

DIAGNOSIS KERUSAKAN PADA SISTEM REFRIGERASI MENGUNAKAN SENSOR BIAYA RENDAH DAN KLASIFIKASI BERBASIS PEMBELAJARAN

Baso Alauddin^{1*}, Haslinda HS², Muh. Ilham Nur³, Muhammad Arham⁴, A. Aswin Salam⁵

^{1,2,3}Universitas Pejuang Republik Indonesia

⁴Universitas Patria Artha

⁵Politeknik Bosowa

*Corresponding Author Email: basoalauddin84@gmail.com

Abstrak

Sistem refrigerasi merupakan komponen penting dalam berbagai sektor seperti pendingin ruangan, transportasi makanan, dan sistem industri. Kinerja sistem ini sering menurun akibat berbagai jenis kerusakan seperti kebocoran refrigeran, penyumbatan ekspansi, atau penurunan performa kompresor. Penelitian ini mengusulkan metode diagnosis kerusakan berbasis **sensor biaya rendah** dan **algoritma pembelajaran mesin (Machine Learning)** untuk mendeteksi dan mengklasifikasikan jenis kesalahan secara real time. Data dikumpulkan menggunakan sensor suhu, tekanan, dan arus listrik yang terhubung dengan mikrokontroler ESP32. Data tersebut kemudian diolah menggunakan model **Random Forest**, **Support Vector Machine (SVM)**, dan **K-Nearest Neighbors (KNN)** untuk membandingkan akurasi klasifikasi. Hasil penelitian menunjukkan bahwa sistem berbasis sensor murah mampu mencapai akurasi diagnosis hingga 95% dengan waktu respon cepat dan biaya implementasi yang rendah. Temuan ini berpotensi digunakan untuk sistem monitoring preventif di sistem pendingin rumah tangga dan industri kecil.

Kata kunci: diagnosis kerusakan, sistem refrigerasi, sensor biaya rendah, pembelajaran mesin, klasifikasi.

1. Pendahuluan

Sistem refrigerasi kompresi uap merupakan teknologi kunci pada berbagai aplikasi, mulai dari lemari pendingin rumah tangga, cold storage, rantai dingin (cold chain) pangan, hingga sistem pendingin pada bangunan dan proses industri. Keandalan sistem refrigerasi berpengaruh langsung terhadap kualitas produk yang didinginkan, kenyamanan termal, serta efisiensi energi. Namun dalam praktiknya, sistem ini sering mengalami degradasi performa akibat faktor operasional dan lingkungan, seperti penurunan jumlah refrigeran, fouling pada kondensor, penyumbatan pada elemen ekspansi, kerusakan kompresor, hingga gangguan pada kipas dan aliran udara. Kerusakan-kerusakan tersebut biasanya terjadi secara bertahap (incipient faults) dan pada fase awal sulit terdeteksi, tetapi dapat menimbulkan dampak signifikan berupa peningkatan konsumsi daya, penurunan kapasitas pendinginan, kenaikan temperatur evaporator, dan percepatan keausan komponen. Di lapangan, diagnosis kerusakan sistem refrigerasi umumnya dilakukan melalui inspeksi teknisi menggunakan alat ukur manual seperti manifold gauge, termometer kontak, dan clamp meter serta interpretasi pengalaman untuk menilai kondisi tekanan dan suhu pada sisi hisap dan buang. Pendekatan ini memiliki beberapa keterbatasan: (1) ketergantungan pada keterampilan teknisi dan potensi subjektivitas interpretasi, (2) kebutuhan alat ukur tertentu yang relatif mahal untuk monitoring berkelanjutan, (3) tidak tersedianya data historis yang memadai untuk analisis tren, dan (4) sulitnya penerapan pemantauan kontinu pada skala rumah tangga maupun unit-unit kecil yang tersebar. Akibatnya, banyak sistem baru mendapatkan penanganan setelah kerusakan berkembang menjadi berat (fault berkembang menjadi failure), sehingga biaya perbaikan meningkat dan efisiensi energi semakin menurun.

Perkembangan Internet of Things (IoT), sensor berbiaya rendah, dan pembelajaran mesin (machine learning) membuka peluang untuk mengotomatisasi deteksi serta klasifikasi kerusakan pada

