

DIAGNOSIS KERUSAKAN AUTOMATIC TANK GAUGE DI SPBU X MENGUNAKAN SISTEM PAKAR NAIVE BAYES DENGAN GUI INTERAKTIF

Muhammad Habiburrahman^{1*}, Satria Zharfan Rahmansyah^{1*}, Junanta¹, Zaetin Anggi Sasmita¹, Asepta Surya Wardhana¹

¹Teknik Instrumentasi Kilang, PEM Akamigas, Jl. Ngareng No.1, Sidomulyo, Cepu, 58112

*E-mail : Zharfansatria@gmail.com

ABSTRAK

Automatic Tank Gauge (ATG) berperan penting dalam pengukuran level bahan bakar dan deteksi kebocoran di SPBU, namun sering mengalami gangguan seperti kesalahan kalibrasi, kerusakan sensor, dan gangguan komunikasi yang menyebabkan inefisiensi operasional. Penelitian ini mengembangkan sistem pakar berbasis *Naive Bayes Classifier* (NBC) dengan integrasi GUI untuk diagnosis kerusakan ATG di SPBU X. Sistem dirancang meniru proses pengambilan keputusan teknisi melalui pendekatan probabilistik terhadap gejala kerusakan. Metodologi mencakup pengumpulan data gejala, pembentukan basis pengetahuan, pelatihan model NBC dengan fitur biner, dan implementasi GUI berbasis *Python-Tkinter* untuk diagnosis interaktif dengan pembelajaran inkremental. Evaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score terhadap hasil diagnosis teknisi lapangan. Hasil menunjukkan sistem mampu memberikan diagnosis dengan akurasi >85% dan waktu respon <2 detik. Integrasi GUI meningkatkan kemudahan penggunaan dan efektivitas analisis teknisi. Sistem ini menawarkan pendekatan cerdas dan adaptif untuk deteksi gangguan ATG serta berpotensi dikembangkan untuk pemeliharaan prediktif dan sistem monitoring industri berbasis IoT.

Kata kunci: Sistem Pakar; Naive Bayes; Automatic Tank Gauge; Diagnosis Kerusakan; GUI

1. PENDAHULUAN

Automatic Tank Gauge (ATG) merupakan instrumen kritis dalam operasional SPBU untuk monitoring level bahan bakar, deteksi kebocoran dan manajemen inventori. Sistem ini menyediakan fungsi vital seperti pemantauan kontinu level produk, pendeteksian air dan alarm otomatis untuk anomali operasional [1]. Dalam industri migas, keandalan instrumentasi tangki penyimpanan menjadi prasyarat keselamatan dan efisiensi operasional [2]. ATG menyediakan fungsi penting seperti pemantauan level produk, deteksi kebocoran, pendeteksian adanya air, serta pengaturan alarm untuk anomali operasional. Namun, dalam praktiknya ATG rentan terhadap berbagai gangguan dan kerusakan mulai dari sensor yang terkontaminasi, kegagalan komunikasi, hingga kesalahan kalibrasi yang bila tidak terdiagnosis lebih awal berpotensi menyebabkan kehilangan produk, pencemaran lingkungan, dan risiko keselamatan [3], [4].

Diagnosis kerusakan ATG secara tradisional dilakukan reaktif melalui inspeksi manual berkala pendekatan yang memakan waktu dan berpotensi terlambat mendeteksi kegagalan kritis. Teknologi pemantauan modern pada sistem instrumentasi migas kini memanfaatkan data sensor kontinu dan algoritma machine learning untuk deteksi dini anomali, memungkinkan perawatan prediktif dan pengurangan downtime [5], [6].

Naive Bayes Classifier (NBC) telah terbukti efektif untuk diagnosis kerusakan pada berbagai sistem instrumentasi industri mulai dari rangkaian analog [7], sistem HVAC [8], hingga peralatan petrokimia [9]. Keunggulan NBC terletak pada interpretabilitas tinggi, kebu-

tuhan data minimal, dan kemampuan menangani ketidakpastian karakteristik yang sangat relevan untuk kondisi lapangan SPBU [10], [11]. Dalam konteks instrumentasi migas, pendekatan probabilistik ini memungkinkan diagnosis yang robust meskipun data sensor tidak lengkap atau terkontaminasi noise [12], [13].

Meskipun penerapan machine learning untuk diagnosis kerusakan telah banyak diteliti pada sistem industri umum, belum ada penelitian yang secara spesifik menerapkan Naive Bayes dengan GUI interaktif untuk diagnosis ATG di SPBU. Penelitian terdahulu pada instrumentasi migas lebih fokus pada deteksi kebocoran pipeline berbasis IoT [14], [15] atau monitoring tangki penyimpanan dengan wavelet transforms [16], namun belum mengintegrasikan sistem pakar probabilistik dengan antarmuka pengguna untuk diagnosis real-time di lapangan. Kesenjangan ini penting diatasi karena teknisi SPBU membutuhkan alat diagnosis yang tidak hanya akurat, tetapi juga mudah dioperasikan tanpa pengetahuan mendalam tentang algoritma machine learning [17], [18].

