

Klasifikasi Status Rujukan Pasien Poliklinik Bandara Berbasis Random Forest dan Interpretabilitas Model Menggunakan SHAP

Mirechelin Kristanaya^{1)*}, Melinda Putri Azzahra²⁾, Trimono³⁾, Mohammad Idhom⁴⁾

^{1,2,3,4)} Fakultas Ilmu Komputer, UPN "Veteran" Jawa Timur,

Received: 12 June 2025

Accepted: 23 June 2025

Published: 1 July 2025



*trimono.stat@upnjatim.ac.id

Kata Kunci: Klasifikasi Rujukan Pasien, Random Forest, SHAP (*SHapley Additive exPlanations*), *Explainable ai* (XAI), Poliklinik Bandara

DSI: Jurnal Data Science Indonesia is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).

Abstrak :

Transformasi digital di sektor kesehatan Indonesia masih menghadapi ketimpangan implementasi, di mana fasilitas kesehatan primer seperti poliklinik bandara tertinggal dalam adopsi *Artificial Intelligence* (AI), sementara sistem rujukan manual yang berlaku rentan terhadap kesalahan subjektif dan ketidakefisienan terutama dalam lingkungan dinamis bandara dengan pasien berisiko tinggi dan waktu respons kritis. Penelitian ini mengembangkan solusi berbasis Random Forest yang diintegrasikan dengan *SHapley Additive exPlanations* (SHAP) untuk mengklasifikasi status rujukan pasien ke dalam dua kelas target: "Dirujuk" (memerlukan penanganan lanjutan) dan "Tidak Dirujuk" (dapat ditangani di tempat), secara akurat dan terinterpretasi. Metode ini dipilih karena kemampuannya menangani data multivariat dan tidak seimbang, serta menyediakan penjelasan transparan melalui nilai SHAP. Analisis dilakukan pada 374 rekam medis poliklinik Bandara Juanda dengan fitur utama seperti usia, tanda vital, dan status pasien. Hasil menunjukkan akurasi 94,59% dan AUC 0,91, dengan *recall* sempurna (100%) untuk kelas dirujuk, meski *precision*-nya masih rendah (43%) akibat ketidakseimbangan data (hanya 15 kasus dirujuk vs 359 tidak dirujuk). Interpretasi SHAP mengungkap usia sebagai faktor dominan dalam pembedaan kedua kelas, diikuti nadi dan status pasien. Inovasi penelitian terletak pada kombinasi Random Forest-SHAP untuk konteks bandara yang belum banyak dieksplorasi, serta desain antarmuka yang sesuai alur kerja klinis. Temuan ini mendukung percepatan *AI-assisted triage* di fasilitas primer, dengan rekomendasi penggunaan resampling atau threshold adjustment untuk optimasi lebih lanjut. Implementasi sistem ini berpotensi mengurangi waktu rujukan hingga 40% dan menjadi model replikasi untuk layanan kesehatan berorientasi mobilitas tinggi.

PENDAHULUAN

Transformasi digital dalam sektor kesehatan telah menjadi pilar utama dalam upaya peningkatan kualitas layanan medis, efisiensi operasional, serta aksesibilitas pelayanan kepada masyarakat luas. Di Indonesia, digitalisasi sektor kesehatan menjadi prioritas nasional seiring dengan pesatnya perkembangan teknologi informasi dan komunikasi. Salah satu inovasi yang mendapat perhatian besar adalah pemanfaatan teknologi *Artificial Intelligence* (AI) dan *Machine Learning* (ML) dalam mendukung sistem pengambilan keputusan klinis, manajemen rumah sakit, serta klasifikasi penyakit berbasis data [1]. Berbagai studi menunjukkan bahwa teknologi ini dapat meningkatkan akurasi diagnosis, efisiensi waktu penanganan, serta deteksi dini penyakit kritis [2].

Namun, dalam konteks Indonesia, implementasi teknologi cerdas ini masih menghadapi berbagai tantangan. Mayoritas penerapan sistem AI dan ML terpusat pada fasilitas kesehatan tersier seperti rumah

sakit rujukan nasional, sementara fasilitas kesehatan primer seperti puskesmas dan poliklinik—yang berperan sebagai garda terdepan pelayanan medis—masih tertinggal dalam hal infrastruktur, kompetensi sumber daya manusia (SDM), dan pendanaan [3]. Ketimpangan ini memperlebar kesenjangan layanan dan menghambat transformasi digital yang menyeluruh dan merata di seluruh ekosistem kesehatan.

Salah satu tantangan utama yang dihadapi oleh fasilitas layanan primer adalah sistem rujukan pasien yang belum optimal. Sistem ini menjadi krusial karena menentukan kecepatan dan ketepatan penanganan lanjutan bagi pasien. Keterlambatan atau ketidaktepatan dalam proses rujukan dapat berakibat fatal, terutama dalam situasi darurat atau kondisi penyakit kronis yang memerlukan penanganan cepat dan spesifik [4]. Di lingkungan khusus seperti poliklinik bandara, tantangan ini semakin kompleks. Poliklinik bandara tidak hanya melayani masyarakat umum, tetapi juga melayani penumpang pesawat dan personil penerbangan yang memiliki mobilitas tinggi, keterbatasan waktu, serta tuntutan terhadap kecepatan pelayanan medis yang presisi dan efisien.

Namun demikian, sebagian besar sistem rujukan yang digunakan di poliklinik masih berbasis pendekatan manual atau rule-based, yakni menggunakan aturan-aturan tetap yang dibuat berdasarkan pengalaman atau protokol konvensional. Pendekatan ini memiliki kelemahan signifikan: tidak adaptif terhadap pola baru dalam data, tidak fleksibel terhadap kondisi yang dinamis, dan sangat tergantung pada subjektivitas pengambil keputusan [5]. Selain itu, sistem rule-based cenderung kurang efektif dalam menangani data medis yang bersifat multivariat, tidak terstruktur, serta sering mengandung noise atau missing values.

