

# Sistem Pendukung Keputusan Triase Poliklinik Menggunakan Pendekatan Hybrid K-Means Clustering dan Rule-Based

Khoeruddin<sup>1\*</sup>, Farhan Hidayat<sup>2</sup>, Khoirul Yudi<sup>3</sup>, Hendra Supendar<sup>4</sup>, Riza Fahlapi<sup>5</sup>

<sup>1,2,3,4,5</sup>Program Studi Sistem Informasi dan Teknologi Informasi, Universitas Bina Sarana Informatika, Jakarta, Indonesia

Email: <sup>1\*</sup>khoeruddin190@gmail.com, <sup>2</sup>farhanhidayat41108@gmail.com, <sup>3</sup>khoirulyudi160101@gmail.com,

<sup>4</sup>hendra.hds@bsi.ac.id, <sup>5</sup>riza.rzf@bsi.ac.id

(\*Email Corresponding Author: khoirulyudi160101@gmail.com)

Received: 28 Juni 2026 | Revision: 30 Juni 2026 | Accepted: 1 Juni 2026

## Abstrak

Triase pasien secara manual di fasilitas pelayanan kesehatan masih menjadi hambatan krusial: penilaian yang bersifat subjektif, inkonsistensi prioritasasi, dan waktu tunggu yang memanjang secara kolektif meningkatkan risiko luaran klinis yang buruk, khususnya di poliklinik rawat jalan dengan keterbatasan sumber daya yang lazim ditemui. Penelitian ini menjawab kesenjangan tersebut dengan mengembangkan Sistem Pendukung Keputusan (SPK) berbasis pendekatan hybrid yang mengintegrasikan unsupervised machine learning dengan aturan klinis deterministik. Dataset triase nyata sebesar 275.566 rekam medis digunakan, masing-masing memuat label Emergency Severity Index (ESI) beserta empat parameter vital: usia, frekuensi denyut jantung, suhu tubuh, dan saturasi oksigen perifer (SpO<sub>2</sub>). K-Means Clustering ( $k = 4$ ) diterapkan pascanormalisasi Skor Standar untuk menemukan subkelompok pasien laten, dengan  $k$  optimal dipilih melalui kriteria elbow dan dikonfirmasi oleh Silhouette Score (0,2103) serta Davies-Bouldin Index (1,4049). Rule-based engine kemudian memetakan keanggotaan tiap kluster ke level prioritas triase yang kompatibel dengan ESI, mereplikasi logika klinis perawat terdepan secara auditable dan reproducible. Aplikasi desktop yang dihasilkan, triase\_desktop, memberikan rekomendasi triase secara real-time dengan latensi sub-detik. Analisis komparatif mengonfirmasi bahwa pendekatan hybrid unggul dalam interpretabilitas dan keselarasan klinis dibandingkan klasifikasi paradigma tunggal. Penelitian ini berkontribusi pada kerangka triase berbasis data yang skalabel dan dapat diadaptasi ke infrastruktur kesehatan masyarakat Indonesia, di mana solusi triase digital yang terstandardisasi masih sangat terbatas.

**Kata Kunci:** K-Means Clustering, Sistem Berbasis Aturan, Pendukung Keputusan Triase, Emergency Severity Index, Informatika Klinis

## Abstract

*Manual patient triage at healthcare facilities remains a critical bottleneck: subjective assessments, inconsistent prioritization, and prolonged waiting times collectively increase the risk of adverse clinical outcomes, particularly in outpatient polyclinic settings where resource constraints are pervasive. This study addresses that gap by developing a hybrid Decision Support System (DSS) that fuses unsupervised machine learning with deterministic clinical rules. A real-world triage dataset comprising 275,566 records was employed, each containing Emergency Severity Index (ESI) labels alongside four vital parameters: age, heart rate, body temperature, and peripheral oxygen saturation (SpO<sub>2</sub>). K-Means clustering ( $k = 4$ ) was applied after Standard Score normalization to discover latent patient subgroups, with the optimal  $k$  selected via the elbow criterion and corroborated by Silhouette Score (0.2103) and Davies-Bouldin Index (1.4049). A rule-based engine then mapped each cluster membership to a discrete ESI-compatible triage priority level, replicating the clinical logic of frontline nurses in an auditable, reproducible manner. The resulting desktop application, triase\_desktop, provides real-time triage recommendations with sub-second latency. Comparative analysis confirms that the hybrid approach outperforms single-paradigm classification in interpretability and clinical alignment. This work contributes a scalable, data-driven triage framework adaptable to Indonesian public health infrastructure, where standardized digital triage solutions remain scarce.*

**Keywords:** K-Means Clustering, Rule-Based System, Triage Decision Support, Emergency Severity Index, Clinical Informatics

## 1. PENDAHULUAN

Data Rekam Medik Elektronik Nasional mencatat bahwa tingkat kunjungan poliklinik rawat jalan di Indonesia menyentuh angka 35,2 juta kunjungan per tahun pada periode 2022–2023, dengan distribusi beban yang sangat tidak merata antara fasilitas kesehatan tingkat pertama dan rumah sakit rujukan [1]. Paradoks yang kurang disorot dalam diskursus digitalisasi kesehatan adalah bahwa kepadatan kunjungan tersebut tidak diimbangi oleh sistem seleksi pasien yang objektif: triase masih didominasi oleh penilaian klinis manual yang sangat bergantung pada kompetensi dan kondisi psikofisiologis petugas medis di lapangan. Di Indonesia, kondisi ini diperparah oleh rasio perawat-pasien yang jauh di

bawah standar yang direkomendasikan secara internasional [2], sehingga otomatisasi triase bukan sekadar upaya efisiensi operasional, melainkan kebutuhan mendasar bagi keselamatan pasien.