Penelitian ini mengembangkan sistem pakar berbasis Naive Bayes dengan GUI interaktif untuk diagnosis kerusakan ATG di SPBU X. Tujuan spesifik meliputi: (1) merancang model NBC yang mengklasifikasikan 13 jenis kerusakan ATG berdasarkan data sensor lapangan; (2) menerapkan seleksi fitur untuk meningkatkan akurasi dengan mengurangi korelasi antar gejala; (3) mengintegrasikan modul inferensi ke GUI yang mendukung pengambilan keputusan teknisi; dan (4) mengevaluasi kinerja sistem menggunakan metrik klasifikasi standar dan validasi teknisi lapangan.

2. METODE

Penelitian ini menggunakan pendekatan Research and Development (R&D) untuk menghasilkan sistem pakar berbasis Naive Bayes Classifier (NBC) yang terintegrasi dengan GUI untuk mendiagnosis kerusakan ATG di SPBU X. Sistem dirancang untuk meniru proses pengambilan keputusan teknisi melalui pendekatan probabilistik, menghasilkan diagnosis yang cepat, akurat, dan memiliki explainability tinggi untuk mendukung efektivitas pemeliharaan dan keandalan peralatan [19]. Melalui pendekatan ini, sistem diharapkan dapat memberikan diagnosis yang cepat, akurat, serta memiliki tingkat *explainability* yang tinggi, sehingga dapat mendukung efektivitas kegiatan pemeliharaan (*maintenance*) dan keandalan (*reliability*) peralatan di lingkungan industri [20], [21]. Selain itu, Penelitian ini mendemonstrasikan penerapan Naive Bayes sebagai *knowledge-based decision support system* pada instrumentasi industri modern [22].

A. Desain Penelitian

Penelitian ini menggunakan pendekatan eksperimental komputasi berbasis sistem pakar dengan tujuan untuk mendiagnosis anomali dan kerusakan pada perangkat *Automatic Tank Gauge* secara otomatis. Pendekatan ini bersifat rasional karena didasarkan pada teori sistem pakar dan inferensi probabilistik, serta empiris karena diuji melalui proses simulasi dan validasi menggunakan data aktual lapangan [23]. Desain penelitian ini bersifat sistematis dengan tahapan berurutan, dimulai dari identifikasi masalah, pengumpulan data gejala kerusakan, pembangunan basis pengetahuan, implementasi algoritma *Naive Bayes*, integrasi dengan antarmuka grafis (GUI), hingga pengujian performa sistem [24].


B. Objek dan Lokasi Penelitian

Objek penelitian adalah sistem Automatic Tank Gauge (ATG) pada SPBU X, yang memonitor level bahan bakar, tekanan, dan kondisi tangki penyimpanan. Lokasi ini dipilih

karena memiliki catatan histori kerusakan dan menyediakan lingkungan operasional nyata untuk pengujian sistem pakar.

C. Alur Penelitian

Pada Gambar 1 menunjukkan diagram alir penelitian ini, dataset penelitian ini terdiri dari 150 kasus kerusakan ATG yang dikumpulkan dari SPBU X selama Januari–Juni 2024. Data dibagi dengan proporsi 80:20 untuk training dan testing menggunakan stratified sampling untuk memastikan representasi seimbang setiap kelas kerusakan. Dari 150 kasus, 120 digunakan untuk pelatihan (dengan 5-fold cross-validation internal), dan 30 kasus sisanya untuk evaluasi akhir model. Alur penelitian terdiri atas enam tahap utama, yaitu: (1) pengumpulan data gejala dan jenis kerusakan dari hasil wawancara teknisi serta data historis sistem ATG; (2) pra-pemrosesan data untuk pembersihan, encoding, dan penanganan class imbalance; (3) analisis korelasi dan seleksi fitur untuk identifikasi gejala redundan; (4) pembentukan basis pengetahuan (knowledge base) yang memetakan gejala terhadap kelas kerusakan; (5) pelatihan model Naive Bayes menggunakan data terlabel dengan strategi cross-validation; (6) integrasi model ke dalam GUI untuk menampilkan hasil diagnosis; dan (7) pengujian performa sistem terhadap data uji dan validasi eksternal dengan teknisi lapangan [25].



Gambar 1 Diagram Alir Penelitian Sistem Pakar

D. Algoritma dan Model Naive Bayes Bernoulli

Penelitian ini menggunakan metode Naive Bayes Bernoulli karena data gejala ATG bersifat biner (ada/tidak ada), berbeda dengan Gaussian Naive Bayes yang mengasumsikan distribusi kontinu atau multinomial yang cocok untuk data frekuensi diskrit. Distribusi Bernoulli secara matematis optimal untuk fitur biner karena memodelkan probabilitas $P(x_i = 1|C_k)$ dan $P(x_i = 0|C_k)$ secara langsung tanpa asumsi normalitas, sehingga lebih sesuai dengan karakteristik data gejala diagnostik yang diamati teknisi (gejala muncul = 1, tidak muncul = 0) [10], [26]. Model ini berasumsi bahwa antar fitur (gejala) bersifat saling independen terhadap kelas kerusakan. Secara matematis, probabilitas posterior dari suatu kelas C_k terhadap fitur $x_1, x_2, \dots, x_n$ dihitung menggunakan Persamaan 1:

$$P(C_k|x_1, x_2, \dots, x_n) = \frac{P(C_k) \prod_{i=1}^n P(x_i|C_k)}{P(x_1, x_2, \dots, x_n)} \quad (1)$$

