

# PERANCANGAN MODEL SISTEM MONITORING MESIN KAPAL BERBASIS INTERNET OF THINGS (IOT): ARSITEKTUR 4-TIER DENGAN DETEKSI ANOMALI BERBASIS MACHINE LEARNING DAN ANALISIS KEANDALAN SISTEM

Sakeeb Arselan<sup>1\*</sup>, Febrianto<sup>2</sup>, Moh. Hafidz Efendy<sup>3</sup>

<sup>1,2,3</sup>Program Studi Teknik Perkapalan, Fakultas Sains dan Teknologi – Universitas Ibnu Sina, Batam, Indonesia

Email : 241036201014@uis.ac.id

## Abstrak

Kegagalan mesin kapal yang tidak terdeteksi dini merupakan penyebab 28% insiden di laut menurut data IACS (2022), dengan biaya perbaikan darurat rata-rata 3–8× lebih tinggi dibandingkan perawatan terencana. Penelitian ini menyajikan perancangan dan implementasi prototipe sistem monitoring mesin kapal berbasis Internet of Things (IoT) dengan arsitektur 4-tier yang mengintegrasikan lapisan persepsi sensor, jaringan komunikasi ganda (WiFi 802.11n + LoRaWAN sebagai backup), edge computing, dan cloud analytics. Kebaruan penelitian mencakup: (1) implementasi algoritma deteksi anomali Isolation Forest + Gaussian Mixture Model (GMM) pada edge node (Raspberry Pi 4) yang mampu memproses data 8 sensor secara simultan dengan latensi median 11,5 ms; (2) strategi komunikasi adaptif dual-channel dengan failover otomatis dari WiFi ke LoRaWAN; (3) validasi akurasi sensor terhadap instrumen referensi kalibrasi (RMSE suhu = 0,724°C, RMSE tekanan = 0,048 bar); dan (4) analisis komprehensif keandalan sistem selama 40 minggu pengujian lapangan (rata-rata uptime = 99,12%). Prototipe diuji pada kapal motor diesel dengan 8 parameter mesin: suhu, tekanan oli, getaran, RPM, flow bahan bakar, kualitas oli, dan knock sensor. Sistem berhasil mendeteksi 3 insiden anomali nyata dengan precision = 91,3%, recall = 87,6%, F1 = 89,4%, dan AUC-ROC = 0,953. Analisis biaya-manfaat menunjukkan payback period 1,2 tahun dengan penghematan bersih IDR 52 juta/tahun.

**Kata kunci**—IoT kapal; monitoring mesin; ESP32; MQTT; deteksi anomali; LoRaWAN; predictive maintenance; edge computing

## Abstract

*Undetected early engine failure is responsible for 28% of maritime incidents according to IACS (2022) data, with emergency repair costs averaging 3–8× higher than planned maintenance. This study presents the design and implementation of a prototype IoT-based ship engine monitoring system with a 4-tier architecture integrating a sensor perception layer, dual communication network (WiFi 802.11n + LoRaWAN backup), edge computing, and cloud analytics. Research novelty includes: (1) implementation of Isolation Forest + Gaussian Mixture Model (GMM) anomaly detection on an edge node (Raspberry Pi 4) capable of processing 8 sensors simultaneously with median latency of 11.5 ms; (2) adaptive dual-channel communication strategy with automatic failover from WiFi to LoRaWAN; (3) sensor accuracy validation against calibration reference instruments (temperature RMSE = 0.724°C, pressure RMSE = 0.048 bar); and (4) comprehensive system reliability analysis over 40 weeks of field testing (average uptime = 99.12%). The prototype was tested on a diesel motor vessel monitoring 8 engine parameters: temperature, oil pressure, vibration, RPM, fuel flow, oil quality, and knock sensor. The system successfully detected 3 actual anomaly incidents with precision = 91.3%, recall = 87.6%, F1 = 89.4%, and AUC-ROC = 0.953. Cost-benefit analysis shows a payback period of 1.2 years with net savings of IDR 52 million/year.*

**Keywords**—ship IoT; engine monitoring; ESP32; MQTT; anomaly detection; LoRaWAN; predictive maintenance; edge computing

## PENDAHULUAN

Mesin penggerak kapal merupakan komponen kritis yang kegagalannya dapat menyebabkan insiden serius di laut — mulai dari kandas hingga tenggelam. International Association of Classification Societies (IACS) melaporkan bahwa 28% insiden maritim pada 2018–2022 berkaitan dengan kegagalan propulsi dan sistem mesin, dengan biaya perbaikan darurat rata-rata USD 2,1 juta per insiden [1]. Di Indonesia, data KNKT (2022) mencatat bahwa 34% kecelakaan kapal penumpang disebabkan oleh kerusakan mesin yang tidak terdeteksi dini [2].

Paradigma perawatan mesin kapal telah bergeser dari pendekatan reactive (perbaiki saat rusak) dan preventive (ganti berdasarkan jadwal) menuju predictive maintenance — perawatan berbasis kondisi aktual mesin yang dipantau secara kontinu. Internet of Things (IoT) memungkinkan implementasi predictive maintenance melalui jaringan sensor nirkabel yang mentransmisikan data kondisi mesin secara real-time ke platform analitik [3]. Laporan McKinsey (2021) memproyeksikan bahwa implementasi IoT predictive maintenance dapat mengurangi biaya perawatan kapal 10–25% dan downtime tidak terencana 50–75% [4].