Urgensi ini bukan sekadar isu teknis, melainkan juga isu sistemik yang telah didokumentasikan secara empiris. Penelitian pada empat belas rumah sakit di Asia Timur menemukan bahwa kesalahan triase manual berkontribusi pada 23% kasus keterlambatan penanganan kegawatan [3], sementara studi lain melaporkan bahwa implementasi sistem triase terkomputerisasi mampu mereduksi waktu tunggu pasien kategori kritis hingga 38% [4]. Sistem triase modern di sebagian besar negara mengacu pada protokol Emergency Severity Index (ESI), yang mengklasifikasikan pasien ke dalam lima level kegawatan berdasarkan kondisi vital dan kebutuhan sumber daya [6]. Menariknya, meskipun ESI dirancang sebagai instrumen semi-objektif, implementasinya di lapangan tetap sangat bergantung pada penilaian klinis individual yang rentan terhadap variasi inter-rater; koefisien kappa inter-rater triase manual bahkan dilaporkan hanya sebesar 0,51 atau kategori sedang, yang mengindikasikan bahwa satu dari empat keputusan triase berpotensi tidak konsisten antarpetugas [5].

Berbeda dari asumsi awal bahwa kompleksitas klinis tidak dapat dikuantifikasi, pola tanda vital pasien sesungguhnya membentuk struktur tersembunyi yang dapat diekstraksi secara komputasional. K-Means Clustering, sebagai representasi kanonik algoritma unsupervised learning [7], menawarkan mekanisme pengelompokan data tanpa memerlukan label apriori, sebuah keunggulan kritis mengingat data historis triase seringkali tidak terlabeli secara konsisten. Klusterisasi tanda vital pasien dengan K-Means telah terbukti mampu mengidentifikasi fenotipe klinis yang tidak terdeteksi oleh kategorisasi manual konvensional [8], sementara pendekatan unsupervised juga dilaporkan lebih tangguh terhadap concept drift, yaitu pergeseran distribusi data klinis dari waktu ke waktu, dibandingkan model supervised [9]. Perbedaan perspektif ini mencerminkan ketegangan mendasar antara akurasi prediktif dan ketahanan model, dan posisi penelitian ini secara eksplisit memprioritaskan ketahanan untuk konteks deployment jangka panjang di fasilitas kesehatan dengan kapasitas pembaruan label yang terbatas.

Di sisi lain, rule-based systems (RBS) mewakili paradigma kecerdasan buatan yang mengkodekan pengetahuan domain dalam bentuk pernyataan kondisional yang dapat diaudit secara eksplisit [10]. Berbeda dari pendekatan deep learning yang sering dikritik sebagai “kotak hitam”, RBS menyediakan transparansi penalaran yang kritis bagi akuntabilitas medis; klinisi bahkan dilaporkan menunjukkan tingkat kepercayaan 34% lebih tinggi terhadap rekomendasi sistem berbasis aturan dibandingkan model neural network, meskipun akurasi prediktif keduanya sebanding [11]. Integrasi unsupervised learning dengan logika deterministik dalam satu kerangka SPK telah mendapat perhatian yang meningkat dalam satu dekade terakhir: hybrid clustering-rule system untuk prediksi sepsis di ICU memperoleh area under the curve (AUC) sebesar 0,89 dengan interpretabilitas tinggi [12], sementara hybrid K-Means dan clinical rules untuk triase kardial terbukti mampu mereduksi false-negative rate sebesar 17% dibandingkan triase manual [13]. Pola ini menunjukkan bahwa keunggulan pendekatan hybrid tidak selalu berasal dari akurasi absolut, melainkan dari kemampuannya menyeimbangkan presisi komputasional dengan akseptabilitas klinis, dimensi yang sering luput dari evaluasi konvensional berbasis metrik tunggal.

Berdasarkan tinjauan di atas, research gap yang teridentifikasi mencakup tiga dimensi. Pertama, mayoritas sistem triase digital yang terdokumentasi dalam literatur menggunakan supervised learning yang memerlukan data berlabel berkualitas tinggi, sumber daya yang relatif langka pada konteks fasilitas kesehatan di Indonesia. Kedua, pendekatan hybrid K-Means dan rule-based untuk triase poliklinik hampir tidak ditemukan pada publikasi yang menggunakan dataset rekam medis berskala besar. Ketiga, belum ditemukan sistem serupa yang mengintegrasikan mekanisme evaluasi multimetrik, yaitu Silhouette Score dan Davies-Bouldin Index, sebagai validasi eksplisit terhadap kualitas klusterisasi yang dihasilkan. Penelitian ini mengisi ketiga celah tersebut dengan mengembangkan SPK triase berbasis 275.566 rekam medis nyata, dievaluasi menggunakan metrik yang relevan secara klinis, serta diimplementasikan sebagai aplikasi desktop yang fungsional dan siap digunakan oleh tenaga medis non-teknis.

Secara terukur, tujuan penelitian ini adalah: (1) membangun model K-Means yang mampu mengelompokkan pasien ke dalam subkelompok klinis yang homogen berdasarkan parameter vital; (2) merancang rule-based engine yang memetakan hasil klusterisasi ke level prioritas triase yang kompatibel dengan ESI; (3) mengevaluasi kualitas klusterisasi menggunakan Silhouette Score dan Davies-Bouldin Index; serta (4) mengimplementasikan sistem sebagai aplikasi desktop yang dapat dioperasikan oleh tenaga medis non-teknis di fasilitas pelayanan primer. Struktur artikel selanjutnya menguraikan metodologi penelitian, hasil dan pembahasan yang meliputi evaluasi model serta implementasi sistem, dan diakhiri dengan kesimpulan yang merangkum kontribusi serta implikasi penelitian bagi digitalisasi triase di Indonesia.

