IDENTIFIKASI KERUSAKAN MESIN POMPA PADA *BOILER FEEDWATER* MENGGUNAKAN PENDEKATAN HIBRIDA *CERTAINTY FACTOR* DAN *RANDOM FOREST*

Arby Alghifari Yusra[1], Afifah Primadani[1], Garet Dony Cristanto[1], Grageeyanto Soeparlan[1] Asepta Surya Wardhana[1*]
[1]Teknik Instrumentasi Kilang , Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58311
**E-mail*: *aseptasw@esdm.go.id*

ABSTRAK

Penelitian ini menginvestigasi penerapan metode *Certainty Factor* untuk identifikasi kerusakan pada mesin pompa *boiler feedwater*. Mengadopsi pendekatan kuantitatif, studi ini menganalisis data operasional seperti tekanan, suhu, laju aliran, dan vibrasi yang dikumpulkan dari sistem kontrol terdistribusi. Analisis sinyal getaran secara khusus diintegrasikan sebagai metode utama dalam pemeliharaan prediktif untuk mendeteksi anomali dan mengidentifikasi karakteristik kerusakan potensial pada tahap awal. Pendekatan ini bertujuan untuk mencegah kegagalan katastropik, memperpanjang umur operasional pompa, serta mengurangi biaya pemeliharaan dan waktu henti produksi. Temuan penelitian mengkonfirmasi bahwa penerapan Sistem Diagnostik berbasis *Certainty Factor* efektif dalam mendeteksi dan mengklasifikasikan berbagai jenis kerusakan (seperti ketidakseimbangan atau *misalignment*) pada mesin pompa *boiler feedwater* dengan akurasi diagnostik yang tinggi. Hasil ini mendukung transisi menuju strategi perawatan prediktif yang memanfaatkan analisis data waktu nyata, sebagai bagian dari implementasi sistem cerdas untuk mengantisipasi potensi kegagalan, secara signifikan meningkatkan keandalan operasional dan mengurangi biaya siklus hidup aset.

Kata kunci: ***Analisis Vibrasi, Certainty Factor, Identifikasi Kerusakan, Pemeliharaan Prediktif, Pompa Boiler Feedwater***

1. PENDAHULUAN

Dalam industri minyak dan gas (migas), keandalan mesin pompa *boiler feedwater* merupakan faktor vital yang berpengaruh langsung terhadap efisiensi operasi dan keselamatan sistem. Kegagalan pompa dapat menimbulkan kerugian besar akibat waktu henti produksi dan biaya perbaikan [1],[2]. Oleh karena itu, diperlukan sistem diagnosis dini yang mampu mendeteksi potensi kerusakan secara akurat [3],[4].

Metode *Certainty Factor* (CF) banyak digunakan dalam sistem pakar karena kemampuannya meniru cara berpikir pakar melalui aturan *if–then* dan memberikan nilai keyakinan diagnosis [5],[6]. Namun, pendekatan ini memiliki kelemahan, seperti ketergantungan terhadap subjektivitas pakar dan kesulitan beradaptasi terhadap dinamika sistem. Penelitian ini mengadopsi pendekatan kuantitatif dengan berfokus pada pengumpulan dan analisis data kinerja pompa *boiler feedwater* dari sistem kontrol terdistribusi [2]. Data tersebut mencakup parameter operasional seperti tekanan, suhu, laju aliran, dan data vibrasi, yang esensial untuk mendeteksi anomali pada sistem permesinan rotasi [1], [7]. Analisis sinyal getaran, yang menjadi metode utama dalam pemeliharaan prediktif, diintegrasikan untuk mengidentifikasi karakteristik kerusakan potensial pada tahap awal, sehingga menghindari kegagalan katastropik dan memperpanjang umur operasional pompa [3].

Untuk mengatasi keterbatasan tersebut, penelitian ini menggabungkan CF dengan metode pembelajaran mesin *Random Forest* (RF) yang mampu mengenali pola dari data historis sensor.

RF digunakan untuk menghasilkan probabilitas kerusakan berdasarkan data operasional aktual, sedangkan CF berperan dalam memberikan interpretasi berbasis pengetahuan pakar. Pemanfaatan strategi pemeliharaan prediktif dapat meningkatkan keandalan peralatan industri dengan mengidentifikasi akar penyebab kegagalan sistem, sehingga meminimalkan biaya operasional dan pemeliharaan jangka panjang [5]. Metode *Certainty Factor* yang telah terbukti efektif dalam sistem diagnosa kerusakan di berbagai bidang, memungkinkan integrasi pengetahuan pakar dengan data sensor untuk menghasilkan diagnosis yang akurat dan terpercaya [4], [6].