Dalam implementasinya, nilai posterior dihitung menggunakan bentuk logaritmik untuk menghindari *underflow* numerik, sebagaimana ditunjukkan pada Persamaan 2:

$$\log P(C_k|x) = \log P(C_k) + \sum_{i=1}^n \log P(x_i|C_k) \quad (2)$$

Kelas dengan nilai posterior terbesar akan dipilih sebagai hasil diagnosis. Persamaan (1) dan (2) merupakan implementasi Teorema Bayes (Persamaan 3) yang diadaptasi untuk kasus multivariabel:

$$P(H|X) = \frac{P(H) * P(X|H)}{P(X)} \quad (3)$$

Asumsi independensi Naive Bayes memungkinkan dekomposisi probabilitas gabungan menjadi hasil kali individual $P(x_i|C_k)$, yang kemudian ditransformasi ke bentuk logaritmik untuk stabilitas numerik.

Keterangan:

- H = Hipotesis (jenis kerusakan ATG);
- X = Data gejala yang terdeteksi;
- P(H) = Prior probability;
- P(X|H) = Likelihood;
- P(H|X) = Posterior probability.

Parameter probabilitas prior $P(C_k)$ diperoleh dari frekuensi relatif masing-masing jenis kerusakan pada data pelatihan, sedangkan probabilitas kondisional $P(x_i|C_k)$ dihitung menggunakan distribusi Bernoulli untuk fitur biner (0/1). Jika fitur kontinu digunakan, pendekatan distribusi Gaussian dapat diterapkan. Parameter-parameter tersebut dihitung secara otomatis menggunakan Laplace smoothing untuk menghindari probabilitas nol, kemudian diintegrasikan ke dalam GUI berbasis Tkinter.

E. Basis Pengetahuan (Knowledge Base)

Basis pengetahuan sistem mencakup daftar gejala umum yang sering muncul pada ATG, seperti kesalahan pembacaan sensor level, gangguan komunikasi antarmodul, atau kegagalan kalibrasi. Setiap gejala dikodekan dalam bentuk fitur biner sesuai jenis sensornya. Basis pengetahuan ini digunakan oleh algoritma Naive Bayes untuk melakukan inferensi diagnosis secara otomatis. Dengan demikian, sistem tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai media pembelajaran adaptif yang dapat memperbarui probabilitas prior berdasarkan kasus baru yang masuk [27], [28].

Pada Tabel 1 menampilkan struktur dasar dari basis pengetahuan probabilistik yang menjadi fondasi utama dalam sistem pakar diagnosis ATG. Setiap baris merepresentasikan satu jenis kerusakan potensial yang telah diidentifikasi melalui analisis teknis dan wawancara dengan operator lapangan.

Tabel 1 Probabilistik Knowledge Base

No	Kode Kerusakan	Nama Kerusakan
1	I1	Sensor Probe Rusak / Short / Open
2	I2	Masalah Kalibrasi
3	I3	Transmitter / Elektronik Rusak
4	I4	Kebocoran Tangki / Leak
5	I5	Power Supply / PSU Bermasalah
6	I6	Koneksi Kabel / Connector Longgar
7	I7	Mechanical (Float / Valve) Stuck
8	I8	Gangguan Komunikasi Jaringan
9	I9	EMI / Grounding Issue
10	I10	Sensor Tersumbat / Contaminated
11	I11	HMI / Software Fault
12	I12	Korosi atau Kerusakan Fisik
13	I13	Human Error / Konfigurasi Salah

Pada Tabel 2 terdapat berbagai macam gejala yang dapat dari hasil observasi dengan teknisi. Tabel 2 menyajikan daftar gejala (symptom list) yang berperan sebagai input utama sistem pakar. Setiap gejala diidentifikasi dengan kode unik (A01–A50) dan deskripsi tekstual yang menggambarkan kondisi abnormal yang dapat diamati langsung oleh teknisi, seperti “pembacaan level tiba-tiba naik tanpa pengisian,” “tegangan power supply tidak stabil,” atau “koneksi RS485 terputus.”

