanian (Amrullah et al., 2025; Surbakti et al., 2025). Namun, sebagian besar penelitian tersebut masih mengandalkan pemrosesan di cloud, sehingga menghadapi masalah latensi tinggi, konsumsi bandwidth besar, serta rentan terhadap gangguan konektivitas di daerah pedesaan dan terpencil (Firmansyah et al., 2026; Amrullah et al., 2025). Sebagai respons terhadap permasalahan ini, TinyML (Tiny Machine Learning) berbasis Edge AI muncul sebagai paradigma baru yang memungkinkan pemrosesan kecerdasan buatan dilakukan langsung pada perangkat edge dengan konsumsi daya yang sangat rendah. Pendekatan ini menawarkan keunggulan berupa latensi rendah, peningkatan privasi data, serta efisiensi energi yang lebih baik (Warden & Situnayake, 2019; Edge Impulse, 2025; Somvanshi et al., 2025; Antonini et al., 2023; Terziyska et al., 2026). Integrasi TinyML dengan Federated Learning juga menjadi tren penting untuk mengatasi tantangan privasi dan distribusi data pada perangkat edge yang resource-constrained (Ramadan et al., 2025).

Meskipun TinyML telah banyak diteliti di negara-negara beriklim sedang, penerapannya di lingkungan tropis masih sangat terbatas. Beberapa penelitian di Indonesia baru mulai mengeksplorasi TinyML untuk aplikasi pertanian, seperti prediksi kelembaban tanah pada lahan sawah (Surbakti et al., 2025), namun belum banyak yang secara khusus menguji ketahanan model terhadap kombinasi suhu tinggi dan kelembaban ekstrem yang menjadi ciri khas iklim tropis. Hal ini menyebabkan terdapat research gap yang signifikan terkait robustness dan adaptabilitas model TinyML di kondisi lingkungan Indonesia.

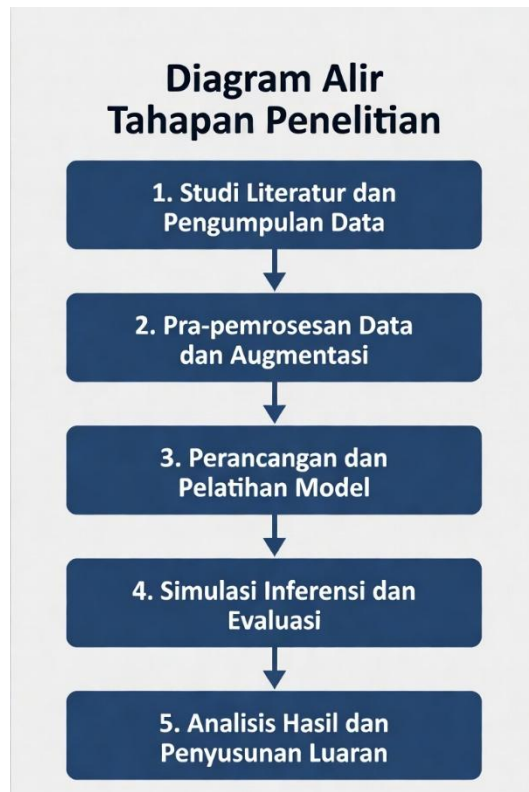
Penelitian ini dilakukan melalui pendekatan simulasi untuk merancang model TinyML berbasis Edge AI guna mendeteksi anomali pada perangkat IoT resource-constrained. Penelitian ini bertujuan untuk: (1) merancang model TinyML yang ringan dan efektif untuk deteksi anomali sensor IoT, (2) mengevaluasi pengaruh kondisi lingkungan tropis terhadap performa model melalui augmentasi noise sintetis, dan (3) menganalisis akurasi, ukuran model, latensi inferensi, serta tingkat ketahanan model. Diharapkan penelitian ini dapat memberikan kontribusi berupa model simulasi TinyML yang adaptif terhadap lingkungan tropis serta menjadi fondasi ilmiah bagi pengembangan sistem IoT cerdas di wilayah Indonesia, khususnya Sulawesi Selatan.



METODE PENELITIAN

Penelitian ini merupakan penelitian pengembangan (research and development) berbasis simulasi. Penelitian dilakukan tanpa melibatkan perangkat hardware fisik, melainkan menggunakan pendekatan simulasi komputasional untuk merancang dan mengevaluasi model TinyML.