Meskipun demikian, penelitian yang mengintegrasikan secara spesifik logika inferensi *Certainty Factor* berbasis aturan pengetahuan dengan analisis data operasional dan sinyal vibrasi *real-time* dari pompa *boiler feedwater* untuk menghasilkan tingkat keyakinan diagnosis yang terukur masih terbatas. Sistem ini berpotensi besar untuk mengintegrasikan data *real-time* dari sensor untuk mendeteksi anomali pada kinerja pompa, yang kemudian diinterpretasikan oleh aturan-aturan berbasis pengetahuan dalam sistem pakar [8]. Dengan demikian, sistem ini diharapkan dapat memberikan pemeliharaan prediktif yang lebih efektif, mengidentifikasi potensi kegagalan sebelum terjadi, dan mengurangi waktu henti produksi yang tidak terencana [3], [9]. Pendekatan ini sejalan dengan kebutuhan industri modern akan sistem cerdas yang mampu mengoptimalkan pemeliharaan dan memprediksi kegagalan mesin secara proaktif, terutama dalam konteks peralatan kritis seperti pompa injeksi air [10], [11].

Perusahaan minyak dan gas harus meningkatkan efisiensi operasional, mengurangi biaya, dan meningkatkan keselamatan secara signifikan dengan mengadopsi model prediksi yang didukung oleh kecerdasan buatan dan pembelajaran mesin [11]. Sistem pakar berbasis *Certainty Factor* ini menawarkan pendekatan inovatif untuk mengatasi tantangan tersebut dengan menyediakan kerangka kerja yang robust untuk identifikasi kerusakan yang kompleks pada mesin pompa di lingkungan operasi yang keras [12].

2. METODE

Pendekatan ini sangat krusial mengingat kompleksitas dan biaya yang terlibat dalam penggantian atau perbaikan komponen pompa *boiler feedwater* [11]. Optimalisasi kinerja dan keandalan pompa industri seringkali dicapai melalui sistem perawatan prediktif yang memanfaatkan data sensor waktu nyata, dengan pendekatan pembelajaran mesin mampu memprediksi kondisi kerusakan dalam jangka pendek [13]. Integrasi *Artificial Intelligence* dalam pemeliharaan prediktif pompa injeksi air, termasuk pompa *boiler feedwater*, telah menunjukkan kemampuan signifikan dalam menganalisis pola data dan anomali untuk memprediksi kebutuhan perawatan secara proaktif [11]. Metode ini memungkinkan identifikasi dini kerusakan, yang dapat secara signifikan mengurangi biaya pemeliharaan dan waktu henti produksi [5].

Hal ini sejalan dengan konsep pemeliharaan prediktif yang memanfaatkan analisis data dan algoritma pembelajaran mesin untuk mengantisipasi potensi kegagalan, sehingga transisi dari perawatan reaktif menjadi proaktif dapat tercapai [11]. Pendekatan ini selaras dengan tren peningkatan popularitas metode diagnostik berbasis data yang mengkategorikan kerusakan menjadi *model-based* atau *data-driven*, yang mana keduanya membandingkan output sistem untuk mengidentifikasi sinyal residual atau anomali [11]. *Model-based diagnostics* memanfaatkan model matematis sistem untuk memprediksi perilaku normal, sementara *data-driven diagnostics* menggunakan pembelajaran mesin untuk mengidentifikasi pola anomali dari data historis tanpa memerlukan model fisik eksplisit [11]. Dengan demikian, fokus pada pemeliharaan prediktif berbasis data merupakan strategi yang efektif untuk meningkatkan keandalan operasional dan mengurangi biaya siklus hidup aset [11], [14].

Dalam kerangka sistem hibrida ini, algoritma Random Forest Classifier digunakan sebagai alat prediksi awal berbasis data untuk mendapatkan probabilitas kerusakan, yang kemudian

dipadukan dengan *Certainty Factor* untuk mengukur tingkat keyakinan diagnosis akhir untuk merepresentasikan tingkat keyakinan dalam proses diagnosis kerusakan berdasarkan data sensor dan hasil analisis model. CF memungkinkan sistem menggabungkan nilai keyakinan pakar dengan hasil analisis data, sehingga prediksi kerusakan tidak hanya berbasis probabilitas, tetapi juga memiliki bobot kepastian yang lebih jelas [15]. Gambar 1 merupakan alur penelitian ini.