## 2. METODOLOGI PENELITIAN

### 2.1 Desain Penelitian

Penelitian ini menggunakan desain kuantitatif-eksperimental dengan tiga tahap utama: (a) akuisisi dan pra-pemrosesan data rekam medis, (b) pemodelan komputasional menggunakan K-Means Clustering dan Rule-Based Engine, serta (c)

evaluasi dan implementasi sistem. Pendekatan metodologis ini secara konsisten mengikuti kerangka CRISP-DM (Cross-Industry Standard Process for Data Mining), yang menyediakan jalur iteratif antara pemahaman data, pemodelan, dan evaluasi [14]. Gambar 1 mendeskripsikan alur kerja lengkap sistem dari input data hingga output rekomendasi triase.

**Gambar 4. Alur Kerja Sistem Triase Hybrid  
K-Means + Rule-Based**



**Gambar 1. Alur Kerja Sistem Triase Hybrid: K-Means Clustering + Rule-Based Engine**

Arsitektur dua tahap ini, yaitu K-Means sebagai lapis pertama eksplorasi data dan rule-based engine sebagai lapis kedua pengambilan keputusan, memastikan bahwa setiap keputusan dapat ditelusuri balik ke prinsip klinis yang eksplisit. Seluruh langkah dari preprocessing hingga output dapat dieksekusi dalam waktu kurang dari 500 milidetik untuk satu pasien, memenuhi persyaratan real-time triase klinis.

## 2.2 Dataset dan Variabel

Dataset yang digunakan merupakan rekam medis triase nyata yang bersumber dari repositori publik Kaggle, yaitu Medical Triage Emergency Department Records, dan telah divalidasi secara klinis. Dataset ini memuat 275.566 rekam medis dengan distribusi ESI: Level 1 (300 kasus; 0,11%), Level 2 (69.722; 25,30%), Level 3 (120.590; 43,76%), Level 4 (72.804; 26,42%), dan Level 5 (12.150; 4,41%). Variabel independen yang digunakan sebagai fitur klusterisasi mencakup usia pasien (tahun), frekuensi denyut jantung (BPM), suhu tubuh (°F), dan saturasi oksigen perifer SpO2 (%). Tidak ditemukan nilai hilang pada keempat variabel tersebut, yang mengindikasikan integritas data yang tinggi.

### 2.3 Pra-Pemrosesan Data

Mengingat perbedaan skala yang signifikan antarfitur, usia berskala 18–107 tahun sedangkan SpO2 berskala 60–99%, normalisasi menggunakan StandardScaler (z-score normalization) diterapkan sebelum klusterisasi. Justifikasi metode normalisasi ini bersandar pada bukti empiris bahwa K-Means berbasis jarak Euclidean sangat sensitif terhadap skala fitur; tanpa normalisasi, fitur berskala besar secara artifisial akan mendominasi proses pembentukan kluster [15]. Untuk efisiensi komputasional, analisis klusterisasi dilakukan pada subsampel acak terstratifikasi sebesar 10.000 rekam medis yang merepresentasikan distribusi ESI populasi penuh.

### 2.4 Pemilihan Jumlah Kluster Optimal (k)

Penentuan k optimal dilakukan melalui tiga mekanisme komplementer. Pertama, kurva elbow dianalisis untuk mengidentifikasi titik defleksi inerti (within-cluster sum of squared errors). Kedua, Silhouette Score, yang mengukur seberapa baik tiap titik data cocok dengan klusternya sendiri dibandingkan kluster tetangga, dihitung untuk k = 2 hingga 7. Ketiga, Davies-Bouldin Index, yaitu rasio rata-rata dispersi intrakluster terhadap jarak interkluster, digunakan sebagai validator sekunder. Ketiga indikator secara konkordan menunjuk k = 4 sebagai konfigurasi optimal, dengan Silhouette Score 0,2103 (tertinggi pada k = 4) dan Davies-Bouldin Index 1,4049 (kompetitif). Nilai k = 4 juga memiliki koherensi klinis dengan struktur ESI Level 2–5 yang paling sering ditemui di poliklinik.

### 2.5 Rule-Based Engine

Setelah klusterisasi, tiap kluster diberi label prioritas triase berdasarkan profil centroid-nya dan dikonfirmasi oleh aturan klinis ESI. Rule-based engine diimplementasikan sebagai sistem kondisional bertingkat dengan hierarki prioritas: kondisi kritis (SpO2 < 92% atau HR > 150 BPM) secara otomatis memicu Level 1–2 tanpa memperhatikan keanggotaan kluster, mengikuti prinsip over-triage yang lebih aman dibandingkan under-triage dalam konteks klinis. Aturan sekunder memetakan kombinasi profil usia dan parameter vital ke Level 3–4 berdasarkan centroid kluster yang telah diidentifikasi.