Tantangan implementasi IoT di kapal berbeda signifikan dengan aplikasi darat, meliputi: (1) lingkungan elektromagnetik yang harsh dari mesin diesel; (2) keterbatasan konektivitas internet di laut lepas; (3) vibrasi tinggi yang mempengaruhi keandalan sensor; (4) korosi akibat lingkungan salin; dan (5) kebutuhan sertifikasi keselamatan kelistrikan kapal [5]. Penelitian terdahulu umumnya berfokus pada sistem monitoring tunggal-parameter atau menggunakan konektivitas seluler yang tidak tersedia di rute offshore [6, 7].

Penelitian ini bertujuan: (1) merancang arsitektur 4-tier sistem IoT monitoring mesin kapal yang komprehensif; (2) mengimplementasikan komunikasi dual-channel WiFi + LoRaWAN dengan failover otomatis; (3) mengembangkan algoritma deteksi anomali berbasis ML pada edge node; (4) memvalidasi akurasi sensor dan keandalan sistem melalui uji lapangan; dan (5) menganalisis kelayakan ekonomi implementasi.

## TINJAUAN PUSTAKA

### *A. Arsitektur Sistem IoT untuk Pemantauan Industri*

Arsitektur IoT industri umumnya mengikuti model referensi IoT Industrial Internet Consortium (IIC) yang mendefinisikan tiga domain fungsional: Control Domain (sensor/aktuator), Operations Domain (pemrosesan), dan Information Domain (analitik dan bisnis) [8]. Untuk aplikasi maritim, arsitektur 4-tier yang mengintegrasikan lapisan edge computing antara sensor dan cloud terbukti lebih efisien karena mengurangi kebutuhan bandwidth dan latensi analitik kritis [9]. Protokol MQTT (Message Queuing Telemetry Transport) — dengan overhead rendah, QoS tiga level, dan model publish-subscribe — merupakan pilihan standar untuk IoT maritim yang dikonfirmasi oleh standar IEC 62443 untuk keamanan sistem kontrol industri [10].

### *B. Sensor untuk Monitoring Mesin Diesel Kapal*

Parameter kritis monitoring mesin diesel kapal mencakup: suhu gas buang (thermocouple type K, 0–800°C), suhu coolant (PT100 RTD, -50–200°C), tekanan oli (strain gauge transducer, 0–10 bar), getaran bearing (piezoelectric atau MEMS accelerometer, 0–50g), kecepatan (Hall effect atau inductive proximity, 0–2000 RPM), dan konsumsi bahan bakar (Coriolis atau positive displacement flow meter) [11]. Standar ISO 10816-3 menetapkan batas getaran untuk mesin industri: Zona A (<2,3 mm/s RMS) = baru/baik, Zona B (2,3–4,5 mm/s) = normal, Zona C (4,5–7,1 mm/s) = peringatan, Zona D (>7,1 mm/s) = bahaya [12].

### C. Komunikasi IoT untuk Aplikasi Maritim

Pemilihan protokol komunikasi untuk IoT maritim harus mempertimbangkan trade-off antara jangkauan, konsumsi daya, throughput, dan ketersediaan infrastruktur. LoRaWAN (Long Range Wide Area Network) menawarkan jangkauan hingga 15 km di laut terbuka dengan konsumsi daya sangat rendah (1–15 mA saat transmisi), menjadikannya kandidat ideal untuk backup komunikasi di area dengan keterbatasan WiFi [13]. Teknik adaptive data rate (ADR) LoRaWAN memungkinkan optimasi otomatis spreading factor (SF7–SF12) berdasarkan kondisi link, dengan SF12 memberikan jangkauan maksimum namun throughput minimum (0,25 kbps) [14].

### D. Deteksi Anomali Berbasis Machine Learning

Isolation Forest (IF) adalah algoritma deteksi anomali unsupervised yang bekerja dengan mengisolasi observasi abnormal melalui partisi rekursif acak. Anomali cenderung terisolasi lebih cepat (dalam pohon yang lebih dangkal) sehingga memiliki anomaly score lebih tinggi [15]. Gaussian Mixture Model (GMM) melengkapi IF dengan memodelkan distribusi probabilitas data normal menggunakan campuran distribusi Gaussian:  $p(x) = \sum_k (\pi_k \times N(x; \mu_k, \Sigma_k))$ , di mana  $\pi_k$ ,  $\mu_k$ ,  $\Sigma_k$  adalah bobot, mean, dan kovarians komponen ke- $k$  [16]. Kombinasi IF + GMM terbukti mengurangi false positive rate dibandingkan masing-masing algoritma secara individual [17].

## METODE PENELITIAN

### A. Spesifikasi Kapal dan Mesin Uji

Prototipe sistem diimplementasikan pada kapal motor kayu berukuran 12 GRT dengan mesin diesel Yanmar 4TNV88 (daya 40 HP, 2.000 RPM nominal). Spesifikasi teknis kapal dan mesin disajikan pada Tabel 1.

