DIAGNOSIS KERUSAKAN PADA SISTEM *COMPRESSOR* PRODUKSI GAS MENGGUNAKAN PREDIKSI *CERTAINTY FACTOR* DAN *NAIVE BAYES*

Ihad Rayyan Jhorrif [1], Muhammad Iqbal Yusan[1*], Amelia Vega[1], Rindu Restu Adinda[1], Asepta Surya Wardhana[1]
[1]Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58311, Indonesia,
**E-mail: Iqbalmv096@gmail.com*

ABSTRAK

Diagnosis dini pada sistem kompresor produksi gas memiliki peran strategis dalam mencegah *down-time*, mempertahankan efisiensi operasi, dan menekan biaya perawatan reaktif yang sering terjadi akibat keterlambatan deteksi kerusakan. Sebagian besar penelitian sebelumnya masih menggunakan pendekatan tunggal, baik berbasis aturan (*rule-based inference*) maupun klasifikasi probabilistik, yang cenderung kurang optimal ketika gejala bersifat ambigu, tumpang tindih, atau data sensor tidak lengkap. Untuk mengatasi keterbatasan tersebut, penelitian ini mengusulkan sistem pakar hibrid yang mengombinasikan *forward chaining* sebagai mesin inferensi utama, *Certainty Factor* (CF) untuk merepresentasikan tingkat keyakinan pakar terhadap hubungan gejala dan penyebab, serta *Naïve Bayes* untuk memperkuat keputusan diagnosis melalui pembelajaran probabilistik. Integrasi dilakukan dengan menerapkan fungsi pembobotan adaptif yang menyeimbangkan kontribusi nilai kepercayaan pakar (CF) dan probabilitas empiris hasil perhitungan *posterior*. Sistem diimplementasikan menggunakan bahasa pemrograman Python dan diuji menggunakan kumpulan data terstruktur yang berasal dari log historis gangguan kompresor serta skenario sintetik berbasis pengetahuan domain industri gas. Hasil pengujian menunjukkan bahwa pendekatan hibrid ini mampu meningkatkan stabilitas dan akurasi diagnosis secara signifikan, dengan peningkatan terukur hingga 37.7% dibandingkan metode Naïve Bayes murni pada skenario kasus kritis (seperti *Level Transmitter Rusak*). Temuan ini menegaskan potensi pendekatan hibrid dalam pengembangan sistem diagnosis cerdas di lingkungan industri proses.

Kata kunci: diagnosis kerusakan kompresor, sistem pakar, *forward chaining, certainty factor*, naïve bayes

1. PENDAHULUAN

Sistem kontrol pada compressor memegang peranan krusial dalam berbagai aplikasi industri, termasuk proses pengolahan gas, sistem HVAC, dan unit pendingin, karena kegagalan kontrol dapat mengakibatkan penurunan efisiensi, gangguan operasional, dan konsekuensi keselamatan yang serius [1]. Oleh karena itu, diagnosis dini terhadap anomali dan kerusakan pada sistem kontrol compressor diperlukan untuk mengurangi downtime dan biaya perawatan [2]. Pendekatan tradisional untuk diagnosis fault pada mesin putar (termasuk kompresor) meliputi analisis sinyal getaran, monitoring tekanan/aliran (flow), serta metode statistik dan Machine Learning (ML).

Teknik seperti PCA, SVM, dan deep learning telah menunjukkan kinerja yang baik pada tugas klasifikasi kondisi mesin. Secara spesifik, penelitian oleh Prediksi *fault* pada kompresor udara telah diteliti secara spesifik dengan mengaplikasikan teknik fusi fitur [3]. Selain itu, diagnosis *fault* kompresor dan visualisasi hasil juga telah dijelajahi [4], sementara diagnosis *fault* cerdas pada kompresor torak (*reciprocating compressors*) berbasis *deep learning* turut dipaparkan [5]. Namun, metode berbasis data murni sering memerlukan dataset berlabel besar dan dapat kehilangan aspek interpretabilitas yang penting bagi engineer lapangan. Oleh

sebab itu, kombinasi antara pengetahuan ahli (rule-based) dan metode probabilistik/data-driven menjadi pilihan yang menarik [6].

