

Artikel Penelitian (Teknik Informatika)

## Komparasi Algoritma Machine Learning dengan SMOTE untuk Prediksi Retensi Donor Darah

Wisnu Dwi Gumilang<sup>\*</sup>, Riana Safitri, Lutvi Riyandari

Teknik Informatika, STMIK Widya Utama, Purwokerto, Indonesia

### INFORMASI ARTIKEL

Diterima Redaksi: 23 Maret 2026  
Revisi Akhir: 12 April 2026  
Diterbitkan Online: 18 April 2026

### KATA KUNCI

Ketidakseimbangan Kelas  
Machine Learning  
SMOTE

### KORESPONDENSI<sup>(\*)</sup>

Phone: +62 896-3051-0678  
E-mail: [wisnudwigumilang@gmail.com](mailto:wisnudwigumilang@gmail.com)

### A B S T R A K

Ketersediaan pasokan darah yang memadai merupakan tantangan kritis dalam sistem pelayanan kesehatan, di mana rendahnya tingkat retensi donor menjadi salah satu faktor utama penyebab kekurangan pasokan. Penelitian ini membandingkan performa empat algoritma machine learning, yaitu K-Nearest Neighbor, Random Forest, Support Vector Machine, dan Decision Tree, dalam memprediksi retensi donor darah pada dataset Blood Transfusion Service Center UCI yang terdiri dari 748 sampel. Ketidakseimbangan kelas pada dataset dengan rasio 1:3,2 ditangani menggunakan Synthetic Minority Oversampling Technique (SMOTE). Eksperimen dilakukan pada dua kondisi, yaitu tanpa SMOTE sebagai baseline dan dengan SMOTE, menggunakan pembagian data 80:20 dengan stratified split. Evaluasi dilakukan menggunakan metrik accuracy, precision, Recall, F1-score, dan AUC-ROC. Hasil eksperimen menunjukkan bahwa SMOTE secara konsisten meningkatkan Recall dan F1-score pada tiga dari empat algoritma meskipun diikuti penurunan accuracy. Sebagai contoh, pada SVM, accuracy turun dari 0,7733 menjadi 0,7000, namun Recall meningkat secara dramatis dari 0,0833 menjadi 0,7778, yang menunjukkan trade-off antara akurasi keseluruhan dengan kemampuan deteksi donor potensial. Support Vector Machine dengan SMOTE diidentifikasi sebagai model terbaik dengan Recall 0,7778, F1-score 0,5545, dan AUC 0,769, mengungguli seluruh algoritma yang diuji. Temuan ini mengkonfirmasi dan memperluas studi sebelumnya dengan membuktikan bahwa dampak SMOTE bervariasi secara signifikan antar algoritma, dari peningkatan dramatis pada SVM hingga penurunan performa pada Decision Tree. Secara praktis, model SVM+SMOTE dapat diimplementasikan oleh bank darah dan pusat layanan transfusi untuk mengoptimalkan strategi retensi donor, meningkatkan efisiensi kampanye rekrutmen ulang, dan membantu strategi manajemen stok darah melalui prediksi donor yang berpotensi kembali berdonasi.

### PENDAHULUAN

Ketersediaan pasokan darah yang memadai merupakan komponen kritis dalam sistem pelayanan kesehatan modern. Menurut World Health Organization [1], sekitar 118,5 juta donasi darah dikumpulkan secara global setiap tahunnya dengan distribusi yang tidak merata, di mana 40% donasi terkumpul di negara berpenghasilan tinggi yang hanya merepresentasikan 16% populasi dunia, dengan kesenjangan signifikan dalam tingkat donasi antara negara berpenghasilan tinggi (31,5 per 1000 penduduk) dan negara berpenghasilan rendah (5,0 per 1000 penduduk). Kekurangan pasokan darah ini menyebabkan penundaan perawatan medis vital bagi pasien yang membutuhkan transfusi [2]. Rendahnya tingkat retensi donor menciptakan tantangan besar bagi bank darah, mengingat biaya dan upaya rekrutmen donor baru jauh lebih tinggi dibandingkan mempertahankan donor eksisting [3].