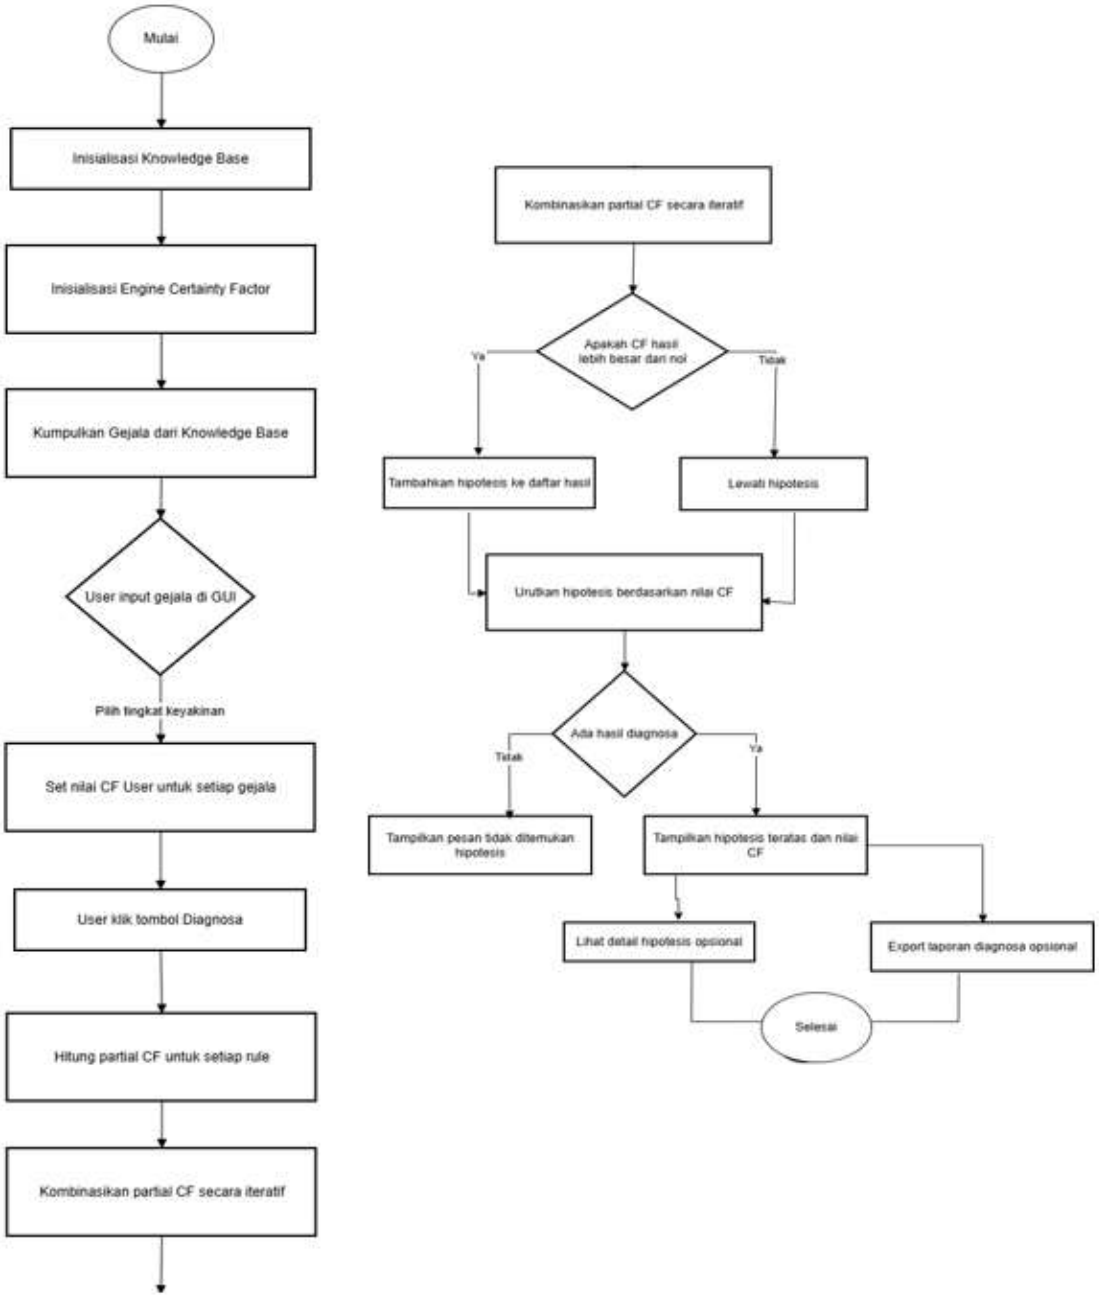

Gambar 1. Diagram alir penelitian

Tahap awal dilakukan dengan inisialisasi input berupa parameter operasional pompa (tekanan, suhu, laju aliran, vibrasi) yang kemudian diolah menjadi evidence bagi sistem. *Certainty Factor* dasar dihitung dari selisih antara *Measure of Belief* (MB) dan *Measure of Disbelief* (MD) terhadap hipotesis kerusakan:

$$CF(H, E) = MB(H, E) - MD(H, E) \quad (1)$$

Selanjutnya, implementasi dilakukan menggunakan algoritma *Random Forest Classifier* untuk klasifikasi kondisi pompa berdasarkan data input. *Random Forest* bekerja dengan membangun sejumlah pohon keputusan dari subset data, lalu hasil prediksi diperoleh melalui voting mayoritas. Probabilitas prediksi kelas Y diberikan oleh rata-rata prediksi dari seluruh pohon [16]:

$$P(Y = c|x) = T \sum t=1\ Ht\ (xz \quad - \quad (2)$$

Pengujian data dilakukan secara sistematis melalui beberapa tahap. Pertama, data sensor dari pompa *boiler feedwater* yang mencakup parameter tekanan, suhu, laju aliran, dan vibrasi dibagi menjadi dua bagian, yaitu data latih (*training set*) dan data uji (*testing set*) menggunakan teknik *train-test split* dengan rasio umum 80:20. Data latih digunakan untuk membangun model klasifikasi menggunakan algoritma *Random Forest Classifier*, sementara data uji digunakan untuk mengevaluasi performa model secara objektif [16]. Untuk mengukur kinerja model, digunakan confusion matrix yang menilai perbandingan antara hasil prediksi dengan label aktual [17]. Nilai akurasi (Acc) dihitung dengan rumus,

$$Acc = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