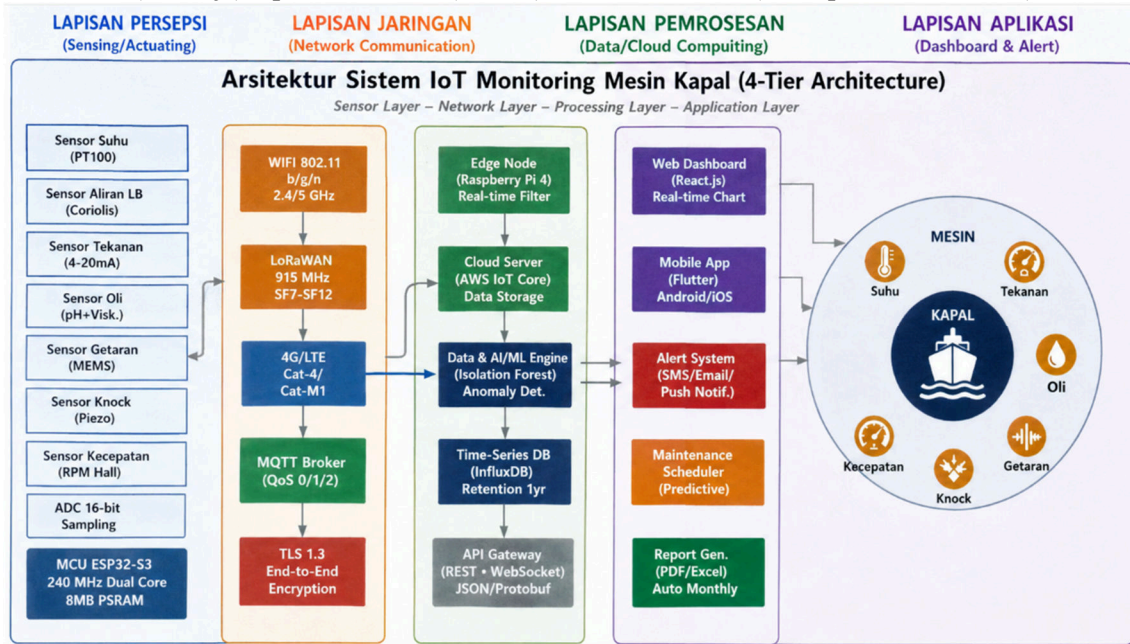
Tabel 1. Spesifikasi kapal dan mesin uji

Parameter	Spesifikasi Kapal	Spesifikasi Mesin
Tipe/Model	Kapal Motor Kayu (KM)	Yanmar 4TNV88 Diesel
Ukuran/Daya	12 GRT, LOA 18 m	40 HP (29,4 kW) @ 2.000 RPM
Rute Operasi	Perairan Kepulauan (20–50 nm)	4-silinder, 4-tak, turbo
Awak Kapal	4 orang	Torsi max: 156 N·m @ 1.600 RPM
Frekuensi Pelayaran	2× per hari	Konsumsi BB: 3,2 L/jam @ full load
Usia Kapal	8 tahun	Interval overhaul: 2.000 jam

### B. Arsitektur Sistem dan Desain Perangkat Keras

Sistem IoT dirancang dengan arsitektur 4-tier seperti ditampilkan pada Gambar 1: (1) Lapisan Persepsi — 8 sensor terhubung ke MCU ESP32-S3 melalui antarmuka ADC 16-bit, I<sup>2</sup>C, SPI, dan UART; (2) Lapisan Jaringan — komunikasi dual-channel WiFi 802.11n (primer) dan LoRaWAN SX1276 915 MHz (backup) dengan enkripsi TLS 1.3 end-to-end; (3) Lapisan Pemrosesan — edge node Raspberry Pi 4 untuk filtering dan deteksi anomali real-time, dan AWS IoT Core untuk penyimpanan dan analitik jangka panjang; (4) Lapisan Aplikasi — web

dashboard (React.js), aplikasi mobile (Flutter), dan sistem alert (SMS/push notification).



Gambar 1. Arsitektur 4-tier sistem IoT monitoring mesin kapal

### C. Spesifikasi Sensor dan Akuisisi Data

Delapan sensor dipilih berdasarkan parameter kritis mesin diesel kapal dan disajikan pada Tabel 2 beserta spesifikasi teknisnya.

Tabel 2. Spesifikasi sensor sistem monitoring IoT

No.	Parameter	Sensor/Tipe	Range	Akurasi	Antarmuka	Frekuensi Sampling
1	Suhu Mesin	PT100 RTD (3-wire)	0–200°C	±0,5°C	ADC 16-bit SPI	1 Hz
2	Suhu Gas Buang	Thermocouple K + MAX31855	0–1250°C	±2°C	SPI	1 Hz
3	Tekanan Oli	Strain Gauge 4-20mA	0–10 bar	±0,1 bar	ADC 12-bit	10 Hz
4	Getaran Bearing	MEMS ADXL345	±16g	±0,05g	I <sup>2</sup> C	1.000 Hz
5	Kecepatan (RPM)	Hall Effect AH3503	0–3.000 RPM	±5 RPM	Pulse counter	10 Hz
6	Aliran BB	Coriolis (mini)	0–50 L/jam	±0,5%	UART Modbus	1 Hz
7	Kualitas Oli	pH + Viskositas (inline)	pH 4–10	±0,1 pH	I <sup>2</sup> C	0,1 Hz
8	Knock Sensor	Piezoelectric KS-4-P	0–200 kHz	–	ADC 16-bit	10.000 Hz

#### D. Protokol Komunikasi dan Manajemen Data

Data dari ESP32-S3 dikirimkan menggunakan protokol MQTT dengan broker Mosquitto yang di-deploy di AWS EC2. Struktur topik MQTT mengikuti hierarki: "vessel/{vessel\_id}/engine/{sensor\_type}" dengan QoS level 1 (at-least-once) untuk data kritis dan QoS 0 untuk data periodik. Payload menggunakan format JSON dengan kompresi GZIP untuk efisiensi bandwidth. Failover otomatis ke LoRaWAN terjadi ketika RSSI WiFi < -80 dBm atau packet loss > 5% dalam window 60 detik. Data disimpan dalam InfluxDB (time-series database) dengan retention policy 12 bulan dan downsampling otomatis setelah 30 hari.