Dalam menghadapi tantangan retensi donor, pendekatan berbasis machine learning telah menunjukkan potensi yang menjanjikan. Algoritma machine learning mampu menganalisis dataset besar untuk memprediksi pola donasi masa depan

dan mengidentifikasi donor dengan probabilitas tinggi untuk berdonasi kembali, sehingga bank darah dapat merencanakan strategi rekrutmen dan retensi secara lebih efektif [4] [5]. Namun, sebagian besar penelitian yang ada masih memiliki keterbatasan dalam cakupan metodologisnya, khususnya dalam menangani permasalahan ketidakseimbangan kelas yang umum ditemukan pada dataset donor darah dan dalam membandingkan performa berbagai algoritma secara komprehensif. Penelitian ini bertujuan untuk membandingkan performa empat algoritma machine learning, yaitu Random Forest, Decision Tree, K-Nearest Neighbor, dan Support Vector Machine, dalam memprediksi retensi donor darah pada dataset donor darah UCI. Selain itu, penelitian ini bertujuan untuk menganalisis pengaruh penerapan teknik Synthetic Minority Oversampling Technique (SMOTE) terhadap performa masing-masing algoritma dalam menangani ketidakseimbangan kelas pada dataset tersebut, serta mengidentifikasi algoritma yang paling optimal untuk digunakan dalam prediksi retensi donor darah setelah penerapan SMOTE.

Penelitian ini memberikan dua kontribusi utama. Pertama, secara teoritis, penelitian ini berkontribusi dalam memperluas pemahaman mengenai efektivitas penerapan SMOTE pada berbagai algoritma machine learning untuk prediksi retensi donor darah, melengkapi studi sebelumnya yang hanya mengevaluasi SMOTE pada algoritma SVM. Dibandingkan dengan Widyanto et al [6], yang hanya mengevaluasi satu algoritma (SVM) dengan SMOTE pada dataset yang sama, penelitian ini membandingkan empat algoritma sekaligus (Random Forest, Decision Tree, K-Nearest Neighbor, dan Support Vector Machine) dalam satu kerangka kerja SMOTE yang konsisten. Pendekatan komparatif ini memberikan beberapa kelebihan: (1) memungkinkan identifikasi algoritma yang paling responsif terhadap SMOTE, (2) mengungkap variasi respons antar algoritma yang tidak terlihat pada studi single-algorithm, dan (3) memberikan rekomendasi berbasis bukti empiris mengenai kombinasi algoritma-SMOTE yang optimal untuk dataset donor darah UCI. Hasil perbandingan komprehensif antara Random Forest, Decision Tree, K-Nearest Neighbor, dan Support Vector Machine dengan dan tanpa SMOTE diharapkan dapat menjadi rujukan metodologis bagi penelitian selanjutnya di bidang prediksi perilaku donor darah. Kedua, secara praktis, penelitian ini menghasilkan rekomendasi algoritma machine learning yang paling optimal untuk diimplementasikan dalam sistem prediksi retensi donor darah, yang dapat dimanfaatkan oleh bank darah dan lembaga transfusi darah dalam merancang strategi retensi donor yang lebih efektif dan berbasis data.

## TINJAUAN PUSTAKA

### *Machine Learning untuk Prediksi Retensi Donor Darah*

Algoritma machine learning mampu menganalisis dataset besar untuk memprediksi pola donasi masa depan dan mengidentifikasi donor dengan probabilitas tinggi untuk berdonasi kembali, sehingga bank darah dapat merencanakan strategi rekrutmen dan retensi secara lebih efektif [4] [5]. Pendekatan prediktif ini memungkinkan bank darah untuk mengoptimalkan kampanye retensi dengan menargetkan donor yang memiliki probabilitas tinggi untuk berdonasi kembali. Dengan demikian, machine learning menawarkan solusi potensial untuk mengatasi ketidakefisienan dalam strategi penargetan donor konvensional yang menggunakan pendekatan broadcast kepada seluruh database tanpa differensiasi, serta memberikan wawasan yang lebih mendalam tentang faktor-faktor yang mempengaruhi keputusan donor untuk kembali berdonasi.