dengan TP (*True Positive*), TN (*True Negative*), FP (*False Positive*), dan FN (*False Negative*). Selain akurasi, metrik lain seperti presisi dan recall juga digunakan untuk mengevaluasi[17].

A. Akuisisi dan Persiapan Data

Data diambil dari sistem kontrol terdistribusi (DCS) dan sensor vibrasi yang merekam parameter tekanan, suhu, laju aliran, dan getaran pompa [2],[7], [11]. Langkah-langkahnya adalah Preprocessing data yaitu dilakukan *cleaning* untuk menghapus data noise atau *outlier*, kemudian dilakukan normalisasi agar variabel memiliki skala yang sebanding [8]. Selanjutnya adalah *feature selection*, yaitu parameter signifikan ditentukan menggunakan analisis *feature importance* dari algoritma *Random Forest* untuk mengetahui kontribusi setiap variabel terhadap kondisi pompa [13]. Terakhir dilakukan *Splitting data*, yaitu dataset dibagi menjadi 80% data latih (*training set*) dan 20% data uji (*testing set*) guna memastikan validasi model dilakukan secara objektif [16].

B. Sistem Penalaran *Certainty Factor*

Metode *Certainty Factor* digunakan untuk merepresentasikan keyakinan pakar terhadap hipotesis kerusakan berdasarkan gejala yang terdeteksi. Nilai CF ditentukan dari perbedaan antara tingkat kepercayaan (*Measure of Belief, MB*) dan tingkat ketidakpercayaan (*Measure of Disbelief, MD*) [15], [16]:

$$CF(H, E) = MB(H, E) - MD(H, E) \quad (4)$$

Untuk kasus dengan lebih dari satu gejala yang mendukung hipotesis, nilai CF dikombinasikan menggunakan persamaan [4], [6]:

$$CF_{komb} = CF_1 + CF_2(1 - CF_2) \quad (5)$$

Hasil dari sistem CF merepresentasikan tingkat keyakinan pakar terhadap jenis kerusakan tertentu, seperti kavitasi, *misalignment*, atau kebocoran *seal*.

