

Perbandingan Random Forest dan XGBoost dalam Penentuan Jenis Perawatan Pasien Berdasarkan Hasil laboratorium Darah

Trhecia Priscila Momongan, Jong Jek Siang*, Halim Budi Santoso

Sistem Informasi, Fakultas Teknologi Informasi, Universitas Kristen Duta Wacana, Yogyakarta, Indonesia

Email: ¹trhecia.priscila@si.ukdw.ac.id, ^{2,*}jjsiang@staff.ukdw.ac.id, ³hbudi@staff.ukdw.ac.id

Email Penulis Korespondensi: jjsiang@staff.ukdw.ac.id*

Submitted: 12/01/2026; Accepted: 15/02/2026; Published: 31/03/2026

Abstrak– Umumnya, keputusan rawat inap dan rawat jalan seorang pasien ditentukan secara subyektif oleh dokter menggunakan hasil laboratorium darah. Pada pasien yang masuk melalui Instalasi Gawat Darurat, keputusan tersebut dilakukan oleh dokter umum yang menangani banyak pasien sekaligus sehingga berpotensi salah keputusan. *Machine Learning* dapat dipakai untuk membantu dokter dalam pengambilan keputusan jenis perawatan. Penelitian ini membandingkan performa *Random Forest* dan *XGBoost* dalam memprediksi jenis perawatan pasien. Dataset yang digunakan berisi 4.412 data pasien dari beberapa rumah sakit swasta di Indonesia, dengan 11 atribut mencakup profil pasien serta hasil laboratorium seperti hematokrit, hemoglobin, eritrosit, leukosit, trombosit, MCH, MCHC, dan MCV. Dataset termasuk dalam kategori ketidakseimbangan ringan karena terdiri dari 59,6% pasien rawat jalan dan 40,4% rawat inap. Pengujian dilakukan menggunakan parameter *default* maupun dengan pengaturan fitur. Hasil pengujian menunjukkan bahwa kinerja *Random Forest* lebih baik dibanding *XGBoost*. Model *Random Forest* terbaik didapat dengan menggunakan parameter *default* dengan *feature selection*, mencapai akurasi 77%, presisi 77%, *recall* 77%, *F1-Score* 76% dan ROC-AUC 81,4%. *XGBoost* terbaik diperoleh dengan menggunakan default parameter seluruh variabel, dengan akurasi 76%, presisi 74%, *recall* 76%, *F1-Score* 75% dan ROC-AUC 80,2%. *Random Forest* menunjukkan keseimbangan prediksi antar kelas dan sensitivitas serta spesifisitas tinggi sehingga efektif dalam mendukung keputusan klinis. Penelitian selanjutnya dapat difokuskan pada metode *feature selection* dan optimasi parameter yang mempertimbangkan waktu dan beban komputasi.

Kata Kunci: *Random Forest*; *XGBoost*; *Machine Learning*; *Ensemble Learning*; laboratorium darah

Abstract– For patients entering through the Emergency Department, this decision is often made by general practitioners who handle many patients at once, which may increase the risk of incorrect decisions. Machine Learning can be used to assist physicians in determining the appropriate type of care. This study compares the performance of Random Forest and XGBoost in predicting the type of patient care. The dataset used consists of 4,412 patient records from several private hospitals in Indonesia, with 11 attributes covering patient profiles and laboratory results such as hematocrit, hemoglobin, erythrocytes, leukocytes, platelets, MCH, MCHC, and MCV. The dataset falls into the mildly imbalanced category, consisting of 59.6% outpatients and 40.4% inpatients. Testing was conducted using both default parameters and feature selection settings. The results show that Random Forest performs better than XGBoost. The best Random Forest model was obtained using default parameters with feature selection, achieving 77% accuracy, 77% precision, 77% recall, 76% F1-score, and 81.4% ROC-AUC. The best XGBoost model was obtained using default parameters with all variables, achieving 76% accuracy, 74% precision, 76% recall, 75% F1-score, and 80.2% ROC-AUC. Random Forest showed balanced predictions across classes, along with high sensitivity and specificity, making it effective in supporting clinical decision-making. Future research may focus on feature selection methods and parameter optimization that take computational time and workload into account.

Keywords: Random Forest; XGBoost; Machine Learning; Ensemble Learning; blood laboratory tests.

1. PENDAHULUAN

Penentuan jenis perawatan pasien, rawat inap dan rawat jalan, merupakan aspek krusial dalam pelayanan dasar kesehatan. Ketepatan keputusan klinis tidak hanya mempengaruhi kondisi pasien, tetapi juga berperan dalam meningkatkan kualitas layanan medis, efisiensi penggunaan sumber daya dan biaya perawatan[1]. Penerimaan pasien ditentukan oleh dokter umum sebagai penanganan pertama di instalasi gawat darurat (IGD) secara cepat berdasarkan penilaian awal, pengetahuan, dan bukti praktik, sehingga berisiko terjadi kesalahan[2]. Proses identifikasi pasien yang membutuhkan perawatan rawat inap merupakan tahap kritis di IGD karena memiliki implikasi besar terhadap keselamatan dan kesinambungan perawatan. Memulangkan pasien yang seharusnya dirawat dapat meningkatkan risiko perburukan kondisi klinis yang berujung pada readmisi atau bahkan kematian. Sebaliknya, menerima pasien yang tidak memerlukan perawatan tingkat rawat inap berpotensi menimbulkan kejadian merugikan di rumah sakit, sekaligus berkontribusi pada penumpukan pasien dan peningkatan tekanan terhadap sistem layanan kesehatan[3]

Di beberapa rumah sakit di Indonesia, pemeriksaan hematologi digunakan sebagai salah satu dasar penentuan jenis perawatan pasien[4][5], umumnya mencakup hematokrit, hemoglobin, eritrosit, leukosit, trombosit, *mean corpuscular hemoglobin* (MCH), *mean corpuscular hemoglobin concentration* (MCHC), dan *mean corpuscular volume* (MCV), serta informasi demografi pasien, usia dan jenis kelamin. Profil darah memberikan gambaran komprehensif kondisi pasien. Perubahan nilai pada parameter darah umumnya mengindikasikan gangguan metabolik maupun kerusakan struktur dan fungsi organ. Pemeriksaan hematologi berperan signifikan dalam memperkuat diagnosis, mendukung diagnosis banding, memantau perkembangan penyakit, mengevaluasi tingkat keparahan, serta membantu dalam penetapan prognosis[6].