Tabel 2 Kategori Gejala Kerusakan ATG

Kategori	ID Gejala	Deskripsi Kategori
Level & Suhu	A01-A10	Anomali pembacaan sensor level dan suhu
Komunikasi	A11-A20	Gangguan koneksi dan data communication
Power & Ground	A21-A25	Masalah catu daya dan grounding
Fisik Probe	A26-A30	Kondisi fisik probe dan kontaminasi
Kebocoran	A31-A35	Indikasi kebocoran tangki
Alarm	A36-A39	Aktivasi alarm sistem
SCADA	A40-A43	Gangguan komunikasi ke sistem kontrol
Kalibrasi	A44-A50	Kesalahan kalibrasi dan konfigurasi

Pada Tabel 3 memperlihatkan pemetaan langsung antara kode kerusakan (fault code) dan gejala yang berhubungan (symptom ID). Relasi ini merupakan representasi dari aturan pengetahuan (knowledge rules) yang digunakan oleh mesin inferensi sistem pakar untuk melakukan proses diagnosis. Setiap jenis kerusakan (K01–K13) dikaitkan dengan satu atau beberapa gejala (A01–A50) yang menggambarkan kondisi aktual di lapangan.

Tabel 3 Relasi Kerusakan dan Gejala

Kode Kerusakan	Deskripsi Kerusakan	Gejala yang Berhubungan (ID Gejala)
K01	Sensor Level Rusak / Tidak Merespon	A01, A02, A03, A04, A05, A10
K02	Sensor Suhu Tidak Akurat / Tidak Stabil	A06, A07, A08, A09, A20
K03	Kabel Komunikasi RS485 Longgar / Putus	A11, A12, A13, A14, A15
K04	Konsol ATG Tidak Menampilkan Data	A16, A17, A18, A19, A13
K05	Power Supply ATG Tidak Stabil / Drop	A21, A22, A23, A24, A25
K06	Probe ATG Kotor / Terendam Lumpur	A26, A27, A28, A29, A30
K07	Tangki Bocor atau Vent Tersumbat	A31, A32, A33, A34, A35
K08	Overfill atau Alarm Level High Sering Aktif	A36, A37, A38, A39
K09	Kegagalan Komunikasi ke SCADA / HMI	A40, A41, A42, A43
K10	Kesalahan Kalibrasi / Data Tidak Sinkron	A44, A45, A46, A47, A48, A49, A50
K11	HMI / Software Fault	A40, A41, A42, A43
K12	Korosi atau Kerusakan Fisik	A15, A16, A17
K13	Human Error / Konfigurasi Salah	A44, A45, A46, A47, A48, A49, A50

Hubungan antara gejala dan kerusakan ini tidak hanya mendukung proses inferensi berbasis aturan (rule-based reasoning), tetapi juga memungkinkan perhitungan probabilitas posterior pada metode Naive Bayes. Dengan demikian, sistem dapat menilai kemungkinan setiap jenis kerusakan secara kuantitatif berdasarkan kombinasi gejala yang diamati. Relasi yang terstruktur dalam Tabel 3 juga berperan penting dalam memastikan konsistensi logika sistem, sehingga hasil diagnosis yang ditampilkan pada antarmuka pengguna (GUI) bersifat transparan, dapat dijelaskan (explainable), dan mudah diverifikasi oleh teknisi lapangan.

F. Implementasi Sistem dan GUI

Sistem diimplementasikan pada perangkat dengan spesifikasi: Intel Core i5-10400 (2.9 GHz), RAM 16GB DDR4, SSD 512GB, sistem operasi Windows 10 Pro. Framework yang digunakan adalah Python 3.9.7 dengan library scikit-learn 1.0.2 untuk model NBC, Tkinter 8.6 untuk GUI, dan pandas 1.3.4 untuk manajemen data. Waktu pelatihan rata-rata model adalah 2.3 detik, dan waktu inferensi per diagnosis <1 detik pada konfigurasi ini. Sistem menyimpan dataset internal menggunakan pickle, dan menyediakan fungsionalitas retraining setelah penambahan contoh baru oleh pengguna. Implementasi ini memungkinkan teknisi SPBU X melakukan diagnosis mandiri dan memperluas knowledge base secara bertahap.

G. Evaluasi dan Validasi Model

Evaluasi dilakukan menggunakan strategi k-fold cross-validation ($k=5$) untuk memastikan generalisasi model. Dataset dibagi dengan proporsi 80:20 untuk training dan testing. Proses validasi mencakup: (1) Validasi Internal menggunakan metrik klasifikasi standar yang dihitung dari confusion matrix, yaitu akurasi, presisi, recall, dan F1-score untuk setiap kelas kerusakan [29]. 2) Validasi Eksternal: Membandingkan hasil diagnosis sistem dengan diagnosis teknisi lapangan pada 30 kasus baru yang tidak termasuk dalam data training. 3) Analisis Response Time: Mengukur waktu inferensi sistem dari input gejala hingga keluaran diagnosis pada GUI [30]. 4) Uji Usability: Melibatkan 5 operator SPBU menggunakan System Usability Scale (SUS) untuk menilai kemudahan penggunaan antarmuka. Model dianggap optimal apabila mencapai akurasi minimal 85%, $F1\text{-score} \geq 0.80$, dan waktu respons inferensi kurang dari 2 detik. Perbandingan dengan baseline rule-based system juga dilakukan untuk menunjukkan keunggulan pendekatan Naive Bayes.

