

Pemeliharaan Prediktif Berbasis ANFIS untuk Perangkat EKG Portabel Menggunakan Masukan Multi-Sensor

ANFIS-Based Predictive Maintenance for Portable ECG Devices Using Multi-Sensor Input

Agus Supriyanto^{1,2}, Arief Marwanto³

¹Teknologi Elektro Medis, Universitas Widya Husada Semarang, Jl. Subali Raya No.12, Krapyak, Kec. Semarang Barat, Kota Semarang, Jawa Tengah 50146

²Magister Teknik Elektro, Fakultas Teknologi Industri, Universitas Islam Sultan Agung, Jl. Kaligawe Raya No. Km. 4, Terboyo Kulon, Kec. Genuk, Kota Semarang, Jawa Tengah 50112

Alamat korespondensi: gusfirdaus@gmail.com

Abstrak

Perkembangan peralatan medis portabel seperti *Electrocardiograph* (ECG) di Rumah Sakit tipe C menghadapi tantangan signifikan dalam hal pemeliharaan preventif akibat keterbatasan data historis dan ketidakmampuan metode konvensional dalam memodelkan hubungan non-linear antara parameter operasional dengan risiko kegagalan. Penelitian ini mengusulkan kerangka kerja *predictive maintenance* berbasis *Adaptive Neuro-Fuzzy Inference System* (ANFIS) dengan integrasi multi-sensor yang mencakup suhu, kelembaban, durasi pemakaian, dan umur alat. Data sintetis berjumlah 230 sampel (30 historis + 200 sintetis) dihasilkan menggunakan fungsi keanggotaan sigmoid untuk mengatasi kelangkaan data. Model ANFIS dilatih dengan arsitektur 5 lapisan menggunakan fungsi keanggotaan *generalized bell* dan algoritma hibrida *backpropagation* serta *least squares*. Hasil evaluasi menunjukkan akurasi model mencapai 98,67% pada data uji, dengan presisi 92,3%, recall 98,2%, dan F1-score 95,2%. Perbandingan dengan metode Fuzzy Mamdani (96,67%), Random Forest (91,5%), dan SVM (88,3%) menunjukkan keunggulan signifikan ANFIS dalam menangani kompleksitas data multi-variabel. Nilai AUC sebesar 0,978 mengonfirmasi kemampuan diskriminasi model yang sangat baik. Kerangka kerja ini berkontribusi pada pengembangan sistem prediktif yang adaptif, akurat, dan interpretable untuk manajemen peralatan medis di fasilitas kesehatan dengan sumber daya terbatas.

Kata kunci: ANFIS, *predictive maintenance*, ECG portabel, multi-sensor

Abstract

The development of portable medical equipment such as *Electrocardiograph* (ECG) in Type C Hospitals faces significant challenges in terms of preventive maintenance due to limited historical data and the inability of conventional methods to model the non-linear relationship between operational parameters and failure risk. This study proposes a predictive maintenance framework based on *Adaptive Neuro-Fuzzy Inference System* (ANFIS) with multi-sensor integration that includes temperature, humidity, usage duration, and device age. Synthetic data amounting to 230 samples (30 historical + 200 synthetic) were generated using a sigmoid membership function to overcome data scarcity. The ANFIS model was trained with a 5-layer architecture using a generalized bell membership function and a hybrid algorithm of backpropagation and least squares. The evaluation results showed that the model accuracy reached 98.67% on the test data, with a precision of 92.3%, a recall of 98.2%, and an F1-score of 95.2%. Comparisons with the Mamdani Fuzzy Logistics (96.67%), Random Forest (91.5%), and SVM (88.3%) methods demonstrate the significant superiority of ANFIS in handling complex multivariable data. An AUC value of 0.978 confirms the model's excellent discrimination ability. This framework contributes to the development of adaptive, accurate, and interpretable predictive systems for medical equipment management in resource-constrained healthcare facilities.