Sebagai solusi atas keterbatasan tersebut, algoritma berbasis pembelajaran mesin seperti Random Forest mulai dilirik karena keunggulannya dalam menangani data kompleks, berukuran besar, serta interaksi antarfitur yang nonlinear. Random Forest, sebagai algoritma ensemble learning, memiliki mekanisme voting dari banyak pohon keputusan (decision tree), sehingga menghasilkan prediksi yang lebih stabil dan akurat [6]. Algoritma ini juga relatif tahan terhadap overfitting dan dapat bekerja baik meskipun terdapat fitur-fitur yang saling berkorelasi. Dalam berbagai studi, Random Forest telah digunakan untuk klasifikasi penyakit kronis, prediksi kegagalan organ, hingga pengklasifikasian prioritas pelayanan kesehatan [7].

Meskipun demikian, tantangan dalam mengadopsi model machine learning dalam praktik medis tidak hanya terletak pada akurasi model, tetapi juga pada interpretabilitasnya. Banyak algoritma AI, termasuk Random Forest, digolongkan sebagai model “black box” karena sulit dijelaskan cara kerjanya secara intuitif kepada pengguna non-teknis, seperti dokter umum atau perawat. Padahal, kepercayaan dan penerimaan pengguna akhir menjadi faktor penting dalam keberhasilan adopsi teknologi AI di lingkungan klinis. Penelitian menunjukkan bahwa sekitar 65% tenaga medis di Indonesia masih ragu untuk mengandalkan sistem prediktif berbasis AI karena minimnya transparansi dan penjelasan terhadap hasil prediksi [8].

Untuk menjawab tantangan ini, pendekatan Explainable AI (XAI) hadir sebagai solusi yang mampu menjembatani kesenjangan antara kecanggihan teknis model dan pemahaman pengguna. Salah satu metode XAI yang paling populer dan banyak digunakan adalah SHapley Additive exPlanations (SHAP), yang dikembangkan berdasarkan teori permainan kooperatif. SHAP memberikan interpretasi kontribusi masing-masing fitur terhadap hasil prediksi secara kuantitatif dan visual, sehingga memungkinkan tenaga medis memahami logika di balik keputusan model [9]. Penggunaan SHAP terbukti meningkatkan kepercayaan pengguna dan menjadi alat edukatif dalam menjelaskan prediksi kepada pasien atau sesama profesional medis.

Namun demikian, penerapan kombinasi antara algoritma Random Forest dan interpretasi SHAP dalam sistem klasifikasi rujukan pasien, khususnya di poliklinik bandara, masih sangat terbatas. Sebagian besar penelitian yang ada masih berfokus pada penyakit spesifik seperti diabetes atau gagal jantung, dan belum banyak yang mengkaji konteks implementasi klinis secara langsung dalam sistem rujukan di layanan kesehatan primer dengan mobilitas tinggi seperti bandara. Padahal, kebutuhan terhadap sistem yang adaptif, cepat, dan transparan di lingkungan tersebut sangat tinggi. Oleh karena itu, dibutuhkan penelitian yang tidak hanya membangun model klasifikasi yang akurat, tetapi juga mengutamakan interpretasi hasil yang dapat dipahami dan digunakan secara langsung oleh tenaga medis.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan sistem


klasifikasi status rujukan pasien pada poliklinik bandara berbasis algoritma Random Forest yang dikombinasikan dengan metode interpretasi SHAP. Sistem ini dirancang untuk meningkatkan efektivitas dan efisiensi pengambilan keputusan medis serta menyediakan penjelasan terhadap setiap hasil klasifikasi yang dihasilkan. Dengan demikian, diharapkan sistem ini mampu menjawab tantangan praktis dalam pelayanan kesehatan primer dan menjadi model penerapan AI yang dapat diadopsi secara luas di fasilitas kesehatan serupa di Indonesia.

TINJAUAN LITERATUR

Penerapan metode klasifikasi dalam bidang kesehatan berperan penting dalam mendukung keputusan klinis yang cepat dan akurat. Di antara berbagai algoritma, Random Forest sering digunakan karena mampu menangani data kompleks dan menghasilkan prediksi stabil. Namun, selain akurasi, interpretabilitas model juga dibutuhkan agar hasil dapat dipahami oleh tenaga medis. Sejumlah penelitian telah mengkaji performa Random Forest, termasuk pengaruh pra-pemrosesan dan integrasi *Explainable ai* (XAI). Suryanegara et al. [10] menunjukkan bahwa normalisasi fitur, khususnya min-max, mampu meningkatkan akurasi klasifikasi pasien diabetes hingga 95,45%. [11] membandingkan Random Forest dan XGBoost dalam klasifikasi penyakit diabetes, serta mengintegrasikan SHAP dan LIME untuk menjelaskan kontribusi fitur. Meski XGBoost lebih akurat, interpretasi model menjadi kunci untuk meningkatkan kepercayaan pengguna. Pratiwi et al. juga menekankan pentingnya penanganan ketidakseimbangan data [12], dengan menunjukkan bahwa kombinasi Random Forest dan SMOTE-ENN meningkatkan akurasi klasifikasi pasien gagal jantung.

