

Deret Multi-Sensor IoT Berbasis AI untuk Termal Mesin Sepeda Motor

¹ Lutfi Agung Swarga, ² Ratna Hartayu, ³ Kukuh Setyadjit, ⁴ Izzah Aula Wardah

^{1,2,3,4} Program Studi Teknik Elektro, Universitas 17 Agustus 1945 Surabaya, Surabaya

¹lutfiagung@untag-sby.ac.id, ²ratnahartayu@untag-sby.ac.id, ³kukuh@untag-sby.ac.id, ⁴iwardah@untag-sby.ac.id

Abstract — Engine overheating is a primary cause of performance loss and premature component failure in motorcycles, yet factory temperature indicators are reactive and only warn once an unsafe condition has occurred. This study extends a prior IoT thermal-monitoring system by adding an artificial-intelligence (AI) layer and framing the platform as a teaching model for sustainable engineering education. A three-sensor array—PT100 (via MAX31865), Thermocouple Type-K (via MAX31855), and a non-contact GY-906 (MLX90614)—is read by an ESP32, displayed on a 20x4 LCD, and streamed to a Blynk dashboard with a buzzer, push, and email Early Warning System. Using 81 field samples collected from a Honda PCX 150 across daytime, evening, and night sessions with and without coolant, a lightweight edge-AI model (logistic regression) performs sensor fusion to (a) predict overheating two minutes ahead and (b) detect coolant loss before overheating occurs. Under leave-one-session-out cross-validation the predictor reached 93.8% accuracy and an AUC of 0.984, issuing warnings on average 2.0 minutes earlier than a fixed 100 C threshold, while cooling-fault detection identified coolant loss about 5 minutes before overheat onset. The IoT link stayed stable (latency < 2 s, zero packet loss). Beyond the technical result, the system is presented as a project-based learning module that integrates IoT, machine learning, and green technology to build sustainability-oriented graduate competencies.

Keywords — engine thermal monitoring; Internet of Things; edge AI; early warning system; sustainable engineering education

Abstrak — Overheating merupakan penyebab utama penurunan performa dan kerusakan dini komponen mesin sepeda motor, sementara indikator suhu bawaan bersifat reaktif dan baru memberi peringatan setelah kondisi tidak aman terjadi. Penelitian ini mengembangkan sistem monitoring suhu berbasis IoT sebelumnya dengan menambahkan lapisan artificial intelligence (AI) serta memframing platform sebagai teaching model untuk pendidikan teknik yang berkelanjutan. Deret tiga sensor—PT100 (melalui MAX31865), Thermocouple Type-K (melalui MAX31855), dan GY-906 non-kontak (MLX90614)—dibaca oleh ESP32, ditampilkan pada LCD 20x4, dan dikirim ke dashboard Blynk yang dilengkapi buzzer, notifikasi push, serta email sebagai Early Warning System. Menggunakan 81 sampel data lapangan dari Honda PCX 150 pada sesi siang, sore, dan malam dengan dan tanpa coolant, sebuah model edge-AI ringan (logistic regression) melakukan sensor fusion untuk (a) memprediksi overheat dua menit lebih awal dan (b) mendeteksi kehilangan coolant sebelum overheat terjadi. Dengan validasi leave-one-session-out, prediktor mencapai akurasi 93.8% dan AUC 0.984, memberi peringatan rata-rata 2.0 menit lebih cepat dibanding ambang tetap 100 C, sedangkan deteksi gangguan pendingin mengenali kehilangan coolant sekitar 5 menit sebelum overheat. Koneksi IoT tetap stabil (latensi < 2 detik, tanpa kehilangan data). Selain hasil teknis, sistem disajikan sebagai modul project-based learning yang memadukan IoT, machine learning, dan green technology untuk membangun kompetensi lulusan yang berorientasi keberlanjutan.

Kata Kunci — monitoring suhu mesin; Internet of Things; edge AI; early warning system; pendidikan teknik berkelanjutan

I. PENDAHULUAN

Overheating merupakan salah satu penyebab utama kerusakan pada mesin sepeda motor. Kenaikan temperatur yang melewati batas aman dapat menurunkan performa, mempercepat keausan komponen, dan pada akhirnya memperpendek umur mesin. Sistem indikator suhu bawaan kendaraan umumnya bersifat reaktif: lampu peringatan baru menyala ketika kondisi overheat telah terjadi, sehingga pengendara kehilangan kesempatan untuk melakukan tindakan pencegahan lebih awal. Padahal, dari sudut pandang green technology, deteksi dini terhadap anomali termal berkontribusi langsung pada keberlanjutan—memperpanjang usia komponen, mengurangi limbah suku cadang, serta menjaga efisiensi pembakaran dan konsumsi energi kendaraan.