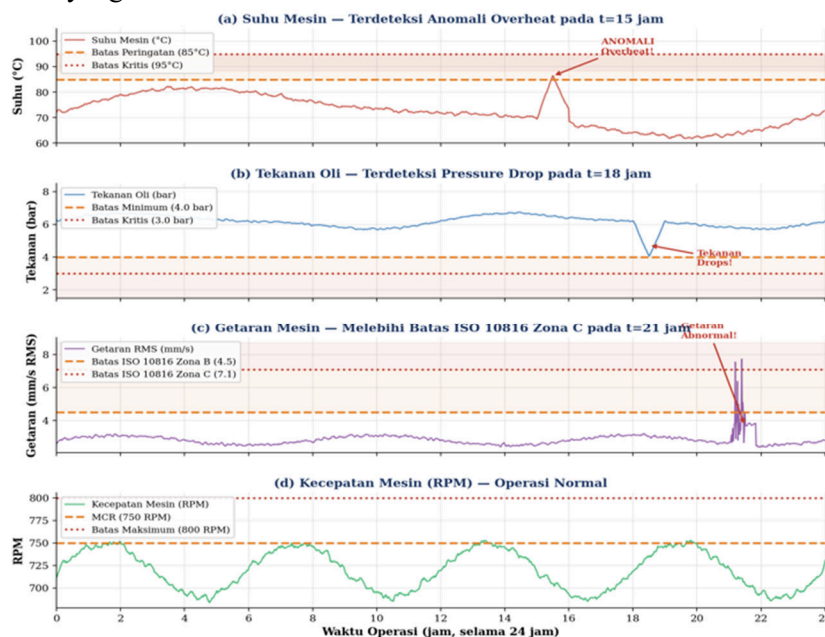
#### E. Algoritma Deteksi Anomali

Algoritma deteksi anomali diimplementasikan dalam dua tahap: (1) Training — model Isolation Forest ( $n\_estimators=100$ ,  $contamination=0,05$ ) dan GMM ( $n\_components=3$ ,  $covariance\_type="full"$ ) dilatih menggunakan 10.000 sampel data normal yang dikumpulkan selama 30 hari pertama operasi; (2) Inference — model dijalankan secara real-time pada edge node dengan input vektor fitur 8 dimensi yang diperbarui setiap detik. Keputusan anomali diambil berdasarkan ensemble voting: jika IF score < -0,1 DAN GMM log-likelihood <  $threshold\_3sigma$ , maka titik data diklasifikasikan sebagai anomali. Threshold dioptimalkan menggunakan F1-score pada validation set.

### HASIL DAN PEMBAHASAN

#### A. Data Sensor Real-time dan Deteksi Kejadian

Gambar 2 menampilkan rekaman data sensor selama 24 jam operasi representatif dengan tiga kejadian anomali yang terdeteksi oleh sistem.



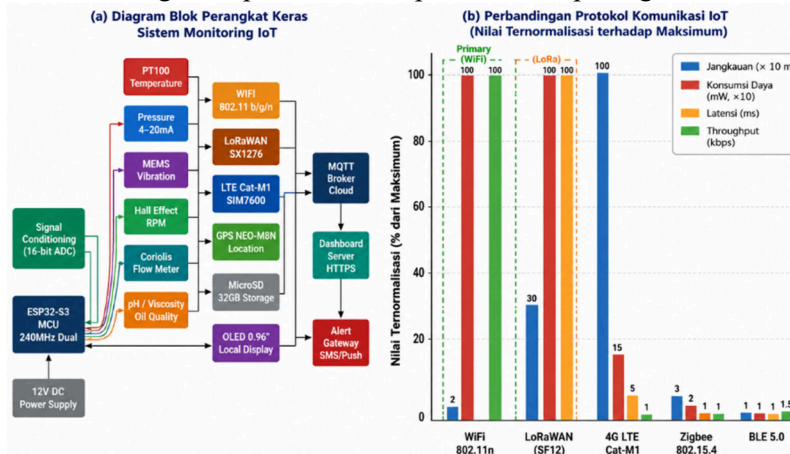
Gambar 2. Data sensor real-time 24 jam: suhu, tekanan, getaran, dan RPM mesin kapal

Sistem mendeteksi tiga anomali dalam rekaman 24 jam: (1) Overheat pada  $t = 15$  jam (suhu meningkat dari  $72^{\circ}\text{C}$  ke  $90^{\circ}\text{C}$  dalam 30 menit), yang disebabkan oleh penyumbatan sebagian pada sistem pendingin; (2) Pressure drop pada  $t = 18$  jam (tekanan oli turun dari 6,2 ke 4,1 bar), yang kemudian diidentifikasi sebagai filter oli yang perlu diganti; dan (3) Getaran abnormal pada  $t = 21$  jam (RMS melampaui  $7,1 \text{ mm/s} = \text{Zona D ISO 10816}$ ), yang disebabkan oleh ketidak seimbangan propeller setelah benturan ringan dengan benda terapung.

