

DIAGNOSIS ABNORMALITAS KONTROL SUHU *HEAT EXCHANGER* INDUSTRI PETROKIMIA BERBASIS *CERTAINTY FACTOR*

Moch. Habibi Attiqullah¹, Airlangga Petit Gayuhan¹, Muh. Rafly Bayu Syahputra¹,
Asepta Surya Wardhana¹

¹ Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58312

*E-mail:airlanggapetitgayuhan@gmail.com

ABSTRAK

Heat exchanger merupakan komponen krusial dalam industri petrokimia yang rentan mengalami abnormalitas kontrol suhu akibat *fouling*, *malfungsi control valve*, *drift sensor*, dan gangguan lainnya. Deteksi dini abnormalitas masih menghadapi tantangan signifikan karena ketergantungan pada pengalaman operator, *alarm flood*, serta potensi *human error*. Penelitian ini mengembangkan sistem pakar berbasis *Certainty Factor* (CF) untuk mendiagnosis abnormalitas kontrol suhu *heat exchanger* di industri petrokimia. *Knowledge base* dibangun melalui observasi lapangan bersama pakar, menghasilkan dataset komprehensif dengan 314 gejala dan 32 jenis kerusakan. Sistem diimplementasikan menggunakan Python dengan antarmuka web yang memungkinkan operator memilih gejala, kemudian sistem menghitung nilai CF dan memberikan diagnosis beserta rekomendasi perbaikan. Evaluasi terhadap 22 skenario menunjukkan akurasi 81,82%, precision 100%, recall 81,82%, dan F1-score 90,00%. Nilai CF rata-rata 90,32% dengan perbedaan signifikan antara diagnosis benar (94,43%) dan salah (72,00%), membuktikan efektivitas CF sebagai indikator ketidakpastian. Precision 100% mengindikasikan tidak ada false positive, penting untuk menghindari tindakan perbaikan tidak perlu di lingkungan petrokimia berisiko tinggi. Sistem ini berfungsi sebagai decision support tool yang dapat diimplementasikan tanpa infrastruktur tambahan untuk pengambilan keputusan yang lebih cepat, akurat, dan konsisten.

Kata kunci: sistem pakar, *certainty factor*, *heat exchanger*, diagnosis abnormalitas, industri petrokimia

1. PENDAHULUAN

Industri petrokimia merupakan sektor vital dengan kompleksitas operasional tinggi, di mana *heat exchanger* (penukar panas) berperan krusial dalam transfer panas antarfluida. Kegagalan atau operasi tidak optimal pada *heat exchanger* dapat memicu insiden keselamatan dan kerugian signifikan, terutama pada kondisi operasional ekstrem dengan suhu dan tekanan tinggi [1]. Kontrol suhu yang tepat sangat penting untuk menjaga kestabilan proses, namun sistem ini rentan terhadap berbagai masalah teknis seperti *fouling* (pengotoran permukaan) [2], [3], *malfungsi control valve*, *drift sensor* [4], dan perubahan karakteristik proses yang tidak terduga. *Fouling* sendiri dikenal sebagai "masalah miliaran dolar" karena menyebabkan kerugian operasional besar dan biaya pemeliharaan tinggi [3], sementara suhu abnormal pada peralatan kritis sering menjadi indikasi kerusakan serius yang membutuhkan deteksi dini [5].

Deteksi dini abnormalitas kontrol suhu masih menghadapi tantangan signifikan. Operator umumnya mengandalkan pengalaman dan sistem alarm konvensional yang memiliki kelemahan mendasar: subjektivitas interpretasi, fenomena alarm flood (banjir alarm) [6], dan potensi human error yang dapat menunda diagnosis atau mengabaikan alarm kritis [7]. Ketidaksempurnaan pengukuran sensor serta kompleksitas dinamika proses mempersulit deteksi dan diagnosis abnormalitas [8]. Kondisi ini menunjukkan kebutuhan mendesak akan sistem otomatis yang mampu menganalisis data operasional dengan cepat dan memberikan tingkat keyakinan terukur untuk mendeteksi tanda-tanda awal abnormalitas [9].

Sistem pakar muncul sebagai solusi potensial untuk mengatasi tantangan diagnosis di industri. Sistem pakar mampu meniru penalaran pakar dalam menyelesaikan masalah kompleks dan tidak terstruktur dengan mengkodekan pengetahuan ke dalam basis pengetahuan [10], [11]. Implementasi sistem pakar untuk diagnosis kesalahan di industri petrokimia dan proses telah menunjukkan hasil yang menjanjikan, baik secara online maupun real-time [12], [13]. Keunggulan utamanya terletak pada penalaran transparan dan fleksibilitas representasi pengetahuan [10], [14]. Namun, tantangan utama dalam diagnosis abnormalitas heat exchanger adalah menangani ketidakpastian yang muncul dari keterbatasan akurasi sensor, variabilitas proses, dan interpretasi gejala yang ambigu.