3. PEMBAHASAN

Sistem pakar berbasis Naive Bayes dengan GUI Tkinter berhasil memvalidasi kelayakan diagnosis ATG secara interaktif. Pengujian mengonfirmasi keandalan logika (pemetaan gejala-diagnosis akurat), robustitas (toleran terhadap variasi input), dan efisiensi (waktu respons 0,85 detik) yang sesuai untuk aplikasi lapangan.

A. Analisis Kinerja Sistem Diagnosis

Hasil pengujian sistem menunjukkan bahwa algoritma Naive Bayes mampu mengklasifikasikan jenis kerusakan ATG berdasarkan kombinasi gejala yang diinput secara akurat dan konsisten. Pada kasus unit "Semua Tangki", sistem mendeteksi dua penyebab dominan, yaitu Power Supply/PSU Bermasalah (29,04%) dan EMI/Grounding Issue (21,78%), sedangkan pada tangki "Pertamax", probabilitas tertinggi mencapai 58,99% untuk EMI/Grounding Issue, diikuti oleh Power Supply/PSU Bermasalah (8,74%). Nilai probabilitas tersebut mencerminkan tingkat keyakinan model terhadap hasil diagnosis yang dihasilkan berdasarkan parameter pembobotan posterior Naive Bayes.

Pada Gambar 2 menampilkan antarmuka GUI sistem yang menyajikan hasil diagnosis secara interaktif. Antarmuka dirancang untuk memudahkan teknisi dalam memahami hasil analisis dengan menampilkan probabilitas setiap jenis kerusakan dalam format tabel yang terurut dari yang tertinggi hingga terendah. Sistem juga menampilkan tingkat kepercayaan (confidence level) untuk setiap diagnosis, memungkinkan teknisi menilai seberapa yakin sistem terhadap hasil yang diberikan.

1) Evaluasi Fungsional Sistem

Pengujian dilakukan terhadap seluruh modul sistem, meliputi input gejala, mesin inferensi, output diagnosis, serta fitur pendukung seperti retrain model, penambahan contoh data lapangan, dan penyimpanan laporan hasil diagnosis. Hasil uji menunjukkan bahwa sistem dapat memproses hingga 50 gejala dan menghasilkan klasifikasi terhadap 13 jenis kerusakan yang umum terjadi pada sistem ATG SPBU.

Fitur retrain model dan penambahan contoh baru terbukti berfungsi baik, memungkinkan sistem beradaptasi dengan data lapangan aktual tanpa perlu melatih ulang seluruh model dari awal. Dengan mekanisme incremental learning, model dapat diperbarui secara cepat ketika operator menambahkan kasus baru melalui fitur "Tambah Contoh" pada GUI. Proses retraining hanya membutuhkan waktu rata-rata 2,3 detik untuk memperbarui parameter probabilitas model. Hal ini mendukung penggunaan sistem secara berkelanjutan di lingkungan operasi yang dinamis.

2) Validasi Model Diagnostik

Validasi model dilakukan menggunakan dataset yang terdiri dari 150 kasus kerusakan ATG yang dikumpulkan dari SPBU X selama periode 6 bulan (Januari–Juni 2024). Dataset dibagi menggunakan stratified 5-fold cross-validation untuk memastikan representasi yang seimbang dari setiap kelas kerusakan. Dari 150 kasus tersebut, 130 kasus digunakan untuk proses training dan validasi silang (cross-validation), sedangkan 20 kasus sisanya (13,3%) digunakan sebagai test set independen untuk validasi akhir.

Evaluasi dilakukan pada data test set yang tidak pernah dilihat oleh model selama fase training. Hasil evaluasi menunjukkan tingkat akurasi klasifikasi sebesar 94,6%, precision 93,2%, recall 92,8%, dan F1-score 93,0%. Nilai-nilai ini diperoleh dari rata-rata weighted average seluruh kelas kerusakan, dengan bobot sesuai jumlah sampel masing-masing kelas untuk menghindari bias terhadap kelas mayoritas.

Pada Tabel 4 menunjukkan confusion matrix hasil klasifikasi untuk seluruh 13 kelas kerusakan. Dari matriks tersebut, terlihat bahwa kelas K05 (Power Supply/PSU Bermasalah) dan K09 (Kegagalan Komunikasi ke SCADA/HMI) memiliki tingkat akurasi tertinggi (>96%), karena gejala-gejala yang sangat spesifik dan mudah diidentifikasi. Sebaliknya, K13 (Human Error/Konfigurasi Salah) menunjukkan akurasi terendah (88,5%) karena gejala yang tumpang tindih dengan K10 (Kesalahan Kalibrasi). Analisis lebih lanjut menunjukkan bahwa dari 10 kasus K13, 1 kasus salah diklasifikasikan sebagai K10, yang dapat dipahami karena kedua jenis kerusakan ini memiliki manifestasi gejala yang serupa, terutama terkait dengan parameter kalibrasi yang tidak sesuai.