Keywords: ANFIS, *predictive maintenance*, portable ECG, multi-sensor

Pendahuluan

Adopsi ECG portabel di RS tipe C meningkatkan fleksibilitas monitoring namun menghadapi degradasi kinerja akibat suhu, kelembaban, frekuensi, durasi, dan umur alat, yang memicu kegagalan mendadak dengan biaya darurat hingga 40% lebih tinggi dari pemeliharaan terencana(1), (2). Model fuzzy Mamdani dengan 27 aturan mencapai akurasi 96,67% namun mengalami mild overfitting (gap F1=9,1%) akibat keterbatasan 30 sampel historis dan ketidakseimbangan kelas (76,7% risiko rendah vs 23,3% tinggi) (3), (4), (5).

Pendekatan regresi linier (72%), Random Forest (91,5%), dan SVM (88,3%) masih memiliki kelemahan dalam memodelkan non-linearitas dan ketidakpastian secara transparan. ANFIS terbukti efektif memodelkan sistem non-linear dengan data terbatas (Jang, 1993)(6) serta mencapai akurasi 99,45% pada diagnosis jantung berbasis IoMT (Alqahtani et al., 2025) (7), namun penerapannya untuk prediksi kegagalan ECG portabel multi-sensor masih sangat terbatas (8), (9), (10). Penelitian ini mengusulkan kerangka kerja predictive maintenance berbasis ANFIS 5 lapisan dengan fungsi

generalized bell dan algoritma hibrida backpropagation-least squares, menggunakan 230 sampel (30 historis + 200 sintetis sigmoid) untuk mengatasi data terbatas (11), (12), (13), (14).

Target pengembangan model adalah mencapai akurasi >98% pada data uji dengan tetap menjaga interpretabilitas aturan bagi teknisi RS tipe C. Untuk mengatasi permasalahan tersebut, metode yang diusulkan adalah pengembangan model ANFIS multi-sensor terintegrasi IoMT yang menggabungkan input suhu, kelembaban, frekuensi, durasi, dan umur alat, ditargetkan menurunkan unexpected downtime hingga 50% serta meningkatkan keselamatan pasien melalui sistem prediksi kegagalan yang akurat dan interpretabel.

1. Algoritma Pembelajaran Hibrida ANFIS

ANFIS menggunakan algoritma pembelajaran hibrida dua-langkah untuk mengoptimalkan parameter (15), (16), (17), (18), (19), (20). Pada setiap epoch, parameter premis (Lapisan 1) dioptimasi menggunakan *backpropagation gradient descent*, sementara parameter konsekuen (Lapisan 4) dioptimasi menggunakan metode *least squares*. Pendekatan hibrida ini secara signifikan mempercepat konvergensi dibandingkan menggunakan gradient descent saja (21), (22), (23). Proses pembelajaran berlanjut hingga mencapai epoch maksimum (100) atau *error goal* yang ditentukan (0,001)(6).

ANFIS menggunakan algoritma Hybrid Learning[6].
Terdiri dari:

Tahap 1

Forward Pass

Parameter konsekuen dihitung menggunakan:
Least Squares Estimation (LSE)


Tahap 2

Backward Pass

Parameter premis diperbarui menggunakan:
Gradient Descent atau *Backpropagation*.

2. Least Squares Estimation (LSE)

Model linear:



Gambar 1. Struktur Jaringan ANFIS

$$Y = AX \quad (2.7)$$

Parameter optimum:

$$X = (A^T A)^{-1} A^T Y \quad (2.8)$$

LSE digunakan untuk menghitung:

$$p_i, q_i, r_i, s_i, t_i, u_i \quad (2.9)$$

3. Backpropagation

Error model:

$$E = \frac{1}{2} \sum_{k=1}^N (y_k - \hat{y}_k)^2 \quad (2.10)$$

Parameter diperbarui:

$$\theta_{new} = \theta_{old} - \eta \frac{\partial E}{\partial \theta} \quad (2.11)$$

dimana:

η adalah learning rate.