Metode Certainty Factor (CF) menawarkan pendekatan sistematis untuk menangani ketidakpastian dalam diagnosis dengan mengkuantifikasi tingkat keyakinan terhadap suatu kondisi berdasarkan gejala yang diamati [15]. Berbeda dengan metode probabilistik konvensional, CF mampu menggabungkan gejala dari berbagai sumber dan menghasilkan kesimpulan dengan tingkat keyakinan yang lebih mencerminkan penalaran manusia. Metode CF telah terbukti efektif dalam aplikasi sistem pakar untuk diagnosis, baik di bidang medis [16] maupun industri [17], [18].

Meskipun sistem pakar telah diterapkan dalam berbagai konteks diagnosis industri, gap penelitian yang teridentifikasi adalah: (1) minimnya penerapan sistem pakar khusus untuk diagnosis abnormalitas kontrol suhu heat exchanger di industri petrokimia yang mengintegrasikan metode CF dengan knowledge base komprehensif berbasis data lapangan; (2) kurangnya sistem yang mampu memberikan tingkat keyakinan terukur untuk setiap diagnosis guna mendukung pengambilan keputusan operator; dan (3) belum adanya evaluasi kuantitatif menyeluruh terhadap akurasi sistem pakar CF dalam konteks diagnosis abnormalitas heat exchanger dengan dataset operasional nyata. Berdasarkan permasalahan tersebut, penelitian ini mengusulkan implementasi sistem pakar dengan metode Certainty Factor untuk mendeteksi abnormalitas pada kontrol suhu heat exchanger di industri petrokimia. Sistem ini diharapkan dapat menjadi alat bantu keputusan yang proaktif, sehingga diagnosis abnormalitas dapat dilakukan lebih cepat, akurat, dan konsisten.

2. METODE

Penelitian ini mengembangkan sistem pakar berbasis Certainty Factor (CF) untuk diagnosis abnormalitas kontrol suhu heat exchanger di industri petrokimia. Metode CF dipilih karena kemampuannya mengakomodasi ketidakpastian dalam hubungan gejala-kerusakan, yang merupakan tantangan utama dalam sistem industri kompleks [16], [18]. Pendekatan eksperimen dengan pengumpulan data lapangan secara langsung digunakan untuk memperoleh data operasional dari sistem heat exchanger yang beroperasi. Data tersebut dianalisis untuk mendeteksi gejala abnormalitas dan menghitung nilai CF guna mendukung diagnosis yang akurat [17].

A. Desain Penelitian

Penelitian ini menggunakan desain eksperimen observasional untuk mengumpulkan data operasional heat exchanger di industri petrokimia. Data mencakup parameter suhu, tekanan, aliran fluida, dan variabel lain yang mempengaruhi kinerja sistem.

Pembangunan knowledge base sistem pakar dilakukan melalui:

1. Pakar instrument dan process engineer.
2. Studi literatur tentang *troubleshooting heat exchanger* [2], [3].
3. Analisis data historis kerusakan.

Monitoring dilakukan terhadap kondisi operasional normal dan abnormal, mencakup gangguan seperti *fouling* [2], malfungsi *control valve*, dan *drift sensor* [4]. Data yang terkumpul dianalisis menggunakan mekanisme inferensi CF untuk mendeteksi abnormalitas dan menghitung tingkat keyakinan diagnosis [17], [18].

B. Peralatan dan Instrumen Penelitian

Sistem *heat exchanger* industri petrokimia yang dilengkapi sensor suhu, tekanan, dan aliran fluida digunakan sebagai sumber data operasional. Sistem pakar berbasis CF dikembangkan untuk menganalisis data dan mendeteksi abnormalitas berdasarkan aturan dalam basis pengetahuan. Pengolahan data dilakukan menggunakan Python untuk perhitungan, analisis statistik, dan visualisasi hasil.

C. Pengumpulan Data

Data dalam penelitian ini dikumpulkan melalui dua sumber utama, yaitu:

1. Data Operasional *Heat Exchanger*

Parameter suhu inlet/outlet (*hot side* dan *cold side*), set point dan process variable (PV), output controller, tekanan, aliran fluida, deviasi suhu dari set point, dan profil perubahan suhu terhadap waktu.