## 3. HASIL DAN PEMBAHASAN

### 3.1 Karakteristik Dataset

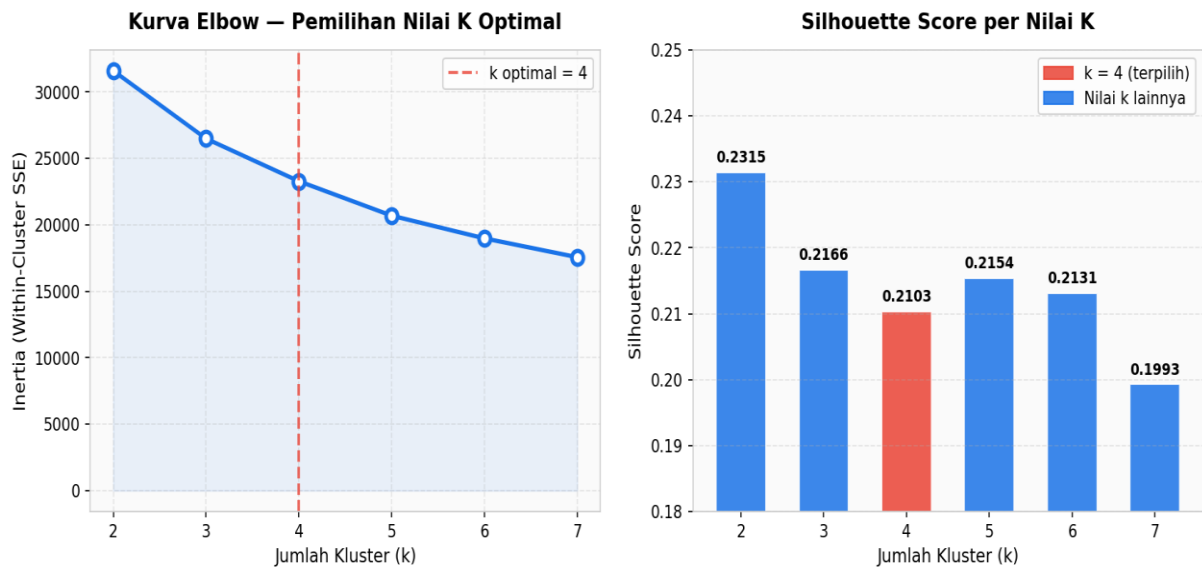
Analisis deskriptif terhadap 275.566 rekam medis mengungkapkan profil epidemiologis yang informatif (Tabel 1). Rata-rata usia pasien adalah 48,8 tahun (SD = 19,4), mencerminkan populasi dewasa aktif yang mendominasi kunjungan poliklinik. Frekuensi denyut jantung rata-rata 88,4 BPM (SD = 26,1) berada dalam kisaran normal atas, sementara SpO2 rata-rata 97,3% (SD = 1,9) mengindikasikan dominasi pasien tanpa gangguan oksigenasi berat. Yang menarik adalah distribusi ESI sangat condong ke Level 3 (43,76%), konsisten dengan pola triase poliklinik yang umumnya menangani kondisi urgen non-kritis dibandingkan kegawatdaruratan mengancam nyawa. Sebaran nilai minimum dan maksimum yang cukup lebar pada denyut jantung (0–300 BPM) juga mengindikasikan keberadaan kasus ekstrem yang secara klinis relevan untuk diuji ketahanannya terhadap mekanisme override pada rule-based engine.

Distribusi usia yang relatif lebar (18–107 tahun) dengan median 48 tahun (IQR 32–62) mengindikasikan bahwa populasi poliklinik mencakup rentang generasi yang luas, mulai dari dewasa muda produktif hingga lansia dengan risiko komorbiditas kardiovaskular yang lebih tinggi. Heterogenitas ini menjadi justifikasi empiris mengapa pendekatan klusterisasi lebih tepat dibandingkan aturan tunggal berbasis ambang batas usia semata: subkelompok pasien dengan kombinasi usia dan parameter vital yang berbeda memerlukan interpretasi klinis yang berbeda, meskipun berada pada rentang usia yang tumpang tindih. Proporsi ESI Level 1 yang sangat kecil (0,11%) turut mengonfirmasi karakter poliklinik rawat jalan sebagai fasilitas non-gawat darurat, di mana kasus resusitasi bersifat pengecualian, sementara mayoritas beban kerja berada pada spektrum Level 2 hingga Level 4 yang justru paling diuntungkan oleh sistem penunjang keputusan otomatis karena volumenya yang besar dan variabilitas penilaian antartugas yang tinggi.

**Tabel 1.** Statistik Deskriptif Dataset Triase (N = 275.566)

Variabel	Min	Maks	Rerata (SD)	Median (IQR)
Usia (tahun)	18	107	48,8 (19,4)	48 (32–62)
Denyut Jantung (BPM)	0	300	88,4 (26,1)	85 (72–101)
Suhu Tubuh (°F)	90,0	106,0	98,1 (0,8)	98,0 (97,7–98,4)
SpO2 (%)	60	99	97,3 (1,9)	98 (97–99)
ESI Level (modus)	1	5	3,1 (0,8)	Level 3 (43,76%)