Wu dkk. [5] membuktikan bahwa algoritma machine learning mampu memprediksi kesediaan donor untuk berdonasi kembali dengan akurasi yang baik, namun penelitian tersebut lebih berfokus pada konteks rekrutmen donor selama pandemi COVID-19 dan belum secara eksplisit menangani permasalahan ketidakseimbangan kelas yang umum ditemukan pada dataset donor darah.

### *Penanganan Ketidakseimbangan Kelas dengan SMOTE*

Permasalahan ketidakseimbangan data terbukti berdampak signifikan terhadap performa model klasifikasi. Widyanto dkk. [6] membuktikan bahwa penerapan SMOTE pada dataset donor darah UCI mampu meningkatkan performa Recall kelas minoritas secara drastis dari 2,8% menjadi 75,6% berdasarkan evaluasi 10-fold cross-validation. Namun demikian, studi tersebut hanya terbatas pada satu algoritma klasifikasi, yaitu Support Vector Machine, sehingga belum dapat memberikan gambaran komprehensif mengenai algoritma mana yang paling optimal ketika dikombinasikan dengan teknik penyeimbangan data.

Bukti empiris dari domain kesehatan yang lebih luas semakin memperkuat urgensi perluasan evaluasi ini. Agyemang dkk. [7] membuktikan bahwa seluruh teknik oversampling yang diujitermasuk SMOTE secara konsisten meningkatkan

kemampuan berbagai algoritma machine learning, meliputi KNN, SVM, Random Forest, dan Decision Tree, dalam mengklasifikasikan kelas minoritas pada data kesehatan yang tidak seimbang, meskipun belum pernah diterapkan pada konteks prediksi retensi donor darah.

### ***Komparasi Algoritma Machine Learning***

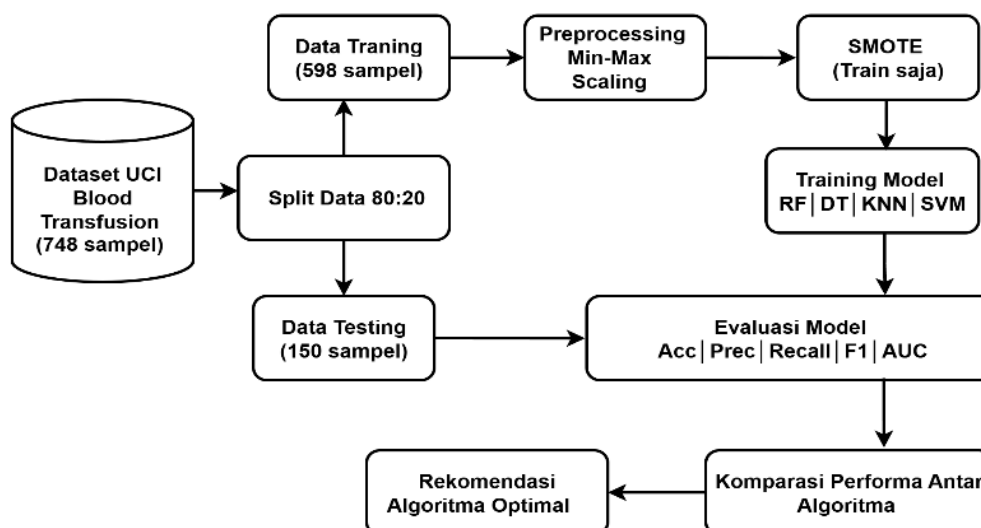
Mujahid dkk. [8] dalam evaluasi komprehensif terhadap kombinasi teknik oversampling dan enam algoritma machine learning menegaskan bahwa tidak ada satu kombinasi yang secara universal unggul di semua konteks, sehingga komparasi empiris pada domain spesifik termasuk prediksi retensi donor darah tetap merupakan kebutuhan penelitian yang mendesak.