2. Observasi Gejala Abnormalitas

Identifikasi kondisi abnormal yang disebabkan fouling, malfungsi control valve, drift sensor, dan gangguan lain yang mempengaruhi kinerja sistem.

D. Prosedur Analisis Data

Data yang dikumpulkan akan melalui beberapa tahap pengolahan dan analisis sebagai berikut:

1. Identifikasi Gejala

Gejala abnormalitas dianalisis untuk mendeteksi penurunan efisiensi atau indikasi kerusakan, kemudian dibandingkan dengan aturan dalam basis pengetahuan sistem pakar.

2. Perhitungan Certainty Factor (CF)


Metode CF digunakan untuk menghitung tingkat keyakinan terhadap kemungkinan abnormalitas berdasarkan gejala yang terdeteksi.

3. Evaluasi Kinerja Sistem Pakar

Sistem dievaluasi menggunakan 22 skenario abnormalitas kontrol suhu dari data historis dan simulasi kondisi abnormal. Metrik evaluasi meliputi akurasi, precision, dan *recall*. *Ground truth* ditentukan melalui verifikasi pakar dan inspeksi fisik peralatan, kemudian dibandingkan dengan hasil diagnosis sistem [13].

E. Alur Kerja Sistem

Gambar 1 dibawah ini menunjukkan alur kerja sistem diagnosis. Proses dimulai dari import dataset yang berisi data gejala dan kerusakan. Pengguna memilih gejala sesuai kondisi yang di amati, kemudian menekan tombol Diagnosa untuk memulai perhitungan CF. Sistem menganalisis setiap kemungkinan kerusakan, menghitung nilai CF kombinasi untuk semua gejala, dan mengurutkan hasil berdasarkan nilai CF tertinggi. Hasil diagnosis beserta rekomendasi perbaikan kemudian ditampilkan kepada pengguna.



Gambar 1. Diagram Blok Pengelolaan Data

F. Persamaan Certainty Factor

Certainty Factor (CF) mengukur tingkat keyakinan terhadap suatu hipotesis berdasarkan evidence yang diamati. Metode ini menangani ketidakpastian data dan pengetahuan dalam sistem pakar menggunakan persamaan (1):

1. CF dari Pakar dan Pengguna

$$CF(H, E) = CF_{pakar} \times CF_{user} \quad (1)$$

Keterangan :

- $CF(H, E)$: Nilai *certainty factor* untuk hipotesis H (jenis kerusakan) berdasarkan evidence E (gejala yang diamati).
 - CF_{pakar} : Tingkat keyakinan pakar terhadap hubungan antara gejala dan kerusakan, diperoleh dari wawancara atau literatur.
 - CF_{user} : Tingkat keyakinan pengguna (operator) terhadap gejala yang dipilih berdasarkan observasi di lapangan.
- Nilai CF_{pakar} dan CF_{user} biasanya berada dalam rentang $[0,1]$ atau $[0\%, 100\%]$.

2. Kombinasi Certainty Factor untuk Beberapa Gejala

Untuk lebih dari satu gejala yang mendukung hipotesis sama, nilai CF dikombinasikan menggunakan persamaan (2):

$$CF_{combine} = CF_1 + CF_2(1 - CF_1) \quad (2)$$

Dengan CF_1 dan CF_2 adalah nilai CF dari gejala pertama dan kedua.

3. Kombinasi untuk n Gejala

Untuk n gejala, rumus kombinasi dilakukan secara iteratif menggunakan persamaan (3):

$$CF_{combine} = CF_{combine-prev} + CF_{next}(1 - CF_{combine-prev}) \quad (3)$$

Dengan $CF_{combine-prev}$ adalah hasil kombinasi gejala sebelumnya dan CF_{next} adalah CF gejala berikutnya. Proses iteratif ini menghasilkan nilai CF akhir yang mencerminkan keyakinan sistem terhadap diagnosis.

Contoh Penerapan

Untuk mendiagnosis "Sensor Suhu Inlet Rusak", dengan tiga gejala:

- Gejala G1 : $CF = 0,8$
- Gejala G3 : $CF = 0,7$
- Gejala G4 : $CF = 0,6$

Kombinasi CF dilakukan sebagai berikut:

- $CF_{combine} (G1, G3) = 0,8 + 0,7 \times (1 - 0,8) = 0,94$
- $CF_{combine} ((G1, G3), G4) = 0,94 + 0,6 \times (1 - 0,94) = 0,976$

Sehingga nilai CF akhir untuk hipotesis "Sensor Suhu Inlet Rusak" adalah 97,6%.