a. Integrasi (Fusi) Model RF–CF

Untuk meningkatkan reliabilitas diagnosis, hasil probabilitas dari *Random Forest* diintegrasikan dengan nilai CF dari basis pengetahuan pakar. Proses ini dilakukan menggunakan pendekatan linier yang diusulkan oleh peneliti dalam penelitian ini (*proposed model*), bukan berasal dari referensi tertentu. Formulasinya adalah sebagai berikut:

$$C_{final} = \alpha + CF_{rule}(1 - \alpha) \times P(C_k|X) \quad (6)$$

Persamaan ini merupakan model fusi yang dikembangkan peneliti untuk menggabungkan dua sumber keyakinan, yaitu pakar dan data sensor agar diagnosis lebih objektif dan terukur [11], [15].

3. HASIL DAN PEMBAHASAN

Hasil dari penerapan metode CF menunjukkan bahwa sistem dapat menghasilkan diagnosis dengan tingkat kepastian tertentu yang mendekati logika pakar. Namun, untuk meningkatkan reliabilitas dan validasi, dilakukan simulasi data sensor dengan parameter viskositas, flow, massa jenis, dan densitas. Data ini kemudian digunakan untuk melatih model *Random Forest* yang berfungsi sebagai alat prediksi berbasis data yang hasilnya (probabilitas) digunakan sebagai *evidence* untuk diolah dan digabungkan (fusi) dengan *Certainty Factor* yang berbasis aturan pengetahuan pakar. Gambar 2 adalah menu sistem pakar dan *Random Forest.*

Gambar 2. Menu Sistem Pakar & *Random Forest*

A. Implementasi Hibrida *Certainty Factor* dan *Random Forest*

Penelitian ini mengintegrasikan metode *Certainty Factor* (CF) dengan *Random Forest* untuk mendiagnosis kerusakan pada pompa *boiler feedwater*. Sistem ini menganalisis gejala yang terdeteksi dari data operasional pompa, seperti getaran tinggi pada *casing*, aliran *feedwater* yang tidak stabil, dan kondisi lainnya yang mengindikasikan potensi kerusakan. Hasil implementasi CF pada Gambar 3 menunjukkan bahwa diagnosis utama untuk gejala yang dimasukkan adalah kavitasi akibat NPSH rendah, dengan nilai keyakinan CF sebesar 95,2%. Nilai CF ini diperoleh melalui kombinasi beberapa gejala yang mendukung hipotesis kerusakan, sebagai berikut:

- **Getaran tinggi pada *casing* pompa**: CF = 0,90, dengan tingkat keyakinan input 1,0 (sangat yakin) dan bobot aturan 0,90.
- **Aliran *feedwater* yang tidak stabil**: CF = 0,52.

Formula untuk menghitung CF parsial dalam sistem ini adalah,

$$CF_{parsial} = CF_{rule} \times CF_{User} \quad (7)$$

Di mana CF_rule adalah nilai CF yang diperoleh berdasarkan aturan sistem pakar. Sedangkan CF_User adalah tingkat keyakinan yang diberikan oleh pengguna berdasarkan gejala yang terdeteksi. Selain hipotesis utama mengenai kavitasi, sistem ini juga mengidentifikasi beberapa kemungkinan kerusakan lain pada pompa *boiler feedwater*, antara lain:

- **impeller akibat erosi/korosi** dengan nilai CF sebesar 75,0%, didukung oleh gejala getaran abnormal.
- **Kebocoran pada *mechanical seal*** dengan nilai CF 70,5%, berdasarkan gejala kebocoran feedwater di sekitar seal dan penurunan level oli seal.
- **Misalignment pompa-motor (*kopling*)** dengan nilai CF 59,5%, didukung oleh gejala kebisingan pada area kopling.
- **Sumbatan pada *suction strainer/line***, dengan nilai CF 36,8%, yang menunjukkan probabilitas yang lebih rendah dibandingkan dengan hipotesis lainnya.

Dengan pendekatan hibrida CF dan *Random Forest*, sistem ini menghasilkan diagnosis yang lebih akurat, memberikan berbagai kemungkinan kerusakan beserta tingkat keyakinannya. Hal ini memungkinkan teknisi untuk lebih cepat dan tepat dalam melakukan inspeksi dan pemeliharaan pada pompa *boiler feedwater*.