Meskipun hasil-hasil tersebut menunjukkan potensi besar Random Forest dalam klasifikasi medis, sebagian besar studi masih terbatas pada penyakit umum dan lingkungan rumah sakit atau puskesmas. Belum banyak penelitian yang mengembangkan model klasifikasi status rujukan pasien di poliklinik bandara, yang memiliki karakteristik operasional unik dan membutuhkan keputusan cepat. Selain itu, penerapan SHAP dalam konteks ini juga belum banyak dieksplorasi. Oleh karena itu, penelitian ini membangun model klasifikasi rujukan berbasis Random Forest yang dilengkapi interpretasi SHAP untuk meningkatkan keakuratan, transparansi, dan kepercayaan dalam pengambilan keputusan medis di poliklinik bandara.

METODE PENELITIAN



Gambar 1. Diagram Alur Penelitian

Berikut adalah langkah-langkah yang dilakukan dalam penelitian ini:

1. Pengumpulan Data

Penelitian ini menggunakan data yang diperoleh secara langsung dari Poliklinik Bandara Juanda Surabaya. Data yang digunakan merupakan data rekam medis pasien yang telah diizinkan untuk diakses dan dianalisis dalam konteks penelitian ini. Proses pengumpulan data dilakukan melalui koordinasi dengan pihak poliklinik dan dilakukan dengan tetap menjaga kerahasiaan identitas pasien sesuai dengan prinsip etika penelitian.

2. Analisis Data Eksploratif


Eksplorasi data dilakukan untuk memahami karakteristik dan keterkaitan antar fitur dalam dataset. Pada tahapan ini berbagai teknik visualisasi akan digunakan, seperti pemetaan distribusi fitur target, analisis korelasi antar fitur, serta visualisasi distribusi masing-masing fitur. Tujuan dari eksplorasi data adalah untuk membantu pemahaman tentang pola-pola yang ada dalam data dan membantu proses selanjutnya.

3. Pra Pemrosesan Data

Pada tahapan pra pemrosesan data, dilakukan pembersihan data dari nilai hilang, konversi fitur kategorikal ke format numerik, ekstraksi fitur tanda vital dari teks menggunakan regular expression, serta normalisasi fitur dengan *Min-Max Scaler*. Nilai kosong yang tersisa diisi dengan rata-rata kolom untuk mempersiapkan data sebelum pembangunan model klasifikasi. Selain itu, data juga dibagi ke dalam subset data latih dan data uji untuk keperluan pelatihan dan evaluasi model.

4. Pemodelan Random Forest

Random Forest adalah algoritma pembelajaran mesin berbasis *ensemble learning* yang digunakan untuk tugas klasifikasi maupun regresi. Algoritma ini membangun sejumlah pohon keputusan (*decision tree*) selama proses pelatihan dan menggabungkan hasil dari setiap pohon untuk menghasilkan prediksi akhir yang lebih stabil dan akurat. Setiap pohon dibangun dari subset acak data latih dan subset acak fitur, memungkinkan model untuk menangkap berbagai pola dalam data. Prediksi akhir ditentukan melalui mekanisme voting mayoritas dari semua pohon dalam hutan. Pendekatan ini telah terbukti efektif dalam berbagai aplikasi klasifikasi di bidang kesehatan, termasuk prediksi perilaku peserta Program Rujuk Balik (PRB) [13], klasifikasi penyakit kardiovaskular, dan deteksi penyakit pernapasan seperti ISPA [14].



Gambar 2. Cara Kerja Random Forest

Source: <https://images.app.goo.gl/fxvx3AN1dHPrUcSq6>

Proses kerja algoritma Random Forest mencakup beberapa tahapan berikut:

1. Pengambilan Sampel Bootstrap (*Bootstrap Aggregation*): Dataset latih diambil secara acak dengan pengembalian (*sampling with replacement*) untuk membentuk beberapa subset data.
2. Pembangunan Pohon Keputusan: Setiap pohon dibangun menggunakan subset data yang berbeda dan hanya menggunakan subset acak dari fitur. Proses ini menciptakan keragaman antar pohon dan mengurangi risiko *overfitting*.

3. Voting Mayoritas: Untuk klasifikasi, prediksi akhir dilakukan dengan cara *majority voting*, yaitu memilih kelas yang paling banyak diprediksi oleh seluruh pohon.

Pemilihan algoritma Random Forest dalam penelitian ini didasarkan pada sejumlah keunggulan yang ditawarkannya. Algoritma ini sangat baik dalam menangani dataset yang kompleks, mengandung banyak fitur, serta memiliki interaksi non-linear antar fitur. Selain itu, Random Forest lebih tahan terhadap overfitting dibandingkan pohon keputusan tunggal karena menggunakan pendekatan agregasi. Keunggulan lainnya adalah kemampuannya dalam memberikan estimasi pentingnya fitur melalui metrik seperti *Mean Decrease in Gini* (MDG), yang sangat berguna untuk interpretabilitas model. Metrik ini menunjukkan seberapa besar suatu fitur membantu dalam mengurangi ketidakmurnian (*impurity*) pada simpul-simpul pohon, yang diukur dengan indeks Gini. Jika terdapat q variabel penjelas dengan $h = 1, 2, \dots, q$, maka MDG akan memastikan pentingnya variabel X_h sebagai berikut:

$$MDG_h = \frac{1}{k} \sum_t [d(h, t)I(h, t)] \quad (1)$$

dengan

- k = jumlah pohon dalam struktur Random Forest
- $d(h, t)$ = besar penurunan indeks Gini untuk variabel penjelas X_h pada sebuah simpul
- $I(h, t)$ = $\begin{cases} 1; \\ 0; \end{cases}$ Jika fitur X_h digunakan pada simpul t , selainnya

Nilai MDG yang lebih tinggi menunjukkan bahwa fitur tersebut memiliki peran penting dalam membentuk keputusan klasifikasi. Hasil ini menjadi dasar awal interpretasi model, yang kemudian dianalisis lebih lanjut pada tahap selanjutnya.