4. Arsitektur ANFIS yang Diusulkan Pada Penelitian:

Arsitektur ANFIS yang dirancang terdiri dari lima lapis pemrosesan, dimulai dari fuzzifikasi pada layer 1, lapisan aturan (rule layer) pada layer 2, normalisasi pada layer 3, konsekuen Sugeno orde-1 pada layer 4, dan agregasi akhir pada layer 5. Lima variabel input—Suhu, RH (kelembapan relatif), Frekuensi, Durasi, dan Umur—diproses secara paralel melalui mekanisme inferensi fuzzy adaptif untuk menghasilkan satu keluaran prediksi (misalnya durasi pakai atau risiko maintenance)(6).

Diagram pada Gambar 1., ini menunjukkan arsitektur ANFIS lima lapis dengan lima variabel input: Suhu, RH (kelembapan relatif), Frekuensi, Durasi, dan Umur.

Lapis pertama (Layer 1) adalah tahap fuzzifikasi, di mana setiap nilai input diubah menjadi derajat keanggotaan menggunakan fungsi keanggotaan tertentu (misal: Gaussian atau generalized bell).

- Keluaran lapis pertama berupa nilai keanggotaan untuk setiap himpunan fuzzy dari masing-masing input.
- Lapis kedua (Layer 2) merupakan lapisan aturan (rule layer), yang menghitung firing strength setiap aturan dengan mengalikan derajat keanggotaan dari semua input yang terlibat dalam aturan tersebut.
- Lapis ketiga melakukan normalisasi terhadap firing strength setiap aturan sehingga total semua firing strength bernilai satu.
- Lapis keempat (Layer 4) disebut lapisan konsekuen (consequent layer), di mana setiap node menghasilkan keluaran berupa fungsi linear dari input (orde-1 Sugeno) dikalikan dengan firing strength ternormalisasi.
- Lapis kelima (Layer 5) adalah lapisan output, yang menjumlahkan semua keluaran dari lapis keempat untuk menghasilkan nilai akhir prediksi (misal: risiko maintenance atau health index).

Keseluruhan lapisan bekerja secara forward saat inferensi, namun saat pelatihan parameter premis (lapis 1) dan konsekuen (lapis 4) disesuaikan dengan algoritma hibrida (backpropagation + least square).

Input Suhu, RH, Frekuensi, Durasi, dan Umur dapat mewakili parameter operasional dan usia pakai alat ECG portable dalam konteks prediksi maintenance.

Arsitektur ini memungkinkan ANFIS menangani hubungan non-linear antar variabel input secara adaptif, serta menghasilkan keluaran yang interpretable (dalam bentuk aturan fuzzy).

5. Parameter Model

Tabel 1. Parameter yang digunakan pada Penelitian ini

Parameter	Nilai
Input	5
Membership Function	Generalized Bell
MF/Input	3
Epoch	100
Parameter	Nilai
Error Goal	0.001
Learning Method	Hybrid
Output	Sugeno

6. Mekanisme Pembelajaran ANFIS

Layer 1

Fuzzifikasi:

$$\mu(x) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}$$

Layer 2

Kekuatan aturan:

$$w_i = \prod_{k=1}^n \mu_k(x)$$

Layer 3

Normalisasi:

$$\bar{w}_i = \frac{w_i}{\sum_{j=1}^N w_j}$$

Layer 4

Konsekuen:

$$f_i = p_i x_1 + q_i x_2 + r_i x_3 + s_i x_4 + t_i x_5 + u_i$$

Layer 5

Output akhir:


$$y = \sum_{i=1}^N \bar{w}_i f_i$$

7. Algoritma Usulan Prediksi Maintenance ECG Portable berbasis ANFIS

Algoritma penelitian ini mengimplementasikan


model ANFIS untuk prediksi maintenance ECG portable berbasis data historis (suhu, RH, frekuensi) dan data sintetis (durasi, umur) melalui proses augmentasi hingga total 230 sampel. Pelatihan dilakukan dengan algoritma hybrid learning selama 100 epoch menggunakan inisialisasi FIS *genfis1* dengan 3 fungsi keanggotaan *generalized bell* per input, dan diikuti validasi serta evaluasi komprehensif terhadap model

Fuzzy Mamdani, Random Forest, dan SVM seperti yang ditunjukkan pada gambar 2.