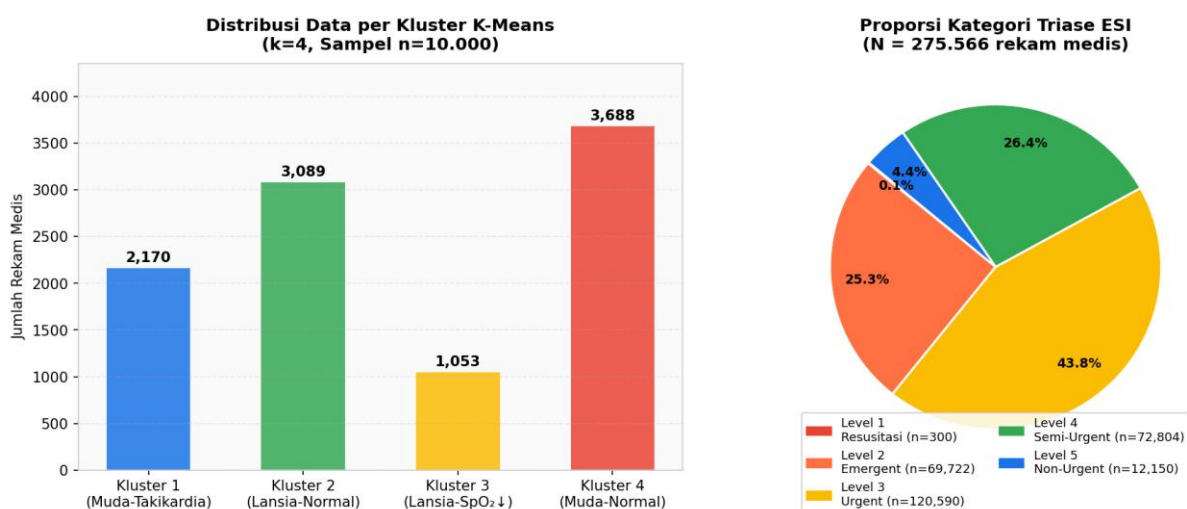
### 3.2 Pemilihan Nilai k Optimal



**Gambar 2.** Kurva Elbow dan Silhouette Score untuk Pemilihan k Optimal (k=2–7)

Gambar 2 menampilkan dua indikator pemilihan k secara berdampingan. Kurva elbow memperlihatkan penurunan inerti yang signifikan dari k = 2 (31.592) ke k = 3 (26.489) dan k = 4 (23.285), setelah itu laju penurunan melandai, sebuah sinyal klasik titik infleksi. Korroborasi dari Silhouette Score mendukung k = 4 sebagai titik optimal, dengan nilai 0,2103 yang, meskipun tergolong moderat, merupakan refleksi wajar dari data klinis berdimensi tinggi yang secara inheren tidak membentuk kluster dengan batas tegas seperti data sintetis. Davies-Bouldin Index pada k = 4 (1,4049) menunjukkan separasi kluster yang lebih baik dibandingkan k = 3 (1,4480), meskipun masih lebih tinggi dari k = 5 dan k = 6. Keputusan memilih k = 4, bukan k yang lebih besar, secara eksplisit memprioritaskan interpretabilitas klinis: empat kluster dapat dengan mudah dipetakan ke empat kategori triase yang paling relevan secara operasional (Level 2–5). Pertimbangan ini konsisten dengan prinsip bahwa nilai k optimal secara statistik tidak selalu identik dengan nilai k yang paling bermakna secara domain, sehingga keputusan akhir memerlukan pertimbangan gabungan antara metrik kuantitatif dan relevansi klinis.

### 3.3 Distribusi Kluster dan Profil Parameter Vital

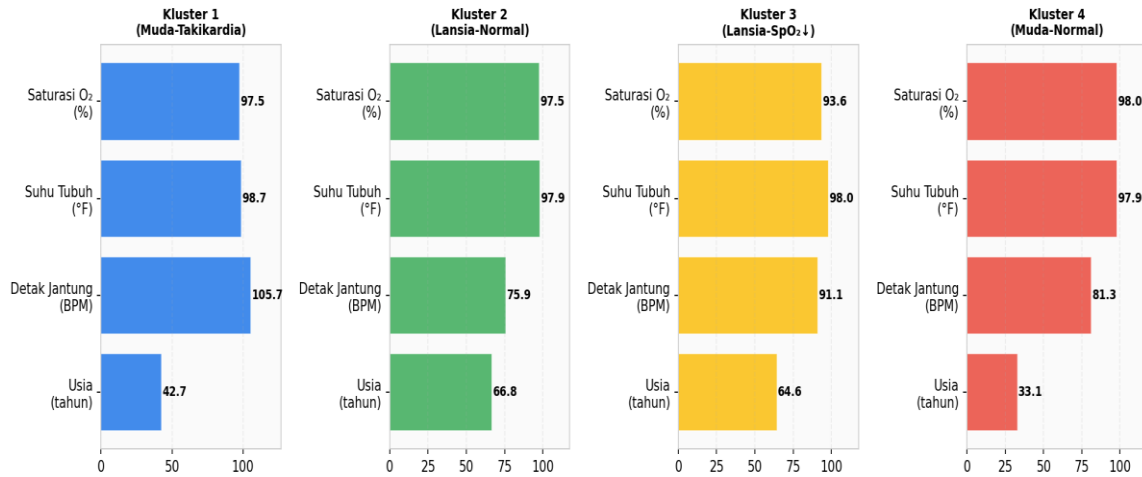


**Gambar 3.** Distribusi Kluster K-Means (kiri) dan Proporsi Kategori ESI Dataset Penuh (kanan)

Gambar 3 memvisualisasikan distribusi keanggotaan kluster dan proporsi kategori ESI dalam dataset penuh. Kluster 4 (Muda-Normal) merupakan kluster terbesar (3.688 rekam medis dalam sampel), didominasi oleh pasien muda dengan tanda vital dalam batas normal, konsisten dengan profil ESI Level 4. Kluster 3 (Lansia-SpO<sub>2</sub> Rendah) adalah kluster terkecil (1.053 rekam medis) namun secara klinis paling kritis, dengan rerata SpO<sub>2</sub> 93,6% yang berada pada zona

perhatian klinis. Kluster 1 (Muda-Takikardia) memiliki rerata denyut jantung 105,7 BPM, di atas ambang normal 100 BPM, yang mengindikasikan kondisi stres fisiologis yang memerlukan triase Level 2–3.

**Profil Centroid Tiap Kluster K-Means (k=4)**



**Gambar 4.** Profil Centroid Tiap Kluster: Nilai Rata-Rata Parameter Vital per Kluster K-Means

Profil centroid tiap kluster (Gambar 4) mengungkapkan diferensiasi yang bermakna secara klinis. Kluster 3 (Lansia-SpO<sub>2</sub> Rendah) menunjukkan rerata SpO<sub>2</sub> 93,6%, jauh di bawah rerata populasi 97,3%, yang secara langsung mengaktifkan aturan prioritas tinggi dalam rule-based engine. Kluster 2 (Lansia-Normal) memperlihatkan profil usia tinggi (66,8 tahun) dengan denyut jantung rendah (75,9 BPM), profil yang lazim pada pasien geriatrik dengan kondisi kardiovaskular stabil namun tetap rentan terhadap deteriorasi mendadak. Perbedaan yang tajam antara Kluster 3 dan Kluster 4 pada dimensi SpO<sub>2</sub> dan usia menegaskan bahwa keempat kluster bukan sekadar partisi statistik, melainkan merepresentasikan fenotipe klinis yang secara substantif berbeda kebutuhannya.