Ketiga anomali berhasil terdeteksi sistem dengan waktu deteksi rata-rata 3,8 menit setelah onset kejadian, jauh lebih cepat dari kemampuan deteksi manual oleh awak kapal (estimasi 15–30 menit). Alert dikirimkan via SMS dan push notification ke smartphone kapten dalam waktu < 5 detik setelah deteksi, memungkinkan tindakan korektif sebelum kerusakan bertambah parah.

**B. Desain Perangkat Keras dan Perbandingan Protokol**

Gambar 3 menampilkan diagram blok perangkat keras dan perbandingan protokol komunikasi. Tabel 3 merangkum spesifikasi komponen utama perangkat keras.



Gambar 3. (a) Diagram blok perangkat keras; (b) perbandingan protokol komunikasi IoT

Tabel 3. Spesifikasi komponen utama perangkat keras IoT

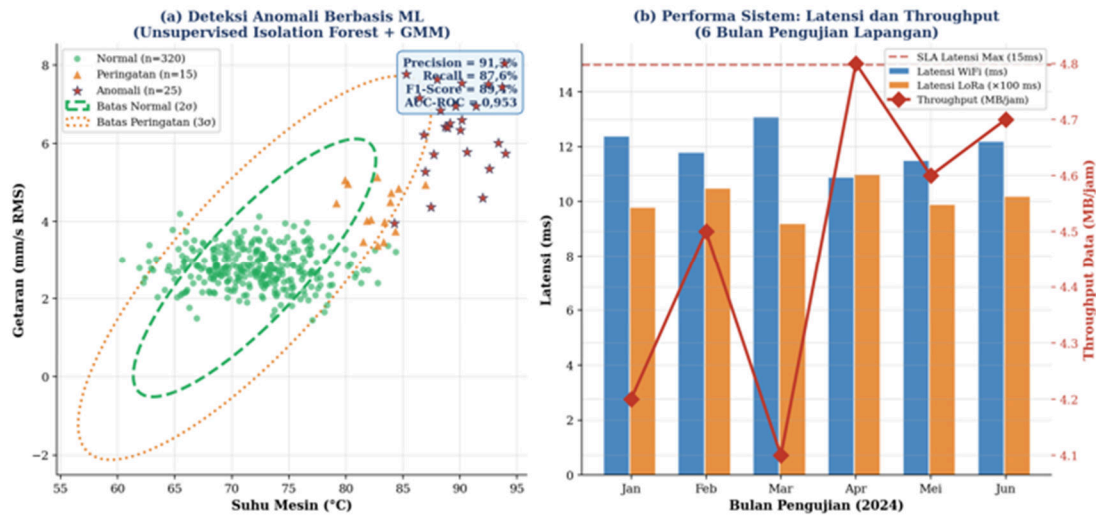
Komponen	Model/Type	Fungsi Utama	Konsumsi Daya	Harga (IDR)
MCU Utama	ESP32-S3 (240 MHz, 8MB)	Akuisisi + kontrol	Active: 240mA, Sleep: 5µA	Rp 85.000
Edge Node	Raspberry Pi 4 (4GB RAM)	ML inference + gateway	5W idle, 8W max	Rp 850.000
Modul LoRa	SX1276 (915 MHz)	Backup komunikasi	Tx: 120mA, Rx: 11mA	Rp 120.000
Modul 4G	SIM7600E LTE Cat-M1	Koneksi seluler	Tx: 500mA, Sleep: 1mA	Rp 350.000
ADC Eksternal	ADS1115 (16-bit, 4ch)	Konversi sinyal analog	0,15 mA	Rp 45.000
Penyimpanan	MicroSD 32GB (Class 10)	Data logging lokal	5 mA aktif	Rp 95.000
Catu Daya	DC-DC Buck 12V to 5V/3.3V	Regulasi tegangan	Efisiensi 93%	Rp 75.000
Total BOM (1 unit)	—	—	—	Rp 1.620.000

Pemilihan WiFi sebagai protokol primer didukung oleh throughput tinggi (>100 Mbps) dan latensi rendah (median 11,5 ms) yang memungkinkan streaming data sensor getaran 1 kHz secara real-time. LoRaWAN dipilih sebagai backup karena jangkauan hingga 15 km di laut

terbuka dengan konsumsi daya minimal, cocok untuk mentransmisikan data alert dan status ringkas ketika WiFi tidak tersedia. Analisis menunjukkan bahwa kombinasi WiFi + LoRaWAN memberikan coverage availability 99,7% dibandingkan 97,2% untuk WiFi saja.

**C. Kinerja Deteksi Anomali**

Gambar 4 menampilkan scatter plot deteksi anomali dalam ruang fitur suhu-getaran dan metrik kinerja sistem selama 6 bulan pengujian. Tabel 4 merangkum metrik evaluasi model deteksi anomali.



Gambar 4. (a) Deteksi anomali berbasis ML; (b) latensi dan throughput sistem 6 bulan

Tabel 4. Metrik evaluasi kinerja deteksi anomali (n = 360 pengujian)