Hasil pemeriksaan tersebut tersimpan dalam *Electronic Health Record* (EHR), sistem informasi digital untuk menyimpan, mengakses, dan mengelola catatan medis pasien[7] yang mencakup seluruh informasi kesehatan relevan pasien[8]. Digitalisasi rekam medis pada EHR menyediakan data potensial untuk penerapan machine learning dalam klasifikasi pasien[9]. Namun, proses klasifikasi saat ini masih bergantung pada interpretasi manual dokter terhadap EHR, termasuk peninjauan catatan perkembangan, hasil laboratorium darah, dan riwayat kunjungan. Analisis menjadi sulit karena tingginya volume catatan medis dengan jumlah kunjungan dan redundansi yang meningkat, serta kompleksitas data laboratorium yang dipengaruhi keterkaitan variabel fisiologis, variasi kondisi klinis, dan pola nonlinear. Beban informasi yang besar ini diperparah oleh ketimpangan antara jumlah pasien dan dokter, sehingga proses analisis menjadi lebih lama dan memicu penundaan perawatan. Akibatnya, beban kerja berlebihan dan keterbatasan waktu meningkatkan risiko salah diagnosis, bias klinis, serta kesalahan medis.

Machine learning telah digunakan untuk mendukung pengambilan keputusan klinis di rumah sakit [10]. *Random Forest* dan *XGBoost* merupakan algoritma *ensemble learning* berbasis pohon keputusan yang digunakan untuk meningkatkan akurasi dan kinerja dari pohon tunggal [11]. Kedua model dibangun dengan teknik berbeda, yakni *Random Forest* bersifat independen dan *XGBoost* bersifat berurutan, namun keduanya dinilai mampu mengatasi *overfitting* yang menjadi masalah umum pada data medis serta unggul dalam memodelkan hubungan kompleks dan non-linear antar variabel klinis [12][13][14]. Oleh karena itu, analisis komparatif diperlukan untuk menilai efektivitas dan performa kedua model dalam mendukung keputusan jenis rawat pasien berbasis data hematologi.

Berbagai penelitian telah menerapkan dan membandingkan algoritma *Random Forest* dan *XGBoost* untuk keputusan klinis. Penelitian [15] dan [16] membandingkan kedua algoritma tersebut untuk klasifikasi penyakit jantung dengan variasi skema pengujian dan tuning parameter, sedangkan penelitian [17] dan [18] juga berfokus pada klasifikasi diagnosis penyakit seperti osteoporosis dan penyakit paru dengan pendekatan parameter default dan tuning. Penelitian yang menggunakan data hematologi dalam konteks penentuan jenis perawatan pasien masih sangat terbatas, seperti penelitian [19] yang mengklasifikasikan rawat inap dan rawat jalan berbasis data pemeriksaan darah, namun hanya menggunakan model *nonensemble* dan *decision tree* tunggal serta belum mengeksplorasi *Random Forest* dan *XGBoost*.


Berdasarkan penelitian-penelitian tersebut, pemanfaatan *Random Forest* dan *XGBoost* pada data hematologi EHR untuk klasifikasi jenis perawatan pasien masih terbatas. Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa algoritma *Random Forest* dan *XGBoost*. Pengujian dilakukan pada dataset EHR dari Kaggle, meliputi hematokrit, hemoglobin, eritrosit, leukosit, trombosit, MCH, MCHC, MCV, umur, dan jenis kelamin. Kedua model diuji pada tiga skenario pemodelan yang telah dikembangkan dari penelitian terdahulu, yaitu penggunaan parameter *default*, penerapan *feature selection*, dan tuning parameter. Hasil pengujian setiap skenario dievaluasi dan dibandingkan berdasarkan nilai akurasi, presisi, *recall*, *F1-Score*, dan *Receiver Operating Characteristic - Area Under the Curve* (ROC-AUC), untuk memberikan gambaran menyeluruh mengenai kemampuan masing-masing model dalam memprediksi jenis perawatan pasien serta mengidentifikasi model dan konfigurasi pemodelan yang menghasilkan performa paling optimal terhadap data hasil pemeriksaan laboratorium.

Kontribusi penelitian ini terletak pada pengembangan model prediksi jenis perawatan pasien, evaluasi komparatif algoritma *Random Forest* dan *XGBoost*, rekomendasi konfigurasi model prediktif berbasis data laboratorium darah, serta penyediaan solusi pendukung yang melengkapi penerapan *Electronic Health Record* (EHR) dalam pengambilan keputusan rawat inap dan rawat jalan yang cepat dan akurat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian dilakukan dalam kerangka kerja *Cross Industry Standard Process for Data Mining* (CRISP-DM) seperti yang tampak pada Gambar 1, meliputi *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling* dan *Evaluation* [20].



Gambar 1. Tahapan Penelitian CRISP-DM

2.2 Analisis Kebutuhan

Penentuan jenis perawatan pasien di IGD bergantung pada analisis manual terhadap hasil laboratorium darah dan data demografis [21]. Proses ini melibatkan peninjauan EHR, pengaitan riwayat medis, dan evaluasi perubahan nilai tes untuk menetapkan rawat inap atau rawat jalan. Tingginya jumlah pasien dan frekuensi kunjungan meningkatkan kompleksitas catatan medis dan risiko kesalahan keputusan. Dalam banyak kasus, *machine learning* terbukti cukup akurat dalam klasifikasi data medis dan mendukung keputusan klinis[22]. Oleh karena itu, *Random Forest* dan *XGBoost* digunakan karena mampu menangani pola nonlinear, interaksi antarvariabel, dan pola data dinamis[23] sesuai karakteristik data darah. *Random Forest* unggul dalam mengidentifikasi struktur tersembunyi dengan presisi tinggi sekaligus mengurangi *overfitting*, sedangkan *XGBoost* efektif dalam analisis laboratorium darah, efisien secara komputasi, dan mampu menangkap pola nonlinear kritis untuk klasifikasi rawat inap atau rawat jalan[24].

2.3 Eksplorasi Dataset

Penelitian ini menggunakan *EHR Dataset for Patient Treatment Classification*[25] yang berisi 4.412 data dengan 11 fitur pada Tabel 1. Fitur numerik meliputi hematokrit, hemoglobin, eritrosit, MCH, MCHC, MCV, dan usia, sedangkan fitur kategorikal mencakup jenis kelamin. Dataset bersumber dari [kaggle](#) tahun 2020 dengan target klasifikasi jenis perawatan pasien, yaitu rawat inap dan rawat jalan.