Perkembangan Internet of Things (IoT) dan artificial intelligence (AI) membuka peluang untuk mengubah pemantauan termal dari sekadar pencatatan menjadi prediksi. Penelitian sebelumnya oleh Ahmad [1] telah merancang sistem monitoring suhu blok mesin sepeda motor menggunakan deret sensor suhu berbasis IoT dengan ESP32, yang mampu menampilkan data secara real-time dan mengirim peringatan melalui platform Blynk. Namun, sistem tersebut masih menggunakan ambang batas tetap (fixed threshold) sebesar 100 C sebagai satu-satunya mekanisme pemicu peringatan, sehingga peringatan tetap muncul pada saat—bukan sebelum—kondisi berbahaya tercapai. Sejumlah studi

menunjukkan bahwa integrasi machine learning pada data sensor mesin dapat meningkatkan kemampuan predictive maintenance dan deteksi anomali [2], [3], [4], termasuk pada perangkat tepi (edge) dengan sumber daya terbatas melalui pendekatan TinyML [5].


Selain aspek teknis, tema transformasi pendidikan tinggi teknik elektro melalui AI dan green technology menuntut adanya media pembelajaran yang mengintegrasikan ketiga elemen tersebut secara utuh. Sistem monitoring termal berbasis IoT dan AI berpotensi menjadi model pembelajaran (teaching model) yang konkret: mahasiswa membangun perangkat keras, mengumpulkan data nyata, melatih model AI, dan merefleksikan dampak keberlanjutannya. Pendekatan project-based learning semacam ini selaras dengan pengembangan kompetensi lulusan yang unggul, berdampak, dan berkelanjutan [6], [7].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk: (1) mengembangkan lapisan edge-AI di atas deret sensor suhu IoT untuk memprediksi kondisi overheat lebih dini serta mendeteksi kehilangan coolant sebelum overheat terjadi; (2) mengevaluasi kinerja model AI menggunakan data pengujian lapangan nyata; dan (3) merumuskan sistem tersebut sebagai teaching model bagi pendidikan teknik yang berkelanjutan. Kontribusi utama penelitian ini adalah penggabungan sensor fusion berbasis AI dengan kerangka pembelajaran yang menautkan IoT, machine learning, dan green technology.

II. METODE PENELITIAN

A. Arsitektur Sistem

Arsitektur sistem terdiri atas tiga lapisan, yaitu sensing layer, edge layer, dan lapisan IoT cloud beserta aksi, sebagaimana ditunjukkan pada Gambar 1. Pada sensing layer digunakan tiga sensor suhu dengan prinsip kerja berbeda agar kondisi termal mesin terekam secara komprehensif: PT100 RTD melalui modul MAX31865 untuk mengukur temperatur coolant pada jalur radiator, Thermocouple Type-K melalui modul MAX31855 untuk mengukur temperatur permukaan blok mesin secara kontak langsung, dan sensor inframerah non-kontak GY-906 (MLX90614) untuk mengukur suhu permukaan blok tanpa menyentuhnya. Ketiga sensor dibaca oleh mikrokontroler ESP32 yang berperan sebagai edge device, menampilkan data pada LCD 20x4 dan mengirimkannya ke dashboard Blynk melalui Wi-Fi.



Gambar 1. Arsitektur sistem AI-Driven IoT multi-sensor array dan kaitannya dengan model pembelajaran berkelanjutan.

Objek pengujian adalah sepeda motor Honda PCX 150 tipe K97 yang menggunakan sistem pendingin cairan (liquid cooling) dengan radiator. Spesifikasi objek dan komponen utama sistem dirangkum pada Tabel 1.

Tabel 1. *Spesifikasi objek dan komponen utama sistem*

Parameter / Komponen	Spesifikasi
Objek uji	Honda PCX 150 K97 (149,16 cc, liquid cooling)
Suhu operasi normal	80 C - 100 C
Mikrokontroler	ESP32 (dual-core, Wi-Fi/Bluetooth)
Sensor coolant	PT100 RTD + MAX31865 (SPI)
Sensor blok (kontak)	Thermocouple Type-K + MAX31855 (SPI)
Sensor blok (non-kontak)	GY-906 / MLX90614 (I2C)
Tampilan & IoT	LCD 20x4 I2C; Blynk (buzzer, push, email)
Ambang overheat	100 C

