

SISTEM PAKAR BERBASIS AGREGASI PROBABILITAS BAYESIAN UNTUK DETEKSI RISIKO BAHAYA DI KILANG MINYAK

Dimas Bara Bhayangkara^{1*}, Astrid Olivia Damayanti¹, Mario Rizky Heriyani Putra¹, Giant Rasendria Hanindyawan¹, Aseptia Surya Wardhana¹

¹Teknik Instrumentasi Kilang, Politeknik Energi dan Mineral Akamigas, Cepu, Blora, 58311 Kabupaten Blora, Jawa Tengah.

*E-mail: dimasbarabhayangkara@gmail.com

ABSTRAK

Industri kilang minyak menghadapi risiko bahaya tinggi dengan ketidakpastian operasional yang kompleks. Sistem pakar konvensional berbasis aturan sering gagal menangani agregasi multiple gejala secara probabilistik. Penelitian ini mengembangkan sistem pakar berbasis agregasi probabilitas Bayesian untuk deteksi risiko bahaya di kilang minyak. Dataset 60 gejala bahaya dari 5 pakar K3 dikodifikasikan menggunakan *Modified Delphi method*. Sistem diimplementasikan dalam Python dengan antarmuka grafis Tkinter dan algoritma inferensi menggunakan rumus $1 - \prod(1 - p)$. Validasi fungsional menunjukkan sistem mampu mengintegrasikan multiple gejala dengan akurasi probabilistik tinggi (contoh: probabilitas 0.88 dari kombinasi 3 gejala dengan nilai individual 0.4-0.6). Fitur *supporting evidence* meningkatkan transparansi diagnosis, sementara ekspor CSV mendukung pembelajaran berkelanjutan. Sistem ini menawarkan solusi praktis untuk manajemen keselamatan proaktif di kilang minyak.

Kata kunci: Agregasi Probabilitas Bayesian, Sistem Pakar, Deteksi Risiko, Kilang Minyak, Inferensi Probabilistik.

1. PENDAHULUAN

Industri kilang minyak menghadapi tantangan keselamatan yang kompleks dengan risiko insiden mayor yang dapat menyebabkan kerugian jiwa dan ekonomi yang signifikan. Menurut data dari International Association of Oil & Gas Producers (IOGP), sektor downstream mengalami peningkatan insiden keselamatan, dalam periode 2015-2013, dengan estimasi kerugian ekonomi mencapai miliaran dolar per tahun akibat kebakaran, ledakan, dan tumpahan material berbahaya. Di Indonesia, kilang minyak mengoperasikan proses bertekanan tinggi (hingga 100 bar) dan temperatur ekstrem ($>400^{\circ}\text{C}$) yang meningkatkan risiko kebakaran, ledakan, dan pelepasan material berbahaya [1]. Meskipun sistem manajemen K3 berbasis ISO 45001 dan OHSAS 18001 telah diterapkan secara luas, analisis insiden historis menunjukkan bahwa 60-70% kecelakaan disebabkan oleh kegagalan dalam mendeteksi kombinasi multiple hazards secara dini [1], [2].

Sistem pakar (expert system) telah diimplementasikan sebagai solusi untuk mengkodifikasi pengetahuan ahli K3 dalam diagnosis bahaya operasional. Pendekatan konvensional umumnya menggunakan metode deterministik seperti rule-based reasoning dan fuzzy logic [3], [4]. dalam analisis sistem FMEA untuk pipeline petroleum menunjukkan bahwa sistem berbasis aturan mengalami keterbatasan signifikan dalam menangani ketidakpastian data sensor dan variabilitas kondisi operasi [4]. Sistem rule-based cenderung "brittle" – efektif untuk skenario yang telah didefinisikan namun gagal ketika menghadapi kombinasi gejala baru atau kondisi anomali yang tidak terdokumentasi dalam knowledge base [3]. Lebih lanjut, sistem fuzzy tradisional bersifat statis; sekali inference rules ditetapkan, sistem tidak dapat secara otomatis mengadaptasi bobot kepercayaan ketika data empiris baru atau near-miss incidents terdokumentasi [5]. Keterbatasan ini menjadi kritis mengingat lingkungan kilang minyak yang dinamis dengan degradasi peralatan progresif dan perubahan komposisi feedstock yang

mempengaruhi profil risiko secara kontinyu, Mengingat keterbatasan sistem rule-based dan fuzzy logic dalam menangani ketidakpastian, pendekatan probabilistik menjadi alternatif yang menjanjikan untuk assesment risiko di kilang minyak.

Agregasi Probabilitas Bayesian menawarkan kerangka probabilistik yang fundamental berbeda dari sistem *rule-based* dalam menangani ketidakpastian dan multi gejala secara simultan. Keunggulan utama pendekatan ini terletak pada kemampuan untuk mengkombinasikan *evidence* dari berbagai sumber dan menghasilkan assesment risiko yang terkuantifikasi [6]. Dalam konteks *risk assessment* industri, agregasi probabilitas memungkinkan integrasi eksplisit dari faktor multi risiko. Misalnya, bagaimana kombinasi antara kebocoran kecil (faktor alat), peningkatan temperatur proses (faktor proses), dan *human error* (faktor manusia) secara kumulatif meningkatkan probabilitas insiden [7].