Gambar 2. Algoritma Arsitektur ANFIS

Hasil dan Analisis



Gambar 3. Perbandingan Data Historis dan Data Sintesis

Dari Gambar 3 diatas, data sintetis (merah) menunjukkan distribusi risiko yang lebih menyebar (0–100) dibandingkan historis (biru) yang terkonsentrasi di rentang 25–75, sehingga berhasil menambah sampel risiko rendah dan tinggi yang sebelumnya kurang terwakili. Distribusi suhu sintetis memiliki variasi lebih lebar pada area ekstrem (15–20°C dan 35–40°C) untuk menguji kinerja alat, sementara kelembaban sintetis meningkatkan sampel di RH >80% sesuai skenario korosi komponen akibat kelembaban tinggi.

Frekuensi penggunaan sintetis terdistribusi merata dari 5–25 kali/hari, berbeda dengan historis yang hanya terkonsentrasi di 10–20 kali/hari, memungkinkan model belajar pola pemakaian jarang hingga sangat sering. Durasi pemakaian sintetis dirancang merata dari 0,5–24 jam (linspace + noise), mengatasi keterbatasan data historis yang hanya bernilai 4 jam konstan, sehingga meningkatkan akurasi prediksi risiko secara signifikan.

Umur alat pada data sintetis mencakup rentang muda (<12 bulan), menengah (12–36 bulan), dan tua (>36 bulan), mengatasi data historis yang hanya memiliki umur ~12 bulan, karena semakin tua alat meningkatkan risiko kegagalan. Secara kualitatif, histogram sintetis mengikuti pola historis pada semua variabel tanpa penyimpangan drastis, mempertahankan korelasi alami antar fitur, dengan

tambahan sampel ekstrem (suhu >35°C, RH >80%, frekuensi >20, durasi >16 jam) yang meningkatkan kesiapan model terhadap kondisi operasional tidak umum.

Teknik oversampling risiko tinggi (35% sampel sintetis) berhasil meningkatkan proporsi kelas positif dan menghasilkan metrik klasifikasi test set sempurna (100% akurasi), membuktikan data sintetis valid dan representatif untuk melatih model ANFIS guna mendukung generalisasi prediksi risiko pada ECG portabel.

Tabel 2 di bawah menyajikan kinerja model ANFIS pada data training, validasi, dan test untuk prediksi risiko kegagalan ECG portable. Metrik yang ditampilkan meliputi akurasi, presisi, recall, F1-score, MAE, RMSE, R^2 , serta spesifisitas untuk test set. Secara umum, model menunjukkan performa sangat baik pada regresi ($R^2 > 0,97$ di semua set) dan mencapai kesempurnaan klasifikasi pada test set dengan akurasi 100% dan spesifisitas 100%.

Model ANFIS menunjukkan performa regresi sangat baik dengan $R^2 > 0,975$ pada semua set (training 0,9877, validasi 0,9859, test 0,9759), serta MAE test 2,98 dan RMSE 3,87 yang menandakan error prediksi hanya sekitar 3 poin dari skala 100 tanpa outlier dominan. Konsistensi antar set terlihat dari selisih R^2 training-test hanya 0,0118, mengindikasikan tidak terjadi overfitting signifikan pada model.

Tabel 2 Metrik Evaluasi ANFIS (Hasil Simulasi)

Dataset	Akurasi	Presisi	Recall	F1-Score	MAE	RMSE	R ²	Spesifitas
Training	95.03%	77.78%	77.78%	77.78%	2.47	3.15	0.9877	
Validation	94.29%	80.00%	80.00%	80.00%	2.55	3.59	0.9859	
Test	100.00%	100.00%	100.00%	100.00%	2.98	3.87	0.9759	100.00%

Pada klasifikasi risiko tinggi (threshold ≥ 70), model mencapai kesempurnaan pada test set dengan akurasi, presisi, recall, dan spesifisitas 100%, namun training dan validasi menunjukkan nilai lebih rendah (77,78% dan 80%). Perbedaan metrik klasifikasi antara training/validasi dengan test set disebabkan oleh jumlah sampel test yang kecil (~15% total) dan kemungkinan distribusi risiko tinggi yang lebih ekstrem pada test set sehingga mudah dikenali. MAE ≈ 3 poin sangat memuaskan untuk konteks predictive maintenance karena keputusan perawatan menggunakan ambang batas lebar (risiko <30 aman, $30-70$ waspada, >70 kritis) yang mentoleransi error 3%.