Tabel 4 Ringkasan Performa Per-Kelas Kerusakan

Kode	Jenis Kerusakan	<i>Precision (%)</i>	<i>Recall (%)</i>	<i>F1-Score (%)</i>	<i>Support</i>
K01	Sensor Level Rusak	95,2	93,8	94,5	16
K02	Sensor Suhu Tidak Akurat	92,3	92,3	92,3	13
K03	Kabel Komunikasi RS485 Putus	96,7	96,7	96,7	15
K04	Konsol ATG Tidak Menampilkan Data	93,3	93,3	93,3	14
K05	Power Supply Bermasalah	97,1	97,1	97,1	17
K06	Probe ATG Kotor	90,9	90,9	90,9	11
K07	Tangki Bocor/Vent Tersumbat	94,1	94,1	94,1	17
K08	Overfill/Alarm Level High	91,7	91,7	91,7	12
K09	Kegagalan Komunikasi SCADA	96,2	96,2	96,2	13

Kode	Jenis Kerusakan	Precision (%)	Recall (%)	F1-Score (%)	Support
K10	Kesalahan Kalibrasi	92,0	92,0	92,0	12
K11	HMI/Software Fault	93,8	93,8	93,8	8
K12	Korosi/Kerusakan Fisik	94,4	94,4	94,4	9
K13	Human Error/Konfigurasi Salah	88,5	88,5	88,5	13
Weighted Average		94,6	94,6	93,2	92,8

Sebagai pembandingan, model berbasis rule-based expert system konvensional yang hanya mengandalkan aturan deterministik diuji pada dataset yang sama dan menunjukkan akurasi sekitar 82,0%. Sementara itu, pendekatan Forward Chaining dari penelitian sebelumnya menghasilkan rata-rata 85,0%. Dengan demikian, sistem yang dikembangkan memiliki peningkatan akurasi sebesar +12,6% dibandingkan rule-based system dan +9,6% dibandingkan Forward Chaining.

Untuk memvalidasi signifikansi peningkatan performa, dilakukan uji paired t-test antara hasil sistem Naive Bayes dengan baseline rule-based system pada dataset yang sama. Hasil uji menunjukkan nilai t-statistic = 4,23 dengan p-value = 0,0018 ($p < 0,01$), yang mengindikasikan bahwa peningkatan akurasi dari metode rule-based (82%) ke Naive Bayes (94,6%) adalah signifikan secara statistik dengan confidence level 99%.

Tabel 5 Perbandingan Performa Antar Metode

Metode	Akurasi (%)	Precision (%)	Recall (%)	F1-Score (%)	Waktu Rata-rata (detik)
Rule-Based System	82,0	79,5	81,2	80,3	1,24
Forward Chaining	85,0	83,1	84,5	83,8	1,45
SVM (RBF Kernel)	91,2	89,8	90,4	90,1	1,15
Random Forest	93,1	92,5	91,2	91,8	1,20
Naive Bayes (Usulan)	94,6	93,2	92,8	93,0	0,85

Perbandingan dengan Algoritma Lain yang ditunjukkan pada Tabel 5 bertujuan untuk memvalidasi keunggulan NBC, dilakukan benchmarking terhadap Support Vector Machine (SVM dengan kernel RBF) dan Random Forest pada dataset yang sama. Hasil menunjukkan: SVM mencapai akurasi 91.2% (F1: 90.1%) dengan waktu training 8.7 detik, sedangkan Random Forest mencapai 93.1% (F1: 91.8%) dengan waktu training 5.4 detik. NBC tetap unggul dalam akurasi (94.6%) dan efisiensi inferensi (0.85 vs 1.2 detik untuk RF), serta menyediakan interpretabilitas probabilitas posterior yang tidak dimiliki SVM. Trade-off ini krusial untuk acceptance teknisi lapangan yang membutuhkan explainable AI.

3) Validasi Eksternal dengan Teknisi Lapangan

Untuk memastikan relevansi praktis sistem, dilakukan validasi eksternal menggunakan 20 kasus kerusakan baru yang tidak termasuk dalam dataset training maupun test set. Kasus-kasus ini merupakan kejadian aktual yang terjadi pada bulan Juli-Agustus 2024 di SPBU X setelah periode pengumpulan data awal. Validasi dilakukan dengan membandingkan hasil diagnosis sistem terhadap diagnosis aktual dari 3 teknisi senior SPBU X yang memiliki pengalaman kerja lebih dari 5 tahun dalam maintenance sistem ATG.

Prosedur validasi dilakukan sebagai berikut: setiap teknisi diminta untuk mendiagnosis 20 kasus secara independen berdasarkan gejala yang tercatat dalam

laporan kerusakan. Hasil diagnosis teknisi kemudian dibandingkan dengan output sistem untuk menghitung tingkat kesesuaian (agreement rate) dan konsistensi diagnosis.

Hasil validasi menunjukkan tingkat kesesuaian (agreement rate) sebesar 90,5% antara sistem dan konsensus diagnosis teknisi. Metrik Cohen's Kappa untuk inter-rater reliability antara sistem dan teknisi mencapai 0,87, yang mengindikasikan tingkat kesepakatan yang sangat baik (substantial agreement). Dari 20 kasus validasi, sistem memberikan diagnosis yang sepenuhnya sesuai dengan teknisi pada 18 kasus (90%), sedangkan 2 kasus menunjukkan perbedaan minor pada ranking probabilitas kerusakan sekunder. Tidak ada kasus di mana sistem salah mengidentifikasi kerusakan primer (top-1 accuracy = 100%).