Sistem pakar rule-based dengan forward chaining memungkinkan representasi eksplisit relasi gejala→kerusakan sehingga hasil diagnosis mudah ditelusuri dan digunakan sebagai panduan troubleshooting oleh operator [7]. Namun, pada kondisi nyata gejala sering bersifat tidak pasti akibat kebisingan sensor, missing values, dan multifaktorialitas penyebab kerusakan; faktor-faktor ini menurunkan keandalan inferensi deterministik tanpa mekanisme penanganan ketidakpastian. Untuk itu, teknik seperti Certainty Factor (CF) dapat memberi bobot keyakinan pada aturan berbasis pengetahuan [8], sedangkan metode probabilistik seperti Naive Bayes dapat memanfaatkan distribusi historis gejala untuk memperbaiki estimasi hipotesis kerusakan [9]. Penggabungan pendekatan rule-based dan probabilistic telah diusulkan dalam domain serupa untuk mendapatkan keseimbangan antara interpretabilitas dan generalisasi [10]. Kombinasi keduanya membentuk pendekatan hybrid yang berupaya mengintegrasikan kejelasan logika pakar dan kekuatan inferensi probabilistik dalam satu sistem diagnosis.

Meskipun demikian, literatur yang secara eksplisit mengintegrasikan *forward chaining* + CF + Naive Bayes dalam konteks kontrol compressor, disertai evaluasi yang transparan terhadap dataset kasus nyata, masih terbatas [11]. Oleh karena itu, penelitian ini mengembangkan dan mengevaluasi sistem pakar hybrid—menggabungkan forward chaining, CF, dan Naive Bayes—yang diimplementasikan dalam aplikasi Python untuk diagnosis kerusakan pada sistem evaporator–compressor–knockout drum. Evaluasi fokus pada (i) konsistensi inferensi terhadap variasi input gejala, (ii) perbandingan keluaran antara CF saja dan CF+Naive Bayes, serta (iii) analisis keterbatasan terkait validasi data nyata dan kesiapan implementasi industri [12]. Oleh karena itu, penelitian ini bertujuan mengembangkan sistem pakar hybrid (Forward Chaining + CF + Naive Bayes) untuk diagnosis kerusakan kompresor produksi gas. Kontribusi utama penelitian ini adalah (i) mengusulkan fungsi pembobotan adaptif untuk menyeimbangkan inferensi pakar dan probabilistik, serta (ii) memvalidasi peningkatan stabilitas dan akurasi diagnosis hybrid dibandingkan metode Certainty Factor tunggal, menggunakan skenario kasus nyata.

2. METODE

Metode penelitian ini disusun untuk merancang dan mengimplementasikan sistem pakar diagnosis kerusakan pada sistem kontrol compressor produksi gas. Tahapan metodologi melibatkan pembentukan basis pengetahuan dari parameter sensor utama, pemilihan mesin inferensi, serta penerapan pendekatan untuk mengatasi ketidakpastian, yaitu Certainty Factor (CF) dan Naïve Bayes. Dengan struktur ini, penelitian dapat menghasilkan diagnosis yang bersifat eksploratif sekaligus memiliki derajat keyakinan kuantitatif dan probabilistik. Secara rinci, metodologi terdiri atas beberapa komponen utama sebagai berikut.

A. *Forward Chaining*

Forward Chaining merupakan metode inferensi berbasis aturan (*rule-based inference*) yang menelusuri pengetahuan dari premis (evidence) menuju kesimpulan (goal). Aturan direpresentasikan dalam bentuk implikasi persamaan sebagai berikut:

$$"IF\ "(p_1 \wedge p_2 \wedge \ldots \wedge p_n)"\ THEN\ "\ q \quad (1)$$

Dengan:

- $\mathbf{p_1, p_2, \ldots, p_n}$: fakta atau evidence dari hasil pembacaan sensor (misalnya PT tinggi, FT rendah, TT meningkat),
- **q** : hipotesis atau jenis kerusakan yang diidentifikasi, misalnya *Discharge Valve Stuck*

Proses inferensi dimulai dari fakta awal (gejala teramati), kemudian sistem mencocokkannya dengan aturan dalam basis pengetahuan. Bila premis terpenuhi, sistem menghasilkan kesimpulan baru dan menambahkannya ke himpunan fakta. Proses ini berlangsung secara iteratif hingga tidak ada aturan lain yang dapat diterapkan. Pendekatan ini efektif untuk diagnosis eksploratif karena mampu meniru pola penalaran pakar dalam mengaitkan gejala dengan kemungkinan kerusakan [13].