Penerapan pendekatan probabilistik dalam penilaian risiko operasional kilang minyak telah menunjukkan perkembangan yang signifikan, namun masih menghadapi tantangan dalam penanganan ketidakpastian dan kemampuan adaptasi. Penelitian Qi et al. (2024) mengembangkan Jaringan Bayesian Fuzzy untuk penilaian risiko kuantitatif kebocoran tangki penyimpanan minyak mentah, yang menyoroti kompleksitas model dalam menangani data tidak lengkap dan ketidakpastian parameter [8]. Penerapan model Jaringan Bayesian Fuzzy untuk analisis risiko dinamis kegagalan tangki penyimpanan depot minyak, dengan menekan kebutuhan sistem yang mampu menyesuaikan diri dengan kondisi operasional yang dinamis [9]. Meskipun efektif secara teoretis, kedua penelitian tersebut mengungkapkan keterbatasan dalam penanganan data tidak lengkap serta kebutuhan sistem pakar yang adaptif dan interaktif untuk lingkungan operasional nyata. Penerapan model-model kompleks tersebut memerlukan data pelatihan yang ekstensif dan komputasi yang intensif, sehingga menjadi kendala dalam penerapan waktu-nyata di lapangan. Penelitian ini mengatasi kesenjangan tersebut dengan mengembangkan sistem agregasi probabilitas Bayesian yang mengutamakan kemudahan penerapan dan tingkat interaktivitas tinggi, memungkinkan operator melakukan penilaian risiko secara *real-time* meskipun dengan data yang terbatas. Pendekatan praktis ini menawarkan solusi jembatan antara akurasi teknis model probabilistik kompleks dan kebutuhan operasional akan sistem yang responsif serta mudah digunakan di lingkungan kilang minyak.

Meskipun penelitian Qi et al. (2024) dan Zhou dan Zhou et al. (2023) telah menunjukkan efektivitas model bayesian network Fuzzy dalam penilaian risiko, kedua pendekatan tersebut memerlukan data pelatihan ekstensif dan komputasi intensif yang menjadi kendala dalam implementasi real-time di lapangan. Penelitian ini mengisi kesenjangan tersebut dengan tiga kebaruan utama: Pertama, penggunaan metode agregasi probabilitas yang lebih sederhana ($1 - \prod(1 - p)$) dibandingkan Bayesian Network kompleks, sehingga dapat diimplementasikan dengan data terbatas. Kedua, sistem dirancang dengan fokus pada interaktivitas tinggi dan kemudahan penggunaan operator (*user-friendly interface*) yang tidak ditemukan dalam penelitian sebelumnya. Ketiga, integrasi fitur supporting evidence dan ekspor data untuk pembelajaran berkelanjutan yang memungkinkan adaptasi sistem terhadap kondisi operasional spesifik kilang minyak. Pendekatan praktis ini menawarkan solusi jembatan antara akurasi teknis model probabilistik kompleks dan kebutuhan operasional akan sistem yang responsif, transparan, serta mudah digunakan di lingkungan kilang minyak.

2. METODE

Penelitian ini bertujuan merancang dan mengimplementasikan sistem pakar berbasis agregasi probabilitas Bayesian yang mampu mendeteksi dan mengevaluasi tingkat risiko bahaya di lingkungan industri kilang minyak secara kuantitatif. Kompleksitas operasi kilang, yang melibatkan proses bertekanan tinggi dan temperatur ekstrem, menuntut sistem pendukung keputusan yang mampu mengintegrasikan multi gejala menjadi *risk assessment*

terpadu melalui pendekatan probabilistik [10]. Sistem yang dikembangkan menggunakan metode agregasi probabilistik dengan formula Bayesian untuk mengkombinasikan beberapa gejala yang teramati menjadi skor risiko yang terkuantifikasi, mengatasi keterbatasan sistem konvensional yang hanya mengandalkan pengalaman kualitatif atau analisis gejala tunggal. Pendekatan ini memungkinkan penilaian risiko yang lebih komprehensif dan berbasis bukti melalui mekanisme kombinasi probabilitas posterior dari setiap gejala bahaya [11], [12].

A. Desain Penelitian

Penelitian ini mengembangkan sistem pakar melalui pendekatan komputasi probabilistik yang mencakup akuisisi pengetahuan dari dataset gejala bahaya, konstruksi model agregasi probabilitas Bayesian, dan implementasi antarmuka grafis berbasis Python. Proses pengembangan difokuskan pada pembangunan algoritma inferensi untuk mengintegrasikan multiple gejala menjadi evaluasi risiko terpadu, serta validasi fungsional melalui simulasi skenario bahaya.

B. Variabel Penelitian

Adapun Variabel-variabel yang dianalisis dalam penelitian ini diklasifikasikan berdasarkan peran fungsionalnya dalam proses inferensi Jaringan Bayesian, dengan data sumber utama dari *dataset* yaitu, “Dataset_Gejala_Bahaya_Bayes_C1_C60_tanpa_label_Sensor_.csv”:

1. Gejala (E): Variabel independen yang dimasukkan oleh operator. Merepresentasi dari kondisi gejala yang teramati, berfungsi sebagai *evidence* untuk memicu proses diagnosis.
2. Level Bahaya (H): Variabel dependen yang diprediksi oleh sistem. Merepresentasikan hasil akhir evaluasi risiko dalam bentuk tingkat prioritas (ringan, sedang, tinggi).
3. Probabilitas posterior (P): Variabel kuantifikasi yang mewakili probabilitas terjadinya bahaya berdasarkan gejala yang teramati. Probabilitas ini dihitung berdasarkan Bayesian untuk menghasilkan keputusan yang probabilistik.
4. Kategori Posterior (S): Informasi tambahan untuk analisis kontekstual, mengklasifikasikan sumber utama bahaya (misalnya: Proses, Peralatan) untuk mendukung rekomendasi mitigasi.