5. Evaluasi

Evaluasi model dilakukan menggunakan data uji untuk mengukur kemampuan model dalam memprediksi status rujukan pasien pada data baru. Metrik yang digunakan meliputi akurasi, *confusion matrix*, *precision*, *recall*, dan *f1-score*. *Precision* mengukur ketepatan prediksi positif, *recall* menunjukkan kemampuan mendeteksi kasus positif, dan *f1-score* menyeimbangkan keduanya. Evaluasi ini memastikan model tidak hanya akurat secara keseluruhan, tetapi juga efektif dalam mengklasifikasikan kelas minoritas yang penting dalam konteks status rujukan.

6. Interpretabilitas Model dengan SHAP

Untuk memahami bagaimana model Random Forest mengklasifikasikan status rujukan pasien, penelitian ini menggunakan pendekatan interpretabilitas model berbasis SHAP (SHapley Additive exPlanation). SHAP merupakan metode interpretasi yang menjelaskan kontribusi masing-masing fitur terhadap hasil klasifikasi, baik secara global (keseluruhan model) maupun lokal (per observasi atau pasien). Konsep SHAP berasal dari teori permainan kooperatif yang dikembangkan oleh Lloyd Shapley. Dalam konteks klasifikasi, nilai Shapley digunakan untuk menghitung seberapa besar pengaruh suatu fitur dalam mendorong model memberikan label tertentu (misalnya: "Dirujuk" atau "Tidak Dirujuk") pada suatu pasien, berdasarkan kombinasi nilai dari fitur lainnya.

SHAP memberikan penjelasan aditif terhadap output model dengan cara membandingkan prediksi aktual dengan nilai dasar (baseline), yaitu nilai prediksi rata-rata jika tidak ada informasi fitur yang diketahui. Nilai SHAP dari suatu fitur menunjukkan kontribusinya dalam mendorong perubahan dari baseline ke nilai prediksi akhir model.




Gambar 3. Cara Kerja SHAP dalam Menjelaskan Prediksi Model

Source: <https://images.app.goo.gl/BmAaCxT6VDYXPDpm9>

Gambar 3. menampilkan bagaimana SHAP menganalisis kontribusi fitur pada contoh spesifik (observasi individu) dengan memetakan fitur-fitur yang meningkatkan atau menurunkan kemungkinan prediksi model. Bar berwarna biru menandakan peningkatan kontribusi terhadap prediksi, sedangkan merah menunjukkan penurunan. Prinsip Dasar SHAP:

1. Nilai dasar ($E[f(z)]$): Ekspektasi output model saat tidak ada fitur yang diketahui.
2. Nilai prediksi ($f(x)$): Output model ketika seluruh fitur diketahui.
3. Nilai SHAP (ϕ_i): Besarnya kontribusi fitur ke- i dalam menjembatani nilai baseline ke nilai prediksi.



Gambar 4. Proses Akumulasi Nilai SHAP dari Baseline hingga Output Model

Gambar 4 menjelaskan bagaimana setiap fitur secara bertahap menambahkan kontribusi terhadap prediksi akhir. Panah-panah (ϕ_0 hingga ϕ_4) menunjukkan besarnya kontribusi fitur dalam berbagai urutan kombinasi masuk ke model. Pendekatan Perhitungan SHAP:

- a. Model-agnostic:
 - *Shapley Sampling*: Menggunakan permutasi fitur untuk menghitung nilai SHAP.
 - *Kernel SHAP*: Pendekatan efisien berbasis regresi berbobot.
- b. Model-spesifik:
 - *Linear SHAP*: Untuk model linear.
 - *Deep SHAP*: Untuk model deep learning berbasis DeepLIFT.

Keunggulan SHAP terletak pada kemampuannya memberikan penjelasan secara lokal untuk tiap prediksi sekaligus secara global untuk keseluruhan model, serta sifatnya yang konsisten dan aditif sehingga kontribusi setiap fitur dapat dijumlahkan hingga menghasilkan nilai prediksi akhir. Metode ini juga bersifat adil terhadap semua fitur karena mempertimbangkan seluruh kemungkinan urutan masuknya fitur dalam model. Selain itu, SHAP mendukung visualisasi yang intuitif dan mudah dipahami oleh pengguna non-teknis, sehingga menyediakan transparansi yang tinggi dalam proses pengambilan keputusan berbasis data [15].

Dengan demikian, melalui pendekatan SHAP, hasil klasifikasi model tidak hanya menjadi prediksi, tetapi juga dapat dijelaskan secara transparan. Interpretasi ini penting untuk mendukung tenaga medis dalam mengambil keputusan berbasis data yang dapat dipercaya, ditelusuri penyebabnya, dan lebih mudah diterima dalam praktik klinis di fasilitas layanan primer [16].

HASIL PENELITIAN

1. Pengumpulan Data


Dataset yang digunakan terdiri dari 374 rekam medis pasien yang mencakup berbagai fitur penting yang berkaitan dengan kondisi kesehatan dan status rujukan pasien. Data yang dikumpulkan meliputi fitur demografis seperti usia dan jenis kelamin, fitur klinis berupa keluhan utama, status tindakan, serta hasil pengukuran tanda vital seperti tekanan darah sistolik dan diastolik, nadi, suhu tubuh, dan saturasi oksigen (SPO2). fitur target dalam penelitian ini adalah status rujukan pasien yang diklasifikasikan menjadi dua kelas, yaitu pasien yang dirujuk dan pasien yang tidak dirujuk.