3. PEMBAHASAN

A. Pembangunan Sistem

1. Dataset

Knowledge base sistem dibangun melalui observasi langsung di lapangan bersama pakar instrument engineer dan disusun dalam Microsoft Excel. Dataset komprehensif mencakup 314 gejala abnormalitas yang dikelompokkan berdasarkan komponen sistem kontrol suhu heat exchanger:

1. Sensor dan transmitter (suhu, tekanan, aliran): 180 gejala
2. Aktuator (control valve, pneumatic, hydraulic): 65 gejala
3. Sistem kontrol (PLC, RTU, SCADA, HMI): 45 gejala
4. Komponen pendukung (motor, kabel, thermocouple): 24 gejala

Setiap gejala dikaitkan dengan 32 jenis kerusakan yang telah diidentifikasi berdasarkan data historis kerusakan dan validasi pakar.

2. Pengolahan dan Implementasi

Data dari Microsoft Excel (format Dataset_Heat Exchanger) diolah untuk menentukan nilai certainty factor yang digunakan dalam mekanisme inferensi sistem. Implementasi dilakukan menggunakan Python pada Visual Studio Code untuk perhitungan CF, analisis data, dan visualisasi antarmuka. Hasil akhir adalah sistem pakar berbasis web dengan knowledge base terstruktur yang siap digunakan untuk diagnosis.

B. Implementasi Sistem dan Tampilan Antarmuka

1. Tampilan Umum Sistem

Gambar 2 menunjukkan antarmuka sistem yang terbagi menjadi dua area: panel input gejala (kiri) dan panel hasil diagnosis beserta rekomendasi (kanan). Sistem secara otomatis memproses data dan menampilkan hasil berdasarkan nilai Certainty Factor.

Gambar 2. Tampilan Umum Sistem



2. Input Gejala



Gambar 3. Tampilan Input Gejala

Panel input gejala (Gambar 3) menyediakan daftar 314 gejala dengan nomor identifikasi yang dipilih sesuai kondisi lapangan. Fitur pencarian memungkinkan menemukan gejala dengan cepat. Dua tombol disediakan: tombol hijau "Diagnosa" untuk memulai perhitungan CF, dan tombol merah "Reset" untuk mereset sistem mengembalikan sistem ke kondisi awal.

3. Output Diagnosis



Gambar 4. Tampilan Hasil Diagnosa dan Rekomendasi

Panel output pada gambar 4 menampilkan hasil analisis berupa jenis kerusakan teridentifikasi, nilai CF sebagai tingkat keyakinan diagnosis, dan rekomendasi tindakan perbaikan. Tombol "Export Hasil" memungkinkan pengguna menyimpan laporan diagnosis dalam format file untuk dokumentasi dan tindak lanjut. Format output yang terstruktur memudahkan operator dalam pengambilan keputusan perbaikan.

C. Hasil Uji Implementasi Sistem

1. Pengujian Fungsional

Tabel 1 menunjukkan hasil pengujian fungsional sistem. Seluruh fitur utama berfungsi dengan baik seperti pada Tabel 1, sehingga sistem siap untuk evaluasi akurasi diagnosis.

Tabel 1. Hasil Pengujian Fungsional

No	Fitur	Fungsi	Keterangan
1	Checklist Gejala	Menyediakan daftar gejala yang dapat dipilih oleh pengguna sebagai input analisis sistem.	Berhasil
2	Pencarian Gejala	Mempermudah pengguna mencari gejala tertentu menggunakan kata kunci agar proses input lebih cepat dan akurat.	Berhasil
3	Tampilan Hasil Diagnosa & Rekomendasi	Menampilkan hasil analisis sistem pakar berdasarkan gejala yang dipilih pengguna.	Berhasil
4	Area Teks Hasil	Menyajikan informasi hasil diagnosa dan rekomendasi perbaikan secara otomatis.	Berhasil
5	Tombol "Export Hasil"	Menyimpan hasil diagnosa ke dalam bentuk file laporan.	Berhasil

2. Evaluasi Akurasi Diagnosis

Pengujian akurasi dilakukan terhadap 22 skenario yang mewakili berbagai kondisi kerusakan heat exchanger dengan kombinasi gejala yang didefinisikan berdasarkan dataset dan validasi pakar. Hasil lengkap disajikan pada Tabel 2.