Keempat variabel ini memiliki peran berbeda namun saling terkait: Gejala (E) berfungsi sebagai input *evidence* yang mengaktifkan inferensi sistem, Level Bahaya (H) merupakan output prediksi risiko, Probabilitas Posterior (P) mengkuantifikasi tingkat keyakinan sistem terhadap prediksi tersebut, dan Kategori Pemicu (S) memberikan konteks kausal untuk mendukung rekomendasi mitigasi yang spesifik.

C. Akuisisi Pengetahuan Pakar

Eksperimen ini dilaksanakan menggunakan perangkat lunak Python 3.11 dengan pustaka-pustaka utama seperti *tkinter*, *math*, *messagebox*, *filedialog*, dan *datetime* untuk membangun antarmuka grafis serta mesin inferensi. Python dipilih karena fleksibilitasnya dalam mengelola *rule-based system*, kemudahan pembuatan GUI interaktif, serta kemampuannya dalam visualisasi hasil perhitungan inferensi dalam bentuk tabel diagnosis yang dinamis [13], [14]. *Tkinter* digunakan untuk membangun antarmuka grafis pengguna (GUI) yang interaktif, memungkinkan pengguna memilih gejala yang diamati dan menampilkan hasil diagnosa secara langsung [15]. *Math* digunakan untuk perhitungan matematis, terutama dalam implementasi metode Bayesian untuk menghitung probabilitas posterior bahaya, sementara *messagebox* dan *filedialog* mengelola interaksi pengguna dengan memberikan peringatan atau hasil diagnosa serta memungkinkan ekspor hasil diagnosa ke dalam format CSV. *Datetime* dimanfaatkan untuk menyimpan dan menampilkan waktu dalam analisis untuk melacak riwayat perhitungan.

1. Pemilihan Panel Pakar:

- Melibatkan 5 pakar K3 dengan pengalaman minimal 10 tahun di kilang minyak.

- Representasi dari berbagai disiplin: Process Engineer (2 orang), Mechanical Engineer (1 orang), HSE Supervisor (2 orang).
 - Kriteria seleksi: pengalaman langsung dalam penanganan insiden dan sertifikasi K3 profesional.
2. Metode Elicitasi Terstruktur:
- Tahap 1 - Identifikasi Gejala: Wawancara semi-terstruktur untuk mengidentifikasi 60 gejala bahaya yang relevan berdasarkan incident report dan near-miss database periode 2018-2023.
 - Tahap 2 - Penilaian Probabilitas: Setiap pakar diminta menilai probabilitas setiap gejala mengindikasikan level bahaya tertentu menggunakan skala 0-1 dengan interval 0.05.
 - Tahap 3 - Konsensus: Modified Delphi method dengan 2 putaran untuk mencapai kesepakatan. Pada putaran kedua, pakar diberikan feedback berupa distribusi penilaian kelompok dan diminta untuk mempertimbangkan kembali estimasi mereka.

D. Karakteristik Dataset

Dataset yang digunakan dalam penelitian ini bersumber dari basis pengetahuan pakar K3 kilang minyak yang dikodifikasikan dalam file "Dataset_Gejala_Bahaya_Bayes_C1_C60_-tanpa_label_Sensor_.csv". Dataset ini terdiri dari 60 records (C1-C60) yang merepresentasikan 60 gejala bahaya berbeda beserta parameter probabilitiknya. Setiap record memiliki 9 atribut: kode gejala, deskripsi gejala, kategori pemicu (Bahan, Peralatan, Proses, Prosedur, Lingkungan, Manusia), indikator observasi lapangan, level bahaya (skala 2-4), nilai prior probability, likelihood gejala diberi bahaya, evidence rate gejala, dan posterior probability bahaya dengan gejala.


Distribusi level bahaya dalam dataset menunjukkan dominasi gejala berisiko tinggi dengan 34 gejala (56.67%) pada Level 4, 25 gejala (41.67%) pada Level 3, dan 1 gejala (1.67%) pada Level 2. Berdasarkan kategori pemicu, gejala terkait Peralatan mendominasi dengan 21 records (35%), diikuti Prosedur 11 records (18.33%), Lingkungan 10 records

(16.67%), Bahan 9 records (15%), Proses 8 records (13.33%), dan Manusia 1 record (1.67%). Validitas dataset dijamin melalui inter-rater reliability check menggunakan Fleiss' Kappa, menghasilkan koefisien $\kappa = 0.78$ (substantial agreement) untuk penilaian probabilitas posterior. Inkonsistensi antar pakar diselesaikan melalui Modified Delphi method putaran kedua.

Proses preprocessing meliputi: (1) validasi konsistensi probabilitas memastikan semua nilai berada dalam rentang 0-1, (2) normalisasi format numerik untuk kompatibilitas komputasi, dan (3) verifikasi hubungan kausal antara gejala dengan level bahaya menggunakan logic checking algorithm. Mengingat sifat sistem ini sebagai *proof-of-concept* berbasis pengetahuan pakar, seluruh 60 records digunakan sebagai basis pengetahuan (knowledge base) sistem tanpa split training-testing, dengan validasi sistem dilakukan melalui pengujian skenario dan cross-validation dengan kasus nyata.