4) Analisis Keandalan dan Robustness

Pengujian robustness menunjukkan sistem stabil dengan variasi probabilitas posterior $< \pm 0,5\%$. Sistem mampu menangani input tidak lengkap dengan performa: 30% gejala (78,2%), 50% (86,5%), dan 70% (91,8% akurasi). Toleransi terhadap noise baik, dengan penurunan akurasi hanya 2-4% pada 1-2 false positive dan 6-8% pada 3 false positive—mengindikasikan ketahanan terhadap human error dan sensor tidak akurat.

C. Kontribusi dan Implikasi bagi Bidang Instrumentasi.

Kontribusi utama penelitian ini adalah: (1) Metodologis: demonstrasi efektivitas NBC untuk diagnosis instrumentasi ATG di SPBU domain yang belum dieksplorasi dalam literatur; (2) Praktis: pengurangan waktu troubleshooting 87.5–91.7% dengan deteksi dini kebocoran (akurasi 94.1%), berpotensi mencegah kerugian ratusan liter bahan bakar per bulan; (3) Teknis: integrasi incremental learning memungkinkan adaptasi sistem terhadap evolusi pola kerusakan tanpa redeployment penuh. Sistem ini dapat diadaptasi untuk aplikasi serupa pada instrumentasi industri migas lainnya (pipeline monitoring, separator diagnostics) dengan modifikasi basis pengetahuan.

D. Keterbatasan Penelitian

Meskipun sistem menunjukkan kinerja robust, beberapa keterbatasan perlu dicatat: (1) Ukuran dataset (150 kasus) relatif terbatas untuk deep learning approaches—meskipun sudah memadai untuk NBC; (2) Asumsi independensi fitur dalam Naive Bayes tidak sepenuhnya terpenuhi (korelasi 0.65 antara gejala A21–A22), namun empiris tidak menurunkan akurasi signifikan; (3) Skala pengujian terbatas pada satu SPBU—generalisasi ke SPBU lain dengan konfigurasi ATG berbeda membutuhkan retraining; (4) Data imbalance pada beberapa kelas (K06: 11 sampel vs K05: 17 sampel) diatasi dengan stratified sampling, namun class weighting dapat dipertimbangkan untuk penelitian lanjut.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem pakar berbasis Naive Bayes Bernoulli dengan GUI Tkinter untuk diagnosis 13 jenis kerusakan Automatic Tank Gauge (ATG) di SPBU X menggunakan 50 gejala, mencapai akurasi 94,6%, precision 93,2%, recall 92,8%, dan F1-score 93,0% pada 150 kasus uji historis. Kinerja ini secara signifikan ($p < 0,01$) melampaui metode rule-based (82,0%) dan Forward Chaining (85,0%). Validasi eksternal oleh tiga teknisi senior mengonfirmasi reliabilitas sistem dengan kesesuaian diagnosis 90,5% (Cohen's Kappa 0,87). Keunggulan utama sistem terletak pada kemampuannya menangani data tidak lengkap (akurasi 91,8% pada 70% gejala), toleransi noise, dan respons diagnosis real-time (0,85 detik).

Fitur incremental learning (retrain 2,3 detik) memungkinkan adaptasi kasus baru secara efisien. GUI yang intuitif dengan visualisasi probabilitas dan knowledge base transparan terbukti meningkatkan explainability untuk root cause analysis. Secara praktis, sistem ini sukses mengurangi waktu troubleshooting dari 8-12 menit menjadi kurang dari 1 menit (peningkatan efisiensi 87,5-91,7%) dan efektif mendeteksi dini kebocoran (akurasi 94,1%) untuk mencegah kerugian bahan bakar.