### ***Kesenjangan Penelitian***

Dengan demikian, terdapat kesenjangan penelitian yang perlu diisi, yakni belum adanya studi yang secara sistematis membandingkan performa berbagai algoritma machine learning secara komprehensif, termasuk memperluas evaluasi SMOTE yang sebelumnya hanya diterapkan pada Support Vector Machine ke algoritma lain seperti Random Forest, Decision Tree, dan K-Nearest Neighbor untuk prediksi retensi donor darah pada dataset yang sama. Penelitian ini hadir untuk mengisi kesenjangan tersebut sekaligus memberikan rekomendasi algoritma yang paling optimal untuk digunakan dalam sistem prediksi retensi donor darah.

## **METODOLOGI**

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen komputasional untuk membandingkan performa empat algoritma machine learning dalam memprediksi retensi donor darah. Secara umum, penelitian ini terdiri dari beberapa tahapan utama. Pertama, dataset dibagi menjadi data training dan data testing dengan rasio 80:20. Kedua, data training melalui proses preprocessing menggunakan Min-Max Scaling untuk menormalisasi fitur, dilanjutkan dengan penerapan SMOTE untuk menangani ketidakseimbangan kelas. Ketiga, empat algoritma machine learning yaitu Random Forest, Decision Tree, K-Nearest Neighbor, dan Support Vector Machine dilatih menggunakan data training yang telah diproses. Keempat, model dievaluasi menggunakan data testing berdasarkan metrik Accuracy, Precision, Recall, F1-Score, dan AUC. Terakhir, performa antar algoritma dibandingkan untuk mengidentifikasi algoritma yang paling optimal. Alur penelitian secara keseluruhan digambarkan pada Gambar 1.



Gambar 1. Alur Penelitian

### ***Dataset***

Penelitian ini menggunakan dataset Blood Transfusion Service Center yang dikembangkan oleh Yeh [9] dan bersumber dari UCI Machine Learning Repository, diakses melalui platform Kaggle. Dataset ini berasal dari pusat layanan transfusi darah di Kota Hsin-Chu, Taiwan, yang mengumpulkan data donasi darah setiap tiga bulan sekali. Dataset terdiri dari 748 sampel dengan empat fitur input dan satu variabel target biner sebagaimana ditunjukkan pada Tabel 1.

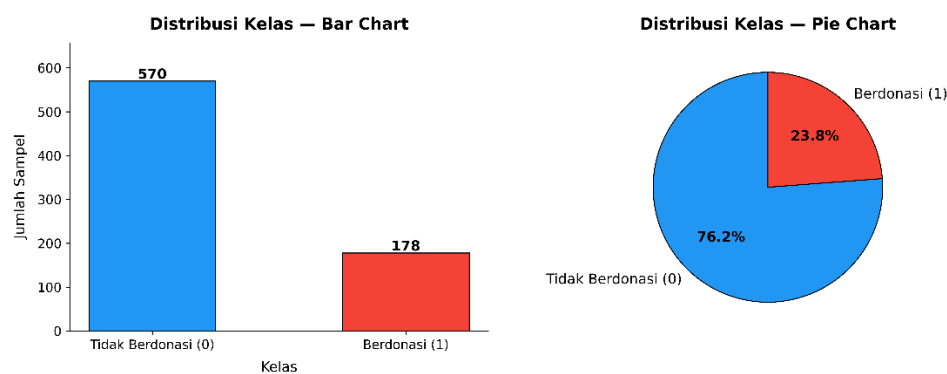
Keempat fitur input tersebut adalah Recency (R) yaitu jumlah bulan sejak terakhir berdonasi, Frequency (F) yaitu total jumlah donasi yang telah dilakukan, Monetary (M) yaitu total volume darah yang didonasikan dalam satuan cc, dan Time (T) yaitu jumlah bulan sejak pertama kali berdonasi [9]. Variabel target merepresentasikan apakah donor berdonasi pada Maret 2007, dengan nilai 1 untuk berdonasi dan 0 untuk tidak berdonasi. Hasil pemeriksaan awal menunjukkan bahwa dataset ini tidak memiliki missing value pada seluruh variabel, sehingga tidak diperlukan tahap imputasi data.