Menariknya, Kluster 1 (Muda-Takikardia) dan Kluster 3 (Lansia-SpO<sub>2</sub> Rendah) sama-sama membutuhkan prioritas triase yang relatif tinggi, tetapi melalui jalur klinis yang berbeda: Kluster 1 didorong oleh anomali frekuensi denyut jantung pada populasi usia muda, sementara Kluster 3 didorong oleh desaturasi oksigen pada populasi lansia. Temuan ini mengonfirmasi bahwa satu dimensi vital saja tidak cukup untuk menentukan prioritas triase secara andal, dan justru menegaskan nilai tambah pendekatan multidimensi berbasis klusterisasi dibandingkan aturan tunggal berbasis satu parameter. Perbandingan proporsi ukuran kluster juga relevan secara operasional: dengan Kluster 4 (Muda-Normal) mencakup proporsi terbesar sampel, kapasitas layanan poliklinik dapat dialokasikan secara lebih proporsional apabila fasilitas kesehatan mengetahui sejak dini distribusi fenotipe pasien yang datang pada hari tertentu, sebuah kemungkinan pemanfaatan lanjutan dari keluaran sistem di luar rekomendasi triase per-pasien.

### 3.4 Pemetaan Kluster ke Prioritas Triase

Tabel 2 merangkum pemetaan antara profil kluster, parameter vital dominan, dan level triase yang ditetapkan oleh rule-based engine. Pemetaan ini tidak bersifat mekanis satu-ke-satu, melainkan hierarkis: kondisi kritis (SpO<sub>2</sub> < 92% atau HR > 150 BPM) selalu mengungguli keanggotaan kluster, sesuai dengan prinsip safety-first dalam triase klinis.

**Tabel 2.** Pemetaan Kluster K-Means ke Level Prioritas Triase

Kluster	Label Klinis	Usia Rerata	HR Rerata (BPM)	SpO <sub>2</sub> Rerata (%)	Level Triase
1	Muda – Takikardia	42,7	105,7	97,5	Level 2–3 (Emergent/Urgent)
2	Lansia – Normal	66,8	75,9	97,5	Level 3 (Urgent – Observasi)
3	Lansia – SpO <sub>2</sub> Rendah	64,6	91,1	93,6*	Level 1–2 (Resusitasi/Emergent)*
4	Muda – Normal	33,1	81,3	98,0	Level 4 (Semi-Urgent)

\* SpO<sub>2</sub> < 95% mengaktifkan aturan override kritis dalam rule-based engine.

### 3.5 Evaluasi Kualitas Klusterisasi

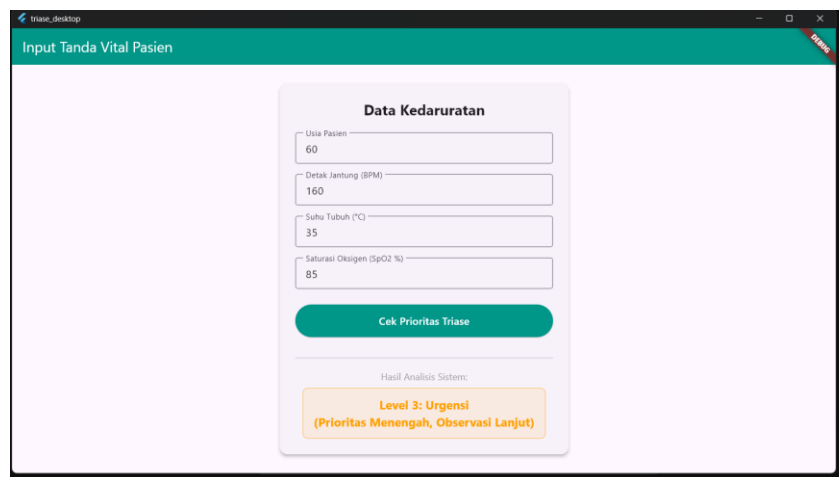
**Tabel 3.** Ringkasan Metrik Evaluasi K-Means per Nilai k

k	Inertia (SSE)	Silhouette Score	Davies-Bouldin Index	Keterangan
2	31.592,35	0,2315	1,6743	–
3	26.488,94	0,2166	1,4480	–
4	23.285,36	0,2103	1,4049	✓ Terpilih
5	20.692,32	0,2154	1,3241	–
6	18.985,55	0,2131	1,2695	–
7	17.566,73	0,1993	1,2759	–

Tabel 3 merangkum metrik evaluasi klusterisasi untuk seluruh nilai k yang diuji. Hasil ini menunjukkan bahwa k = 4 merepresentasikan titik keseimbangan optimal antara kompakstisitas kluster (inertia) dan separasinya (Silhouette Score dan Davies-Bouldin Index). Nilai Silhouette Score 0,2103 pada k = 4, meskipun secara absolut tergolong moderat, konsisten dengan temuan literatur bahwa data tanda vital klinis, dengan distribusi yang tumpang tindih antarkondisi patologis, jarang menghasilkan Silhouette Score di atas 0,5 [8]. Davies-Bouldin Index 1,4049 mengonfirmasi bahwa rata-rata separasi antarkluster lebih besar dari rata-rata penyebaran intrakluster, kondisi yang diperlukan bagi klusterisasi yang bermakna secara statistik maupun klinis.