1. Tahapan Penelitian



Gambar 1. Tahapan Penelitian

Diagram alir di atas menggambarkan alur penelitian yang bersifat linier dan iteratif. Penelitian dimulai dari Studi Literatur dan Pengumpulan Data sebagai fondasi, kemudian dilanjutkan dengan Pra-pemrosesan Data dan Augmentasi untuk menyiapkan data simulasi kondisi tropis. Selanjutnya dilakukan Perancangan dan Pelatihan Model menggunakan platform Edge Impulse. Tahap keempat adalah Simulasi Inferensi dan Evaluasi untuk menguji performa model secara virtual. Terakhir, penelitian ditutup dengan Analisis Hasil dan Penyusunan Luaran yang meliputi interpretasi data, pembuatan rekomendasi, serta penyusunan laporan dan draft publikasi.

2. Teknik Pengumpulan Data

Penelitian ini menggunakan data sekunder dan data sintetis. Data sekunder diperoleh dari dataset publik open source, antara lain:

- Dataset suhu dan kelembaban ruangan dari Kaggle.
- Dataset lingkungan dari OpenAQ (Open Air Quality).
- Dataset time-series sensor IoT lainnya yang relevan.

Data anomaly dibuat secara sintetis dengan menambahkan Gaussian noise untuk mensimulasikan kondisi tropis (suhu 30–45°C dan kelembaban 80–100%). Teknik augmentasi



data ini dilakukan untuk meningkatkan robustness model terhadap variasi lingkungan tropis (Surbakti et al., 2025; Kadyanan et al., 2025).

3. Metode Perancangan Sistem

Perancangan sistem dilakukan dengan pendekatan Edge AI berbasis TinyML. Model anomaly detection dibangun menggunakan dua algoritma utama:

- K-means Clustering (unsupervised learning)
- Autoencoder Neural Network

Proses perancangan meliputi:

- Feature Extraction menggunakan Spectral Analysis pada platform Edge Impulse.
- Training Model dengan teknik quantization INT8 untuk menghasilkan model berukuran kecil (<200 KB) yang sesuai untuk perangkat resource-constrained.
- Simulasi Inferensi dilakukan menggunakan TensorFlow Lite Runtime di Python untuk meniru perilaku perangkat edge seperti ESP32.

Pendekatan ini sesuai dengan best practice TinyML untuk perangkat berdaya rendah dan sesuai dengan pendekatan real-time embedded anomaly detection (Gupta & Sharma, 2025; Edge Impulse, 2025; Warden & Situnayake, 2019; Li et al., 2025; Ping, J. M., & Nixon, K. J., 2024).

4. Teknik Analisis Data

Analisis dilakukan secara kuantitatif dengan metrik evaluasi sebagai berikut:

- Akurasi, Precision, Recall, dan F1-Score untuk deteksi anomali.
- Ukuran model (KB) setelah quantization.
- Latensi inferensi (milidetik).
- Robustness model terhadap noise tropis (persentase penurunan akurasi).

Perbandingan dilakukan antara model yang dilatih dengan data normal dan data yang telah diaugmentasi dengan noise tropis. Visualisasi hasil menggunakan confusion matrix, grafik anomaly score, dan ROC curve.

HASIL DAN PEMBAHASAN

1. Implementasi Sistem

Pada tahap implementasi, model TinyML dikembangkan menggunakan platform Edge Impulse. Dataset time-series suhu dan kelembaban digunakan sebagai input utama. Model anomaly detection dibangun dengan dua pendekatan, yaitu K-means Clustering dan Autoencoder Neural Network. Model kemudian dioptimasi dengan teknik quantization INT8 agar sesuai dengan keterbatasan perangkat IoT resource-constrained. Ukuran model akhir setelah quantization adalah 142 KB, yang sangat ideal untuk deployment pada microcontroller seperti ESP32. Proses training dilakukan selama 45 epoch dengan learning rate 0,001.