B. Akuisisi Data dan Skenario Pengujian

Pengambilan data dilakukan pada tiga waktu (siang, sore, malam) dengan dua skenario pada setiap sesi, yaitu radiator terisi coolant dan radiator tanpa coolant, sambil mengendarai motor pada rute yang sama untuk menjaga konsistensi beban kerja. Pada kondisi terisi coolant data dicatat tiap 2 menit selama 30 menit, sedangkan pada kondisi tanpa coolant data dicatat tiap 1 menit hingga sistem mendeteksi overheat. Seluruh sesi menghasilkan 81 sampel data (PT100, Type-K, GY-906, dan status) yang menjadi dasar pelatihan serta evaluasi model AI. Uji akurasi masing-masing sensor terhadap termometer referensi memberikan rata-rata error PT100 0,63 C, Type-K 0,64 C, dan GY-906 0,49 C, sehingga seluruh sensor berada dalam batas toleransi spesifikasinya.

C. Lapisan AI (Edge AI) dan Sensor Fusion

Di atas deret sensor ditambahkan lapisan AI yang melakukan sensor fusion, yaitu menggabungkan pembacaan ketiga sensor beserta laju perubahannya menjadi fitur untuk pengambilan keputusan. Dari setiap sampel diekstraksi sembilan fitur: tiga nilai suhu (PT100, Type-K, GY-906), tiga laju perubahan per menit (dT/dt), dua selisih divergensi antar sensor (Type-K - PT100 dan GY-906 - PT100), serta nilai suhu blok maksimum. Laju perubahan dihitung mengikuti Persamaan (1) dan divergensi antar sensor mengikuti Persamaan (2), di mana divergensi besar menandakan panas blok tidak terbawa oleh coolant—sebuah tanda kehilangan coolant.

$$dT/dt = (T_t - T_{t-1}) / \Delta t \quad (1)$$

$$D = T_{block} - T_{coolant} \quad (2)$$

Lapisan AI menjalankan dua tugas klasifikasi. Tugas pertama adalah prediksi overheat dini, yaitu memprediksi apakah suhu blok akan mencapai ambang 100 C dalam dua menit ke depan. Tugas kedua adalah deteksi kehilangan coolant, yaitu mengklasifikasikan kondisi sistem pendingin (normal vs. tanpa coolant) sebelum overheat terjadi. Model utama yang digunakan adalah logistic regression (Persamaan 3) karena bersifat ringan dan dapat diterapkan langsung pada ESP32 sebagai TinyML, dengan decision tree (kedalaman 3) sebagai pembanding. Model dievaluasi menggunakan leave-one-session-out cross-validation (LOSO-CV): pada setiap iterasi, satu sesi pengujian penuh digunakan sebagai data uji sementara lima sesi lainnya menjadi data latih, sehingga model selalu diuji pada kondisi operasi yang belum pernah dilihat.

$$P(\text{overheat} | x) = 1 / (1 + e^{-(w \cdot x + b)}) \quad (3)$$

D. Perumusan Model Pembelajaran (Teaching Model)

Sistem yang dikembangkan dirumuskan sebagai model pembelajaran berbasis proyek (project-based learning) melalui empat tahap yang saling terhubung, sebagaimana ditunjukkan pada Gambar 4: (1) identifikasi masalah hijau (green problem)—overheating yang memboroskan energi dan memperpendek umur komponen; (2) membangun perangkat IoT—merangkai deret sensor, ESP32, dan Blynk; (3) menganalisis dengan AI—mengumpulkan data, melatih, dan mengevaluasi model edge-AI; serta (4) refleksi keberlanjutan—predictive maintenance, efisiensi sumber daya, dan keterkaitan dengan Sustainable Development Goals (SDGs). Kerangka ini memetakan capaian

pembelajaran ke kompetensi embedded IoT, alur kerja machine learning, pengambilan keputusan berbasis data, dan pola pikir keberlanjutan.


III. HASIL DAN PEMBAHASAN

A. Karakteristik Respons Sensor

Gambar 2 menampilkan respons ketiga sensor pada skenario tanpa coolant di siang hari. Sensor Type-K dan GY-906 yang mengukur permukaan blok mengalami kenaikan suhu cepat dan melampaui ambang 100 C, sedangkan PT100 yang mengukur jalur coolant tetap rendah karena tidak ada cairan yang membawa panas menuju sensor. Perbedaan (divergensi) inilah yang dieksploitasi oleh lapisan AI: pola suhu blok yang naik tajam sementara jalur coolant tetap dingin merupakan tanda khas kehilangan coolant. Area yang diarsir menunjukkan selisih waktu antara peringatan dini AI dan pemicuan ambang tetap 100 C.