Tabel 1. Dataset

Hematokrit	Hemoglobin	Eritrosit	Leukosit	Trombosit	MCH	MCHC	MCV	Jenis Kelamin	Status Rawat
35.1	11.8	4.65	6.3	310	25.4	33.6	75.5	F	out
43.5	14.8	5.39	12.7	334	27.5	34	80.7	F	out
33.5	11.3	4.74	13.2	305	23.8	33.7	70.7	F	out
39.1	13.7	4.98	10.5	366	27.5	35	78.5	F	out
30.9	9.9	4.23	22.1	333	23.4	32	73	M	out
35.1	11.8	4.65	6.3	310	25.4	33.6	75.5	F	out


2.4 Pengolahan Data

Tahap ini melakukan pemisahan variabel numerik dan kategori untuk format data konsisten dan siap digunakan algoritma *machine learning*[26]. Variabel Jenis Kelamin dan Status Rawat diberi label biner agar dapat diproses dalam pemodelan. Selanjutnya, *feature selection* menggunakan matriks korelasi Pearson untuk menyederhanakan model, efisiensi komputasi, dan meningkatkan akurasi serta generalisasi[27]. Proses ini menghapus fitur bermultikolinearitas tinggi, hemoglobin dan MCV dengan r 0,97 dan 0,93. Dataset akhir kemudian dibagi dengan *train-test-split*, skema 80:20, 80% data pelatihan dan 20% untuk pengujian model pada data baru.

2.5 Pembangunan Model

a. Random Forest

Random Forest melakukan klasifikasi dalam beberapa tahapan pembangunan pohon keputusan seperti yang tampak pada Gambar 2[28]. Model membangun 100 pohon pada skenario *default* dan 500 pohon pada tuning parameter, hasil *grid search* dengan 5-fold *cross validation*. Setiap pohon dibangun dari 3.530 data hasil *bootstrap sampling* dengan 3 fitur, dari $\sqrt{10}$ total fitur[29] secara acak. Struktur pohon ditentukan berdasarkan nilai *entropy* dan *information gain* setiap variabel dengan persamaan (1) dan (2). Kelas akhir pasien ditentukan melalui *majority voting* dari seluruh pohon.



Gambar 2. Random Forest Architecture

$$Entropy(S) = \sum_{i=1}^c -p_i \log_2 p_i \quad (1)$$

S adalah himpunan dataset, C jumlah Kelas, p_i probabilitas frekuensi kelas ke-1 dalam dataset.

$$Gain(A) = Entropy(S) - \sum_{i=1}^k \frac{|S_i|}{|S|} \times Entropy(S_i) \quad (2)$$

S adalah himpunan dataset, A atribut, $|S_i|$ jumlah sampel untuk nilai I, $|S|$ jumlah seluruh sampel data, $Entropy(S_i)$ sampel yang memiliki nilai i.

b. XGBoost

Klasifikasi XGBoost dilakukan melalui proses inti pada Gambar 3[30]. Model membangun 100 pohon pada skenario *default* dan 300 pada *tuning*. Prediksi awal pohon merupakan rata-rata target dari data uji. *Wrong predictions* pohon pertama digunakan untuk pembangunan pohon kedua dengan sampel error lebih besar. Proses dilakukan secara iteratif dengan meminimumkan *objective function* yang terdiri dari *training loss* dan *regularization term* hingga error dan kompleksitas menurun [31] berdasarkan persamaan (3). Prediksi akhir kemudian dilakukan dengan menjumlahkan *output* dari semua pohon yang telah dibangun melalui persamaan (4).



Gambar 3. Extreme Gradient Boosting (XGBoost) Architecture

$$obj^t = \sum_{i=1}^t l(y_i, \hat{y}_i^t) + \sum_{i=1}^t \Omega(f_i) \quad (3)$$

$\hat{y}_i^t$ merupakan nilai prediksi, y_i nilai aktual, $l(y_i, \hat{y}_i^t)$ loss function dan $\Omega(f_i)$ regularisasi.

$$\hat{y}_i^t = \sum_{k=1}^t F_k(x_i) \quad (4)$$

$F_k(x_i)$ prediksi pohon ke-k untuk data ke-i, X_i data input ke-i, n total *tree* model.

2.6 Evaluasi Model

Evaluasi performa model pada data uji dilakukan menggunakan *confusion matrix* untuk mengukur akurasi, presisi, *recall*, *F1-Score*[32] serta ROC-AUC dengan membandingkan *True Positive Rate* dan *False Positive Rate*[33], dengan kategori performa Tabel 2 [34],[35], [36],[37].

Tabel 2. Kategori Performa Metrik Evaluasi

Metrik	Kategori Performa				
	Sangat Baik	Baik	Cukup	Kurang	Sangat Kurang
Akurasi	0.8 – 1.0	0.71 – 0.8	0.61 – 0.7	0.51 – 0.6	< 0.5
AUC	0.9 – 1.0	0.8 – 0.9	0.7 – 0.8	0.6 – 0.7	0.5 – 0.6
Presisi	0.9 – 1.0	0.7 – 0.9	0.6 – 0.7	0.5 – 0.6	< 0.5
Recall	0.9 – 1.0	0.7 – 0.9	0.6 – 0.7	0.5 – 0.6	< 0.5
F1-score	0.9 – 1.0	0.8 – 0.9	0.5 – 0.8	0.4 – 0.5	< 0.4

3. HASIL DAN PEMBAHASAN

Pengujian dan evaluasi dilakukan terhadap model *Random Forest* dan *XGBoost* pada tiga skenario pemodelan. Tiga skenario tersebut meliputi penggunaan parameter *default* pada seluruh variabel, penerapan *feature selection* dengan parameter *default*, dan penyesuaian parameter pada seluruh variabel. Setiap skenario dievaluasi untuk menilai performa model menggunakan *confusion matrix* dan ROC-AUC, dengan metrik evaluasi meliputi akurasi,

presisi, *recall*, *F1-score*, dan AUC. Hasil evaluasi setiap model kemudian dianalisis dan dibandingkan untuk menentukan konfigurasi dan model terbaik.