Distribusi kelas pada dataset ini tidak seimbang sebagaimana ditunjukkan pada Gambar 2, dengan 570 sampel (76,2%) termasuk kelas tidak berdonasi (0) dan 178 sampel (23,8%) termasuk kelas berdonasi (1), sehingga menghasilkan rasio ketidakseimbangan 1:3 [6]. Ketidakseimbangan kelas ini berpotensi menyebabkan model cenderung memprediksi kelas mayoritas dan mengabaikan kelas minoritas, sehingga menjadi justifikasi penerapan SMOTE dalam penelitian ini.

Tabel 1. Deskripsi Variabel Dataset

No	Fitur	Type Data	Satuan	Deskripsi	min	max	mean	std
1	Recency (R)	Numerik	Bulan	Bulan sejak terakhir berdonasi	0	74	9,51	8,10
2	Frequency (F)	Numerik	Kali	Total jumlah donasi	1	50	5,51	5,84
3	Monetary (M)	Numerik	cc	Total volume darah didonasikan	250	12.500	1.378,68	1.459,83
4	Time (T)	Numerik	Bulan	Bulan sejak pertama berdonasi	2	98	34,28	24,38
5	Class	Biner	-	1 = berdonasi, 0 = tidak berdonasi	0	1	-	-

Distribusi Kelas Dataset Blood Transfusion UCI

Gambar 2. Distribusi Kelas Dataset *Blood Transfusion* UCI

### Pembagian Data

Dataset yang terdiri dari 748 sampel dibagi menjadi data training dan data testing menggunakan rasio 80:20, menghasilkan 598 sampel untuk data training dan 150 sampel untuk data testing. Pembagian data dilakukan sebagai tahap pertama sebelum preprocessing untuk memastikan tidak terjadi kebocoran data (data leakage), di mana informasi statistik dari data testing tidak mempengaruhi proses pelatihan model. Pembagian data dilakukan secara terstratifikasi (stratified split) untuk mempertahankan proporsi distribusi kelas pada data training dan data testing. Data testing diasingkan sejak awal dan tidak disentuh hingga tahap evaluasi akhir.

### Preprocessing

Tahap preprocessing yang diterapkan dalam penelitian ini adalah normalisasi data menggunakan metode Min-Max Scaling. Normalisasi diperlukan karena keempat fitur input memiliki rentang nilai yang sangat berbeda, di mana fitur dengan rentang nilai besar berpotensi mendominasi hasil klasifikasi secara tidak proporsional [10], terutama pada algoritma berbasis jarak seperti K-Nearest Neighbor dan Support Vector Machine. Min-Max Scaling mentransformasikan seluruh nilai fitur ke dalam rentang 0 hingga 1 [10]. Proses fitting scaler dilakukan secara eksklusif pada data training,

sedangkan data testing hanya ditransformasikan menggunakan parameter scaler yang diperoleh dari data training untuk menghindari kebocoran data.