Gambar 2. Perangkat Sistem AI-Driven IoT Multi-Sensor Array for Motorcycle Engine Thermal.



Gambar 3. Respons sensor dan titik peringatan dini AI dibanding ambang tetap 100 C (skenario tanpa coolant, siang hari).


Pada kondisi radiator terisi coolant, seluruh sesi (siang, sore, malam) menunjukkan status NORMAL dengan suhu stabil pada rentang operasi aman, membuktikan sistem pendingin mampu menjaga temperatur mesin. Sebaliknya, pada kondisi tanpa coolant, sistem konsisten mendeteksi overhear pada menit ke-6 (siang dan sore) serta menit ke-7 (malam).

B. Kinerja Prediksi Overheat Dini


Hasil evaluasi LOSO-CV untuk prediksi overhear dini dirangkum pada Tabel 2 dan divisualisasikan pada Gambar 3. Model logistic regression mencapai akurasi 93.8%, precision 78.9%, recall 93.8%, F1-score 0.857, dan AUC 0.984, mengungguli decision tree (akurasi 88.9%, AUC 0.830). Yang terpenting bagi fungsi Early Warning System, model memberikan peringatan rata-rata 2.0 menit lebih awal dibanding aturan ambang tetap 100 C, dengan lead time 1, 2, 3 menit berturut-turut untuk sesi siang, sore, dan malam. Dari matriks kebingungan (Gambar 3b), model hanya melewati 1 dari 16 kondisi pra-overheat (recall tinggi), yang sesuai dengan prioritas keselamatan di mana kegagalan mendeteksi (false negative) jauh lebih berbahaya daripada peringatan palsu.

Tabel 2. Kinerja model AI (GRU)

Metrik	LogReg	GRU	Tugas B*
Accuracy	93.8%	88.9%	88.2%
Precision	78.9%	-	80.0%
Recall	93.8%	-	80.0%
F1-score	0.857	0.727	0.800
AUC	0.984	0.830	-
Lead time rata-rata	2.0 mnt	1.7 mnt	5 mnt**



(a)



(b)

Gambar 3. Kinerja prediksi overhear dini: (a) kurva ROC, (b) matriks kebingungan,


C. Deteksi Kehilangan Coolant Sebelum Overheat

Pada tugas kedua, model mengklasifikasikan kondisi kehilangan coolant hanya dari sampel sebelum overhear (suhu blok < 100 C) untuk membuktikan kemampuan deteksi dini. Model mencapai akurasi 88.2% dengan precision, recall, dan F1-score masing-masing 0.8. Lebih penting lagi, model mengenali kondisi kehilangan coolant jauh sebelum overhear terjadi: siang 4 menit, sore 5 menit, malam 6 menit lebih awal, dengan rata-rata 5 menit sebelum ambang overhear tercapai. Kemampuan ini memberikan jendela waktu berharga bagi pengendara untuk menepi dan memeriksa sistem pendingin sebelum kerusakan termal terjadi—sebuah bentuk predictive maintenance yang mendukung keberlanjutan komponen.

D. Kinerja IoT dan Early Warning System

Integrasi ESP32 dengan platform Blynk berjalan stabil selama seluruh sesi pengujian. Interval pengiriman 1 detik menggunakan BlynkTimer menghasilkan pemantauan real-time dengan latensi kurang dari 2 detik, tanpa putus koneksi maupun kehilangan paket data. Nilai suhu yang ditampilkan pada aplikasi Blynk identik dengan tampilan LCD, sehingga integritas data terjaga selama transmisi. Ketika kondisi overhear terdeteksi, notifikasi pop-up dan email otomatis dikirim ke pengguna terdaftar bersamaan dengan aktifnya buzzer. Dengan penambahan lapisan AI, Early Warning System kini tidak hanya bereaksi terhadap kondisi overhear, tetapi juga memberikan peringatan prediktif beberapa menit sebelumnya.

E. Implementasi sebagai Model Pembelajaran Berkelanjutan



Gambar 4. Kerangka teaching model: dari prototipe penelitian menjadi modul pembelajaran berkelanjutan.