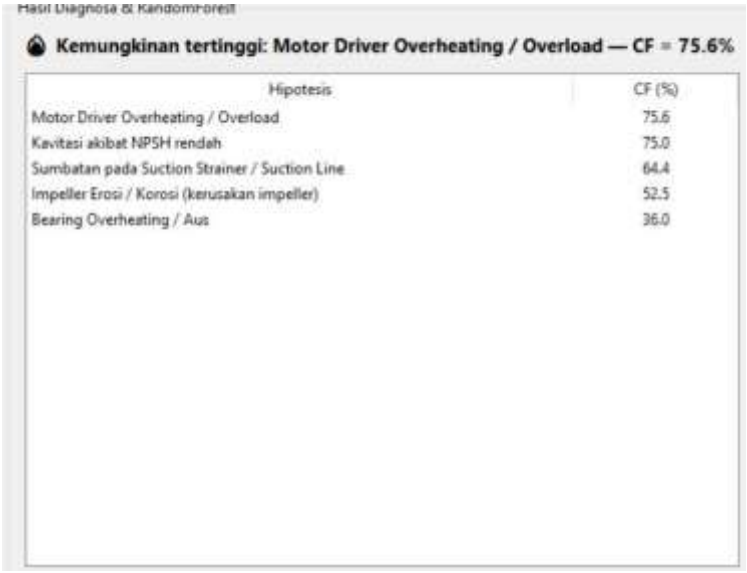

Gambar 2 Hasil *Certainty Factor*

B. Analisis Hasil *Certainty Factor*

Hipotesis dengan CF tertinggi adalah *Motor Driver Overheating / Overload* (Kelebihan Beban Motor) dengan nilai CF = 75.6%, yang menunjukkan kemungkinan terbesar bahwa motor pompa mengalami kelebihan beban atau *overheating*. Gejala yang mendukung hipotesis ini kemungkinan besar adalah peningkatan suhu atau getaran yang tidak normal pada motor pompa. Hipotesis kedua yang memiliki nilai CF yang hampir sama adalah Kavitasi Akibat NPSH Rendah dengan nilai CF = 75.0%, yang menunjukkan adanya kavitasi pada pompa yang disebabkan oleh kekurangan *Net Positive Suction Head* (NPSH). Kavitasi biasanya ditandai dengan getaran berlebihan dan penurunan kestabilan aliran pada pompa, yang berpotensi merusak komponen pompa lebih lanjut.

Selain dua hipotesis utama tersebut, terdapat beberapa kemungkinan kerusakan lain yang juga terdeteksi, namun dengan keyakinan yang lebih rendah. Sumbatan pada *Suction Strainer / Suction Line* tercatat dengan nilai CF = 64.4%, menunjukkan adanya kemungkinan sumbatan pada saluran isap yang dapat menghambat aliran feedwater ke dalam pompa. Kerusakan pada *Impeller* akibat Erosi atau Korosi terdeteksi dengan nilai CF = 52.5%, yang menunjukkan kemungkinan sedang terjadi erosi atau korosi pada impeller yang dapat menurunkan kinerja pompa. Sementara itu, *Bearing Overheating* / Aus memiliki nilai CF = 36.0%, yang menunjukkan probabilitas kerusakan pada bearing pompa cukup rendah dibandingkan dengan hipotesis lainnya.

Tabel 1 yang ditampilkan menggambarkan hasil diagnosis sistem pakar berdasarkan gejala yang dimasukkan oleh pengguna dan tingkat keyakinan terhadap setiap hipotesis kerusakan. Berdasarkan input gejala, seperti aliran *feedwater* masuk berkurang, arus listrik motor berlebih, dan bau isolasi terbakar, sistem pakar menghasilkan diagnosis terkait kerusakan pada pompa *boiler feedwater. Motor Driver Overheating / Overload* merupakan hipotesis dengan kemungkinan tertinggi, dengan nilai CF sebesar 75.6%, menunjukkan bahwa kemungkinan besar masalah terkait dengan kelebihan beban pada motor pompa. Diikuti oleh hipotesis Kavitasi Akibat NPSH Rendah dengan nilai CF 75.0%, yang mengindikasikan potensi kavitasi pada pompa akibat ketidakseimbangan tekanan pada sistem isap.

Tabel 1 Hasil Percobaan

a.