E. Prosedur Penelitian

Pelaksanaan penelitian mengikuti prosedur sistematis untuk menjamin keabsahan dan keterulangan hasil. Prosedur ini dibagi menjadi empat fase utama: (1) Akuisisi Data dan Kuantifikasi Model, (2) Konstruksi Mesin Inferensi Bayesian, (3) Implementasi Antarmuka Pengguna (GUI), dan (4) Validasi Fungsional melalui Simulasi Skenario. Fase 1 dan 2 diuraikan dalam Gambar 1, sementara fase 3 dan 4 dijelaskan dalam bagian Pembahasan.



Gambar 1. Diagram Alur Penelitian

Alur lengkap dari prosedur penelitian ini dapat dilihat pada Gambar 1, yang mencakup tahapan akuisisi data, konstruksi model probabilistik, implementasi sistem, dan validasi fungsional.

1. Akuisisi Data dan Kuantifikasi Model:

- **Pemrosesan Data:** *Dataset* sumber dimuat menggunakan pustaka Pandas. Kolom-kolom utama (gejala, level_bahaya, posterior_bahaya_dengan_gejala) diidentifikasi dan dinormalisasi untuk memastikan format numerik yang valid (0 hingga 1) untuk probabilitas posterior.
- **Basis Pengetahuan:** Data yang sudah diproses menjadi Basis Pengetahuan Probabilistik sistem pakar. Nilai Probabilitas Posterior ($P(H|E)$) digunakan sebagai koefisien *weighting* untuk setiap gejala terhadap kelas bahaya terkait.

2. Konstruksi Mesin Inferensi Bayesian (Agregasi Probabilitas):

- Pemilihan Gejala: Operator (pengguna) memilih satu atau lebih Gejala (E_i) yang teramati di lapangan melalui antarmuka GUI.
- Inferensi Gabungan (Perhitungan Skor Mentah): Mesin inferensi menjalankan algoritma Agregasi Probabilitas Independence untuk setiap kelas bahaya (H_c) yang relevan. Probabilitas gabungan (P Gabungan) dihitung dengan mengasumsikan kontribusi independen dari setiap gejala pada Pers. (1):

$$P_{Gabungan}(H_c) = \prod_{i=1}^n (1 - P(H_c | E_i)) \quad (1)$$

3. Implementasi Antarmuka Pengguna (GUI):

- Desain Interface: Antarmuka grafis dibangun menggunakan library Tkinter dengan fokus pada user experience yang intuitif.
- Komponen Utama: Sistem checklist interaktif untuk seleksi gejala, tabel hasil diagnosis dengan tiga kolom (Probabilitas, Gejala Pendukung, Rekomendasi), dan

- fitur ekspor hasil ke format CSV untuk dokumentasi.
- Integrasi: Mesin inferensi Bayesian diintegrasikan dengan GUI melalui event handler yang memicu perhitungan probabilitas setiap kali operator melakukan perubahan seleksi gejala.
- 4. Validasi Fungsional melalui Simulasi Skenario:
 - Pengujian Single-Symptom: Verifikasi bahwa sistem menghasilkan diagnosis yang konsisten dengan knowledge base untuk setiap gejala individual. Metrik evaluasi: exact match accuracy = 100% (60/60 gejala).
 - Pengujian Multi-Symptom: Simulasi 30 kombinasi gejala yang mempresentasikan skenario bahaya realistis untuk memastikan agregasi probabilitas berfungsi dengan benar sesuai Persamaan (1).
 - Evaluasi Supporting Evidence: Menghitung rata-rata selisih absolut antara probabilitas yang diprediksi sistem dengan probabilitas referensi dari pakar untuk 30 skenario uji.

Formula: $MAE = (1/n) \sum |P_{prediksi} - P_{pakar}|$

- Root Mean Square Error (RMSE): Mengukur deviasi kuadrat probabilitas prediksi. Formula: $RMSE = \sqrt{(1/n) \sum (P_{prediksi} - P_{pakar})^2}$
- Threshold Akurasi: Prediksi dianggap akurat jika $|P_{prediksi} - P_{pakar}| < 0.15$
- Evaluasi Supporting Evidence: Konfirmasi bahwa sistem menampilkan gejala pendukung yang relevan untuk setiap level bahaya yang diprediksi. Metrik: precision = jumlah gejala relevan / total gejala yang ditampilkan.
- Analisis Sensitivitas: Menguji bagaimana perubahan nilai probabilitas posterior individual ($\pm 10\%$) mempengaruhi probabilitas gabungan akhir. Sistem dianggap robust jika perubahan $\leq 10\%$ pada input menghasilkan perubahan $\leq 15\%$ pada output.
- User Experience Testing: Penilaian kemudahan penggunaan antarmuka oleh 3 operator dengan berbagai tingkat keahlian menggunakan System Usability Scale (SUS). Target skor: ≥ 70 (acceptable).
- Computational Performance:
 - Response time: waktu yang dibutuhkan sistem untuk menghasilkan diagnosis sejak operator mengklik tombol "Diagnosa" (target: < 2 detik).
 - Scalability test: performa sistem ketika jumlah gejala dipilih meningkat dari 1 hingga 60 gejala.

3. PEMBAHASAN

Sistem pakar ini diimplementasikan melalui antarmuka grafis (GUI) yang dikembangkan dengan library Tkinter pada Python, menyediakan platform yang *user-friendly* bagi operator untuk melakukan assessment risiko. Implementasi ini mengintegrasikan metode agregasi probabilitas Bayesian sebagai mesin inferensi utama, di mana pengetahuan pakar tentang probabilitas posterior gejala terhadap level bahaya telah dikodifikasikan dalam *knowledge base* probabilistik.