Tabel 2. Hasil Pengujian Diagnosis

No	Gejala	Kerusakan (Berdasarkan Dataset)	Sistem Pakar		Hasil Pengujian
			Hasil Diagnosa	CF (%)	
1	G1, G3, G4, G5, G7	Sensor suhu inlet rusak	Sensor suhu inlet rusak	94.30%	Sesuai
2	G10, G11, G12, G14	Sensor suhu outlet rusak	Sensor suhu outlet rusak	92.75%	Sesuai
3	G20, G21, G22, G23, G29	Flow transmitter error	Flow transmitter error	96.50%	Sesuai
4	G30, G31, G32, G35, G40	Level transmitter gagal ukur	Level transmitter gagal ukur	95.75%	Sesuai
5	G41, G42, G43, G44	Control valve macet	Control valve macet	93.25%	Sesuai
6	G131, G141, G151	PLC tidak merespon	RTU komunikasi gagal	71.50%	Tidak Sesuai
7	G51, G52, G53, G57, G59	Pneumatic actuator bocor	Pneumatic actuator bocor	95.00%	Sesuai
8	G61, G62, G65, G67	Hydraulic actuator bocor	Hydraulic actuator bocor	91.25%	Sesuai
9	G71, G72, G73, G74, G79	Motor pompa trip	Motor pompa trip	96.25%	Sesuai
10	G41, G51, G61	Control valve macet	Pneumatic actuator bocor	68.75%	Tidak Sesuai
11	G81, G82, G83, G87	Motor kompresor trip	Motor kompresor trip	93.75%	Sesuai

12	G91, G92, G93, G97	Motor fan overheating	Motor fan overheating	96.75%	Sesuai
13	G101, G102, G103, G108	Kabel sinyal putus	Kabel sinyal putus	98.50%	Sesuai
14	G121, G123, G129	Panel HMI mati	Panel HMI mati	96.67%	Sesuai
15	G131, G132, G134, G135	PLC tidak merespon	PLC tidak merespon	97.50%	Sesuai
16	G141, G142, G145, G149	RTU komunikasi gagal	RTU komunikasi gagal	97.50%	Sesuai
17	G71, G91, G93	Motor pompa trip	Motor fan overheating	76.50%	Tidak Sesuai
18	G151, G152, G155, G159	SCADA tidak update data	SCADA tidak update data	94.50%	Sesuai
19	G181, G182, G185, G190	Thermocouple putus	Thermocouple putus	98.75%	Sesuai
20	G1, G2, G5	Sensor suhu inlet rusak	Sensor suhu inlet rusak	89.50%	Sesuai
21	G1, G10, G20	Sensor suhu inlet rusak	Flow transmitter error	73.25%	Tidak Sesuai
22	G161, G162, G165, G167	Flowmeter kotor	Flowmeter kotor	93.25%	Sesuai

Tabel 3. Metrik Kinerja Sistem

No	Metrik	Nilai	Keterangan
1	Total Pengujian	22 kasus	Seluruh skenario pengujian
2	Deteksi Benar	18 kasus	Diagnosis sistem = ground truth
3	Deteksi Salah	4 kasus	Diagnosis sistem $\neq$ ground truth
4	Akurasi	81,82%	$(18/22) \times 100\%$
5	Error Rate	18,18%	$(4 / 22) \times 100\%$
6	CF Rata-rata (Benar)	94,43%	Rata-rata CF untuk diagnosis benar
7	CF Rata-rata (Salah)	72,00%	Rata-rata CF untuk diagnosis salah
8	CF Rata-rata (Overall)	90,32%	Rata-rata seluruh nilai CF
9	CF Tertinggi	98,75%	Kasus No. 19
10	CF Terendah	68,75%	Kasus No. 10
11	Precision	100%	Tidak ada false positive
12	Recall	81,82%	18 dari 22 kasus terdeteksi benar
13	F1-Score	90,00%	Harmonic mean precision & recall

3. Analisis Kinerja Sistem

Sistem mencapai akurasi 81,82% dengan precision 100%, recall 81,82%, dan F1-score 90,00%. Precision sempurna menunjukkan tidak ada false positive, yang krusial untuk menghindari tindakan perbaikan tidak perlu di lingkungan petrokimia berisiko tinggi. Nilai CF rata-rata 90,32% menunjukkan konsistensi tingkat keyakinan sistem dalam proses inferensi. Perbedaan signifikan antara CF rata-rata diagnosis benar (94,43%) dan salah (72,00%) membuktikan efektivitas CF sebagai indikator ketidakpastian. Nilai CF rendah pada misdiagnosis dapat menjadi tanda peringatan bagi operator untuk melakukan verifikasi tambahan, sejalan dengan prinsip decision support system yang menyertakan tingkat kepercayaan dalam rekomendasinya.