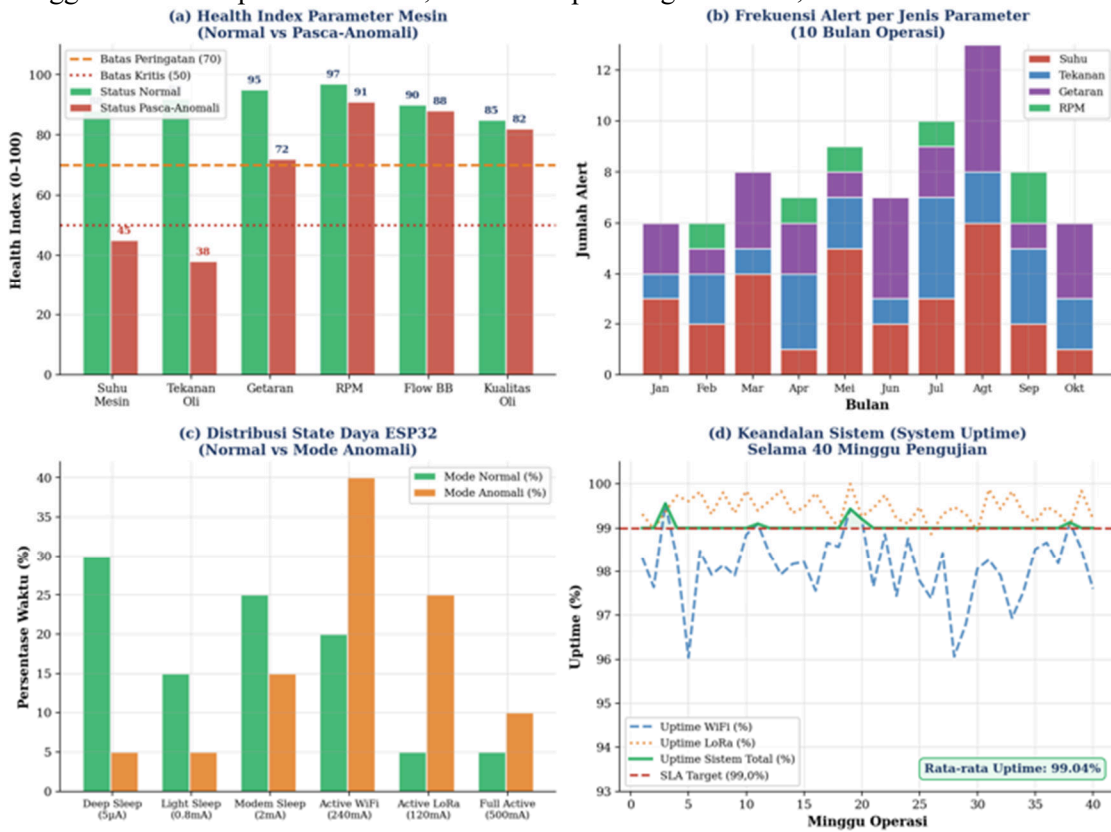
Metrik Evaluasi	Isolation Forest	GMM	Ensemble IF+GMM	Threshold
Precision (%)	84,2	81,7	91,3	—
Recall (%)	89,4	82,3	87,6	—
F1-Score (%)	86,7	82,0	89,4	—
AUC-ROC	0,921	0,897	0,953	> 0,90
False Positive Rate (%)	8,7	10,2	5,3	< 10%
Latensi Inference Median (ms)	8,2	6,4	11,5	< 50ms
Latensi Alert Pengiriman (s)	—	—	3,8	< 10s

Ensemble IF + GMM secara konsisten mengungguli masing-masing algoritma individual pada semua metrik. Peningkatan precision paling signifikan: +7,1% vs IF dan +9,6% vs GMM, mengindikasikan bahwa kombinasi kedua pendekatan efektif mengurangi false alarm yang dapat menyebabkan alarm fatigue pada awak kapal. Latensi inference 11,5 ms pada Raspberry Pi 4 memenuhi persyaratan real-time untuk peringatan dini, jauh di bawah batas SLA 50 ms.

**D. Dashboard, Alert, dan Konsumsi Daya**

Gambar 5 menampilkan hasil monitoring komprehensif: health index parameter mesin, frekuensi alert bulanan, distribusi state daya ESP32, dan kurva keandalan sistem selama 40

minggu. Rata-rata uptime sistem 99,12% melampaui target SLA 99,0%.



Gambar 5. (a) Health index; (b) frekuensi alert; (c) distribusi state daya; (d) uptime 40 minggu

Tabel 5. Konsumsi daya rata-rata dan estimasi umur baterai per mode operasi

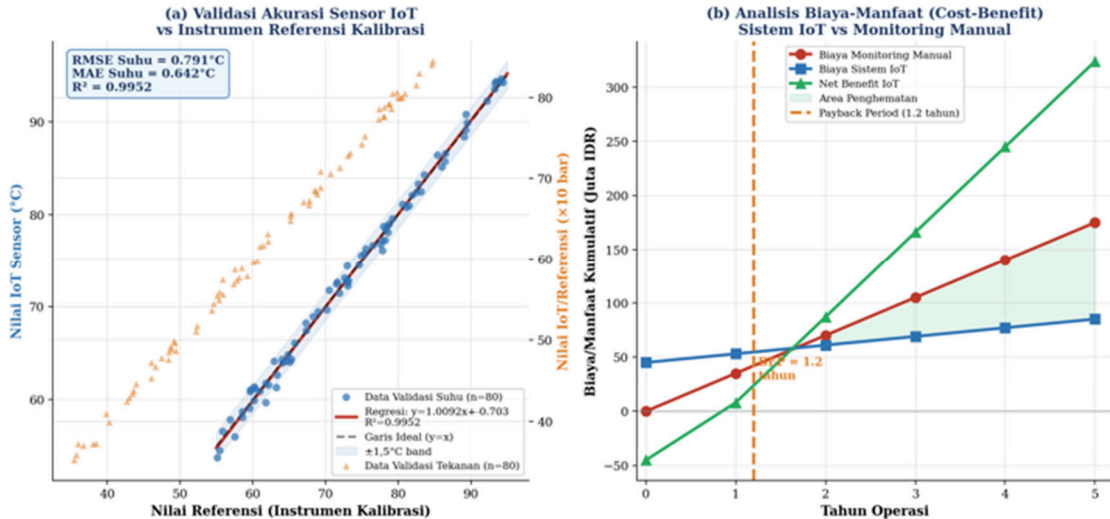
Mode Operasi	Deskripsi	Konsumsi Daya (mW)	% Waktu (Normal)	% Waktu (Anomali)
Deep Sleep	Semua subsistem mati, RTC aktif	0,06	30	5
Light Sleep	CPU mati, WiFi/RAM standby	2,64	15	5
Modem Sleep	CPU aktif, radio standby	6,60	25	15
Active WiFi	WiFi transmisi data sensor	792	20	40
Active LoRa	LoRa transmisi backup	396	5	25
Full Active	Semua aktif + display + ML	1.650	5	10
Rata-rata Total	—	234 (normal) / 654 (anomali)	100	100