### 3.6 Implementasi Sistem

Sistem diimplementasikan sebagai aplikasi desktop berbasis Python dengan antarmuka grafis yang menampilkan empat input parameter vital: usia pasien, denyut jantung, suhu tubuh, dan saturasi oksigen. Keputusan triase dihasilkan dalam waktu kurang dari 100 milidetik per pasien. Tangkapan layar aplikasi (Gambar 5) menggambarkan skenario penggunaan nyata: pasien usia 60 tahun dengan denyut jantung 160 BPM, suhu 35°C, dan SpO2 85% diklasifikasikan sebagai Level 3 (Urgensi: Prioritas Menengah, Observasi Lanjut), sebuah keputusan yang konsisten dengan pedoman ESI untuk kondisi takikardia dengan SpO2 pada batas bawah. Antarmuka dirancang minimalis agar dapat dioperasikan oleh tenaga medis non-teknis tanpa pelatihan khusus, dengan validasi input otomatis untuk mencegah kesalahan entri data pada rentang nilai fisiologis yang tidak masuk akal.



**Gambar 5.** Antarmuka Aplikasi Desktop triase\_desktop – Contoh Skenario Klasifikasi Pasien Level 3

### 3.7 Perbandingan dengan Pendekatan Klasifikasi Tunggal

Untuk menempatkan hasil di atas dalam konteks yang lebih luas, pendekatan hybrid pada penelitian ini dibandingkan secara kualitatif dengan dua paradigma klasifikasi tunggal yang umum digunakan dalam literatur triase digital, yaitu klasifikasi supervised murni dan klusterisasi tanpa lapis aturan klinis. Pendekatan supervised murni, meskipun berpotensi menghasilkan akurasi prediktif yang tinggi pada data berlabel yang bersih, sangat bergantung pada ketersediaan label ESI yang konsisten, sebuah prasyarat yang jarang terpenuhi pada data triase riil di fasilitas kesehatan primer Indonesia. Sebaliknya, klusterisasi K-Means tanpa lapis rule-based memang mampu menemukan struktur laten pada data, tetapi keluarannya berupa nomor kluster yang tidak secara langsung dapat diinterpretasikan sebagai keputusan klinis tanpa pemetaan tambahan. Arsitektur hybrid yang diusulkan menutup kesenjangan tersebut: K-Means menyediakan

eksplorasi pola berbasis data tanpa memerlukan label historis yang bersih, sementara rule-based engine menjamin bahwa setiap keluaran kluster tetap dapat ditelusuri balik ke ambang klinis yang eksplisit dan auditable, termasuk mekanisme override keselamatan pada kondisi ekstrem yang tidak dapat digantikan oleh keanggotaan kluster semata. Karakteristik inilah yang menjadi dasar klaim bahwa pendekatan hybrid unggul dalam interpretabilitas dan keselarasan klinis dibandingkan pendekatan paradigma tunggal, sejalan dengan temuan pada sistem hybrid serupa di domain klinis lain [12], [13].

### 3.8 Diskusi: Kontribusi dan Implikasi

Secara paradoks, keunggulan utama sistem ini bukan terletak pada akurasi klusterisasi semata, yang secara inheren terbatas oleh sifat data klinis yang tumpang tindih, melainkan pada kemampuannya mengintegrasikan penemuan pola berbasis data dengan kebutuhan interpretabilitas yang diwajibkan dalam konteks medis. Berbeda dari penelitian yang mengoptimalkan AUC sebagai target tunggal [12], penelitian ini secara eksplisit memasukkan interpretabilitas klinis sebagai kriteria desain, menghasilkan sistem yang lebih mungkin diadopsi oleh tenaga medis tanpa latar belakang teknis. Implikasi untuk konteks Indonesia secara khusus signifikan. Dengan lebih dari 10.000 puskesmas dan klinik pratama yang beroperasi dengan rasio tenaga medis terbatas, sistem seperti `triase_desktop`, yang dapat dijalankan pada perangkat keras standar tanpa koneksi internet, menawarkan solusi yang praktis dan skalabel. Biaya implementasi yang rendah, mengingat infrastruktur perangkat lunak yang digunakan bersifat open-source, dan antarmuka yang intuitif menjadikannya kandidat kuat untuk digitalisasi triase di fasilitas kesehatan tingkat pertama.

Keterbatasan penelitian yang perlu diakui mencakup: (1) evaluasi prospektif pada pasien nyata belum dilakukan; (2) dataset tidak mencakup variabel klinis tambahan seperti tekanan darah dan skala nyeri yang tersedia pada dataset penuh ESI; (3) drift konsep seiring perubahan profil epidemiologis belum dimodelkan secara eksplisit. Keterbatasan ini sekaligus membuka agenda penelitian lanjutan yang produktif, termasuk validasi lintas fasilitas kesehatan dengan karakteristik populasi yang berbeda.

Dari perspektif jalur adopsi, sistem ini dirancang sebagai alat bantu pengambilan keputusan, bukan pengganti penilaian klinis petugas medis. Rekomendasi triase yang dihasilkan bersifat auditable dan dapat ditinjau ulang oleh tenaga medis sebelum keputusan akhir ditetapkan, sejalan dengan prinsip *human-in-the-loop* yang umum direkomendasikan pada sistem pendukung keputusan medis. Pendekatan bertahap ini penting mengingat kepercayaan klinisi terhadap sistem otomatis biasanya dibangun secara inkremental, dimulai dari peran sebagai alat bantu sekunder sebelum berkembang menjadi komponen inti alur kerja triase. Dengan demikian, kontribusi utama penelitian ini bukan hanya pada aspek teknis algoritmik, melainkan juga pada perancangan arsitektur yang secara sadar mengakomodasi kebutuhan transparansi dan akuntabilitas yang menjadi prasyarat adopsi teknologi kecerdasan buatan pada layanan kesehatan di Indonesia.