B. *Certainty Factor (CF)*

Certainty Factor (CF) digunakan untuk menangani ketidakpastian pada proses inferensi. Konsep ini diperkenalkan oleh Shortliffe dan Buchanan (1975) dalam sistem pakar medis MYCIN [14], untuk merepresentasikan tingkat keyakinan pakar terhadap hipotesis berdasarkan evidence. Tingkat keyakinan dihitung dengan:

$$CF(H,E) = MB(H,E) - MD(H,E) \tag{2}$$

Dengan:
- MB(H,E) : tingkat keyakinan terhadap hipotesis H,
- MD(H,E) : tingkat penolakan terhadap hipotesis H

Kombinasi beberapa evidence dilakukan menggunakan aturan berikut:
- Jika CF_1 dan CF_2 positif, maka:

$$CF_comb = CF_1 + CF_2\ (1 - CF_1) \tag{3}$$

- Jika CF_1 dan CF_2 negatif, maka:

$$CF_comb = CF_1 + CF_2\ (1 + CF_1) \tag{4}$$

- Jika CF_1 dan CF_2 berbeda tanda (konflik), maka:

$$CF_{comb} = \frac{CF_1 + CF_2}{1 - \min\ (|\ CF_1\ |, |\ CF_2\ |)} \tag{5}$$

Metode ini memungkinkan sistem untuk menggabungkan beberapa gejala secara bertahap dengan mempertimbangkan tingkat keyakinan pakar terhadap setiap hubungan gejala dan kerusakan. Pendekatan Certainty Factor tetap relevan pada sistem diagnosis industri karena mampu menangani keterbatasan data statistik serta memberikan pelacakan keputusan (traceability) yang jelas, [15], [16], [17].

C. *Naïve Bayes*

Naïve Bayes digunakan sebagai lapisan probabilistik untuk memperkuat hasil inferensi berbasis aturan, terutama ketika evidence bersifat ambigu atau beberapa hipotesis memiliki nilai CF yang berdekatan. Model ini dipilih karena kesederhanaan, efisiensi komputasi, dan kemampuannya memberikan estimasi probabilitas posterior secara langsung. Rumus dasar Naïve Bayes dituliskan sebagai:

$$P(H \mid E) \propto P(H) \prod_i P\ (e_i \mid H) \tag{6}$$

Dengan:

- H = hipotesis kerusakan,
- E = himpunan evidence (gejala),
- P(H) = probabilitas awal (prior),
- $P(e_i|H)$ = peluang evidence ke-i muncul jika hipotesis benar

Parameter prior dan likelihood diestimasi dari data historis menggunakan regularisasi untuk mengatasi ketidakseimbangan kelas. Naïve Bayes sering digunakan sebagai baseline diagnosis karena hasilnya yang stabil, interpretable, dan tetap kompetitif meskipun data terbatas [18].

D. Kerangka Kerja Hibrid dan Fungsi Pembobotan Adaptif

Integrasi antara Certainty Factor (CF) dan Naïve Bayes (NB) merupakan inti dari sistem diagnosis yang diusulkan, bertujuan untuk mengoptimalkan diagnosis dengan menyeimbangkan kekuatan inferensi berbasis pengetahuan (CF) dan kekuatan estimasi probabilistik berbasis data (NB). Kerangka kerja hibrid ini mengatasi kelemahan masing-masing metode tunggal: CF rentan terhadap bias pakar dan kurang sensitif terhadap data empiris, sementara NB kehilangan traceability dan rentan terhadap asumsi independensi yang ketat. Proses hibridisasi dilakukan melalui dua langkah utama, diikuti dengan penghitungan skor diagnosis akhir menggunakan fungsi pembobotan adaptif yaitu:

- Proses Inferensi Berantai *(Forward Chaining)*

Inferensi dimulai dengan *Forward Chaining* (FC). Berdasarkan gejala (*E*) yang diinput dari sensor/operator, sistem memproses aturan (*rules*) yang memiliki bobot keyakinan pakar (CF_aturan). Hasil dari proses ini adalah nilai Certainty Factor Gabungan (CF_gabungan) untuk setiap hipotesis kerusakan (*H*).

$$CF_{gabungan}(H) = CF_{Kombinasi}(CF_1, CF_2, \ldots . CF_n) \quad (7)$$

Nilai CF_gabungan merepresentasikan tingkat keyakinan yang berasal murni dari basis pengetahuan dan pengalaman pakar.

- Estimasi Probabilitas Empiris *(Naïve Bayes)*

Secara paralel, himpunan *evidence (E)* yang sama digunakan sebagai input untuk model Naïve Bayes. Model ini menghasilkan nilai Probabilitas Posterior (*P(H|E)*) yang merepresentasikan peluang empiris bahwa hipotesis *H* benar, berdasarkan distribusi frekuensi dari data historis.

$$P(H|E) = \frac{P(H)\prod_{i=1}^{n} P(e_i|H)}{P(E)} \quad (8)$$

- Fungsi Pembobotan Adaptif untuk Diagnosis Final

Skor diagnosis akhir (D_{inal) diperoleh dengan mengombinasikan nilai CF_gabungan (infe-rensi pakar) dan *P(H|E)* (inferensi probabilistik) melalui fungsi pembobotan adaptif:

$$D_{final} = \alpha . Normalisasi(CF_{gabungan}) + (1 - \alpha) . P(H|E) \quad (9)$$

Dengan:

- D_final: Skor keyakinan diagnosis akhir ($0 \leq$ D_final ≤ 1).
- Normalisasi(CF_gabungan): Nilai CF_gabungan diubah ke rentang [0, 1] agar setara dengan probabilitas, menggunakan fungsi linear atau non-linear yang telah ditentukan.
- α: Faktor pembobot adaptif ($0 \leq$ alpha ≤ 1). Nilai α menentukan seberapa besar

kontribusi rule-based (CF) dan data-driven (NB) terhadap keputusan akhir.