3.1 Variabel Input

Penelitian ini menggunakan data hasil pemeriksaan laboratorium darah dan data demografi pasien sebanyak 4412 sebagai variabel input dalam perbandingan *Random Forest* dan *XGBoost*. Variabel input meliputi hematokrit, hemoglobin, eritrosit, leukosit, trombosit, MCH, MCHC, MCV, usia, jenis kelamin, dan status rawat pada Tabel 3 digunakan sebagai fitur untuk membangun model penentuan jenis rawat.

Tabel 3. Variabel Input

No	Nama Variabel	Keterangan
1	Hematokrit	Presentase volume sel darah merah dalam darah
2	Hemoglobin	Konsentrasi hemoglobin dalam darah
3	Eritrosit	Jumlah sel darah merah
4	Leukosit	Jumlah sel darah putih
5	Trombosit	Jumlah keping darah
6	MCH	Nilai rata-rata kadar hemoglobin per sel darah merah
7	MCHC	Nilai rata-rata konsentrasi hemoglobin dalam sel darah merah
8	MCV	Volume rata-rata sel darah merah
9	Age	Usia pasien
10	Jenis Kelamin	Jenis kelamin pasien yaitu laki-laki dan perempuan
11	Status Rawat	Status dalam penentuan perawatan pasien yaitu rawat inap dan rawat jalan

3.2 Pembangunan Model Random Forest dan XGBoost

Pada tahap ini dibangun dua model klasifikasi, yaitu *Random Forest* dan *XGBoost*, dengan tiga skenario pemodelan. Setiap skenario menghasilkan model final yang berbeda berdasarkan konfigurasi fitur dan parameter, yang diuji pada data uji untuk memperoleh performa akhir.


3.2.1 Default Parameter Seluruh Variabel

Skenario pertama dilakukan menggunakan parameter *default* dengan seluruh variabel tanpa penghapusan fitur dan tanpa melakukan perubahan parameter pada model sebagai *baseline* model.

a. Random Forest

Tahapan pembangunan model *Random Forest* dimulai dengan *bootstrapping sampling*, yaitu setiap pohon terbentuk dari sampel data acak dengan pengembalian (*bootstrap* = True). Hasilnya berupa subset data sejumlah $n_estimators$ yang masing-masing berisi 3530 sampel dari data latih. Model terdiri dari 100 pohon keputusan ($n_estimators$ = 100). Setiap pohon dibangun menggunakan seluruh fitur yang tersedia, yaitu hematokrit, hemoglobin, eritrosit, leukosit, trombosit, MCH, MCHC, MCV, usia dan jenis kelamin. Pada setiap proses pemisahan node, model hanya menggunakan $\sqrt{(\text{total fitur})}$, sehingga 3 dari 10 fitur dipilih secara acak pada setiap *split* ($max_features$ = *sqrt*). Pohon tidak memiliki batasan kedalaman (max_depth = None) dan tidak dibatasi jumlah daunnya (max_leaf_nodes = none). Node hanya dapat dipecah jika memiliki minimal 2 sampel ($min_samples_split$ = 2) dan setiap daun minimal berisi 1 sampel ($min_samples_leaf$ = 1). Selain itu, model tidak melakukan pemangkasan pohon (cc_alpha = 0.0), tidak menghitung akurasi dari sampel yang tidak digunakan tiap pohon (*oob_score* = none), serta tidak menerapkan bobot kelas khusus (*class_weight* = none).

Model *Random Forest* dilatih dengan konfigurasi parameter tersebut dan model diuji hingga memperoleh prediksi sejumlah 100 untuk tiap pasien. Prediksi akhir ditentukan melalui voting mayoritas dari semua pohon. *Random Forest* memprediksi 310 pasien rawat inap dan 573 pasien rawat jalan. Prediksi akhir kemudian memperoleh *confusion matrix* dan ROC-AUC pada Gambar 4.




Gambar 4. Confusion Matrix dan ROC Curve Random Forest

b. XGBoost

Model menggunakan 100 pohon untuk keputusan klasifikasi biner. Setiap pohon memiliki maksimal kedalaman 6 ($max_depth = 6$). Pohon tidak dibatasi jumlah daunnya ($max_leaves = None$). Setiap node hanya bisa dipecah jika terdapat minimal 1 sampel anak ($min_child_weight = 1$) dan jika pemecahan menurunkan $loss$ minimal 0 ($gamma = 0$). Model menggunakan seluruh data ($subsample = 1$) dan semua fitur per pohon, per level, dan per node ($colsample_bytree = 1$, $colsample_bylevel = 1$, $colsample_bynode = 1$). Regularisasi $L1 = 0$ dan $L2 = 1$ (reg_alpha dan reg_lambda), $learning_rate = 0.3$.

Prediksi akhir pasien diperoleh dari akumulasi kontribusi seluruh pohon, dikonversi menjadi probabilitas kelas, dan dibandingkan dengan $threshold_default$ untuk menentukan kelas pasien. XGBoost memprediksi 325 pasien rawat inap dan 558 pasien rawat jalan. Prediksi akhir memperoleh *confusion matrix* dan ROC-AUC pada Gambar 5.



Gambar 5. *Confusion Matrix* dan ROC Curve XGBoost


3.2.2 Feature Selection dengan Default Parameter

Skenario kedua dilakukan dengan menggunakan parameter *default*, setelah melakukan seleksi fitur berdasarkan multikolinearitas dengan menggunakan matriks korelasi. Berdasarkan matriks korelasi, beberapa fitur pada Tabel 4 menunjukkan korelasi tinggi. Pada pasangan fitur dengan korelasi tinggi ($r > 0.9$), yaitu hematokrit dan hemoglobin, serta MCH dan MCV, dipilih untuk menghapus hemoglobin dan MCV berdasarkan hasil percobaan kombinasi fitur yang lebih baik. Kedua model kembali dilatih menggunakan parameter default dengan delapan fitur hasil laboratorium darah, hematokrit, eritrosit, leukosit, trombosit, MCH, MCHC, usia dan jenis kelamin hingga memperoleh *confusion matrix* dan ROC-AUC pada Gambar 6 dan Gambar 7.

Tabel 4. Korelasi Fitur

No	Variabel	Nilai Korelasi
1	Hematokrit Hemoglobin	0,97
2	Hematokrit Eritrosit	0,86
3	Hemoglobin Eritrosit	0,82
4	MCH MCHC	0,59
5	MCH MCV	0,93

Random Forest memprediksi 308 pasien sebagai rawat inap dan 575 pasien sebagai rawat jalan, sementara *XGBoost* memprediksi 302 pasien rawat inap dan 581 pasien rawat jalan.