Dari 4 kasus misdiagnosis (18,18%), teridentifikasi pola kesalahan sistematis:

1. Kasus 6 (CF: 71,50%): Overlap gejala G131, G141, G151 antara "PLC tidak merespon" dan "RTU komunikasi gagal" karena keduanya dalam hierarki sistem komunikasi kontrol yang sama.
2. Kasus 10 (CF: 68,75%): Gejala G41, G51, G61 tidak cukup spesifik membedakan "Control valve macet" dari "Pneumatic actuator bocor" karena manifestasi serupa pada sistem aktuasi.
3. Kasus 17 (CF: 76,50%): Gejala motor trip (G71, G91, G93) sulit dibedakan antara motor pompa dan motor fan tanpa informasi kontekstual lokasi atau fungsi spesifik.
4. Kasus 21 (CF: 73,25%): Kombinasi lintas-komponen (G1, G10, G20) tanpa pola konsisten dalam knowledge base, menyebabkan sistem memilih diagnosis dengan CF tertinggi yang tidak sesuai ground truth.

Analisis penyebab misdiagnosis menunjukkan kesalahan bukan dari metode CF, melainkan keterbatasan knowledge base rule-based yang diskrit. Keempat kasus gagal memiliki gejala tumpang tindih tanpa distinguishing features memadai. Penyebab spesifik: (1) ketergantungan hierarki PLC dan RTU berbagi jalur komunikasi; (2) keterkaitan fungsional valve dan actuator dalam satu sistem aktuasi; (3) ketiadaan konteks sistem tidak memiliki metadata lokasi; dan (4) kurangnya aturan kombinatorial knowledge base tidak menangani kombinasi lintas-komponen langka. Nilai CF kasus salah (72,00%) lebih rendah dari kasus benar (94,43%), memvalidasi kemampuan sistem mengindikasikan ketidakpastian ketika informasi tidak cukup. Signifikansi metode CF tampak jelas pada kasus gejala tumpang tindih. Sistem mengakumulasi nilai CF melalui inferensi bertingkat untuk menghasilkan ranking diagnosis, memungkinkan operator mendapat beberapa kemungkinan dengan prioritas jelas.

4. Perbandingan dengan Penelitian Sejenis

Untuk memposisikan kontribusi penelitian ini, dilakukan perbandingan dengan studi sejenis yang menerapkan sistem pakar untuk diagnosis industri (Tabel 4).

Tabel 4. Perbandingan dengan Penelitian Sejenis

Penelitian	Metode	Domain Aplikasi	Akurasi	Precision	Recall	Kelebihan Penelitian
Penelitian ini	CF	Heat exchanger petrokimia	81,82%	100%	81,82 %	• Dataset komprehensif (314 gejala, 32 kerusakan) • Nilai CF sebagai indikator ketidakpastian
Taira et al. [12]	Bayesian RNN	FCC process	~85%	N/A	N/A	• Real-time capability • Learning dari data
Yan et al. [13]	Hybrid AI	Smart manufactur	75-90%	N/A	N/A	• Scalable untuk berbagai proses
Kusnadi et al. [17]	CF	Meat classificati on	87,5%	N/A	N/A	• Akurasi lebih tinggi
Setyaputri et al. [18]	CF vs Bayes	ENT disease	CF:80% Bayes:75%	N/A	N/A	CF unggul vs Bayes

Sistem mencapai akurasi 81,82% dan precision 100%, menunjukkan performa kompetitif terhadap penelitian sejenis (75–90%). Meskipun sedikit di bawah Taira et al. [12] (~85%), hasil ini tetap signifikan mengingat kompleksitas heat exchanger dengan 32 jenis kerusakan. Keunggulan utama terletak pada precision sempurna tanpa false positive, yang sangat penting dalam konteks industri petrokimia berisiko tinggi. Pendekatan Certainty Factor juga terbukti efektif untuk diagnosis dengan ketidakpastian tinggi, sejalan dengan temuan Setyaputri dkk [18]. Dataset komprehensif (314 gejala, 32 kerusakan) memperkuat keandalan sistem, sementara nilai recall 81,82% masih dapat ditingkatkan pada kasus ambigu tanpa mengorbankan precision.

D. Limitasi dan Arah Pengembangan

1. Limitasi Sistem

Evaluasi terhadap kinerja sistem mengidentifikasi beberapa keterbatasan utama berikut:

a. Ambiguitas pada Gejala Overlapping

Sebanyak 4 kasus misdiagnosis (18,18%) terjadi akibat kesulitan membedakan gejala yang tumpang tindih, terutama pada komponen berjenjang (PLC–RTU), komponen dengan fungsi terkait (valve–actuator), komponen serupa di lokasi berbeda (motor pompa–fan), serta kombinasi lintas-komponen. Hal ini disebabkan oleh pendekatan rule-based yang bersifat diskrit, sementara relasi gejala–kerusakan di lapangan cenderung probabilistik dan kontekstual.