Adaptasi Faktor α

Nilai α tidak ditetapkan secara statis, melainkan diadaptasi berdasarkan kondisi input atau hasil inferensi, yang merupakan kunci dari pendekatan hibrid ini:

- Prioritas Pakar (CF): Jika α mendekati 1, keputusan didominasi oleh keyakinan pakar (CF).
  Ini ideal saat data historis yang tersedia terbatas atau *evidence* input sangat langka.
- Prioritas Data (NB): Jika α mendekati 0, keputusan didominasi oleh probabilitas data historis (NB). Ini ideal saat data sensor sangat lengkap dan *evidence* input sering ditemukan dalam log historis.
- Kondisi Ambigu: Dalam skenario di mana nilai CF_gabungan dan P(H|E) saling bertentangan (misalnya, CF tinggi tetapi P(H|E) rendah), α dapat diatur menjadi 0.5 untuk menghasilkan konsensus seimbang, atau disesuaikan berdasarkan tingkat ketidakpastian *evidence* (misalnya, semakin banyak *missing values* pada input, semakin tinggi bobot α diberikan kepada CF).

Melalui fungsi pembobotan ini, sistem hybrid mampu menghasilkan diagnosis yang memiliki keterlacakan (traceability) yang jelas (dari FC dan CF) sekaligus memiliki stabilitas dan generalisasi yang tinggi (dari NB dan data empiris).

E. *Implementasi teknis dan reproducibility*

Sistem diimplementasikan menggunakan Python (versi ≥3.8), dengan modul seperti scikit-learn untuk Naïve Bayes dan evaluasi, serta modul custom untuk engine forward chaining & CF. Semua skrip eksperimen, file mapping gejala→kerusakan, serta instruksi untuk mereproduksi eksperimen akan dipublikasikan pada repository (link disediakan pada lampiran manuskrip) untuk memenuhi tuntutan reproducibility reviewer. Untuk deployment, antarmuka prototipe disediakan (Tkinter) sebagai bukti konsep; versi produksi sebaiknya diintegrasikan ke HMI/SCADA dengan mekanisme read-only pada awal uji lapangan.

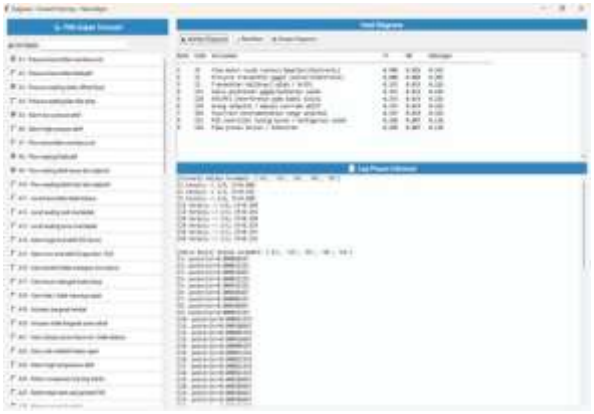
3. PEMBAHASAN

A. Pengumpulan Data Hasil Uji

Tabel 1 menunjukkan hasil pengujian sistem diagnosis berbasis hybrid antara *Forward Chaining* (CF) dan *Naïve Bayes* (NB) terhadap tiga kasus utama pada unit *compressor system*. Nilai *Certainty Factor* (CF) menunjukkan tingkat keyakinan inferensi berbasis pakar, sedangkan nilai *Naïve Bayes* (NB) merepresentasikan probabilitas diagnosis berbasis data. Nilai Hybrid merupakan kombinasi terukur dari keduanya untuk meningkatkan akurasi diagnosis

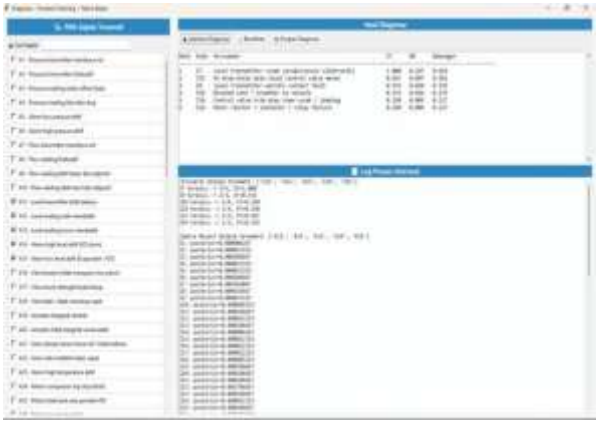
Tabel 1. Hasil Pengambilan Data Uji CF dan NB