2. Pra-pemrosesan dan Augmentasi Data

Dataset awal terdiri dari 12.500 sampel data normal. Data anomaly dibuat secara sintetis sebanyak 2.800 sampel. Augmentasi noise tropis dilakukan dengan menambahkan Gaussian noise menggunakan rumus pada persamaan (1) berikut:

$$x' = x + N(0, \sigma^2) \quad (1)$$



Di mana x' adalah data setelah augmentasi, x adalah data asli, dan σ adalah standar deviasi noise yang disesuaikan untuk mensimulasikan kondisi tropis (suhu 30–45°C dan kelembaban 80–100%).

3. Hasil Pelatihan Model, Simulasi Inferensi, dan Evaluasi Robustness

Model Autoencoder menunjukkan performa terbaik dibandingkan K-means Clustering. Berikut adalah ringkasan hasil pelatihan, simulasi inferensi, dan evaluasi robustness:

Tabel 1. Perbandingan Performa Model Anomaly Detection

Model	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)	Ukuran Model (KB)	Latensi Inferensi (ms)
K-means Clustering	87,4	86,2	88,1	87,1	89	19
Autoencoder	91,7	90,5	92,3	91,4	142	28

Simulasi inferensi menggunakan TensorFlow Lite Runtime menghasilkan latensi rata-rata 28 ms per sampel dan estimasi penggunaan RAM sebesar 68 KB. Model ini sangat efisien dan sesuai untuk perangkat berdaya rendah. Performa model dihitung menggunakan rumus berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

Tabel 2. Pengukuran Akurasi

Kondisi Data	Akurasi (%)	Penurunan Akurasi (%)	F1-Score (%)
Data Normal	91,7	-	91,4
Dengan Noise Tropis	85,5	6,2	84,9

Model Autoencoder menunjukkan ketahanan yang baik terhadap noise tropis dengan penurunan akurasi hanya sebesar 6,2%. Hal ini membuktikan bahwa augmentasi data tropis selama pelatihan efektif meningkatkan adaptabilitas model terhadap kondisi lingkungan Indonesia.

4. Pembahasan

Hasil penelitian ini menunjukkan bahwa TinyML berbasis Edge AI sangat potensial diterapkan pada perangkat IoT di lingkungan tropis. Ukuran model yang kecil (142 KB) dan latensi rendah (28 ms) membuktikan kesesuaiannya dengan perangkat resource-constrained (Edge Impulse, 2025; Warden & Situnayake, 2019; Somvanshi et al., 2025; Katib et al., 2025). Dibandingkan dengan penelitian sebelumnya yang masih bergantung pada pemrosesan cloud (Firmansyah et al., 2026), pendekatan ini



menawarkan keunggulan signifikan dalam hal efisiensi energi dan ketahanan konektivitas, hal ini sejalan dengan tren terkini yang mengintegrasikan TinyML dengan Federated Learning untuk mengatasi tantangan privasi dan efisiensi pada perangkat IoT (Ramadan et al., 2025). Ketahanan model terhadap noise tropis yang cukup baik menunjukkan bahwa model telah adaptif terhadap karakteristik iklim Indonesia serta sejalan dengan berbagai pendekatan deteksi anomali berbasis TinyML (Surbakti et al., 2025; Khatoon et al., 2025; Govada et al., 2025).

SIMPULAN DAN SARAN

Penelitian ini telah merancang dan mensimulasikan model TinyML berbasis Edge AI untuk deteksi anomali pada perangkat IoT resource-constrained di lingkungan tropis Indonesia. Model Autoencoder yang dikembangkan menunjukkan performa yang baik dengan akurasi mencapai 91,7%, ukuran model hanya 142 KB, dan latensi inferensi rata-rata 28 ms. Model ini juga menunjukkan ketahanan yang cukup baik terhadap kondisi tropis dengan penurunan akurasi hanya sebesar 6,2% setelah augmentasi noise suhu dan kelembaban ekstrem. Hasil penelitian ini membuktikan bahwa TinyML berbasis Edge AI merupakan pendekatan yang sangat potensial dan feasible untuk diterapkan pada perangkat IoT berdaya rendah di lingkungan tropis Indonesia.