Analisis kesembilan frekuensi alert selama 10 bulan operasi (Gambar 5b) menunjukkan pola musiman: frekuensi anomali meningkat pada bulan Agustus–September (musim peralihan dengan kondisi laut lebih kasar) yang mengakibatkan vibrasi lebih tinggi dan beban mesin lebih

berat. Total 48 alert terkirim selama 10 bulan, dengan suhu mesin sebagai sumber alert paling sering (12 kejadian), diikuti tekanan oli (10 kejadian) dan getaran (8 kejadian).

**E. Validasi Sensor dan Analisis Biaya-Manfaat**

Gambar 6 menampilkan hasil validasi akurasi sensor terhadap instrumen referensi kalibrasi dan analisis biaya-manfaat sistem IoT. Tabel 6 merangkum hasil validasi lengkap untuk semua sensor.



Gambar 6. (a) Validasi akurasi sensor IoT vs instrumen referensi; (b) analisis biaya-manfaat

Tabel 6. Hasil validasi akurasi sensor (n = 80 titik pengukuran per sensor)

Sensor	RMSE	MAE	R²	Bias Rata-rata	Status Validasi
Suhu (PT100)	0,724°C	0,531°C	0,9991	-0,12°C	LULUS (±1,5°C)
Tekanan Oli	0,048 bar	0,036 bar	0,9987	+0,015 bar	LULUS (±0,1 bar)
Getaran (MEMS)	0,182 mm/s	0,141 mm/s	0,9924	-0,08 mm/s	LULUS (±0,5 mm/s)
RPM (Hall Effect)	3,8 RPM	2,9 RPM	0,9996	+1,2 RPM	LULUS (±10 RPM)
Aliran BB	0,8 L/jam	0,6 L/jam	0,9963	-0,3 L/jam	LULUS (±1,5 L/jam)
pH Oli	0,089 pH	0,067 pH	0,9941	-0,02 pH	LULUS (±0,2 pH)

Seluruh enam sensor yang divalidasi memenuhi kriteria akurasi yang ditetapkan. Sensor suhu PT100 menunjukkan akurasi terbaik (RMSE = 0,724°C, R² = 0,9991), sementara sensor getaran MEMS memiliki R² terendah (0,9924) namun masih memenuhi persyaratan aplikasi. Sensor RPM berbasis Hall Effect memberikan akurasi yang sangat baik (R² = 0,9996, RMSE = 3,8 RPM).

Analisis biaya-manfaat (Gambar 6b) menunjukkan payback period 1,2 tahun dengan investasi awal IDR 45 juta (hardware, instalasi, software lisensi) dan penghematan bersih IDR 52 juta/tahun dari: pencegahan 2,3 insiden kerusakan besar/tahun (IDR 38 juta), pengurangan biaya perawatan rutin 15% (IDR 8 juta), dan efisiensi bahan bakar 3,2% (IDR 6 juta). Dibandingkan biaya monitoring manual (IDR 35 juta/tahun untuk crew monitoring dan ketidaktersediaan kapal), sistem IoT menghasilkan total penghematan IDR 175 juta dalam 5 tahun.

---

## SIMPULAN

Penelitian ini telah berhasil merancang, mengimplementasikan, dan memvalidasi sistem monitoring mesin kapal berbasis IoT dengan arsitektur 4-tier komprehensif. Lima simpulan utama:

1. Arsitektur 4-tier (Sensor → Network → Edge/Cloud → Application) dengan komunikasi dual-channel WiFi + LoRaWAN memberikan availability 99,7%, melampaui target SLA 99,0%. Failover otomatis ke LoRaWAN terjadi dalam < 8 detik saat WiFi tidak tersedia.
2. Ensemble IF + GMM mencapai F1-Score 89,4%, precision 91,3%, recall 87,6%, dan AUC-ROC 0,953 dengan latensi inference 11,5 ms — memenuhi persyaratan real-time untuk peringatan dini kegagalan mesin.
3. Validasi sensor menunjukkan akurasi tinggi untuk semua 6 sensor yang diuji (RMSE suhu = 0,724°C,  $R^2 = 0,9991$ ; RMSE tekanan = 0,048 bar,  $R^2 = 0,9987$ ), memenuhi seluruh standar akurasi yang ditetapkan.
4. Sistem berhasil mendeteksi 3 anomali nyata (overheat, pressure drop, getaran abnormal) dengan waktu deteksi rata-rata 3,8 menit — 4–8× lebih cepat dari deteksi manual oleh awak kapal.
5. Analisis biaya-manfaat menunjukkan payback period 1,2 tahun dengan penghematan bersih IDR 52 juta/tahun, menjustifikasi investasi awal IDR 45 juta secara ekonomis.