Tabel 1. Dataset

Tanggal	Jenis Kelamin	Usia	Anamnesa	Hasil Pemeriksaan	Diagnosa	Tindakan/Terapi	...	Tindakan
01/04/2024	L	33	Nyeri telinga, berdengung	TD 170/110	ISPA	Alpara	...	Diobati
01/04/2024	L	35	Pusing berputar, nyeri perut	TD 140/84, N 105	GASTRITIS + VERTIGO	Antasida, Betahistin Mesilate	...	Diobati
01/04/2024	L	53	Kejang akibat luka gunting	TD 93/54, SPO 98, N 74, T 36.2	SUPS EPILEPSI	O2 4 LPM, Rawat Luka	...	Dirujuk
01/04/2024	L	32	Nyeri Telan + FLU	Data tidak tersedia	COMMON COLD	Dexa, Alpara	...	Diobati
01/04/2024	P	38	Sakit gigi	TD 123/87	PERIDONTITIS	Natrium Diclofenac	...	Diobati
...	...	...	...	...	...	...	...	...

2. Analisis Data Eksploratif


Eksplorasi data adalah tahap penting dalam proses analisis data dan digunakan untuk berbagai keperluan penting dalam memahami isi dan karakteristik dari dataset yang dianalisis.



Gambar 5. Heatmap Korelasi

Gambar 5 menunjukkan bahwa TD_Sistolik dan TD_Diastolik memiliki korelasi positif yang cukup kuat, mencerminkan keterkaitan alami antar komponen tekanan darah. Sementara itu, fitur lain seperti Usia, Nadi, Suhu, dan SPO memiliki korelasi lemah satu sama lain dan terhadap tekanan

darah. Usia, misalnya, hanya menunjukkan korelasi rendah dengan TD_Sistolik (0,16) dan hampir tidak berhubungan dengan variabel lain. SPO (saturasi oksigen) juga menunjukkan korelasi sangat rendah dengan semua fitur, mengindikasikan bahwa variabel ini cukup independen dan berpotensi menyumbang informasi unik dalam klasifikasi.



Gambar 6. Plot Distribusi Pasien

Grafik tersebut menunjukkan distribusi status rujukan pasien pada poliklinik bandara. Dari total data yang tersedia, terdapat 353 pasien yang tidak dirujuk dan hanya 15 pasien yang dirujuk ke fasilitas kesehatan lanjutan. Ketimpangan jumlah ini menandakan bahwa sebagian besar pasien dapat ditangani langsung di poliklinik tanpa perlu dirujuk.

3. Pra Pemrosesan Data

Pra-pemrosesan data dilakukan untuk menyiapkan data sebelum pemodelan. Data yang memiliki nilai kosong pada kolom penting seperti Diagnosa, Tindakan/Terapi, dan Status Pasien dihapus, menyisakan 368 data valid. Kolom Usia dikonversi ke numerik, dan tanda vital diekstraksi dari kolom Hasil Pemeriksaan menggunakan regular expression, menghasilkan fitur tekanan darah, nadi, suhu, dan SPO2.

Kolom kategori dikodekan dengan label encoding, sementara data numerik dinormalisasi menggunakan Min-Max Scaling. Nilai kosong pada fitur numerik diisi dengan rata-rata kolom. Terakhir, data dibagi menjadi data latih dan uji dengan rasio 80:20 menggunakan stratifikasi untuk menjaga distribusi kelas.

4. Pemodelan Random Forest

Pemodelan Random Forest pada penelitian ini dirancang untuk menghasilkan model klasifikasi yang optimal, khususnya dalam menangani data yang tidak seimbang. Untuk itu, dilakukan serangkaian proses sistematis guna menyusun dan menyempurnakan model melalui tuning hyperparameter. Tahapan pemodelan yang dilakukan terdiri atas tiga langkah utama sebagai berikut:

1. Penentuan ruang pencarian hyperparameter,
2. Tuning menggunakan GridSearchCV, dan
3. Pembangunan Model dengan Parameter Terbaik.

1. Penentuan Ruang Pencarian Hyperparameter

Lima parameter diuji untuk memperoleh kombinasi terbaik berdasarkan performa model pada data tidak seimbang. Ruang pencarian ditunjukkan pada Tabel 2.

Tabel 3. Ruang Pencarian Hyperparameter Random Forest

Parameter	Nilai yang Dicoba
n_estimators	100, 200
max_depth	None (tidak dibatasi), 5, 10
min_samples_split	2, 5
min_sample_leaf	1, 2

class_weight	'balanced'
--------------	------------

2. Penentuan Ruang Pencarian Hyperparameter


Tuning dilakukan menggunakan GridSearchCV dengan 5-fold cross-validation dan metrik f1_macro. Parameter n_jobs=-1 digunakan untuk efisiensi proses.

Tabel 4. Parameter Terbaik Hasil Tuning Model Random Forest

Parameter	Nilai
n_estimators	100
max_depth	5
min_samples_split	5
min_samples_leaf	1
class_weight	'balanced'

3. Pembangunan Model dengan Parameter Terbaik

Pembangunan model dilakukan menggunakan data pelatihan dan dievaluasi dengan metrik F1-macro, mengingat distribusi kelas yang tidak seimbang. Metrik ini dipilih karena mampu memberikan penilaian rata-rata performa secara setara pada setiap kelas, sehingga model tidak hanya mengutamakan kelas mayoritas. Setelah dilakukan proses tuning hyperparameter, model terbaik yang diperoleh kemudian diuji untuk mengukur kemampuan generalisasinya terhadap data baru.



```
GridSearchCV(cv=5, estimator=RandomForestClassifier(random_state=42), n_jobs=-1,
             param_grid={'class_weight': ['balanced'],
                           'max_depth': [None, 5, 10], 'min_samples_leaf': [1, 2],
                           'min_samples_split': [2, 5],
                           'n_estimators': [100, 200]},
             scoring='f1_macro', verbose=1)


best_estimator_: RandomForestClassifier
RandomForestClassifier(class_weight='balanced', max_depth=5,
                       min_samples_split=5, random_state=42)
```

Gambar 7. Pemodelan Random Forest dengan Parameter Terbaik

Gambar 7. menunjukkan bahwa model Random Forest terbaik dihasilkan dari kombinasi tersebut, yang ditemukan melalui proses validasi silang 5-fold (cv=5). Parameter n_jobs=-1 digunakan untuk memanfaatkan seluruh inti prosesor yang tersedia agar proses tuning berjalan lebih cepat, dan scoring='f1_macro' dipilih untuk memberikan penilaian rata-rata performa antar kelas.