Antarmuka yang dibangun memfasilitasi tiga fungsi utama: pertama, akuisisi pengetahuan melalui seleksi gejala yang diamati di lapangan; kedua, proses komputasi probabilistik yang mengolah *evidence* tersebut menggunakan teorema Bayesian; dan ketiga, visualisasi hasil diagnostik yang menyajikan tingkat risiko dalam skala terkuantifikasi disertai rekomendasi mitigasi yang spesifik.

1) Efektivitas Agregasi Probabilitas Bayesian

Sistem ini mengimplementasikan agregasi probabilitas Bayesian melalui rumus $1 - \prod(1 - p)$ untuk mengkombinasikan berbagai gejala menjadi skor risiko terpadu, sehingga mampu menangani kontribusi kumulatif dari setiap indikator bahaya [16]. Dalam konteks deteksi

bahaya di kilang minyak, pendekatan ini sangat relevan mengingat risiko biasanya muncul dari interaksi beberapa faktor, bukan berasal dari gejala tunggal.

Implementasi dalam sistem dapat diilustrasikan ketika operator memilih tiga gejala sekaligus, misalnya: "kebocoran kecil pada flange", "bau hidrokarbon menyengat di area proses", dan "penurunan tekanan sistem yang tidak normal". Daripada menganalisis setiap gejala secara terisolasi, sistem menghitung probabilitas gabungan untuk setiap level bahaya. Sebagai contoh, jika gejala A memiliki $P(\text{bahaya}|A) = 0.6$, gejala B memiliki $P(\text{bahaya}|B) = 0.5$, dan gejala C memiliki $P(\text{bahaya}|C) = 0.4$, maka probabilitas terkombinasi untuk level bahaya tertentu dihitung sebagai berikut:

$$\begin{aligned} P_{\text{kombinasi}} &= 1 - [(1 - 0,6) \times (1 - 0,5) \times (1 - 0,4)] \\ &= 1 - [0,4 \times 0,5 \times 0,6] \\ &= 1 - 0,12 = 0,88 \end{aligned}$$

Hasil perhitungan ini menunjukkan bahwa meskipun masing-masing gejala memiliki probabilitas menengah, kombinasi ketiganya menghasilkan keyakinan yang sangat tinggi (88%) terhadap adanya level bahaya tertentu. Metode ini secara efektif menangkap esensi dari *risk accumulation* yang sering terjadi dalam insiden industri [17].

Pendekatan yang digunakan $1 - \prod(1 - p)$ merupakan bentuk penyederhanaan dari model Bayesian yang lebih kompleks, dengan pertimbangan praktis. Dalam konteks industri kilang minyak, data lengkap untuk menghitung semua komponen ini seringkali tidak tersedia atau sangat sulit diperoleh [5]. Sistem ini mengakomodasi keterbatasan data dengan menggunakan probabilitas posterior $P(H|E)$ yang langsung diperoleh dari pengetahuan pakar, sehingga menghindari kebutuhan untuk mengestimasi likelihood dan prior secara terpisah.

Tabel 1: Perhitungan Tingkat Risiko Berdasarkan Gejala

Gejala	Kategori Pemicu	Level Bahaya	Prior	Likelihood Gejala Diberi Bahaya	Evidence Rate Gejala	Posterior Bahaya dengan Gejala
Kebocoran gas metana	Bahan	3	0,12	0,90	0,35	0,31
Kebocoran H2S	Bahan	4	0,10	0,95	0,28	0,34
Kebakaran kecil terlihat	Proses	4	0,08	0,90	0,22	0,33
Overheating permukaan pipa	Peralatan	3	0,14	0,80	0,40	0,28
Tekanan proses cenderung di atas	Proses	3	0,10	0,85	0,30	0,28

Tabel 1 menunjukkan variasi nilai posterior yang dipengaruhi oleh kombinasi prior probability dan likelihood. Kebocoran H2S memiliki posterior tertinggi (0.34) meskipun prior-nya rendah (0.10), mengindikasikan bahwa likelihood yang tinggi (0.95) mendominasi perhitungan posterior. Hal ini sesuai dengan prinsip Bayesian updating dimana evidence kuat dapat mengatasi prior belief yang lemah [6].

2) Transparasi Diagnostik Melalui *Supporting Evidence*

Sistem yang dikembangkan mengintegrasikan fitur diagnosis transparan dengan menampilkan daftar "gejala pendukung" (*supporting evidence*) untuk setiap level risiko yang

dihasilkan. Fitur ini merupakan aspek kritis dalam membangun *trust* dan *accountability* sistem pakar di lingkungan industri yang memerlukan justifikasi yang jelas untuk setiap keputusan [18].

Implementasi dalam sistem dapat diamati pada mekanisme *aggregate_by_class()* dimana setiap hasil diagnosis tidak hanya menyajikan skor probabilitas, tetapi juga menyimpan dan menampilkan daftar spesifik gejala-gejala yang berkontribusi terhadap level bahaya tertentu sebagaimana yang ditujukan pada gambar 2.



Gambar 2. Output Diagnosis Sistem Menampilkan Level Bahaya 3 (Probabilitas 0.571) dengan *Supporting Evidence*: Gangguan Aliran Fluida dan Getaran Berlebih.