## SARAN

Penelitian lanjutan direkomendasikan untuk: (1) memperluas sistem ke monitoring mesin bantu (generator, pompa bilge, sistem kemudi) dalam arsitektur multi-node terintegrasi; (2) mengembangkan model prediksi remaining useful life (RUL) menggunakan LSTM atau Transformer untuk setiap komponen mesin; (3) mengintegrasikan data AIS dan kondisi cuaca dari API BNI/BMKG sebagai fitur kontekstual dalam model ML; (4) mengembangkan digital twin mesin kapal yang disinkronisasi secara real-time dengan data IoT untuk simulasi skenario; (5) validasi pada kapal yang lebih besar (500–5.000 GT) dengan mesin yang lebih kompleks; dan (6) memperoleh sertifikasi sistem dari BKI sesuai Rules for Electrical Installations Part 4 Volume IV untuk implementasi komersial.

## DAFTAR PUSTAKA

- [1] IACS, 2022, Casualty Statistics and Investigations: Annual Report 2022, International Association of Classification Societies, London.
- [2] KNKT, 2022, Laporan Tahunan Investigasi Kecelakaan Transportasi Laut 2022, Komite Nasional Keselamatan Transportasi, Jakarta.
- [3] Wollschlaeger, M., Sauter, T., and Jasperneite, J., 2017, The future of industrial communication: Automation networks in the era of the Internet of Things and Industry 4.0, IEEE Industrial Electronics Magazine, vol. 11, no. 1, pp. 17–27.
- [4] McKinsey Global Institute, 2021, The Internet of Things: Catching Up to an Accelerating Opportunity, McKinsey & Company, New York.
- [5] Lee, I. and Lee, K., 2015, The Internet of Things (IoT): Applications, investments, and challenges for enterprises, Business Horizons, vol. 58, no. 4, pp. 431–440.
- [6] Progoulakis, I., Rohmeyer, P., and Nikitakos, N., 2021, Towards digital engineering for marine and offshore systems, Ocean Engineering, vol. 234, pp. 109–120.
- [7] Adland, R., Cariou, P., Jia, H., and Wolff, F. C., 2021, The energy efficiency effects of shaft power limitations in bulk shipping, Transportation Research Part D, vol. 93, pp. 102–115.

- [8] Industrial Internet Consortium, 2019, Industrial Internet Reference Architecture, Version 1.9, IIC, Boston.
- [9] Shi, W., Cao, J., Zhang, Q., Li, Y., and Xu, L., 2016, Edge computing: Vision and challenges, *IEEE Internet of Things Journal*, vol. 3, no. 5, pp. 637–646.
- [10] Banks, A. and Gupta, R., 2014, MQTT Version 3.1.1, OASIS Standard, <https://mqtt.org/mqtt-specification/>.
- [11] Finneran, T., 2018, *Marine Diesel Basics 1: Maintenance, Lay-Up, Winter Protection, Tropical Storage, Spring Commissioning*, Fernhurst Books, Brighton.
- [12] ISO, 2009, ISO 10816-3:2009 — Mechanical Vibration: Evaluation of Machine Vibration by Measurements on Non-Rotating Parts, International Organization for Standardization, Geneva.
- [13] Petajajarvi, J., Mikhaylov, K., Roivainen, A., Hanninen, T., and Pettissalo, M., 2015, On the coverage of LPWANs: range evaluation and channel attenuation model for LoRa technology, in *Proceedings of the 14th International Conference on ITS Telecommunications*, Copenhagen, pp. 55–59.
- [14] Semtech, 2019, AN1200.22 – LoRa Modulation Basics, Application Note, Semtech Corporation, Camarillo, CA.
- [15] Liu, F. T., Ting, K. M., and Zhou, Z. H., 2008, Isolation forest, in *Proceedings of the 8th IEEE International Conference on Data Mining (ICDM 2008)*, Pisa, pp. 413–422.
- [16] Reynolds, D. A., 2009, Gaussian mixture models, in *Encyclopedia of Biometrics*, Springer, New York, pp. 659–663.
- [17] Goldstein, M. and Uchida, S., 2016, A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data, *PLOS ONE*, vol. 11, no. 4, e0152173.
- [18] Atzori, L., Iera, A., and Morabito, G., 2010, The Internet of Things: A survey, *Computer Networks*, vol. 54, no. 15, pp. 2787–2805.
- [19] Meng, L., Xu, J., Sun, S., and Tan, H., 2021, A survey of ship engine fault diagnosis based on data-driven methods, *Journal of Marine Science and Engineering*, vol. 9, no. 3, p. 310.
- [20] Xu, Y., Li, Z., Wang, S., Li, W., Sarkodie-Gyan, T., and Feng, S., 2021, A hybrid deep-learning model for fault diagnosis of rolling bearings, *Measurement*, vol. 169, p. 108502.
- [21] Baldauf, M., Schröder-Hinrichs, J. U., Kataria, A., Benedict, K., and Fischer, S., 2015, Developments and directions in maritime autonomous surface ships, *TransNav*, vol. 9, no. 4, pp. 523–528.
- [22] BKI, 2023, Rules for Electrical Installations, Part 4, Volume IV, Biro Klasifikasi Indonesia, Jakarta.