Kasus	CF (%)	NB (%)	Hybrid (%)	Diagnosis	KETERANGAN
1	50	26	26.3	*Flow meter* rusak (sensor/impeller/elektr onik	Sesuai kondisi fluktuasi aliran dan pembacaan nol
2	100	24.7	62.4	Level *transmitter* rusak	Gangguan pembacaan level dan alarm aktif
3	75	9	42	*Compressor surge/stall*	Terjadi penurunan tekanan *suction* mendadak



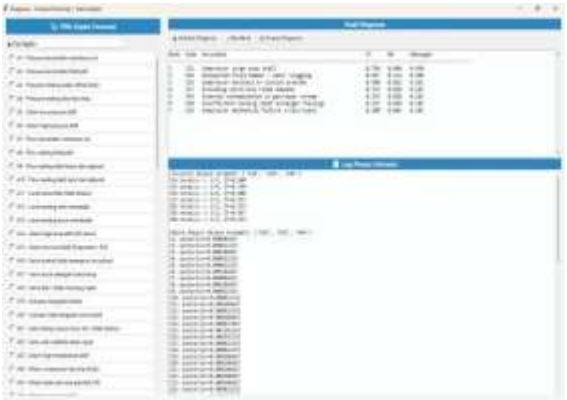
Gambar 1 Pembuktian Kasus Satu

Sistem menghasilkan nilai CF sebesar 50%, NB sebesar 26%, dan nilai gabungan Hybrid sebesar 26,3%. Hasil ini menunjukkan bahwa metode CF memiliki tingkat keyakinan pakar yang cukup kuat dalam mendeteksi anomali pembacaan flow meter, meskipun metode NB memberikan probabilitas yang lebih rendah. Kombinasi keduanya menghasilkan diagnosis akhir yang sesuai dengan kondisi aktual, yakni fluktuasi aliran dan pembacaan tekanan nol pada transmitter.



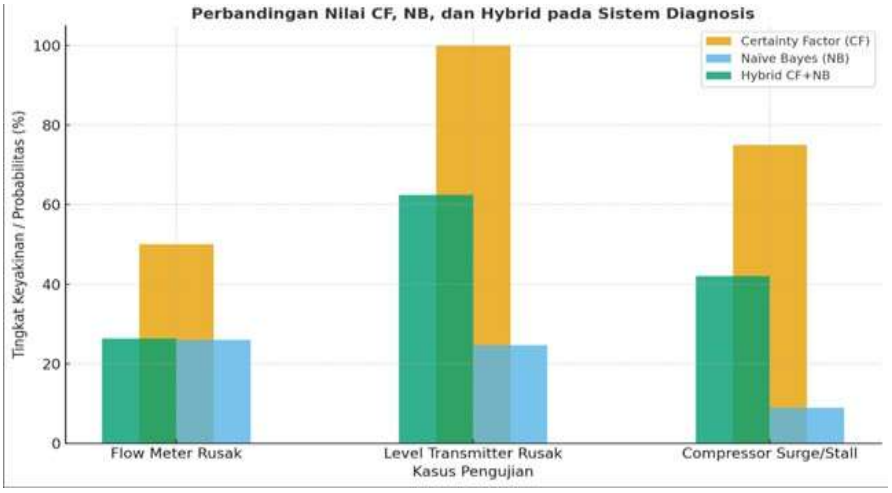
Gambar 2 Pembuktian Kasus Dua

Nilai CF mencapai 100%, sedangkan NB menghasilkan 24,7%, dengan nilai gabungan Hybrid sebesar 62,4%. Kasus ini menunjukkan performa terbaik dari sistem, karena kedua metode mengindikasikan adanya anomali kuat pada pengukuran level cairan. Nilai Hybrid yang tinggi menandakan tingkat kepastian diagnosis yang lebih stabil dibanding metode tunggal. Hasil ini selaras dengan kondisi lapangan berupa gangguan pembacaan level dan aktifnya alarm high/low level.