b. Knowledge Base Statis

Basis pengetahuan bersifat statis dan memerlukan pembaruan manual ketika muncul jenis kerusakan baru, terjadi perubahan karakteristik akibat aging atau modifikasi proses, maupun adanya pembelajaran dari misdiagnosis. Kondisi ini membatasi adaptabilitas sistem terhadap dinamika operasi dan berpotensi menurunkan akurasi jika tidak diperbarui secara berkala.

c. Keterbatasan Reasoning terhadap Common Cause Failure

Knowledge base dirancang untuk single-component failure, sedangkan pada praktik industri sering terjadi multiple failure akibat penyebab umum seperti gangguan daya, faktor lingkungan, atau kesalahan pemeliharaan. Sistem belum memiliki mekanisme untuk mengenali pola tersebut.

2. Arah Pengembangan Sistem

a. Hybrid Intelligence

Integrasi machine learning dengan rule-based system diusulkan untuk mengatasi

keterbatasan knowledge base statis dan ambiguitas diagnosis. Melalui supervised dan active learning, sistem dapat memperbarui knowledge base secara otomatis, dengan target peningkatan recall menjadi 90–95% dengan precision tetap tinggi.

b. Dynamic Confidence Threshold

Penerapan threshold dinamis berbasis konteks dan akurasi historis bertujuan meningkatkan reliabilitas keputusan sistem. Nilai ambang CF disesuaikan dengan jenis komponen, kompleksitas gejala, dan riwayat performa diagnosis, sehingga keputusan lebih konsisten tanpa mengurangi responsivitas.

c. Integrasi SCADA dan Monitoring Real-Time

Integrasi SCADA/DCS memungkinkan automated symptom detection dan predictive diagnosis, dengan target penurunan MTTD menjadi <5 menit dan peringatan dini 6 – 24 jam sebelum kegagalan.

Penelitian ini memvalidasi ontribusi akademis metode *Certainty Factor* dalam diagnosis abnormalitas *heat exchanger*, menunjukkan bahwa nilai CF mampu merepresentasikan tingkat ketidakpastian secara andal. Temuan pola sistematis pada misdiagnosis juga membuka peluang riset lanjutan terkait penanganan gejala ambigu. Secara praktis, sistem dikembangkan menjadi decision support tool dengan infrastruktur minimal dan precision 100%, sehingga layak diterapkan di industri. Sistem ini juga membantu pelestarian pengetahuan pakar serta mudah diadaptasi untuk peralatan lain di pabrik. Secara keseluruhan, penelitian ini membuktikan potensi *Certainty Factor* untuk meningkatkan keandalan diagnosis sistem industri dan menjadi dasar pengembangan sistem cerdas yang lebih adaptif di masa depan.

4. SIMPULAN

Penelitian ini bertujuan mengembangkan sistem pakar berbasis metode *Certainty Factor* (CF) untuk mendiagnosis abnormalitas kontrol suhu pada heat exchanger di industri petrokimia. Dengan pendekatan berbasis pengetahuan (rule-based), sistem mampu memberikan diagnosis yang terukur menggunakan nilai keyakinan (CF) sebagai indikator ketidakpastian. Hasil pengujian menunjukkan akurasi 81,82%, precision 100%, dan recall 81,82%, menegaskan bahwa metode CF efektif dan reliabel dalam mendeteksi kerusakan tanpa menghasilkan false positive. Dataset komprehensif (314 gejala dan 32 jenis kerusakan) memperkuat validitas hasil dan menunjukkan kemampuan sistem dalam menangani kompleksitas industri proses. Secara akademis, penelitian ini memperluas penerapan CF ke ranah industri petrokimia, sementara secara praktis sistem ini berfungsi sebagai alat bantu keputusan (decision support tool) yang mudah diimplementasikan tanpa infrastruktur tambahan. Keterbatasan pada kasus gejala tumpang tindih menjadi dasar untuk pengembangan hybrid expert system yang mengintegrasikan machine learning dan SCADA guna meningkatkan adaptivitas dan diagnosis real-time di masa depan.