Contoh hasil diagnosis yang dihasilkan oleh sistem ditunjukkan pada Gambar 2, yang menampilkan level bahaya, nilai probabilitas, serta daftar gejala pendukung. Output sistem yang menampilkan "Level bahaya teratas: 3 (probabilitas 0.571)" disertai dengan "Gejala pendukung: Gangguan aliran fluida, Getaran berlebih terasa", yang berawal dari pemilihan tiga gejala yaitu: Kebocoran H₂S, Gangguan Aliran Fluida, dan Getaran Lebih Terasa, menunjukkan implementasi nyata dari kemampuan diagnostik yang transparan dalam sistem pakar Bayesian ini. Fitur *supporting evidence* ini merupakan elemen kritis yang membedakan sistem ini dari pendekatan *black-box* konvensional.

Mekanisme diagnostik yang terlihat pada output tersebut mengungkapkan bagaimana sistem tidak hanya menghasilkan kesimpulan probabilistik, tetapi juga secara eksplisit mengidentifikasi dan menampilkan gejala spesifik yang berkontribusi terhadap keputusan tersebut. Dalam contoh ini, kombinasi "Gangguan aliran fluida" dan "Getaran berlebih terasa" secara kolektif menghasilkan probabilitas 0.571 untuk Level Bahaya 3, yang mengindikasikan keyakinan sistem yang moderat hingga tinggi terhadap adanya risiko signifikan.


Fitur ini memungkinkan validasi silang oleh operator. Dengan mengetahui bahwa getaran berlebih dan gangguan aliran fluida menjadi dasar diagnosis, operator dapat secara langsung memverifikasi kedua gejala tersebut di lapangan sebelum mengambil tindakan lebih lanjut. Hal ini mengatasi kelemahan sistem konvensional yang seringkali hanya memberikan output tanpa konteks yang memadai. Daftar gejala pendukung yang berkontribusi pada setiap level bahaya disajikan pada Tabel 2, yang menjadi dasar rekomendasi tindakan mitigasi.

Tabel 2. Gejala Pendukung Tingkat Bahaya

<i>Hazard Level</i>	<i>Probability</i>	<i>Supporting Symptoms</i>	<i>Recommendation</i>
Level 3	0,31	Kebocoran gas metana, Overheating permukaan pipa	Periksa flensa dan pipa
Level 4	0,34	Kebocoran H ₂ S, Kebakaran kecil terlihat	Melakukan pemeriksaan kebocoran dan keselamatan kebakaran
Level 3	0,28	Tekanan proses cenderung di atas normal, Overheating	Periksa tekanan proses dan pengaturan panas

3) Desain Antarmuka User-Friendly untuk *Adoptabilitas* Praktis

Antarmuka grafis yang dikembangkan dalam sistem ini menunjukkan pendekatan *human-centered design* yang secara signifikan meningkatkan *adoptability* sistem di lingkungan industri kilang minyak [19]. Desain GUI yang intuitif mengatasi tantangan klasik dalam penerapan sistem pakar kompleks dengan menjembatani kesenjangan antara kecanggihan algoritma Bayesian dan kebutuhan praktis operator lapangan [20]. Desain antarmuka dapat dilihat pada gambar 3 seperti berikut.



Gambar 3. Tampilan Antarmuka Ketika Sistem Dijalankan

Tampilan antarmuka pengguna yang dikembangkan dalam penelitian ini ditunjukkan pada Gambar 3, yang memperlihatkan struktur menu, checklist gejala, dan tabel hasil diagnosis.

- Struktur *checklist* gejala yang terorganisir rapi memungkinkan operator dengan cepat memindai dan memilih indikator yang diamati. Seperti terlihat pada contoh, operator dapat secara simultan memilih multiple gejala seperti "Kebocoran H2S", "Tekanan proses cenderung di atas normal", "Overflow cairan", dan "Kekurangan oksigen" dengan satu kali scan visual. Efisiensi ini sangat kritikal dalam lingkungan operasional yang memerlukan respons cepat.
- Fitur klik kanan untuk melihat indikator observasi (seperti yang tercantum dalam hint di bawah checklist) menyediakan akses instan terhadap informasi kontekstual tanpa mengganggu alur kerja utama. Ini merepresentasikan implementasi prinsip *progressive disclosure* yang mengurangi cognitive load pengguna sambil tetap menyediakan akses ke informasi detail ketika diperlukan.
- Tampilan hasil diagnosis yang terstruktur dalam tabel tiga kolom - "Prob", "Gejala Pendukung", dan "Rekomendasi" - memfasilitasi pemahaman yang cepat terhadap output sistem. Seperti terlihat pada output, operator dapat langsung melihat bahwa Level 2 (probabilitas 0.429) terutama didukung oleh gejala "Kebocoran H2S" dengan rekomendasi tindakan yang spesifik. Presentasi visual ini mengubah output probabilistik yang kompleks menjadi informasi yang dapat ditindaklanjuti (*actionable information*).

Fitur export hasil diagnosis ke dalam format CSV yang diimplementasikan dalam sistem bukan hanya sekadar utilitas teknis, melainkan komponen strategis yang mendukung manajemen pengetahuan (*knowledge management*) dan peningkatan berkelanjutan dalam sistem manajemen keselamatan kilang minyak. Detail hubungan antara likelihood, evidence

rate, dan posterior probability untuk beberapa gejala utama dapat dilihat pada Tabel 3.