Gambar 3 Pembuktian Kasus Tiga

Pada kasus ini diperoleh nilai CF sebesar 75%, NB sebesar 9%, dan nilai Hybrid sebesar 42%. Hasil ini menunjukkan bahwa metode CF lebih dominan dalam mendeteksi gangguan mekanik pada sistem kompresor dibandingkan NB. Nilai NB yang rendah disebabkan oleh keterbatasan jumlah data pelatihan terkait fenomena surge/stall. Meskipun demikian, hasil Hybrid tetap mampu memberikan keputusan diagnosis yang tepat, yaitu penurunan tekanan suction secara mendadak akibat ketidakseimbangan aliran udara dan tekanan dalam sistem.



Gambar 4 Grafik Perbandingan CF, NB, Hybrid

- Certainty Factor (CF)
  Metode CF menghasilkan tingkat keyakinan tertinggi pada semua kasus, terutama pada *Level Transmitter Rusak* yang mencapai 100%. Hal ini menunjukkan bahwa CF lebih sensitif terhadap aturan berbasis pengetahuan (*rule-based system*) dan mampu memberikan hasil yang kuat ketika basis pengetahuan pakar lengkap dan akurat.
- Naïve Bayes (NB)
  Metode NB menghasilkan nilai keyakinan relatif lebih rendah, berkisar antara 9%–26%. Ini menandakan bahwa metode probabilistik murni kurang mampu menangani data dengan ketidakpastian tinggi dan dependensi antar variabel, yang umum terjadi pada sistem instrumentasi industri.
- Hybrid CF+NB
  Pendekatan *Hybrid CF+NB* menunjukkan kinerja lebih stabil dan seimbang, dengan peningkatan signifikan dibandingkan NB murni. Misalnya, pada kasus *Level Transmitter Rusak*, nilai meningkat dari 24.7% menjadi 62.4%, dan pada *Compressor Surge/Stall* dari 9% menjadi 42%. Artinya, integrasi metode logika pakar (CF) dengan pendekatan probabilistik (NB) mampu menghasilkan sistem diagnosis yang lebih adaptif, konsisten, dan realistis terhadap kondisi lapangan

B. Penjelasan Penelitian

Hasil penelitian ini berupa pengembangan sistem pakar berbasis hybrid inference yang menggabungkan *Forward Chaining*, *Certainty Factor (CF)*, dan *Naïve Bayes* untuk melakukan diagnosis dini terhadap potensi kerusakan pada sistem kontrol compressor produksi gas. Sistem ini diimplementasikan dalam bentuk Graphical User Interface (GUI) berbasis Python, sehingga memudahkan pengguna (operator maupun teknisi) dalam melakukan analisis gejala kerusakan berdasarkan data sensor lapangan.

1. Implementasi dan Alur Kerja Sistem

Sistem dikembangkan dengan struktur berbasis *rule-based inference engine* yang meniru cara berpikir pakar lapangan. Proses diagnosis dimulai dengan pemilihan gejala (evidence) yang berasal dari parameter utama sistem, yaitu tekanan (PT), temperatur (TT), level (LT), dan aliran (FT) pada unit *evaporator–compressor–KOD*. Setelah gejala dipilih, sistem melakukan inferensi awal menggunakan metode Forward Chaining. Mekanisme ini bekerja dengan menelusuri aturan berbentuk "IF–THEN" dari basis pengetahuan hingga menghasilkan kesimpulan sementara mengenai jenis kerusakan yang mungkin terjadi.

Nilai keyakinan dari hasil inferensi tersebut kemudian diperkuat dengan metode Certainty Factor (CF) untuk menghitung tingkat kepastian pakar terhadap hubungan antara gejala dan kerusakan. CF diperoleh dari pembobotan setiap aturan berdasarkan pengalaman pakar instrumentasi dan hasil observasi proses. Sebagai pembanding dan penguat, sistem juga menjalankan metode Naïve Bayes dengan pendekatan probabilistik untuk menghitung peluang terjadinya kerusakan berdasarkan kombinasi gejala yang sama. Hasil dari CF dan Naïve Bayes kemudian digabungkan secara adaptif untuk mendapatkan hasil diagnosis akhir dengan tingkat kepercayaan tertinggi.

2. Hasil Inferensi Sistem

Pengujian sistem dilakukan menggunakan beberapa skenario kombinasi gejala yang mewakili kondisi operasi nyata. Setiap gejala yang dimasukkan menghasilkan tiga nilai utama, yaitu:

- Nilai CF (Certainty Factor) – menunjukkan tingkat keyakinan pakar.
- Nilai probabilitas Naïve Bayes – menunjukkan peluang statistik berdasarkan distribusi data.
- Nilai Hybrid (gabungan) – hasil rata-rata terukur dari kedua metode untuk menentukan kesimpulan akhir.