Gambar 6. *Random Forest* dan XGBoost

3.2.3 Pengaturan Parameter Seluruh Variabel

Skenario ketiga dilakukan dengan pengaturan parameter menggunakan *GridSearchCV* pada seluruh variabel tanpa penghapusan fitur. *GridSearchCV* akan menguji kombinasi parameter yang telah ditentukan, dan setiap kombinasi dievaluasi menggunakan 5-fold *cross-validation*, di mana data dibagi menjadi lima subset. Setiap subset secara bergantian digunakan sebagai data uji, sementara empat subset lainnya digunakan sebagai data latih. Dari hasil pengujian semua kombinasi parameter, akan diperoleh parameter terbaik yang digunakan untuk membangun model final.

a. Random Forest


Hasil pengujian kombinasi parameter menggunakan *Grid Search Values* menunjukkan nilai terbaik parameter, yaitu $max_features = \text{sqrt}$, $n_estimators = 500$, $max_depth = 9$, $min_samples_leaf = 4$, $min_samples_split = 5$, dan $criterion = \text{entropy}$. Dengan kombinasi parameter ini, *random Forest* memprediksi 343 pasien rawat inap dan 540 pasien rawat jalan hingga memperoleh *confusion matrix* dan ROC-AUC pada Gambar 8.



Gambar 7. Confusion Matrix dan ROC-AUC Random Forest

b. XGBoost

Hasil tuning menunjukkan kombinasi parameter terbaik pada $n_estimators = 300$, $max_depth = 4$, $min_child_weight = 1$, $learning_rate = 0.025$, $gamma = 1.0$, $subsample = 1.0$, dan $colsample_bytree = 1.0$. Parameter dipilih karena memberikan performa terbaik berdasarkan evaluasi pada data latih, memprediksi 280 pasien rawat inap dan 603 pasien rawat jalan sehingga memperoleh *confusion matrix* dan ROC-AUC pada Gambar 9.



Gambar 8. Confusion Matrix dan ROC-AUC XGBOOST

3.3 Hasil Pengujian

Model final dari setiap skenario kemudian diuji menggunakan data uji sebanyak 883 sampel dengan komposisi 374 pasien rawat inap dan 509 pasien rawat jalan. Hasil prediksi model pada tiap skenario dirangkum dalam Tabel 5.

Tabel 5. Hasil Confusion Matrix

Metrik	Random Forest			XGBoost		
	Default	Feature selection	Tuning	Default	Feature selection	Tuning
TP	238	238	250	242	225	212
FN	136	136	124	132	149	162
FP	72	70	93	83	77	68
TN	437	439	416	426	432	441

Hasil *confusion matrix* dari ketiga skenario tersebut menunjukkan performa keseluruhan model pada Tabel 6, mencakup metrik akurasi, presisi kelas rawat inap dan rawat jalan, *recall* rawat inap dan rawat jalan, *F1-score* rawat inap dan rawat jalan serta ROC-AUC.

Tabel 6. Hasil Pengujian Model *Random Forest* dan *XGBoost*


Metrik	<i>Random Forest</i>			<i>XGBoost</i>		
	<i>Default</i>	<i>Feature selection</i>	<i>Tuning</i>	<i>Default</i>	<i>Feature selection</i>	<i>Tuning</i>
Akurasi	76%	77%	75%	76%	74%	74%
AUC	81%	81%	81%	80%	80%	80%
Presisi – 0	77%	64%	73%	74%	75%	76%
Presisi – 1	76%	86%	77%	76%	74%	73%
<i>Weighted</i>	76%	77%	75%	76%	74%	74%
<i>Recall</i> – 0	64%	64%	67%	65%	60%	57%
<i>Recall</i> - 1	86%	86%	82%	84%	85%	87%
<i>Weighted</i>	76%	77%	75%	76%	74%	74%
<i>F1-Score</i> – 0	70%	70%	70%	69%	67%	65%
<i>F1-Score</i> – 1	81%	81%	79%	80%	79%	79%
<i>Weighted</i>	76%	76%	75%	75%	74%	79%

Analisis ketiga skenario pemodelan menunjukkan perbedaan respon algoritma *Random Forest* dan *XGBoost* terhadap perubahan konfigurasi. Untuk *Random Forest*, kondisi *default* dengan seluruh variabel telah memberikan performa yang baik dan kuat sebagai *baseline*, dengan akurasi 76% dan *weighted F1-score* 76%. Hal ini menunjukkan bahwa model mampu mengenali dengan baik pola data pasien secara seimbang antara kelas rawat inap dan rawat jalan. Penerapan *feature selection* sedikit meningkatkan akurasi menjadi 77% dan mempertahankan *weighted F1-score* di 76%, menandakan bahwa penghapusan fitur bermultikolinearitas tinggi memperkuat kemampuan model dalam mengenali pasien rawat jalan tanpa mengorbankan performa kelas rawat inap, dengan *recall* dan *F1-score* stabil. Pada skenario *tuning*, akurasi turun sedikit menjadi 75% dan *weighted F1-score* 75%. Menandakan bahwa penyesuaian parameter *Random Forest* sedikit mempengaruhi distribusi prediksi antar kelas. Perubahan relatif kecil karena *baseline* model sudah cukup optimal sehingga *tuning* parameter tidak memberikan peningkatan yang signifikan. Dengan menghapus hemoglobin dan MCV, model *Random Forest default* menjadi konfigurasi terbaik.

Sementara itu, untuk *XGBoost*, kondisi *default* dengan seluruh variabel juga memberikan performa *baseline* yang baik dengan akurasi 76% dan *weighted F1-score* 75%. Hal ini menunjukkan bahwa model mampu mengenali pola data pasien secara seimbang antara kelas rawat inap dan rawat jalan, meskipun kemampuan mendeteksi pasien rawat inap sedikit lebih rendah dibanding kelas rawat jalan, *recall* kelas 0 sebesar 65% dan *F1-score* 69%. Penerapan *feature selection* menurunkan akurasi menjadi 74% dan *weighted F1-score* menurun di 74%, menunjukkan bahwa penghapusan fitur justru mengurangi kemampuan model dalam mengenali pasien rawat inap, *recall* turun menjadi 60% dan *F1-score* 67%. Hal ini menandakan *XGBoost* cukup sensitif terhadap penghapusan fitur penting yang kemungkinan memiliki kontribusi prediktif pada kelas minoritas. Sementara itu, performa kelas rawat jalan tetap relatif stabil dengan *recall* meningkat sedikit menjadi 85% dan *F1-score* 79%, menunjukkan distribusi prediksi lebih baik pada kelas mayoritas. Pada skenario *tuning*, performa *XGBoost* menunjukkan *weighted F1-score* meningkat menjadi 79%, meskipun akurasi keseluruhan tetap stabil di 74%. Namun, *recall* kelas rawat inap turun menjadi 57%, menandakan kemampuan model dalam mendeteksi pasien rawat inap menurun. Dengan demikian, optimasi parameter meningkatkan performa secara keseluruhan, namun model menjadi kurang sensitif terhadap kelas minoritas yaitu rawat inap.