Tabel 3: Tingkat *Evidence* dan Probabilitas Posterior

Gejala	Likelihood Gejala Diberi Bahaya	Evidence Rate Gejala	Posterior Bahaya dengan Gejala
Kebocoran gas metana	0,90	0,35	0,31
Kebocoran H ₂ S	0,95	0,28	0,34
Kebakaran kecil terlihat	0,90	0,22	0,33
Overheating permukaan pipa	0,80	0,40	0,28
Tekanan proses cenderung tinggi	0,85	0,30	0,28

4) Keterbatasan dan Arah Penelitian Mendatang

Penelitian ini berhasil mengembangkan sistem *proof-of-concept* yang mendemonstrasikan potensi metode Bayesian dalam mendeteksi risiko di kilang minyak. Namun, signifikansi hasil ini perlu dilihat dalam konteks beberapa keterbatasan mendasar. Keterbatasan utama berasal dari asumsi independensi statistik antar gejala yang mungkin tidak sesuai dengan realitas, serta ketergantungan pada data simulasi dan *expert judgment* alih-alih data insiden historis yang membatasi validasi empirisnya. Selain itu, sistem bersifat statis tanpa kemampuan adaptif, bergantung sepenuhnya pada akurasi input operator, dan memiliki cakupan terbatas pada 60 skenario yang telah ditentukan. Terakhir, belum adanya evaluasi kuantitatif dengan metrik standar menyebabkan efektivitas sistem belum terukur secara objektif. Meskipun demikian, penelitian ini memberikan fondasi berharga untuk pengembangan lebih lanjut dengan mengidentifikasi area kritis yang perlu disempurnakan. Penelitian mendatang akan fokus pada tiga arah pengembangan: (1) integrasi Bayesian Network untuk memodelkan dependensi antar gejala, (2) implementasi machine learning untuk adaptive updating knowledge base berbasis data insiden historis, dan (3) validasi empiris melalui pilot study di kilang minyak operasional dengan mengukur metrik performa seperti precision, recall, dan response time.

4. SIMPULAN

Penelitian ini berhasil mengembangkan sistem pakar berbasis agregasi probabilitas Bayesian untuk deteksi risiko bahaya di kilang minyak. Kontribusi utama meliputi: (1) model agregasi probabilistik yang mengintegrasikan multiple gejala dengan rumus $1 - \prod(1 - p)$, menghasilkan peningkatan keyakinan diagnosis dari 0.4-0.6 (gejala individual) menjadi 0.88 (kombinasi 3 gejala); (2) mekanisme supporting evidence yang meningkatkan transparansi dan memfasilitasi validasi silang oleh operator; dan (3) antarmuka grafis user-friendly dengan fitur ekspor CSV untuk dokumentasi dan pembelajaran berkelanjutan. Sistem ini menawarkan solusi praktis yang menjembatani kesenjangan antara model probabilistik kompleks dan kebutuhan operasional kilang minyak. Dibandingkan sistem konvensional rule-based, pendekatan Bayesian ini lebih adaptif dalam menangani ketidakpastian dan memberikan justifikasi transparan untuk setiap rekomendasi mitigasi. Implementasi sistem ini berpotensi mengurangi waktu respons insiden dan meningkatkan akurasi deteksi dini risiko, meskipun validasi empiris di lingkungan operasional nyata masih diperlukan. Penelitian mendatang perlu fokus pada pengembangan Bayesian Network untuk memodelkan dependensi antar gejala, integrasi machine learning untuk adaptive learning, dan validasi kuantitatif melalui pilot study dengan metrik performa terukur.