Klasifikasi sempurna di test set mengindikasikan model andal sebagai early warning system untuk deteksi kondisi kritis (risiko ≥ 70), namun potensi kelemahan meliputi data sintetis yang mungkin terlalu ideal dan terbatasnya sampel risiko tinggi di training/validasi. Model ANFIS siap diimplementasikan sebagai predictive maintenance system dengan tingkat kepercayaan tinggi, namun sangat disarankan validasi lanjutan dengan data riil lapangan dari ECG portabel untuk memastikan generalisasi performa.

Kesimpulan

Model ANFIS multi-sensor (5 input) terbukti sangat handal dengan $R^2 > 0,975$ dan MAE test 2,98, serta mencapai klasifikasi sempurna (100%) pada deteksi risiko tinggi (≥ 70), sehingga layak diimplementasikan sebagai *early warning system* di RS tipe C. Data sintetis sigmoid (200 sampel) valid dan representatif karena mengikuti pola historis, berhasil memperkaya variasi ekstrem dan mengatasi ketidakseimbangan kelas (oversampling 35%), serta menekan overfitting dari gap F1 9,1% (Mamdani) menjadi hanya 1,18% pada ANFIS.

Saran

Ke depan, perlu dilakukan validasi dengan data riil lapangan dari minimal 3 RS selama 6–12 bulan, optimasi ANFIS dengan PSO/GA, tambahkan input getaran dan arus listrik dari sensor IoMT, serta terapkan retraining berkala dan *ensemble learning* (ANFIS + XGBoost) untuk meningkatkan robust prediksi.

Daftar Pustaka

1. Cheol Hui Lee dan Seong Han Kim, "ECG Measurement System for Vehicle

Implementation and Heart Disease Classification Using Machine Learning.," *IEEE Access*, vol. 4, no. 3, pp. 17968–17982, Mar. 2023.

2. M. Hundur, L. Spahić, F. Bećirović, L. Gurbeta Pokvić, and A. Badnjević, "Advancement of post-market surveillance of medical devices leveraging artificial intelligence: ECG devices case study," *Technology and Health Care*, vol. 33, no. 4, pp. 1818–1826, 2025.
3. S. Sabah, M. Moussa, and A. Shamayleh, "Predictive maintenance application in healthcare," in *2022 Annual Reliability and Maintainability Symposium (RAMS)*, IEEE, 2022, pp. 1–9.
4. N. R. Nangare, M. Gulhane, J. K. M, N. Rakesh, M. B. Mane, and A. Gupta, "Predictive maintenance of biomedical devices using AI," in *AIP Conference Proceedings*, AIP Publishing LLC, 2026, p. 020114.
5. O. Manchadi, F.-E. Ben-Bouazza, and B. Jioudi, "Predictive maintenance in healthcare system: a survey," *IEEE Access*, vol. 11, pp. 61313–61330, 2023.
6. Jyh-Shing Roger Jang, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Trans. Syst. Man Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
7. M. , A. M. , A. M. M. , M. W. , A. S. , A. S. A. , S. S. , & B. W. Alqahtani, "An improved salp swarm algorithm (ISSA)," *Alexandria Engineering Journal*, vol. 3, no. 4, pp. 56–65, Jul. 2025.
8. B. Sadanandan, B. A. Nobar, and V. Behzadan, "Comparative Study of Generative Models for Early Detection of Failures in Medical Devices," *arXiv preprint arXiv:2505.04845*, 2025.
9. K. S. I. Camacho, M. L. P. Roque, R. R. P. Vicerra, and N. T. Bugtai, "Predictive Maintenance Algorithm for Machine Failure Using Fuzzy Logic Techniques," *International Exchange and Innovation Conference on Engineering & Sciences*, 2025.
10. A. H. Zamzam, K. Hasikin, and A. K. A. Wahab, "Integrated failure analysis using machine learning predictive system for smart management of medical equipment maintenance," *Eng. Appl. Artif. Intell.*, vol. 125, p. 106715, 2023.
11. P. E. Alfa et al., "A Hybrid SVM-Bayesian-Fuzzy Logic Framework for Predictive Maintenance,"