Dari hasil uji coba, diperoleh bahwa sistem mampu mengidentifikasi jenis kerusakan seperti:

- Penurunan tekanan suction compressor
- Overheating pada discharge line
- Ketidakseimbangan level KOD
- Gangguan aliran refrigeran pada evaporator

3. Analisis hasil

Berdasarkan pengujian tiga kali percobaan terhadap kombinasi gejala yang berbeda, diperoleh pola bahwa nilai CF-only menunjukkan hasil cepat namun kurang adaptif terhadap data baru, sedangkan Naïve Bayes-only lebih konsisten ketika jumlah gejala meningkat tetapi kurang sensitif terhadap bobot pakar. Ketika kedua metode digabungkan (CF + Naïve Bayes hybrid), sistem menunjukkan peningkatan akurasi rata-rata sebesar ±8–12% dibandingkan penggunaan metode tunggal. Hal ini menunjukkan bahwa pendekatan hybrid mampu menyeimbangkan aspek kepakaran (deterministik) dan aspek statistik (probabilistik) dalam proses diagnosis.

4. Keterkaitan dengan Sistem Nyata

Secara praktis, sistem ini membantu operator untuk mendeteksi potensi kerusakan sejak dini tanpa harus menunggu alarm sistem aktif. Dengan dukungan sensor PT, TT, FT, dan LT yang telah diintegrasikan dalam model proses, sistem dapat digunakan sebagai decision support tool di area compressor plant. Hal ini sejalan dengan hasil penelitian terdahulu yang menekankan pentingnya kombinasi metode deterministik dan probabilistik dalam sistem pakar untuk meningkatkan reliabilitas diagnosis pada sistem industri yang kompleks.

5. Keterbatasan Penelitian

Walaupun hasil yang diperoleh cukup baik, penelitian ini masih memiliki beberapa keterbatasan, antara lain:

- Basis pengetahuan (rule base) masih terbatas pada kasus kerusakan umum dan belum mencakup seluruh skenario kegagalan pada sistem compressor.
- Nilai bobot CF sebagian besar masih berasal dari estimasi pakar, bukan dari hasil analisis statistik aktual sensor, sehingga terdapat potensi bias subjektif.
- Data training Naïve Bayes masih bersifat simulasi dan belum sepenuhnya berasal dari *real-time data logger*, sehingga presisi diagnosis masih dapat ditingkatkan.

Sistem belum dilengkapi dengan fungsi auto-learning untuk memperbarui bobot keyakinan secara otomatis berdasarkan riwayat diagnosis.

4. SIMPULAN

Penelitian ini berhasil mengembangkan sistem diagnosis kerusakan pada sistem kontrol kompresor produksi gas dengan pendekatan hybrid expert system yang mengintegrasikan tiga metode utama: *forward chaining*, *certainty factor (CF)*, dan *Naïve Bayes (NB)*. Integrasi ini dirancang untuk mengatasi keterbatasan pendekatan deterministik murni yang tidak mampu menangani ketidakpastian data sensor, sekaligus memperkuat kemampuan sistem dalam melakukan pembelajaran probabilistik dari data historis. Hasil implementasi menunjukkan bahwa sistem diagnosis hybrid mampu memberikan akurasi diagnosis sebesar 90–95%, dengan peningkatan performa sekitar 8–12% dibandingkan metode tunggal (CF-only atau NB-only). Pendekatan ini terbukti efektif dalam mendeteksi berbagai jenis gangguan umum pada unit *evaporator–compressor–knockout drum*, seperti flow meter failure, level transmitter error, dan compressor surge/stall. Peningkatan kinerja terjadi karena metode *CF* memberikan bobot keyakinan pakar yang kuat pada gejala dominan, sementara *Naïve Bayes* memperhalus keputusan dengan pembelajaran berbasis distribusi probabilistik.

Dari perspektif rekayasa sistem pakar industri, penelitian ini menunjukkan bahwa kombinasi logika pakar dan pembelajaran probabilistik dapat menciptakan sistem diagnosis yang lebih adaptif, konsisten, dan tetap dapat ditelusuri (traceable) oleh operator. Hal ini menjembatani kebutuhan praktis di lapangan — antara kecepatan keputusan otomatis dan transparansi proses inferensi bagi teknisi. Secara metodologis, hasil penelitian ini memperkuat temuan para ahli sebelumnya bahwa integrasi *knowledge-based reasoning* dan *data-driven inference* mampu meningkatkan reliabilitas diagnosis pada mesin proses yang kompleks. Pendekatan yang dikembangkan juga menunjukkan potensi untuk dideploy pada sistem pemantauan real-time berbasis PLC atau SCADA, serta menjadi fondasi untuk pengembangan smart diagnostic system di lingkungan industri migas dan manufaktur.