### **SMOTE**

Synthetic Minority Over-sampling Technique (SMOTE) merupakan metode oversampling yang bekerja dengan cara membuat sampel sintesis baru pada kelas minoritas, bukan sekadar menduplikasi sampel yang sudah ada [11]. Sampel sintesis dibuat dengan menginterpolasi setiap sampel minoritas dengan tetangga terdekatnya dalam ruang fitur, sehingga wilayah keputusan kelas minoritas menjadi lebih general dan tidak terlalu spesifik [11]. SMOTE dipilih sebagai metode penanganan ketidakseimbangan kelas dibandingkan metode alternatif seperti Random Under-sampling karena beberapa alasan. Pertama, Random Under-sampling mengurangi ukuran dataset dengan membuang sampel kelas mayoritas, yang berpotensi menghilangkan informasi penting dan mengurangi kemampuan generalisasi model [7], terutama pada dataset berukuran kecil seperti dataset donor darah UCI yang hanya memiliki 748 sampel [9]. Kedua, SMOTE mempertahankan seluruh informasi dari data asli sambil memperkaya representasi kelas minoritas melalui interpolasi, sehingga model dapat mempelajari wilayah keputusan kelas minoritas secara lebih robust tanpa kehilangan variabilitas data [11]. Ketiga, penelitian sebelumnya oleh Widyanto dkk. [6] telah membuktikan efektivitas SMOTE pada dataset yang sama dengan peningkatan Recall SVM dari 2,8% menjadi 75,6%, sehingga pemilihan SMOTE memungkinkan komparabilitas hasil dengan studi referensi.

Dalam penelitian ini, SMOTE diterapkan secara eksklusif pada data training untuk menghindari kebocoran data, sehingga data testing tetap mencerminkan distribusi kelas asli [11]. Penerapan SMOTE pada data training bertujuan untuk menyeimbangkan distribusi kelas sebelum proses pelatihan model, mengingat dataset memiliki ketidakseimbangan kelas dengan rasio 1:3,2 antara kelas minoritas dan kelas mayoritas [9].

### **Algoritma Machine Learning**

Penelitian ini membandingkan performa empat algoritma machine learning yang umum digunakan dalam klasifikasi, yaitu Random Forest, Decision Tree, K-Nearest Neighbor, dan Support Vector Machine. Random Forest merupakan algoritma ensemble yang membangun sejumlah pohon keputusan secara paralel menggunakan teknik bagging, di mana setiap pohon dilatih pada subset data yang diambil secara acak dengan pengembalian. Hasil prediksi akhir ditentukan melalui mekanisme voting mayoritas dari seluruh pohon yang dibangun. Algoritma ini memiliki kemampuan untuk menilai tingkat kepentingan setiap fitur dalam proses klasifikasi dan telah terbukti efektif dalam berbagai aplikasi prediksi risiko karena sifatnya yang robust terhadap overfitting dibandingkan pohon keputusan tunggal.

Decision Tree merupakan algoritma klasifikasi berbasis pohon yang membagi data secara rekursif berdasarkan nilai fitur menggunakan kriteria pemisahan seperti Gini impurity atau information gain. Keunggulan utama algoritma ini terletak pada interpretabilitasnya, di mana struktur pohon keputusan dapat dipahami dengan relatif mudah dan memungkinkan visualisasi proses pengambilan keputusan secara langsung tanpa transformasi tambahan.

K-Nearest Neighbor (KNN) mengklasifikasikan sampel baru berdasarkan kelas mayoritas dari k tetangga terdekat dalam ruang fitur menggunakan perhitungan jarak seperti jarak Euclidean. Akurasi KNN sangat sensitif terhadap perbedaan skala antar fitur, di mana fitur dengan rentang nilai yang lebih besar cenderung mendominasi perhitungan jarak secara tidak proporsional [12]. Oleh karena itu, normalisasi data menggunakan Min-Max Scaling yang diterapkan pada tahap preprocessing menjadi prasyarat penting untuk memastikan kontribusi setiap fitur dalam perhitungan jarak bersifat seimbang.

Support Vector Machine (SVM) bekerja dengan mencari hyperplane optimal yang memisahkan dua kelas dengan margin terbesar. Pada kasus data yang tidak dapat dipisahkan secara linear, SVM menggunakan fungsi kernel untuk memetakan data ke ruang dimensi yang lebih tinggi sehingga pemisahan kelas dapat dilakukan secara efektif. Kombinasi SVM dengan teknik oversampling seperti SMOTE telah menunjukkan peningkatan performa yang signifikan pada dataset donor darah dengan ketidakseimbangan kelas, di mana penerapan SMOTE mampu meningkatkan nilai Recall kelas minoritas secara drastis dari 2,8% menjadi 75,6% berdasarkan evaluasi 10-fold cross-validation [6].