3.4 Pembahasan

Hasil seluruh skenario pemodelan pada Tabel 6 menunjukkan bahwa kondisi terbaik diperoleh pada *Random Forest* dengan parameter *default* dan *feature selection*, serta *XGBoost* dengan parameter *default* seluruh variabel. Performa kedua model ditampilkan melalui *Confusion matrix* dan *ROC Curve* pada Gambar 10 dan Gambar 11. Gambar 10 menunjukkan bahwa *Random Forest* mampu memprediksi 238 dari 374 pasien rawat inap, dan 439 dari 509 pasien rawat jalan. Sementara itu, Gambar 11 menunjukkan *XGBoost* berhasil memprediksi 242 pasien rawat inap dan 426 pasien rawat jalan.



Gambar 9. *Random Forest dan XGBoost*

Hasil *Confusion Matrix* dan ROC-AUC menunjukkan *Random Forest* memiliki performa yang lebih baik dibandingkan dengan *XGBoost*. *Random Forest* memberikan akurasi dan AUC tertinggi, 77% dan 81%, menunjukkan performa yang baik. Pada kelas rawat inap(0), presisi dan *recall* 64% serta *f1-score* 70% menunjukkan kemampuan yang cukup baik dalam mengenali pasien rawat inap meski sensitivitas sedikit lebih rendah. Sementara pada kelas rawat jalan(1), performa meningkat dengan presisi 86%, *recall* 86%, dan *F1-score* 81%, sehingga keseimbangan antarkelas dinilai cukup baik dengan rata-rata *F1-Score* 76%. Sedangkan *XGBoost* juga memberikan performa yang baik melalui akurasi 76% dan AUC 80%. Model menunjukkan keseimbangan performa antar kelas yang cukup baik 75%, dengan presisi 74%, *recall* 65%, dan *F1-score* pada kelas rawat inap(0). Sedangkan pada kelas rawat jalan diperoleh presisi 76%, *recall* 84% dan *F1-score* 80%. Kinerja kedua model ini didukung oleh kontribusi fitur-fitur laboratorium darah, seperti trombosit, hematokrit, dan leukosit secara konsisten menjadi variabel berpengaruh dalam proses pengambilan keputusan perawatan pasien.

Selain itu, hasil penelitian ini konsisten dengan penelitian [15],[16],[38], yang menunjukkan bahwa *Random Forest* memiliki performa lebih unggul dibandingkan *XGBoost* terutama pada konfigurasi *default*, meskipun diterapkan pada berbagai skema pengujian data. Temuan ini sejalan dengan penelitian ini yang menunjukkan bahwa *Random Forest* memiliki baseline yang kuat dan stabil, sehingga mampu mempertahankan performa tanpa memerlukan konfigurasi kompleks atau tuning berlebihan.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa dari tiga skenario pemodelan yang diterapkan, *Random Forest* sedikit lebih baik dibandingkan *XGBoost* dalam menentukan jenis perawatan pasien berdasarkan hasil pemeriksaan laboratorium darah, meskipun perbedaan performanya relatif tipis dan masih kompetitif. Unjuk kerja *Random Forest* pada konfigurasi *default* dengan *feature selection* memberikan hasil terbaik dengan akurasi 77%, presisi 77%, *recall* 77%, dan *F1-Score* 76%, serta mampu meningkatkan akurasi tanpa menurunkan kemampuan mengenali pasien rawat inap. Sementara itu, *XGBoost* menunjukkan performa optimal pada kondisi *default* dengan seluruh variabel, dengan akurasi 76%, AUC 80%, presisi 76%, *recall* 76%, dan *F1-Score* 75%, namun sensitif terhadap penghapusan fitur. Proses tuning parameter kedua metode tidak memberikan peningkatan performa maupun kemampuan deteksi rawat inap, bahkan meningkatkan kompleksitas model dan beban komputasi. Secara keseluruhan, *Random Forest* menunjukkan stabilitas yang lebih baik dengan konfigurasi model yang relatif sederhana. Keterbatasan penelitian ini terletak pada teknik *feature selection* yang masih terbatas pada analisis multikolinearitas, sehingga penelitian selanjutnya disarankan untuk menerapkan metode *feature selection* lain serta optimasi parameter yang sepadan dengan karakteristik data dan peningkatan performa yang dihasilkan. Penulis mengucapkan terima kasih kepada Fakultas Teknologi Informasi Universitas Kristen Duta Wacana atas dukungan pendanaan yang diberikan dalam publikasi penelitian ini.

REFERENCES

- [1] D. Dady, K. Ayu Erika, and R. Rachmawaty, "Support system in the making of nursing clinical decisions in the hospital room: a literature review," *Jurnal Ilmu Kesehatan*, vol. 8, no. 2, pp. 173–181, 2020, doi: 10.1136/bmjopen-2023-080208.
- [2] M. K. Glette, "General practitioners decision making in questions of hospital admissions — a review of the literature," in *Safety and Reliability – Theory and Applications*, Cepin and Bris, Eds., London: Taylor & Francis Group, 2017, pp. 2467–2472. doi: 10.1201/9781315210469-311.
- [3] T. Trinh, A. Elfergani, and M. Bann, "Qualitative analysis of disposition decision making for patients referred for admission from the emergency department without definite medical acuity," *BMJ Open*, vol. 11, pp. 1–9, 2021, doi: 10.1136/bmjopen-2020-046598.
- [4] J. Riyono, C. E. Pujiastuti, D. Prayitno, A. Latifa, and R. Putri, "Decision tree for determining hospital treatment for COVID-19 patients based on hematology parameters using the C5.0 algorithm," *JISA (Jurnal Informatika dan Sains)*, vol. 07, no. 02, pp. 125–132, 2024, doi: https://doi.org/10.31326/jisa.v7i2.2103.