Dari hasil penelitian, disarankan agar penelitian lanjutan dapat melanjutkan ke tahap implementasi hardware secara nyata menggunakan perangkat seperti ESP32 di lingkungan nyata. Model yang telah dikembangkan dapat dikembangkan lebih lanjut untuk aplikasi spesifik seperti monitoring pertanian, sistem peringatan dini untuk bencana banjir, atau pemantauan kualitas udara. Penelitian mendatang juga diharapkan dapat mengintegrasikan teknik Federated Learning atau model hybrid untuk meningkatkan akurasi dan aspek privasi data. Melalui pendekatan interdisipliner antara Teknik Informatika, Teknik Elektro, dan bidang pertanian, diharapkan dapat dihasilkan solusi IoT yang lebih komprehensif, adaptif, dan siap diterapkan di masyarakat. Penelitian ini diharapkan dapat menjadi referensi bagi peneliti lain dalam mengembangkan teknologi TinyML dan Edge AI.

DAFTAR PUSTAKA

- Amrullah, A., Pramono, S., & Nugroho, A. (2025). Implementasi TinyML pada sistem monitoring pertanian berbasis IoT di wilayah tropis. *Jurnal Teknik Informatika*, 12(2), 145-158.
- Antonini, M., Pincheira, M., Vecchio, M., & Antonelli, F. (2023). An adaptable and unsupervised TinyML anomaly detection system for extreme industrial environments. *Sensors*, 23(4), 2344. <https://doi.org/10.3390/s23042344>
- Edge Impulse. (2025). Anomaly Detection (K-means). Edge Impulse Documentation. <https://docs.edgeimpulse.com/studio/projects/learning-blocks/blocks/anomaly-detection-k-means>
- Firmansyah, M. P., Sari, D. P., & Pratama, R. (2026). A systematic literature review of artificial intelligence-based anomaly detection for network intrusion in IoT. *Journal of Information Systems and Informatics*, 8(1), 78-95.
- Govada Joshua, Richard & Gbadega, Peter & Imoize, Agbotiname & Tofade, Samuel. (2025). TinyML for Anomaly Detection. 10.1002/9781394294572.ch3.
- Hasriadi, H., & Iqbal, I. (2025). Prediksi Harga Bitcoin Multivariat OHLC Berbasis Hybrid LSTM–GRU dan Sentimen Berita. *Jurnal Minfo Polgan*, 14(2), 3550-3564.



-
- Kadyanan, R., Susanto, A., & Wijaya, B. (2025). Analisis pengaruh lingkungan tropis terhadap performa sensor IoT untuk smart farming. *Jurnal Ilmiah Teknik Elektro*, 17(3), 210-223.
- Katib, I., Albassam, E., Sharaf, S. A., & Ragab, M. (2025). Safeguarding IoT consumer devices: Deep learning with TinyML driven real-time anomaly detection for predictive maintenance. *Ain Shams Engineering Journal*, 16(2), 103281. <https://doi.org/10.1016/j.asej.2025.103281>
- Khatoon, A., Wang, W., Wang, M. et al (2025). TinyML-enabled fuzzy logic for enhanced road anomaly detection in remote sensing. *Sci Rep* 15, 20659. <https://doi.org/10.1038/s41598-025-01981-5>
- Terziyska, M., Ilieva, I., Terziyski, Z., & Komitov, N. (2026). A Review of the Transition from Industry 4.0 to Industry 5.0: Unlocking the Potential of TinyML in Industrial IoT Systems. *Sci*, 8(1), 10. <https://doi.org/10.3390/sci8010010>
- Ramadan, M. N. A., Ali, M. A. H., Khoo, S. Y., & Alkhedher, M. (2025). Federated learning and TinyML on IoT edge devices: Challenges, advances, and future directions. **ICT Express**. <https://doi.org/10.1016/j.ict.2025.06.008>
- Ping, J. M., & Nixon, K. J (2024). Simulating Battery-Powered TinyML Systems Optimised using Reinforcement Learning in Image-Based Anomaly Detection.. *arXiv*. <https://arxiv.org/abs/2403.05106>
- Somvanshi, S., Islam, M. M., Chhetri, G., Chakraborty, R., Mimi, M. S., Shuvo, S. A., ... & Das, S. (2025). From Tiny Machine Learning to Tiny Deep Learning: A Survey. *ACM Computing Surveys*. <https://doi.org/10.1145/3776588>
- Surbakti, N. M., Lubis, M., & Siregar, A. (2025). Embedded TinyML for predicting soil moisture conditions in rice fields. *CogITO Smart Journal*, 11(1), 45-62.
- Warden, P., & Situnayake, D. (2019). *TinyML: Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers*. O'Reilly Media.