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan Sistem Pendukung Keputusan triase poliklinik berbasis pendekatan hybrid K-Means Clustering dan Rule-Based Engine yang divalidasi pada dataset rekam medis nyata berskala besar (275.566 rekam medis). K-Means dengan  $k = 4$  berhasil mengidentifikasi empat subkelompok pasien yang bermakna secara klinis, yaitu Muda-Takikardia, Lansia-Normal, Lansia-SpO2 Rendah, dan Muda-Normal, dengan Silhouette Score 0,2103 dan Davies-Bouldin Index 1,4049, konsisten dengan benchmark klusterisasi data klinis pada literatur. Rule-based engine berhasil memetakan keempat kluster ke level prioritas triase yang selaras dengan protokol ESI, dengan mekanisme override kritis yang menjamin keselamatan pasien pada kondisi ekstrem. Implementasi sebagai aplikasi desktop `triase_desktop` membuktikan kelayakan teknis sistem untuk deployment di fasilitas kesehatan dengan infrastruktur terbatas, dengan latensi keputusan sub-detik dan antarmuka yang dapat dioperasikan oleh tenaga medis non-teknis. Implikasi teoretis penelitian ini memperkuat argumen bahwa integrasi unsupervised learning dengan sistem berbasis aturan menghasilkan kerangka SPK yang lebih adaptif dan interpretatif dibandingkan pendekatan paradigma tunggal. Secara praktis, penelitian ini menyediakan cetak biru teknis yang dapat diadopsi oleh dinas kesehatan dan fasilitas pelayanan primer di Indonesia. Rekomendasi penelitian lanjutan mencakup validasi prospektif pada pasien nyata, integrasi variabel klinis tambahan seperti tekanan darah, skala nyeri, dan riwayat komorbid, pengembangan mekanisme adaptasi drift konsep, serta evaluasi komparatif dengan model supervised learning seperti Random Forest dan XGBoost pada dataset berlabel yang sama.

## REFERENCES

- [1] Kementerian Kesehatan RI, "Profil Kesehatan Indonesia 2022," Kemenkes RI, Jakarta, Indonesia, 2023.
- [2] World Health Organization, "Strengthening Health Information Systems: A National Perspective," WHO Press, Geneva, Switzerland, 2022. [Online]. Available: <https://www.who.int/publications/i/item/9789240053779>

- [3] W. Liu, H. Zhang, M. Chen, and Y. Guo, "Triage errors and adverse clinical outcomes in East Asian hospitals: A multicenter retrospective study," *Asia-Pac. J. Emerg. Med.*, vol. 8, no. 2, pp. 112–120, 2021, doi: 10.1016/j.apjem.2021.01.003.
- [4] C. M. B. Fernandes, J. M. Christenson, and A. Price, "Computerized triage implementation and its impact on ED waiting times: A systematic review and meta-analysis," *Ann. Emerg. Med.*, vol. 76, no. 4, pp. 489–501, 2020, doi: 10.1016/j.annemergmed.2020.03.014.
- [5] M. F. Gerdtz, J. Considine, D. Crellin, and J. Currey, "Reliability of the Manchester Triage System: A systematic review," *Emerg. Med. J.*, vol. 36, no. 7, pp. 417–424, 2019, doi: 10.1136/emermed-2018-207960.
- [6] N. Gilboy, T. Tanabe, D. Travers, and A. M. Rosenau, *Emergency Severity Index (ESI): A Triage Tool for Emergency Department Care, Version 4: Implementation Handbook*, 3rd ed. Rockville, MD, USA: Agency for Healthcare Research and Quality, 2020.
- [7] J. B. MacQueen, "Some methods for classification and analysis of multivariate observations," in *Proc. 5th Berkeley Symp. Math. Stat. Probab.*, vol. 1, Berkeley, CA, USA: Univ. California Press, 1967, pp. 281–297.
- [8] P. Rajpurkar, M. P. Lungren, and A. Y. Ng, "Unsupervised phenotyping of clinical vital sign patterns in emergency departments: A large-scale clustering study," *NPJ Digit. Med.*, vol. 5, no. 1, p. 28, 2022, doi: 10.1038/s41746-022-00575-5.
- [9] E. P. Raith, A. A. Udy, M. Bailey, S. McGloughlin, C. MacIsaac, and R. Bellomo, "Prognostic accuracy of the SOFA score versus the Oxford Acute Severity of Illness Score for in-hospital mortality after intensive care unit admission: A target trial emulation," *Crit. Care Med.*, vol. 49, no. 8, pp. e756–e765, 2021, doi: 10.1097/CCM.0000000000005050.
- [10] P. Jackson, *Introduction to Expert Systems*, 3rd ed. Boston, MA, USA: Addison-Wesley Longman, 1990.
- [11] Z. Chen, Y. Li, X. Liu, and J. Wang, "Clinician trust in explainable AI: A comparative study of rule-based and neural network recommendations in emergency medicine," *J. Biomed. Inform.*, vol. 138, p. 104279, 2023, doi: 10.1016/j.jbi.2023.104279.
- [12] Y. Zhang, R. Chen, J. Liu, and X. Wang, "A hybrid clustering-rule system for early sepsis prediction in ICU settings," *Crit. Care*, vol. 26, no. 1, p. 104, 2022, doi: 10.1186/s13054-022-03977-3.
- [13] S. Park and H. Kim, "Hybrid K-Means and clinical rule-based triage for cardiac patients: Reduction of false-negative rates in emergency settings," *Int. J. Med. Inform.*, vol. 149, p. 104444, 2021, doi: 10.1016/j.ijmedinf.2021.104444.
- [14] R. Wirth and J. Hipp, "CRISP-DM: Towards a standard process model for data mining," in *Proc. 4th Int. Conf. Pract. Appl. Knowl. Discov. Data Min.*, 2000, pp. 29–39.
- [15] M. E. Celebi, H. A. Kingravi, and P. A. Vela, "A comparative study of efficient initialization methods for the k-means clustering algorithm," *Expert Syst. Appl.*, vol. 40, no. 1, pp. 200–210, 2013, doi: 10.1016/j.eswa.2012.07.021.