- [5] K. Paser, A. Salsabila, C. A. Gunawan, and H. Irawiraman, “Profil hematologi pasien malaria rawat inap di RSUD Panglima Sebaya Kabupaten Paser periode Januari 2015–Maret 2018,” *JSK (Jurnal Sains dan Kesehatan)*, vol. 3, no. 4, pp. 551–557, 2021, doi: <https://doi.org/10.25026/jsk.v3i4.535>.
- [6] N. Adinda, I. Jaenuddin, and S. Surdianah, “Pemeriksaan darah lengkap pada sampel pasien dengan metode otomatis dan metode Westergren di Balai Besar Laboratorium Kesehatan Makassar (BBLK Makassar) di Indonesia,” *Filogeni(Jurnal Mahasiswa Biologi)*, vol. 4, no. 3, pp. 205–214, 2024.
- [7] Y. J. Simatupang and Rr. T. S. Hariyati, “Dampak penggunaan electronic health record terhadap tingkat kepuasan pasien: sebuah tinjauan literatur,” *Jurnal Persatuan Perawat Nasional Indonesia (JPPNI)*, vol. 9, no. 2, pp. 103–115, Dec. 2024, doi: [10.32419/jppni.v9i2.536](https://doi.org/10.32419/jppni.v9i2.536).
- [8] H. Crc and H. Informatics, *Statistics and Machine Learning Methods for EHR Data*. CRC Press, 2021. doi: [10.1201/9781003030003](https://doi.org/10.1201/9781003030003).
- [9] A. F. Nasution and P. A. Juledi, “Penerapan algoritma random forest untuk klasifikasi tingkat keparahan penyakit pada data rekam medis,” *Jurnal of Computer Science and Information Systems (JCoInS)*, vol. 43, no. 3, pp. 47–58, 2025, doi: [10.36987/jcoins.v6i3.7993](https://doi.org/10.36987/jcoins.v6i3.7993).
- [10] M. I. Sodikin, “Penerapan dan manfaat machine learning di rumah sakit,” *Multiverse: Open Multidisciplinary Journal*, vol. 2, no. 2, pp. 262–265, Aug. 2023, doi: [10.57251/multiverse.v2i2.1207](https://doi.org/10.57251/multiverse.v2i2.1207).
- [11] A. Sindar Sinaga, S. Ramen, S. Mulyani, K. Kunci, M. Bayi, and E. Metode, “Teknik ensemble dalam machine learning untuk menentukan tingkat akurasi perkembangan motorik bayi 0–12 bulan,” *Jurnal Saintikom (Jurnal Sains Manajemen Informatika dan Komputer)*, vol. 23, no. 2, pp. 418–425, Aug. 2024, doi: [10.53513/jis.v23i2.10059](https://doi.org/10.53513/jis.v23i2.10059).
- [12] A. S. More and D. P. Rana, “Review of Random Forest classification techniques to resolve data imbalance,” in *ICISIM(International Conference on Intelligent Systems and Information Management)*, 2017, pp. 72–78. doi: [10.1109/ICISIM.2017.8122151](https://doi.org/10.1109/ICISIM.2017.8122151).
- [13] M. R. Ansyari, M. I. Mazdadi, F. Indriani, D. Kartini, and T. H. Saragih, “mplementation of random forest and extreme gradient boosting in the classification of heart disease using particle swarm optimization feature selection,” *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, vol. 5, no. 4, pp. 250–260, 2023, doi: [10.35882/jeemi.v5i4.322](https://doi.org/10.35882/jeemi.v5i4.322).
- [14] L. R. Sitompul, A. A. Nababan, M. L. Manihuruk, W. A. Ponsen, and S. Supriyandi, “omparison of XGBoost, Random Forest and Logistic Regression algorithms in stroke disease classification,” *Sinkron*, vol. 9, no. 2, pp. 957–968, 2025, doi: [10.33395/sinkron.v9i2.14794](https://doi.org/10.33395/sinkron.v9i2.14794).
- [15] J. P. Anggraini, Chaya Gladys Zhafirah A, and A. Desiani, “Perbandingan algoritma Random Forest dan Extreme Gradient Boosting (XGBoost) dalam klasifikasi penyakit gagal jantung,” *Komputika : Jurnal Sistem Komputer*, vol. 14, no. 2, pp. 149–157, 2025, doi: [10.34010/komputika.v14i2.16618](https://doi.org/10.34010/komputika.v14i2.16618).
- [16] R. Harahap, M. Irpan, M. A. Dinata, L. Efrizoni, and Rahmaddeni, “Perbandingan algoritma Random Forest dan XGBoost klasifikasi penyakit jantung berdasarkan data medis,” *Betrik*, vol. 15, no. 02, pp. 130–141, 2024, doi: [10.37859/jf.v15i2.9927](https://doi.org/10.37859/jf.v15i2.9927).
- [17] M. Linda, T. Alfianti, and R. Supriyanto, “Perbandingan kinerja algoritma Random Forest, AdaBoost, dan XGBoost dalam memprediksi risiko penyakit osteoporosis,” *Ilmu Komputer Agri-Informatika*, vol. 11, no. 2, pp. 173–183, 2024, doi: [10.29244/jika.11.2.172-184](https://doi.org/10.29244/jika.11.2.172-184).
- [18] B. Septian Cahya Putra, I. Tahyudin, B. Adhi Kusuma, and K. Nur Isnaini, “Efektivitas algoritma Random Forest, XGBoost, dan Logistic Regression dalam prediksi penyakit paru-paru,” *Jurnal Techno.COM*, vol. 23, no. 4, pp. 909–922, Nov. 2024, doi: [10.62411/tc.v23i4.11705](https://doi.org/10.62411/tc.v23i4.11705).
- [19] F. Aziz, A. Wahab, and P. Muna, “Penerapan metode machine learning untuk mengklasifikasi penanganan perawatan pasien,” *JOPACS(Journal Pharmacy and Application of Computer Sciences)*, vol. 1, no. 2, pp. 57–62, 2023, doi: <https://doi.org/10.59823/jopacs.v1i2.37>.
- [20] D. B. Saputra, V. Atina, F. E. Nastiti, and F. I. Komputer, “Penerapan model CRISP-DM pada prediksi nasabah kredit menggunakan algoritma Random Forest,” *Idealis: Indonesia Journal Information System*, vol. 7, no. 2, pp. 240–247, Jul. 2024, doi: [10.36080/idealis.v7i2.3244](https://doi.org/10.36080/idealis.v7i2.3244).
- [21] A. N. Chary, A. Bhananker, B. Torres, V. S. Martell, M. N. Shah, and A. D. Naik, “Older adults’ experiences of emergency department admission decisions: a qualitative study in a public safety net hospital,” *J. Gen. Intern. Med.*, vol. 40, no. 7, pp. 1567–1575, 2025, doi: [10.1007/s11606-024-09250-3](https://doi.org/10.1007/s11606-024-09250-3).
- [22] W. E. Herter *et al.*, “Impact of a machine learning-based decision support system for urinary tract infections: prospective observational study in 36 primary care practices,” *JMIR Med. Inform.*, vol. 10, no. 5, pp. 1–15, 2022, doi: [10.2196/27795](https://doi.org/10.2196/27795).
- [23] F. Orhan and M. N. Kurutkan, “redicting total healthcare demand using machine learning: separate and combined analysis of predisposing, enabling, and need factors,” *BMC Health Serv. Res.*, vol. 25, no. 1, pp. 1–27, 2025, doi: [10.1186/s12913-025-12502-5](https://doi.org/10.1186/s12913-025-12502-5).
- [24] W. Hong *et al.*, “A comparison of XGBoost, Random Forest, and nomograph for the prediction of disease severity in patients with COVID-19 pneumonia: implications of cytokine and immune cell profile,” *Front. Cell. Infect. Microbiol.*, vol. 12, no. April, pp. 1–13, 2022, doi: [10.3389/fcimb.2022.819267](https://doi.org/10.3389/fcimb.2022.819267).
- [25] M. Sadikin, “EHR dataset for patient treatment classification,” Mendeley Data, 2020.
- [26] N. Maulidah, “Prediksi peningkatan jumlah nasabah deposito berjangka menggunakan algoritma KNN, Decision Tree, Random Forest dan XGBoost,” *InComTech : Jurnal Telekomunikasi dan Komputer*, vol. 13, no. 2, p. 90, 2023, doi: [10.22441/incomtech.v13i2.16921](https://doi.org/10.22441/incomtech.v13i2.16921).