No	Input Gejala Utama	Hipotesis Utama (Sistem CF)	Nilai CF (%)	Ekspektasi Pakar	Keterangan
1	Aliran *feedwater* masuk berkurang	*Motor Driver Overheating / Overload*	75.6	*Motor Overheating*	Sesuai
2	Aliran *feedwater* tidak stabil	Kavitasi Akibat NPSH Rendah	75.0	Kavitasi	Sesuai
3	Arus listrik motor berlebih	Sumbatan pada *Suction Strainer / Suction Line*	64.4	Sumbatan	Sesuai
4	Bau isolasi terbakar	*Impeller* Erosi / Korosi (Kerusakan Impeller)	52.5	Impeller Erosi	Sesuai
5	Getaran abnormal	*Bearing Overheating* / Aus	36.0	*Bearing Overheating*	Sesuai

C. Analisis Hasil Random Forest

Hasil evaluasi model *Random Forest* (RF) pada gambar 3 menunjukkan bahwa akurasi model hanya mencapai 25%, yang mengindikasikan performa yang cukup rendah. Hal ini tercermin dari confusion matrix, di mana model cenderung kesulitan dalam memprediksi beberapa kelas dengan tepat. Sebagai contoh, banyak prediksi yang salah antara kelas 1 dan kelas 2, yang ditunjukkan oleh beberapa nilai yang tersebar di sepanjang diagonal dan di luar diagonal pada *confusion matrix.* Dari classification report, dapat dilihat bahwa nilai *precision, recall*, dan *f1-score* untuk beberapa kelas sangat rendah, terutama untuk kelas-kelas dengan lebih banyak kesalahan prediksi. Ini menunjukkan bahwa model tidak mampu membedakan dengan baik antara kelas-kelas tertentu.

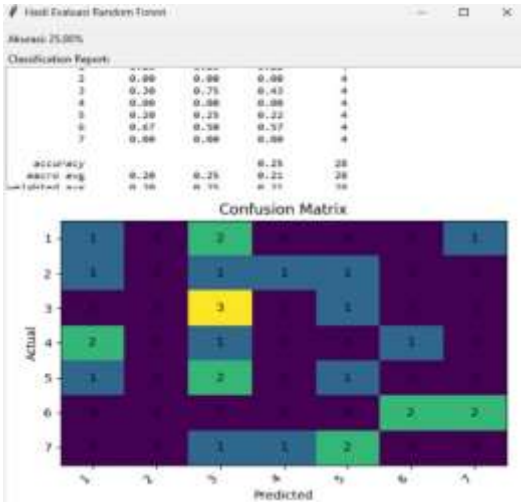

Gambar 3. Hasil *Random Forest*

D. Perbandingan Kinerja CF dan RF

Hasil evaluasi antara *Certainty Factor* (CF) dan *Random Forest* (RF) pada Gambar 4 menunjukkan perbedaan yang signifikan dalam hal akurasi dan interpretabilitas. CF memiliki keunggulan dalam hal interpretabilitas, karena menggunakan aturan yang eksplisit dan dapat ditelusuri (*traceable*), yang memudahkan pemahaman dan verifikasi oleh pakar. Nilai CF tertinggi untuk hipotesis *Motor Driver Overheating/Overload* mencapai 75.6%, yang menunjukkan tingkat keyakinan yang cukup tinggi pada diagnosis berbasis pengetahuan pakar. Di sisi lain, RF menunjukkan akurasi yang lebih rendah, yaitu hanya 25% pada data uji, dengan *precision* dan *recall* masing-masing mencapai 19.52% dan 25.00%. Meskipun RF unggul dalam memproses data dengan jumlah yang besar dan dapat menangani representasi data yang kompleks, namun model ini kurang transparan dan sulit untuk diinterpretasikan, yang menjadi kelemahan utama.

Gambar 4. Hasil Perbandingan CF dan RF

4. SIMPULAN

Penelitian ini menyimpulkan bahwa *Certainty Factor* (CF) dan *Random Forest* (RF) memiliki keunggulan dan kelemahan dalam diagnosis kerusakan pompa *boiler feedwater*. CF unggul dalam interpretabilitas, dengan diagnosis yang mudah dipahami melalui aturan berbasis pengetahuan pakar, seperti pada hipotesis *Motor Driver Overheating* dengan CF 75,6%. Di sisi lain, RF lebih efektif dalam menganalisis data besar dan pola kompleks, meskipun akurasinya hanya 25% pada data uji. Kelemahan RF terletak pada kurangnya transparansi dan interpretabilitas, yang menyulitkan pakar dalam memverifikasi keputusan model.