5. DAFTAR PUSTAKA

- [1] O. Chencheva, S. Sukach, D. Rieznik, I. Petrenko, Ye. Lashko, and O. Hladiuk, "MODERN CONCEPT OF OCCUPATIONAL SAFETY AND HEALTH MANAGEMENT WITH A RISK-BASED APPROACH," *Municipal economy of cities*, vol. 4, no. 185, pp. 221–227, Sep. 2024, doi: 10.33042/2522-1809-2024-4-185-221-227.
- [2] T. Musungwa and P. Kowe, "Effects of occupational health and safety management systems implementation in accident prevention at a Harare beverage company," *Cogent Eng*, vol. 9, no. 1, Dec. 2022, doi: 10.1080/23311916.2022.2124638.
- [3] C. Mitrakas, A. Xanthopoulos, and D. Koulouriotis, "Techniques and Models for Addressing Occupational Risk Using Fuzzy Logic, Neural Networks, Machine Learning, and Genetic Algorithms: A Review and Meta-Analysis," *Applied Sciences*, vol. 15, no. 4, p. 1909, Feb. 2025, doi: 10.3390/app15041909.
- [4] S. Hassan, J. Wang, C. Kontovas, and M. Bashir, "Modified FMEA hazard identification for cross-country petroleum pipeline using Fuzzy Rule Base and approximate reasoning," *J Loss Prev Process Ind*, vol. 74, p. 104616, Jan. 2022, doi: 10.1016/j.jlp.2021.104616.
- [5] T. Eskandari and I. Mohammadfam, "Application of Fuzzy Bayesian Network in Dynamic Risk Analysis of Explosion in Process Industries," *Health in Emergencies & Disasters Quarterly*, vol. 10, no. 03, pp. 193–206, Apr. 2025, doi: 10.32598/hdq.10.3.466.3.
- [6] L. Yang, P. Wang, W. Zhao, C. Wang, X. Wu, and M. G. R. Faes, "On investigation of the Bayesian anomaly in multiple imprecise dependent information aggregation for system reliability evaluation," *International Journal of Intelligent Systems*, vol. 36, no. 6, pp. 2895–2921, Jun. 2021, doi: 10.1002/int.22405.
- [7] B. Hong, B. Shao, J. Guo, J. Fu, C. Li, and B. Zhu, "Dynamic Bayesian network risk probability evolution for third-party damage of natural gas pipelines," *Appl Energy*, vol. 333, p. 120620, Mar. 2023, doi: 10.1016/j.apenergy.2022.120620.
- [8] S. Qi, J. Shuai, L. Shi, Y. Li, and L. Zhou, "Quantitative risk assessment of leakage accident of crude oil storage tank based on fuzzy Bayesian network and improved AHP," *J Loss Prev Process Ind*, vol. 90, p. 105341, Aug. 2024, doi: 10.1016/j.jlp.2024.105341.
- [9] Q.-Y. Zhou, B. Li, Y. Lu, J. Chen, C.-M. Shu, and M. Bi, "Dynamic risk analysis of oil depot storage tank failure using a fuzzy Bayesian network model," *Process Safety and Environmental Protection*, vol. 173, pp. 800–811, May 2023, doi: 10.1016/j.psep.2023.03.072.
- [10] Y. Liu *et al.*, "Failure Risk Assessment of Coal Gasifier Based on the Integration of Bayesian Network and Trapezoidal Intuitionistic Fuzzy Number-Based Similarity Aggregation Method (TpIFN-SAM)," *Processes*, vol. 10, no. 9, p. 1863, Sep. 2022, doi: 10.3390/pr10091863.
- [11] L. Wei, "Application of Bayesian Algorithm in Risk Quantification for Network Security," *Comput Intell Neurosci*, vol. 2022, pp. 1–10, Jul. 2022, doi: 10.1155/2022/7512289.
- [12] N. Dong, N. Nair, and D. Du, "Scalable Bayesian Nonparametric Method for Clinical Risk Prediction Using Large-Scale Data From Heterogeneous Populations," *IEEE J Biomed Health Inform*, vol. 29, no. 10, pp. 7514–7524, Oct. 2025, doi: 10.1109/JBHI.2025.3567944.
- [13] M. Ollenschläger *et al.*, "MaD GUI: An Open-Source Python Package for Annotation and Analysis of Time-Series Data," *Sensors*, vol. 22, no. 15, p. 5849, Aug. 2022, doi: 10.3390/s22155849.
- [14] A. Nakamura, "Iys: interactive multi-dimensional data analysis and visualization platform," *J Open Source Softw*, vol. 8, no. 92, p. 5869, Dec. 2023, doi: 10.21105/joss.05869.
- [15] X. He, Z. Wang, and S. Zhan, "Design and implementation of interactive image measurement software based on Tkinter and PIL library," in *Proceedings of the 4th International Conference on Computer, Artificial Intelligence and Control Engineering*, New York, NY, USA: ACM, Jan. 2025, pp. 564–568. doi: 10.1145/3727648.3727740.
- [16] C. Ji, X. Su, Z. Qin, and A. Nawaz, "Probability Analysis of Construction Risk based on Noisy-or Gate Bayesian Networks," *Reliab Eng Syst Saf*, vol. 217, p. 107974, Jan. 2022, doi: 10.1016/j.res.2021.107974.
- [17] C. Bao, M. Cai, J. Li, Q. Zheng, D. Wu, and Q. Meng, "Risk aggregation considering probabilistic and consequential interactions: A general formulation with computational cost handling," *Risk Analysis*, vol. 44, no. 6, pp. 1440–1459, Jun. 2024, doi: 10.1111/risa.14253.

- [18] L. Famiglini, A. Campagner, M. Barandas, G. A. La Maida, E. Gallazzi, and F. Cabitza, "Evidence-based XAI: An empirical approach to design more effective and explainable decision support systems," *Comput Biol Med*, vol. 170, p. 108042, Mar. 2024, doi: 10.1016/j.combiomed.2024.108042.
- [19] R. K. Khamaisi, M. Peruzzini, R. Raffaelli, G. Mangia, and M. Pellicciari, "Designing adaptive human- cyber-physical systems to improve industrial tasks: a methodological approach," *The International Journal of Advanced Manufacturing Technology*, vol. 136, no. 9, pp. 4067–4082, Feb. 2025, doi: 10.1007/s00170-024-14698-y.
- [20] C. Bajan and G. Lambard, "MADGUI: Multi-Application Design Graphical User Interface for active learning assisted by Bayesian optimization," *Chemometrics and Intelligent Laboratory Systems*, vol. 258, p. 105323, Mar. 2025, doi: 10.1016/j.chemolab.2025.105323.

Daftar Simbol

H	= Level bahaya (Hazard Level) yang diprediksi oleh sistem
H_c	= Kelas bahaya tertentu ke-c (misalnya: Level 2, Level 3, Level 4)
E	= Gejala atau bukti yang diamati (Evidence)
E_i	= Gejala ke-i dari total n gejala yang teramati
$P(H_c E_i)$	= Probabilitas posterior bahaya H_c given gejala E_i
$P_{\text{Gabungan}}(H_c)$	= Probabilitas gabungan untuk kelas bahaya H_c berdasarkan kombinasi multiple gejala
n	= Jumlah total gejala yang teramati oleh operator
i	= Indeks gejala, dengan $i = 1, 2, 3, \dots, n$
S	= Kategori pemicu atau sumber bahaya (misalnya: Proses, Peralatan, Bahan, Lingkungan)
$\prod$	= Simbol produk matematis untuk perkalian berurutan