5. DAFTAR PUSTAKA

- [1] F. Deng and F. Wang, “Misoperation monitoring and early warning during startup and shutdown of petrochemical units,” *J. Loss Prev. Process Ind.*, vol. 67, p. 104265, 2020, doi: 10.1016/j.jlp.2020.104265.
- [2] A. Elwerfalli, S. Alsadaie, and I. M. Mujtaba, “Estimation of shutdown schedule to remove fouling layers of heat exchangers using risk-based inspection (RBI),” *Processes*, vol. 9, no. 12, p. 2177, 2021, doi: 10.3390/pr9122177.
- [3] W. Augustin, L. F. Melo, and D. I. Wilson, “Towards a common taxonomy for heat exchanger fouling,” in *Heat Exchanger Fouling and Cleaning XV – 2024, Heat Transfer (HMT)*, 2025.
- [4] B. Pfortner, W. Al Hadad, V. Schick, et al., “Transient detection of either maldistribution or flowrate change in a counter current plate-fin heat exchanger using an ARX model,” *Chem. Eng.*

- Res. Des.*, vol. 163, pp. 325–335, 2021, doi: 10.1016/j.cherd.2020.12.031.
- [5] T. S. Purwanto, D. I. Permana, M. Nurbanasari, et al., “Failure analysis of low- pressure evaporator in heat recovery steam generator with 200 ton/h of capacity,” *J. Fail. Anal. Prev.*, vol. 23, no. 5, p. 01769, 2023, doi: 10.1007/s11668-023-01769-7.
 - [6] K. Parsa, M. Hassall, and M. Naderpour, “Enhancing Alarm Prioritization in the Alarm Management Lifecycle,” *IEEE Access*, vol. 10, pp. 99–111, 2021, doi: 10.1109/ACCESS.2021.3137865.
 - [7] A. Misuri, G. Landucci, and V. Cozzani, “Assessment of safety barrier performance in the mitigation of domino scenarios caused by Natech events,” *Reliab. Eng. Syst. Saf.*, vol. 205, p. 107278, 2021, doi: 10.1016/j.ress.2020.107278.
 - [8] J. Zhang, W. Luo, and Y. Dai, “Integrated diagnostic framework for process and sensor faults in chemical industry,” *Sensors*, vol. 21, no. 3, p. 822, 2021, doi: 10.3390/s21030822.
 - [9] M. Golyadkin, V. Pozdnyakov, L. Zhukov, and I. Makarov, “SensorSCAN: Self- supervised learning and deep clustering for fault diagnosis in chemical processes,” *Artif. Intell.*, vol. 324, p. 104012, 2023, doi: 10.1016/j.artint.2023.104012.
 - [10] W. Li, H. Li, S. Gu, et al., “Process fault diagnosis with model- and knowledge- based approaches: Advances and opportunities,” *J. Process Control*, vol. 80, pp. 35–45, 2020, doi: 10.1016/j.jprocont.2020.02.003.
 - [11] D. Bouhalouan, B. Nachet, and A. Adla, “Knowledge-Intensive Decision Support System for Manufacturing Equipment Maintenance,” *J. Decis. Syst.*, vol. 18, no. 3, pp. 85–98, 2020, doi: 10.6025/jdim/2020/18/3/85-98.
 - [12] G. R. Taira, S. W. Park, and A. C. Zanin, “Fault detection in a fluid catalytic cracking process using a Bayesian recurrent neural network,” in *Proc. 13th IFAC Symp. on Dynamics and Control of Process Systems, Including Biosystems (DYCOPS 2022)*, 2022, pp. 1–6.
 - [13] W. Yan, J. Wang, S. Lu, et al., “A review of real-time fault diagnosis methods for industrial smart manufacturing,” *Processes*, vol. 11, p. 369, 2023, doi: 10.3390/pr11020369.
 - [14] Reetz, T. Neumann, G. Schrijver, et al., “Expert system-based fault diagnosis for railway point machines,” *J. Rail Transp. Plann. Manage.*, vol. 15, pp. 50–60, 2023, doi: 10.1016/j.jrtpm.2022.100074.
 - [15] X. Yuan *et al.*, “A comparative analysis of certainty factor-based machine learning methods for collapse and landslide susceptibility mapping in Wenchuan County, China,” *Remote Sens (Basel)*, vol. 14, no. 14, p. 3259, 2022, doi: 10.3390/rs14143259.
 - [16] R. Irsyada, N. Cahyani, and L. Badriyah, “Innovation of an expert system for diagnosing allergic diseases in children using the web-based certainty factor method,” *Brilliance: Research of Artificial Intelligence*, vol. 4, no. 2, pp. 909–918, 2024.
 - [17] A. Kusnadi, Y. Arkeman, K. Syamsu, and S. H. Wijaya, “Certainty factor-based expert system for meat classification within an enterprise resource planning framework,” *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika*, vol. 9, no. 3, pp. 661–672, 2023.
 - [18] K. E. Setyaputri, A. Fadlil, and Sunardi, “Comparative analysis of certainty factor method and Bayes probability method on ENT disease expert system,” *Scientific Journal of Informatics*, vol. 5, no. 2, pp. 142–150, 2018.