Dalam penelitian ini, keempat algoritma dijalankan menggunakan konfigurasi hyperparameter default dari library scikit-learn. Pertama, melakukan tuning hyperparameter yang berbeda untuk setiap algoritma justru menciptakan bias komparasi, karena perbedaan performa yang teramati tidak lagi murni mencerminkan karakteristik algoritma melainkan juga intensitas proses tuning. Kedua, penggunaan konfigurasi yang seragam memungkinkan dampak SMOTE diukur

secara terisolasi sebagai satu-satunya variabel yang berubah antar kondisi baseline dan kondisi dengan SMOTE, sehingga inferensi kausal menjadi lebih valid. Ketiga, hyperparameter default scikit-learn telah dirancang berdasarkan kajian empiris yang luas dan terbukti kompetitif pada berbagai domain klasifikasi. Selain itu, seluruh algoritma dikombinasikan dengan teknik Synthetic Minority Oversampling Technique (SMOTE) yang diterapkan pada data training untuk menangani ketidakseimbangan kelas, mengingat dataset memiliki rasio ketidakseimbangan 1:3 antara kelas minoritas dan kelas mayoritas [6]. Perbandingan dilakukan pada dua kondisi, yaitu tanpa SMOTE dan dengan SMOTE, untuk mengukur sejauh mana teknik penyeimbangan data tersebut memengaruhi performa masing-masing algoritma.

### **Matrik Evaluasi**

Evaluasi performa model dalam penelitian ini menggunakan beberapa metrik yang dihitung berdasarkan confusion matrix. Confusion matrix merupakan matriks kontingensi yang menyajikan empat komponen hasil klasifikasi: True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Metrik-metrik evaluasi yang digunakan merupakan metrik standar dalam klasifikasi machine learning yang telah diadopsi secara luas dalam literatur. **Accuracy** mengukur proporsi keseluruhan prediksi yang benar dari seluruh sampel:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Namun pada dataset tidak seimbang seperti dataset donor darah yang digunakan dalam penelitian ini, accuracy dapat memberikan gambaran yang menyesatkan. Model yang selalu memprediksi kelas mayoritas tanpa benar-benar mempelajari pola data pun dapat mencapai nilai accuracy yang tinggi. Oleh karena itu, penelitian ini juga menggunakan metrik Precision, Recall, F1-Score, dan AUC-ROC untuk memberikan evaluasi yang lebih komprehensif.

Precision mengukur proporsi prediksi positif yang benar-benar merupakan kelas positif. Metrik ini relevan ketika biaya dari False Positive perlu diminimalkan:

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Recall mengukur proporsi sampel positif yang berhasil dideteksi oleh model. Dalam konteks prediksi retensi donor darah, Recall menjadi metrik yang sangat penting karena kegagalan mendeteksi donor potensial (False Negative) berdampak langsung pada ketersediaan pasokan darah:

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-Score merupakan harmonic mean dari Precision dan Recall. Metrik ini memberikan keseimbangan antara keduanya dan lebih informatif dibandingkan accuracy pada kondisi ketidakseimbangan kelas, karena memperhitungkan baik False Positive maupun False Negative secara bersamaan:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

AUC-ROC (Area Under the Receiver Operating Characteristic Curve) mengukur kemampuan model dalam membedakan antara kelas positif dan negatif pada berbagai ambang batas klasifikasi. Kurva ROC menggambarkan hubungan antara True Positive Rate (Recall) pada sumbu y dan False Positive Rate pada sumbu x. Nilai AUC berkisar antara 0 hingga 1, di mana nilai 1 menunjukkan kemampuan diskriminasi sempurna dan nilai 0,5 menunjukkan kemampuan diskriminasi yang setara dengan tebakan acak. AUC-ROC dipilih sebagai metrik pelengkap karena mampu mengevaluasi performa model secara menyeluruh tanpa dipengaruhi oleh distribusi kelas pada dataset.