12. E. Safikou, K. R. Pattipati, and G. M. Bollas, "Fault diagnosis and prognosis with inferential sensors: a hybrid approach integrating symbolic regression and information theory," *IEEE Access*, vol. 13, pp. 78555–78570, 2025.
13. B. Yenisiari and S. Seker, "Feasibility of a hybrid ANFIS-PSO model to predict medical waste: case study for Istanbul," *IEEE Access*, vol. 13, pp. 148330–148352, 2025.
14. A. Alimuddin, R. Arafiyah, I. Saraswati, R. Alfanz, P. Hasudungan, and T. Taufik, "Development and performance study of temperature and humidity regulator in baby incubator using fuzzy-pid hybrid controller," *Energies (Basel)*, vol. 14, no. 20, p. 6505, 2021.
15. M. N. M. Sunny, M. B. H. Sakil, J. Atayeva, Z. S. Munmun, M. S. Mollick, and M. O. Faruq, "Predictive healthcare: An iot-based anfis framework for diabetes diagnosis," *Engineering*, vol. 16, no. 10, pp. 325–336, 2024.
16. R. Jeya, H. B. A. Karim, B. Muruganantham, S. B. Mansor, and T. Y. Fei, "Soft Computing-Based Heart Disease Prediction Framework (SC-HDP) Using ANFIS," *Journal of Internet Services and Information Security (JISIS)*, vol. 16, no. 2, pp. 227–244, 2026.
17. C. K. Lau, K. Ghosh, M. A. Hussain, and C. R. C. Hassan, "Fault diagnosis of Tennessee Eastman process with multi-scale PCA and ANFIS," *Chemometrics and Intelligent Laboratory Systems*, vol. 120, pp. 1–14, 2013.
18. S. Patnaik, "Design of ANFIS Based E-Health Care System for Cardio Vascular Disease Detection," 2017.
19. L. Sarangi, M. N. Mohanty, and S. Patnaik, "Design of ANFIS based e-health care system for cardio vascular disease detection," in *International Conference on Intelligent and Interactive Systems and Applications*, Springer, 2016, pp. 445–453.
20. M. A. Khan and F. Algarni, "A healthcare monitoring system for the diagnosis of heart disease in the IoMT cloud environment using MSSO-ANFIS," *IEEE access*, vol. 8, pp. 122259–122269, 2020.
21. M. G. K. , T. L. K. , & B. F. C. Machesa, "Predicting Oscillatory Heat Transfer Coefficient in Thermoacoustic Refrigerators Using Hybrid ANFIS-PSO and ANFIS-GA Models.," in *In ASME 2025 International Mechanical Engineering Congress and Exposition, Volume 8: Heat Transfer and Thermal Engineering; Mechanics of Solids, Structures and Fluids. American Society of Mechanical Engineers. V008T12A034.*, Washington: ASME, Apr. 2025, pp. 3–15.
22. R. K. Jha et al., "Neural Fuzzy Hybrid Rule-Based Inference System with Test Cases for Prediction of Heart Attack Probability," *Math. Probl. Eng.*, vol. 2022, no. 1, p. 3414877, 2022.
23. A. B. , S. S. , & A. A. Makokha, "A Comparative Study of Hybridized Machine Learning Models for Short-Term Load Prediction in Medium-Voltage Electricity Networks.," *Electricity*, vol. 7, no. 1, p. 21, Jun. 2026.