5. DAFTAR PUSTAKA

[1] M. H. Garousi, M. Karimi, P. Casoli, M. Rundo, and R. Fallahzadeh, "Vibration analysis of a centrifugal pump with healthy and defective impellers and fault detection using multi-layer perceptron," *Eng*, vol. 5, no. 4, pp. 2511–2530, 2024.

[2] M. Moleda, A. Momot, and D. Mrozek, "Predictive maintenance of boiler feed water pumps using SCADA data," *Sensors*, vol. 20, no. 2, p. 571, 2020.

[3] N. Singh Ranawat, P. Kumar Kankar, and A. Miglani, "Fault diagnosis in centrifugal pump using support vector machine and artificial neural network," *J. Engg. Res. EMSME Special Issue*, p. 99.

[4] A. I. Zalukhu, I. Syahputra, M. Iqbal, and R. F. Wijaya, "Analisis Metode Certainty Factor Pada Sistem Pakar Diagnosa Kerusakan Sepeda Motor," *Bulletin of Information Technology (BIT)*, vol. 4, no. 4, pp. 524–532, 2023.

[5] N. Hashim, A. Hassan, and M. F. A. Hamid, "Predictive maintenance model for centrifugal pumps under improper maintenance conditions," presented at the AIP Conference Proceedings, AIP Publishing LLC, 2020, p. 030170.

[6] D. Suryadi, R. Meilianda, A. F. Suryono, and M. Munadi, "Sistem Pakar untuk Mengidentifikasi Kerusakan Mesin Industri Menggunakan Metode Certainty Factor," *ROTASI*, vol. 20, no. 1, pp. 56–62, 2018.

[7] C. A. Arinze, V. O. Izionworu, D. Isong, C. D. Daudu, and A. Adefemi, "Predictive maintenance in oil and gas facilities, leveraging ai for asset integrity management," *International Journal of Frontiers in Engineering and Technology Research*, vol. 6, no. 1, pp. 16–26, 2024.

[8] S. Chhabria, R. Ghata, V. Mehta, A. Ghosekar, M. Araspure, and N. Pakhide, "Predictive maintenance using machine learning on industrial water pumps," *International Journal of Innovations in Engineering and Science*, vol. 7, no. 9, pp. 76– 81, 2022.

[9] S. Werbinska-Wojciechowska and R. Rogowski, "Proactive Maintenance of Pump Systems Operating in the Mining Industry—A Systematic Review," *Sensors*, vol. 25, no. 8, p. 2365, 2025.

[10] M. Eddarhri, M. Hain, J. Adib, and A. Marzak, "A Proposed Roadmap for Optimizing Predictive Maintenance of Industrial Equipment," *International Journal of Advanced Computer Science & Applications*, vol. 14, no. 11, 2023.

[11] S. Mohamed Almazrouei, F. Dweiri, R. Aydin, and A. Alnaqbi, "A review on the advancements and challenges of artificial intelligence-based models for predictive maintenance of water injection pumps in the oil and gas industry," *SN Applied Sciences*, vol. 5, no. 12, p. 391, 2023.

[12] A. Latrach, "Application of deep learning for predictive maintenance of oilfield equipment," *arXiv preprint arXiv:2306.11040*, 2023.

[13] K. Alghtus, A. Gannan, K. M. Alhajri, A. L. Al Jubouri, and H. A. Al-Janahi, "Short- Horizon Predictive Maintenance of Industrial Pumps Using Time-Series Features and Machine Learning," *arXiv preprint arXiv:2508.19974*, 2025.

[14] S. T. Bunyan *et al.*, "Intelligent Thermal Condition Monitoring for Predictive Maintenance of Gas Turbines Using Machine Learning," *Machines*, vol. 13, no. 5, p. 401, 2025.

[15] Shortliffe, E. H., & Buchanan, B. G. "A model of inexact reasoning in medicine". *Mathematical Biosciences*, 23(3–4), 351–379. 1975.

[16] Lacher, R.C., Nguyen, K.D. "Hierarchical Architectures for Reasoning". In: Sun, R., Bookman, L.A. (eds) Computational Architectures Integrating Neural And Symbolic Processes. The Springer International Series In Engineering and Computer Science, vol 292. Springer, Boston, MA. 1995. https://doi.org/10.1007/978-0-585-29599-2_4

[17] Buchanan, B.G. and Shortliffe, E.H. "Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project". Addison-Wesley, Reading, MA.. 1984.