Seluruh alur penelitian—dari perancangan perangkat keras, akuisisi data, pelatihan model AI, hingga refleksi keberlanjutan—dapat langsung diadopsi sebagai modul project-based learning pada mata kuliah sistem tertanam, instrumentasi, atau kecerdasan buatan. Model pembelajaran ini menautkan tiga pilar tema seminar: IoT sebagai fondasi akuisisi dan konektivitas, AI sebagai lapisan analitik dan prediksi, serta green technology sebagai orientasi dampak melalui pemeliharaan prediktif dan efisiensi sumber daya. Dengan bekerja pada data dan perangkat nyata, mahasiswa memperoleh kompetensi yang unggul (penguasaan teknologi terkini), berdampak (solusi masalah nyata kendaraan), dan berkelanjutan (kesadaran akan siklus hidup komponen dan efisiensi energi). Dengan demikian, sistem yang dikembangkan tidak hanya berfungsi sebagai alat monitoring, tetapi juga sebagai jembatan konkret bagi transformasi pendidikan tinggi teknik elektro.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan lapisan edge-AI di atas deret sensor suhu IoT untuk pemantauan termal mesin sepeda motor. Dengan sensor fusion dari PT100, Thermocouple Type-K, dan GY-906, model logistic regression yang ringan mampu memprediksi kondisi overheat dengan akurasi 93.8% dan AUC 0.984 (LOSO-CV), memberikan peringatan rata-rata 2.0 menit lebih awal dibanding ambang tetap, serta mendeteksi kehilangan coolant sekitar 5 menit sebelum overheat terjadi. Integrasi IoT dengan Blynk tetap stabil dengan latensi kurang dari 2 detik tanpa kehilangan data. Selain kontribusi teknis, sistem dirumuskan sebagai teaching model berbasis proyek yang memadukan IoT, machine learning, dan green technology untuk membangun kompetensi lulusan yang unggul, berdampak, dan berkelanjutan. Keterbatasan penelitian ini adalah ukuran dataset (81 sampel dari satu unit kendaraan); penelitian lanjutan diarahkan pada perluasan data lintas kendaraan, penerapan model TinyML langsung pada ESP32, serta uji coba modul pembelajaran pada kelas nyata.

V. DAFTAR PUSTAKA

- [1] F. F. Ahmad, "Monitoring Suhu Blok Mesin Sepeda Motor Menggunakan Deret Sensor Suhu dan Berbasis IoT," Tugas Akhir, Program Studi Teknik Elektro, Universitas 17 Agustus 1945 Surabaya, 2026.
- [2] T. P. Carvalho, F. A. A. M. N. Soares, R. Vita, R. da P. Francisco, J. P. Basto, and S. G. S. Alcalá, "A systematic literature review of machine learning methods applied to predictive maintenance," *Comput. Ind. Eng.*, vol. 137, p. 106024, 2019.
- [3] S. Ayvaz and K. Alpay, "Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time," *Expert Syst. Appl.*, vol. 173, p. 114598, 2021.
- [4] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, and R. X. Gao, "Deep learning and its applications to machine health monitoring," *Mech. Syst. Signal Process.*, vol. 115, pp. 213–237, 2019.
- [5] C. R. Banbury et al., "Benchmarking TinyML systems: Challenges and direction," in *Proc. Mach. Learn. Syst. (MLSys)*, 2021.
- [6] L. Ang and K. P. Seng, "GREEN and edge AI for Internet of Things: A framework and case studies," *IEEE Access*, vol. 10, pp. 100–119, 2022.
- [7] M. Bilgin and S. Şentürk, "Project-based learning in engineering education for sustainable development: A systematic review," *Sustainability*, vol. 14, no. 9, p. 5545, 2022.
- [8] J. Gardner et al., "Engineering education for sustainable development: A review of competences and pedagogies," *Eur. J. Eng. Educ.*, vol. 47, no. 5, pp. 1–22, 2022.
- [9] Mirzaryan Oktavaldi, "Prototype Sistem Monitoring Dan Kontrol Temperatur Cat Pada Proses Pengecatan Rangka Sepeda Motor Berbasis Internet Of Things" *JTE Mercubuana.*, vol. 7, no. 1, pp. 40–46, 2022.
- [10] Heni Musvita Sari, "RANCANG BANGUN ALAT MONITORING KERJA SENSOR PADA SEPEDA MOTOR INJEKSI" *Jurnal Rekayasa Mesin (JRM).*, vol. 14, no. 1, pp. 1–7, 2023.
- [11] Muhammad Ariq Kautsar et al, "Implementasi Metode Fuzzy Logic Pada Sistem Peringatan Kondisi Air Radiator Sepeda Motor Berbasis Mikrokontroler" *JURNAL SISTEM KOMPUTER TGD.*, vol. 2, no. 5, pp. 1–10, 2023.
- [12] Feddy Wanditya Setiawan, "SISTEM PEMANTAUAN TEMPERATURMESIN BERBASIS ARDUINO PADA MOTOR MATIC 150cc UNTUK PERAWATAN OPTIMAL" *JURNAL ILMIAH TEKNIK MESIN.*, vol. 6, no. 1, pp. 1–10, 2023.