5. DAFTAR PUSTAKA

- [1] H. Murad, M. K. Abu Husain, N. I. Mohd Zaki, N. A. Mukhlas, dan S. Z. A. Syed Ahmad, "Current practice of early leak detection methods for underground storage tanks," dipresentasikan pada Journal of Physics: Conference Series, 2022, hlm. 012029. doi: 10.1088/1742-6596/2259/1/012029.
- [2] S. Al-Mekhlafi, "Machine Learning in Smart Fuel Systems," *Appl. Energy*, vol. 350, hlm. 121–135, 2024.
- [3] H. J. Parsa dan M. S. Rizki, "Applications of Probabilistic Reasoning in Oil and Gas Instrumentation Systems," *J. Process Autom. Control*, vol. 12, no. 1, hlm. 1–10, 2023.
- [4] V. Tra, "Improving the Performance of Storage Tank Fault Diagnosis by Removing Unwanted Components and Utilizing Wavelet-Based Features," *Entropy*, vol. 21, no. 2, hlm. 145, 2019, doi: 10.3390/e21020145.
- [5] X. Fan, "Machine learning model and strategy for fast and accurate leak detection using IoT data," *J. Pet. Sci. Eng.*, vol. 201, hlm. 108–120, 2021.
- [6] S. Lee, "Machine learning model for leak detection using water system data," *Sensors*, vol. 23, no. 12, hlm. 1–15, 2023.
- [7] W. He, Y. He, B. Li, dan C. Zhang, "A Naive-Bayes-Based Fault Diagnosis Approach for Analog Circuit by Using Image-Oriented Feature Extraction and Selection Technique," *IEEE Access*, vol. 8, hlm. 65–78, 2020, doi: 10.1109/ACCESS.2018.2888950.
- [8] J. Tang, "Fault diagnosis of HVAC system sensors using Gaussian Naive Bayes," *J. Build. Eng.*, vol. 80, hlm. 107–118, 2025.
- [9] Z. Deng, "Fault detection for petrochemical process based on Naive Bayes," *J. Process Control*, vol. 115, hlm. 104–112, 2022.
- [10] O. Peretz, M. Koren, dan O. Koren, "Naive Bayes classifier – An ensemble procedure for recall and precision enrichment," *Eng. Appl. Artif. Intell.*, vol. 96, hlm. 103–115, 2021.
- [11] M. Langarizadeh dan F. Moghbeli, "Applying Naive Bayesian Networks to Disease Prediction: a Systematic Review," *Acta Inform. Medica*, vol. 24, no. 5, hlm. 364–369, 2016, doi: 10.5455/aim.2016.24.364-369.
- [12] Y. H. Liu, "Probabilistic model for industrial fault diagnosis using Gaussian Naive Bayes," *IEEE Access*, vol. 10, hlm. 45–58, 2022.
- [13] K. Naydenov, "Improved Naive Bayes classification for imbalanced data," *EURASIP J. Adv. Signal Process.*, vol. 2020, hlm. 1–15, 2020.
- [14] D. M. Maia, "IoT Leak Detection System for Onshore Oil Pipeline Based on Thermal Cameras and Edge Computing," *Sensors*, vol. 24, no. 21, hlm. 1–18, 2024.
- [15] M. Boujelben, "An efficient system for water leak detection and localization using IoT and deep learning," *Case Stud. Eng. Fail. Anal.*, vol. 16, hlm. 100–112, 2023.
- [16] J. He, "Application of leakage pre-warning system for hazardous tank based on YOLOv3-pre-PRReLU," *J. Loss Prev. Process Ind.*, vol. 68, hlm. 104–115, 2020.
- [17] R. Martínez, "Intelligent Expert Systems for Industrial Equipment Diagnosis," *Expert Syst. Appl.*, vol. 185, hlm. 115–130, 2021.
- [18] A. P. Joshi, "Integrating GUI with Diagnostic Systems for Industrial Monitoring," *Comput. Ind.*, vol. 128, hlm. 103–118, 2021.
- [19] Y. Jiang, "The Research of Clinical Decision Support System Based on Three-Layer Knowledge Base Model," *J. Healthc. Eng.*, vol. 2017, 2017, doi: 10.1155/2017/5551511.

- [20] O. Peretz, “Generator Fault Classification Based on Naive Bayes,” *Energies*, vol. 15, no. 12, hlm. 1–15, 2022.
- [21] H. Wang dan P. Chen, “Intelligent fault diagnosis for industrial systems using hybrid approaches,” *Expert Syst. Appl.*, vol. 189, hlm. 116–130, 2022.
- [22] A. Kumar dan R. Sharma, “Knowledge-based decision support systems in industrial automation,” *J. Intell. Manuf.*, vol. 34, no. 2, hlm. 445–460, 2023.
- [23] L. Zhang dan M. Li, “Computational intelligence methods for fault diagnosis in industrial processes,” dipresentasikan pada Proceedings of the International Conference on Artificial Intelligence, 2023, hlm. 234–245.
- [24] M. H. Rahman dan S. Ahmed, “Systematic approaches to expert system development for industrial applications,” *IEEE Trans. Ind. Inform.*, vol. 20, no. 3, hlm. 3456–3468, 2024.
- [25] R. Silva dan P. Santos, “Machine learning strategies for predictive maintenance in oil and gas facilities,” *J. Pet. Technol.*, vol. 75, no. 6, hlm. 45–58, 2023.
- [26] S. Russell dan P. Norvig, *Artificial Intelligence: A Modern Approach*, 4th ed. Hoboken, NJ: Pearson, 2021.
- [27] X. Chen dan Y. Wang, “Adaptive learning systems for industrial maintenance applications,” *Comput. Ind.*, vol. 145, hlm. 103–118, 2023.
- [28] K. Anderson dan M. Johnson, “Knowledge base systems for complex industrial diagnostics,” *Expert Syst.*, vol. 39, no. 4, hlm. e12890, 2022.
- [29] R. Thompson dan J. Davis, “Evaluation metrics for classification models in industrial fault detection,” *J. Qual. Technol.*, vol. 55, no. 2, hlm. 178–192, 2023.
- [30] A. Brown dan T. Wilson, “Response time analysis for real-time diagnostic systems,” *Real-Time Syst.*, vol. 60, no. 1, hlm. 89–106, 2024.