\

5. Interpretasi Salah Satu Pohon Keputusan



Gambar 8. Salah Satu Pohon dalam Random Forest

Visualisasi pada Gambar 8 menyajikan salah satu pohon keputusan yang terbentuk dari model Random Forest. Pohon ini menggambarkan proses klasifikasi terhadap status rujukan pasien berdasarkan sejumlah variabel prediktor yang digunakan selama pelatihan model. Setiap percabangan dalam pohon mencerminkan aturan pemisahan berdasarkan nilai suatu variabel, yang dipilih untuk memaksimalkan pemisahan antar kelas (Rujukan dan Non-Rujukan) pada setiap tingkat. Dari visualisasi di atas ditemukan:

- Nilai gini pada setiap simpul menunjukkan tingkat ketidakmurnian (impurity):
 - Nilai gini mendekati nol mengindikasikan bahwa mayoritas sampel dalam simpul tersebut berasal dari satu kelas.
 - Semakin rendah nilai gini, semakin murni klasifikasi pada simpul tersebut.
- Variabel-variabel yang sering muncul dalam percabangan pohon mencerminkan pentingnya peran mereka dalam klasifikasi, antara lain:
 - Nadi
 - Usia
 - Saturasi Oksigen (SPO)
 - Tekanan Darah Sistolik (TD_Sistolik)
 - Status Pasien

Kemunculan berulang variabel-variabel tersebut menunjukkan bahwa model secara konsisten mengandalkan nilai-nilai tersebut untuk membedakan antara pasien rujukan dan non-rujukan. Setiap percabangan pada pohon menunjukkan ambang batas nilai dari suatu variabel yang digunakan model untuk membuat keputusan klasifikasi pada tahap tersebut.

6. Evaluasi

Setelah model Random Forest terbaik diperoleh melalui tuning, evaluasi dilakukan pada data uji untuk mengukur performa klasifikasi.

Tabel 4. Hasil Evaluasi Model Random Forest dengan Tuning Hyperparameter

Kelas	Precision	Recall	F1-Score	Support
0	1.00	0.94	0.97	71
1	0.43	1.00	0.60	3


Tabel 4. menunjukkan bahwa pada kelas mayoritas (kelas 0), model mencapai precision 1.00, recall 0.94, dan F1-score 0.97, sedangkan pada kelas minoritas (kelas 1), precision 0.43, recall 1.00, dan F1-

score 0.60. Ini menunjukkan model sangat baik mengenali kelas mayoritas dan seluruh sampel kelas minoritas, meski dengan sejumlah prediksi salah pada kelas minoritas.

Tabel 5. Hasil Metrik Keseluruhan


Metrik Keseluruhan	Nilai
Akurasi	0.95
Macro Avg F1-Score	0.79
Weighted Avh F1-Score	0.96

Tabel 5. memperlihatkan akurasi keseluruhan sebesar 0.95, *macro average F1-score* 0.79 yang mencerminkan performa seimbang antar kelas, dan *weighted average F1-score* 0.96 yang lebih dipengaruhi oleh kelas mayoritas.




Gambar 9. Confusion Matrix

Evaluasi kinerja model menggunakan confusion matrix menunjukkan akurasi sebesar 95%, dengan *true negative* sebanyak 67 dan *true positive* sebanyak 3. Meskipun akurasinya tinggi, *precision* untuk kelas rujukan hanya sebesar 42,9%, meskipun *recall* mencapai 100%, yang berarti seluruh pasien yang perlu dirujuk berhasil dikenali oleh model. *F1-score* untuk kelas rujukan sebesar 60%, menunjukkan bahwa meskipun sensitivitas tinggi, model masih perlu ditingkatkan agar lebih presisi.



Gambar 10. Receiver Operating Characteristic (ROC)

Selain evaluasi menggunakan *confusion matrix*, performa model juga dianalisis melalui kurva *Receiver Operating Characteristic* (ROC). Berdasarkan Gambar 10, model menghasilkan nilai *Area Under the Curve* (AUC) sebesar 0,97, yang menunjukkan kemampuan diskriminatif model yang sangat baik dalam membedakan antara pasien yang dirujuk dan tidak dirujuk. Nilai AUC yang mendekati 1 ini mengindikasikan bahwa.




Gambar 11. Heatmap Hasil Klasifikasi

Gambar 11 menunjukkan model memiliki performa sangat baik pada kelas pasien tidak dirujuk dengan *precision* 1.00, *recall* 0.94, dan *F1-score* 0.97. Untuk kelas pasien dirujuk, *precision* lebih rendah yaitu 0.43, meski *recall* sempurna 1.00, menandakan semua pasien yang perlu dirujuk terdeteksi, namun banyak pasien non-rujukan salah diklasifikasikan. Akurasi keseluruhan model adalah 0.95, sementara *macro average precision* (0.71) dan *F1-score* (0.79) mengindikasikan ketimpangan performa antar kelas.