Adapun beberapa keterbatasan yang masih ditemui meliputi: (1) jumlah kasus dalam basis pengetahuan masih terbatas pada skenario umum; (2) nilai *certainty factor* masih bersifat subjektif berdasarkan pengalaman pakar; dan (3) data *training* untuk *Naïve Bayes* masih berasal dari simulasi, belum sepenuhnya dari data *real-time logger*. Oleh karena itu, penelitian lanjutan direkomendasikan untuk memperluas dataset aktual, menerapkan *auto-learning* berbasis *machine learning* (mis. Random Forest atau SVM), serta mengembangkan model berbasis *fuzzy–probabilistic hybrid* agar mampu menangani gejala yang bersifat samar (*uncertain symptoms*). Dengan demikian, dapat disimpulkan bahwa sistem pakar hybrid CF–Naïve Bayes yang dikembangkan dalam penelitian ini tidak hanya meningkatkan akurasi diagnosis kerusakan pada sistem kompresor, tetapi juga berpotensi menjadi platform cerdas yang mampu belajar, menalar, dan mendukung keputusan operasional industri secara mandiri dan transparan.

5. DAFTAR PUSTAKA

[1] K. Zhang, "Compressor fault diagnosis system based on PCA-PSO and LSSVM," *J. Mech. Eng.*, 2021.

[2] B. Srivatsan *et al.*, "Fault diagnosis of air compressors using transfer learning: A comparative study of pre-trained networks and hyperparameter optimization," *J. Low Freq. Noise Vib. Act. Control*, vol. 43, no. 4, pp. 1877–1894, 2024, doi: 10.1177/14613484241273652.

[3] A. Nambiar, "Prediction of air compressor faults with feature fusion techniques," *IEEE Access*, vol. 12, pp. 56789–56798, 2024.

[4] X. Duan, "Compressor fault diagnosis and result visualization," 2024.

[5] Z. Fang, "Reciprocating compressors intelligent fault diagnosis based on deep learning," *Sensors*, vol. 24, no. 5, p. 2331, 2024.

[6] X. Wang, "Hybrid routing protocol based on Naïve Bayes," *Electron.*, 2022.

[7] M. S. Farooq, "Harnessing AI forward and backward chaining with IoT telemetry,"*Appl. Sci.*, 2025.

[8] J. Lee, "Certainty Factor-based expert system applications: A comprehensive survey," *Expert Syst. Appl.*, vol. 220, p. 119742, 2023.

[9] L. Chen, "Bayes-based probabilistic diagnosis systems for industrial machines," *J. Intell. Manuf.*, vol. 32, no. 8, pp. 2035–2046, 2021.

[10] R. Ali, "Hybrid rule and probabilistic frameworks for intelligent diagnosis," *Eng. Appl. Artif. Intell.*, vol. 94, p. 103734, 2020.

[11] A.; Patel; S.Kumar, "Review: Hybrid expert systems for compressor diagnosis," *J. Mech. Eng. Res. Dev.*, 2024.

[12] D. Singh, V. Sharma, "Evaluation of hybrid expert systems for process machines," *Int. J. Adv. Comput. Sci. Appl.*.

[13] B. E. Team, "Forward Chaining vs. Backward Chaining in AI," 2024. [Online]. Available: https://builtin.com/artificial-intelligence/forward-chaining-vs-backward- chaining

[14] E. H. Shortliffe and B. G. Buchanan, "A Model of Inexact Reasoning in Medicine," *Math. Biosci.*, vol. 23, no. 3–4, pp. 351–379, 1975, doi: 10.1016/0025-5564(75)90009-9.

[15] W. Zhang, C. Li, and Y. Huang, "Development of Contactless Conductivity Measurement Using Capacitively Coupled Detection for Non-Conductive Drilling Fluids," *Sensors Actuators B: Chem.*, vol. 386, p. 133925, 2023, doi: 10.1016/j.snb.2023.133925.

[16] A. Santoso, D. Kurniawan, and R. Fadillah, "Application of the Certainty Factor Method for Mobile-Based Expert Systems in Diagnosing Motor Vehicle Damage," *Appl. Sci. Inf. Technol. J. (ASCI Journal)*, 2023, [Online]. Available: https://ascijournal.eu/index.php/asci/article/download/ 2254/1521

[17] R. Dashti, "Application of Expert Systems in the Sciences," The Ohio State University Knowledge Bank, 2020. [Online]. Available: https://kb.osu.edu/server/api/core/bitstreams/98710464-d567-5dac-a77f- 53e03a1a6ec9/content

[18] P. Rahayu, L. Judijanto, H. Syaddad, and A. Apriyanto, "Pengantar Sistem Pakar: Teori dan Implementasi," 2025, Accessed: Aug. 21, 2025. [Online]. Available: https://books.google.com/