sistem refrigerasi secara lebih cepat dan ekonomis. Sensor suhu digital, sensor tekanan analog, serta sensor arus listrik kini tersedia dengan harga terjangkau dan dapat diintegrasikan dengan mikrokontroler seperti ESP32/Arduino untuk melakukan akuisisi data periodik. Di sisi lain, algoritma pembelajaran mesin mampu memetakan pola perubahan parameter operasi (misalnya temperatur kondensor/evaporator, tekanan sisi rendah/tinggi, dan arus kompresor) untuk mengidentifikasi kondisi normal maupun fault tertentu. Pendekatan data-driven semacam ini berpotensi menghadirkan sistem diagnosis dini (early warning system) yang dapat diterapkan pada unit refrigerasi skala kecil-menengah tanpa menambah biaya investasi yang besar. Walaupun demikian, sebagian penelitian fault diagnosis pada sistem refrigerasi/HVAC masih banyak menggunakan sensor industri, perangkat akuisisi data khusus, atau infrastruktur komputasi yang relatif mahal, sehingga penerapan di lapangan menjadi terbatas. Selain itu, masih terdapat tantangan dalam memanfaatkan data dari sensor murah yang cenderung memiliki noise, drift, dan ketidakpastian yang lebih tinggi. Tantangan lain mencakup pemilihan fitur (feature engineering) yang tepat, penanganan variasi beban dan kondisi lingkungan (ambient), serta kebutuhan model klasifikasi yang tetap akurat pada kondisi operasi yang dinamis. Oleh karena itu, diperlukan penelitian yang fokus pada perancangan sistem diagnosis kerusakan berbasis sensor biaya rendah, strategi pemrosesan data yang sederhana namun robust, serta evaluasi model machine learning yang relevan untuk implementasi praktis.

2. Metode Penelitian

Pengujian dilakukan di laboratorium Teknik Mesin Fakultas Teknik Universitas Pejuang Republik Indonesia, pada bulan Desember 2025

a. Rancangan Sistem

Sistem diagnosis kerusakan terdiri dari tiga lapisan:

1. Lapisan Akuisisi Data:

- Sensor suhu (DS18B20), tekanan (MPX5700AP), dan arus (ACS712).
- Mikrokontroler ESP32 digunakan untuk membaca data dan mengirim ke server melalui Wi-Fi.

2. Lapisan Pemrosesan Data:

- Data dikumpulkan setiap 5 detik, disimpan dalam basis data (CSV/MQTT Broker).
- Preprocessing dilakukan dengan normalisasi dan pembersihan outlier.

3. Lapisan Klasifikasi ML:

- Model ML dilatih dengan data kondisi normal dan empat jenis fault.
- Algoritma yang diuji: SVM, Random Forest, dan KNN.

b. Skenario Fault

Tabel 1. Menjelaskan Empat Jenis Kerusakan Yang Disimulasikan

Jenis Kerusakan	Gejala Utama	Parameter Terpengaruh
Refrigerant Leak	Tekanan rendah	P _{tekanan} ↓, T _{evap} ↑
Expansion Block	Suhu evaporator tinggi	ΔT besar
Condenser Fouling	Tekanan tinggi	P _{cond} ↑, T _{cond} ↑
Compressor Fault	Arus abnormal	I _{motor} ↑ atau ↓

c. Model Pembelajaran Mesin

Data dibagi menjadi 70% untuk pelatihan dan 30% untuk pengujian. Evaluasi dilakukan menggunakan **akurasi, precision, recall, dan F1-score**.

3. Hasil dan Pembahasan

a. Hasil Akuisisi Data

Sensor DS18B20 dan MPX5700AP menunjukkan kesalahan pengukuran <2%. Sistem mampu mengirimkan data stabil melalui Wi-Fi selama 8 jam pengujian tanpa kehilangan paket.

b. Hasil Klasifikasi

Tabel 1. Hasil klasifikasi

Model	Akurasi	Precision	Recall	F1-Score
SVM	92.4%	0.91	0.93	0.92
Random Forest	95.1%	0.95	0.96	0.95
KNN	90.8%	0.90	0.91	0.90

Model **Random Forest** memberikan hasil terbaik, karena mampu menangani data nonlinear dan variasi antar sensor.

c. Analisis Waktu Respon dan Konsumsi Daya

Waktu diagnosis rata-rata <2 detik per siklus, dengan total konsumsi daya sistem 1,2 W. Hal ini menunjukkan sistem cocok untuk implementasi portabel dan low-power.

4. Penutup

a. Kesimpulan

Dari Penelitian ini berhasil mengembangkan sistem diagnosis kerusakan pada sistem refrigerasi berbasis sensor murah dan machine learning hasil menunjukkan bahwa sistem mampu mendeteksi empat jenis kesalahan utama.

1. Model **Random Forest** mencapai akurasi hingga **95%**.
2. Dapat diimplementasikan sebagai early warning system untuk industri kecil, cold storage, dan HVAC rumah tangga

b. Saran

Penelitian lanjutan disarankan untuk integrasi edge computing dan pengujian lebih banyak variasi refrigeran dan kompresor.

Referensi:

- [1] Yang, J., et al. "Fault Detection in Refrigeration Systems Using SVM," *Energy and Buildings*, vol. 183, pp. 35–45, 2019.
- [2] Zhang, X., et al. "Intelligent Diagnosis of HVAC Faults Using Random Forest," *Applied Energy*, vol. 261, 2020.
- [3] Kim, J., and Lee, S., "IoT-Based Monitoring of Cooling Systems Using Low-Cost Sensors," *Sensors*, vol. 22, no. 4, 2022.
- [4] Li, P., et al., "Data-Driven Fault Detection for Air Conditioners," *IEEE Access*, vol. 9, pp. 1123–1136, 2021.

- [5] Su, H., and Wang, M., “Feature Selection in Fault Diagnosis Using Machine Learning,” *Energy Reports*, vol. 7, 2021.