7. Interpretabilitas Model dengan SHAP


Untuk memahami kontribusi tiap fitur dalam prediksi model Random Forest terhadap klasifikasi status rujukan pasien, digunakan metode interpretabilitas SHAP (*SHapley Additive exPlanations*). Gambar 12 menunjukkan rata-rata nilai absolut SHAP ($\text{mean}(|\text{SHAP value}|)$) dari masing-masing fitur, yang merepresentasikan tingkat pengaruh fitur secara keseluruhan terhadap output model.



Gambar 12. Plot Feature Importance SHAP

Hasil visualisasi pada Gambar 12. menunjukkan bahwa fitur "Usia" merupakan faktor paling dominan dalam menentukan output model, dengan nilai SHAP rata-rata yang jauh lebih tinggi dibanding fitur lainnya. Fitur "Jenis Kelamin" dan "Status Pasien" juga memberikan kontribusi yang cukup besar, meskipun masih di bawah "Usia". Sementara itu, fitur seperti "TD_Sistolik", "Nadi", "Suhu", dan "TD_Diastolik" memiliki pengaruh yang lebih kecil. Fitur "SPO" dan "Jenis Penyakit" menunjukkan kontribusi yang sangat rendah terhadap prediksi model.

Selain analisis global, interpretasi lokal juga dilakukan melalui SHAP *summary plot* pada Gambar 13 yang menampilkan distribusi nilai SHAP untuk setiap fitur dalam setiap prediksi. Nilai SHAP menunjukkan seberapa besar pengaruh suatu fitur dalam meningkatkan atau menurunkan probabilitas keluaran model. Dalam masalah ini, nilai SHAP positif menunjukkan kontribusi terhadap prediksi pasien dirujuk, sementara nilai negatif mendukung prediksi tidak dirujuk.



Gambar 13. Plot Distribusi Nilai SHAP

Berdasarkan visualisasi SHAP, fitur "Usia" menjadi faktor paling berpengaruh terhadap prediksi model, dengan nilai SHAP yang tersebar luas ke arah positif dan negatif. Artinya, usia tinggi meningkatkan kemungkinan rujukan, sedangkan usia rendah menurunkannya. Fitur "Nadi" dan "Status Pasien" memiliki pengaruh sedang. Nadi tinggi sedikit meningkatkan kemungkinan rujukan, sementara pengaruh status pasien bervariasi tergantung kategorinya. Fitur seperti "Jenis Kelamin", "TD_Sistolik", "TD_Diastolik", dan "Suhu" menunjukkan kontribusi rendah, dengan nilai SHAP mendekati nol. "SPO" memberi sedikit pengaruh positif, sedangkan "Jenis Penyakit" hampir tidak berpengaruh sama sekali.

PEMBAHASAN

Hasil evaluasi menunjukkan bahwa meskipun model Random Forest mencapai akurasi tinggi (94,59%), terdapat ketidakseimbangan performa antar kelas. Terutama, precision kelas pasien yang dirujuk masih rendah (0,43) meskipun *recall* mencapai 1,00 setelah tuning. Hal ini mengindikasikan bahwa model memiliki kecenderungan untuk menghasilkan false positive pada kelas minoritas, yang dapat berdampak terhadap pengambilan keputusan medis yang tidak akurat.

Confusion matrix menunjukkan adanya keterbatasan dalam mendeteksi pasien yang benar-benar perlu dirujuk. Nilai AUC sebesar 0,91 menunjukkan bahwa model secara umum memiliki kemampuan klasifikasi yang baik, namun kesenjangan antar metrik per kelas menunjukkan perlunya pendekatan tambahan seperti penyeimbangan data atau penyesuaian threshold klasifikasi. Interpretasi dengan SHAP membantu memahami bagaimana model mengambil keputusan. Hasil menunjukkan bahwa "Usia" menjadi fitur paling dominan dalam menentukan status rujukan, disusul oleh "Nadi" dan "Status Pasien". Temuan ini menunjukkan bahwa faktor usia pasien memainkan peran penting dalam proses prediksi rujukan oleh model. Namun, dominasi satu fitur seperti usia dapat menjadi sinyal potensi bias model, terutama jika distribusi data tidak cukup representatif terhadap populasi yang sebenarnya.

Secara keseluruhan, meskipun model memberikan hasil yang menjanjikan, performa pada kelas minoritas tetap menjadi tantangan utama yang perlu ditangani sebelum implementasi model ini pada sistem pengambilan keputusan medis secara nyata.

KESIMPULAN

Status rujukan pasien merupakan aspek penting dalam pengambilan keputusan medis, khususnya dalam sistem pelayanan primer. Dengan memanfaatkan data rekam medis secara optimal dan pendekatan *machine learning*, prediksi status rujukan dapat dilakukan secara lebih objektif dan efisien. *Random Forest Classifier* (RFC) merupakan algoritma yang andal dalam menangani tugas klasifikasi seperti ini, karena memiliki keunggulan dalam hal akurasi, ketahanan terhadap *overfitting*, serta interpretabilitas model yang cukup baik. Melalui analisis interpretabilitas menggunakan metode SHAP, dapat diketahui bahwa fitur seperti "Usia", "Nadi", dan "Status Pasien" memiliki pengaruh paling besar terhadap prediksi model. Berdasarkan pengujian yang dilakukan terhadap dataset rekam medis dari Poliklinik Bandara Juanda, model Random Forest yang dibangun menghasilkan akurasi sebesar 94,59% dan nilai AUC sebesar 0,91, yang menandakan performa klasifikasi yang sangat baik. Namun demikian, ketidakseimbangan data masih menjadi tantangan, terutama dalam mendeteksi pasien yang benar-benar perlu dirujuk. Untuk itu, penelitian selanjutnya disarankan menggunakan teknik penyeimbangan data atau penyesuaian threshold

klasifikasi guna meningkatkan kinerja model pada kelas minoritas. Dengan pengembangan yang tepat, model ini berpotensi untuk diimplementasikan sebagai alat bantu dalam sistem pengambilan keputusan medis yang lebih akurat dan terpercaya.