- [27] D. A. Murtiningsih, W. Sari, and I. N. Fajri, “Comparison of Light Gradient Boosting machine, Extreme Gradient Boosting, and CatBoost with balancing and hyperparameter tuning for hypertension risk prediction on clinical dataset,” *JAIC(Journal of Applied Informatics and Computing)*, vol. 9, no. 5, p. 2753, 2025, doi: 10.30871/jaic.v9i5.10400.
- [28] E. Prasetyo, B. Prasetyo, and P. Korespondensi, “Peningkatan akurasi klasifikasi algoritma C4.5 menggunakan teknik bagging pada diagnosis penyakit jantung,” *JTIK(Jurnal Teknologi Informasi dan Ilmu komputer)*, vol. 7, no. 5, pp. 1035–1040, Oct. 2020, doi: 10.25126/jtiik.202072379.
- [29] K. Aditya Ananta Wisnu Wardana and A. A. Mizwar Rahim, “Analisis perbandingan algoritma XGBoost dan algoritma Random Forest untuk klasifikasi data kesehatan mental,” *LOGIC : Jurnal Ilmu Komputer dan Pendidikan*, vol. 2, no. 5, pp. 808–818, Aug. 2024, doi: 10.36050/3v3xwn06.
- [30] D. T. Murdiansyah, “Prediksi stroke menggunakan Extreme Gradient Boosting,” *JIKO (Jurnal Informatika dan Komputer)*, vol. 8, no. 2, p. 419, Sep. 2024, doi: 10.26798/jiko.v8i2.1295.
- [31] Y. Rombe, S. A. Thamrin, and A. Lawi, “Application of Adaptive Synthetic Nominal and Extreme Gradient Boosting Methods in Determining Factors Affecting Obesity: A Case Study of Indonesian Basic Health Research Survey 2013,” *Indonesian Journal of Statistics and Its Applications*, vol. 6, no. 2, pp. 309–317, 2022, doi: 10.29244/ijsa.v6i2p309-317.
- [32] A. Khairunnisa, “Perbandingan model Random Forest dan XGBoost untuk prediksi kejahatan kesusilaan di provinsi Jawa Barat,” *JIKO (Jurnal Informatika dan Komputer)*, vol. 7, no. 2, p. 202, Sep. 2023, doi: 10.26798/jiko.v7i2.799.
- [33] R. D. Mendrofa, M. H. Siallagan, J. Amalia, and D. P. Pakpahan, “Credit risk analysis with Extreme Gradient Boosting and Adaptive Boosting algorithm,” *Journal of Information System, Graphics, Hospitality and Technology*, vol. 5, no. 1, pp. 1–7, Mar. 2023, doi: 10.37823/insight.v5i1.233.
- [34] Budi Sunarko, Agung Adi Firdaus, Yudha Andriano Rismawan, and Anan Nugroho, “Analysis of facial areas to identify CHD risks based on facial textures,” *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 14, no. 1, pp. 69–76, 2025, doi: 10.22146/jnteti.v14i1.13658.
- [35] M. H. Atan et al., “Automated detection of unattended children via deep learning,” *Journal of Advanced Research in Applied Sciences and Engineering Technology*, vol. 3, no. 3, pp. 11–20, 2026, doi: 10.37934/araset.62.3.1120.
- [36] J. Ben Temones, L. Domanais, J. C. De La Cruz, A. J. Timado, E. Codecio, and M. G. Llonado, “Machine learning-based teacher education student placement model via interest profile and diagnostic test,” *Journal of Education Research*, vol. 6, no. 1, pp. 223–232, 2025, doi: 10.37985/jer.v6i1.2331.
- [37] G. Sambasivam, G. Prabu kanna, M. S. Chauhan, P. Raja, and Y. Kumar, “A hybrid deep learning model approach for automated detection and classification of cassava leaf diseases,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–24, 2025, doi: 10.1038/s41598-025-90646-4.
- [38] E. Sastra Ompusunggu, A. Nainggolan, M. K. Sihombing, F. Sains, and D. Teknologi, “Penentuan kelayakan promosi pegawai menggunakan algoritma Random Forest classifier dan XGBoost classifier,” *Jurnal TEKINKOM*, vol. 6, no. 2, pp. 773–783, 2023, doi: 10.37600/tekinkom.v6i2.949.