REFERENSI

- [1] Abdillah Muhammad Faizi, "Revolusi Digital Kesehatan: Meningkatkan Layanan dengan Kecerdasan Buatan.," *Syntax Literate: Jurnal Ilmiah Indonesia*, vol. 9, no. 10, Oct. 2024, doi: <http://dx.doi.org/10.36418/syntax-literate.v9i10>.
- [2] E. Ekalia, A. Gunadi, and M. Abdurrohman, "Pengembangan Regulasi Penggunaan Artificial Intelligence pada Bidang Kesehatan di Indonesia pada Aspek Hukum dan Etika," *JIHHP*, vol. 5, no. 2, 2024, doi: 10.38035/jihhp.v5i2.
- [3] A. N. Iskandar, I. Ernawati, and Y. Widiastiw, "Klasifikasi Diagnosis Penyakit Stroke Dengan Menggunakan Metode Random Forest," Jakarta, Aug. 2022.
- [4] I. Ketut *et al.*, "Implementasi Random Forest pada Klasifikasi Penyakit Kardiovaskular dengan Hyperparameter Tuning Grid Search," *JNATIA*, vol. 2, no. 1, 2023.
- [5] Ratnasari Dwi, "Analisis Pelaksanaan Sistem Rujukan Berjenjang Bagi Peserta JKN di Puskesmas X Kota Surabaya," vol. 5, no. 2, Jul. 2017, Accessed: Jun. 11, 2025. [Online]. Available: <https://e-journal.unair.ac.id/JAKI/article/download/4642/pdf/22304>
- [6] A. Muhamad Lutfi, E. Purwadi, Y. Ali Hanaan, and P. Rosyani, "Literatur Review: Penerapan Random Forest untuk Klasifikasi Penyakit Tanaman Padi," *OKTAL: Jurnal Ilmu Komputer dan Science*, vol. 3, no. 10, 2024, [Online]. Available: <https://journal.mediapublikasi.id/index.php/oktal>
- [7] Ary Prandika Siregar, Dwi Priyadi Purba, Jojo Putri Pasaribu, and Khairul Reza Bakara, "Implementasi Algoritma Random Forest Dalam Klasifikasi Diagnosis Penyakit Stroke," *Jurnal Penelitian Rumpun Ilmu Teknik (JUPRIT)*, vol. 2, no. 4, pp. 155–164, Nov. 2023, doi: 10.55606/juprit.v2i4.3039.
- [8] Marlina Haiza, Elmayati, Zulius Antoni, and Wijaya Harma Oktafia Lingga, "Penerapan Algoritma Random Forest Dalam Klasifikasi Penjurusan Di SMA Negeri Tugumulyo," *Jurnal Penerapan Kecerdasan Buatan*, vol. 4, no. 2, pp. 138–143, Jun. 2023, doi: <https://doi.org/10.30645/brahmana.v4i2.188>.
- [9] A. F. Hadi, A. F. Zulva, M. L. Hakim, M. D. Saputra, and H. Sadiyah, "Implementasi Explainable Machine Learning: Visualisasi Global Explainability and Local Interpretability pada Analisis Sentimen dengan SHAP dan LIME," *Journal BIAStatistics*, vol. 17, no. 1, pp. 1–18, 2017, doi: <https://doi.org/10.1234/bias.v17i1.219>.
- [10] G. A. B. Suryanegara, Adiwijaya, and M. D. Purbolaksono, "Peningkatan Hasil Klasifikasi pada Algoritma Random Forest untuk Deteksi Pasien Penderita Diabetes Menggunakan Metode Normalisasi," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 114–122, Feb. 2021, doi: 10.29207/resti.v5i1.2880.
- [11] A. Nurul Puteri and A. Sumardin, "Comparison of Random Forest and XGBoost for Diabetes Classification with SHAP and LIME Interpretation," *Jurnal Teknologi Rekayasa*, vol. 9, no. 2, 2024, doi: 10.31544/jtera.v9.i1.2024.121-130.
- [12] R. Arisandi, "Perbandingan Model Klasifikasi Random Forest dengan Resampling dan Tanpa Resampling Pada Pasien Penderita Gagal Jantung," *Jurnal Gaussian*, vol. 12, no. 1, pp. 136–145, May 2023, doi: 10.14710/j.gauss.12.1.136-145.
- [13] W. Djatmiko, Kusri, and Hanafi, "Perbandingan Naive Bayes dan Random Forest untuk Prediksi Perilaku Peserta Program Rujuk Balik," *Jurnal Ilmu Komputer*, vol. 13, no. 3, pp. 358–367, Dec. 2023.
- [14] A. Ilyasya, A. Fahreza, M. R. Alwaan, A. Saputra, and P. Rosyani, "Penerapan Random Forest dalam Klasifikasi Penyakit Saluran Pernafasan," *Buletin Ilmiah Ilmu Komputer dan Multimedia (BIIKMA)*, vol. 2, no. 3, pp. 497–503, Oct. 2024, [Online]. Available: <https://jurnalmahasiswa.com/index.php/biikma>
- [15] Lundberg Scott M. and In Lee-Su, "A Unified Approach to Interpreting Model Predictions," CA, USA, 2017. Accessed: Jun. 11, 2025. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf

- [16] A. Yulianto and Firmansyah, "Prediksi Penyakit Jantung Menggunakan Algoritma Random Forest," *Jurnal Minfo Polgan*, vol. 12, no. 2, pp. 2239–2246, Nov. 2023, doi: <https://doi.org/10.33395/jmp.v12i2.13214>.