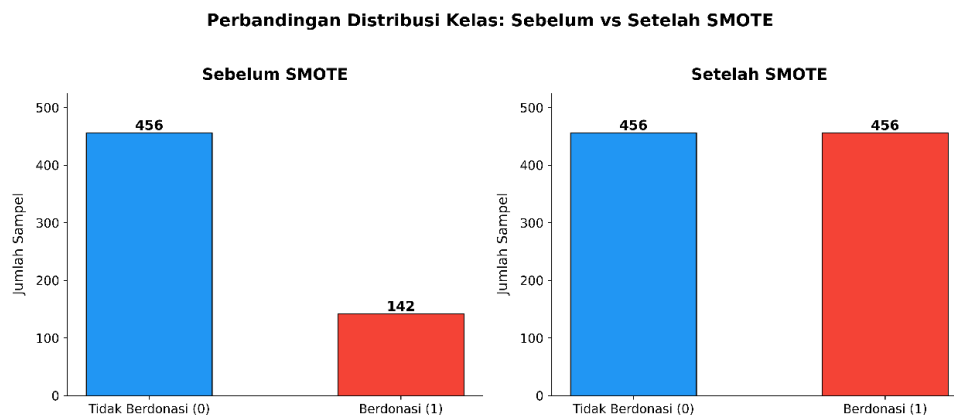
## HASIL DAN PEMBAHASAN

Eksperimen dilakukan terhadap empat algoritma machine learning pada dataset Blood Transfusion Service Center UCI dengan dua kondisi pengujian, yaitu kondisi baseline tanpa penyeimbangan data dan kondisi dengan penerapan SMOTE. Hasil eksperimen disajikan dan dibahas secara sistematis mencakup perbandingan performa antar algoritma, analisis dampak SMOTE, serta identifikasi algoritma yang paling optimal untuk prediksi retensi donor darah.

### Hasil Preprocessing dan Penerapan SMOTE

Tahap preprocessing diawali dengan normalisasi seluruh fitur input menggunakan Min-Max Scaling yang di-fit secara eksklusif pada data training dan ditransformasikan pada data testing, sehingga tidak terjadi kebocoran informasi statistik dari data testing ke proses pelatihan. Setelah normalisasi, distribusi kelas pada data training menunjukkan ketidakseimbangan dengan 456 sampel kelas tidak berdonasi (0) dan 142 sampel kelas berdonasi (1).

SMOTE kemudian diterapkan pada data training yang telah dinormalisasi untuk menyeimbangkan distribusi kelas. Proses sintesis sampel dilakukan dengan menginterpolasi setiap sampel minoritas dengan tetangga terdekatnya dalam ruang fitur, sehingga model tidak sekadar menghafalkan sampel yang diduplikasi melainkan mempelajari wilayah keputusan yang lebih general untuk kelas minoritas [11]. Hasilnya, kelas berdonasi bertambah dari 142 menjadi 456 sampel sehingga rasio kelas menjadi 1:1 sebagaimana ditunjukkan pada Gambar 3. Data testing tidak diikutsertakan dalam proses SMOTE dan tetap mencerminkan distribusi kelas asli dengan 114 sampel kelas tidak berdonasi dan 36 sampel kelas berdonasi, untuk memastikan evaluasi dilakukan pada kondisi distribusi yang realistis.



Gambar 3. Perbandingan Distribusi Kelas Data Training Sebelum dan Setelah Penerapan SMOTE

### Perbandingan Performa Baseline vs SMOTE

Hasil perbandingan performa keempat algoritma pada kondisi baseline dan dengan SMOTE disajikan pada Tabel 2 dan divisualisasikan pada Gambar 4 berikut. Secara umum, terdapat pola yang konsisten di mana penerapan SMOTE menyebabkan penurunan accuracy dan precision pada seluruh algoritma, namun diikuti peningkatan Recall dan F1-score pada tiga dari empat algoritma.

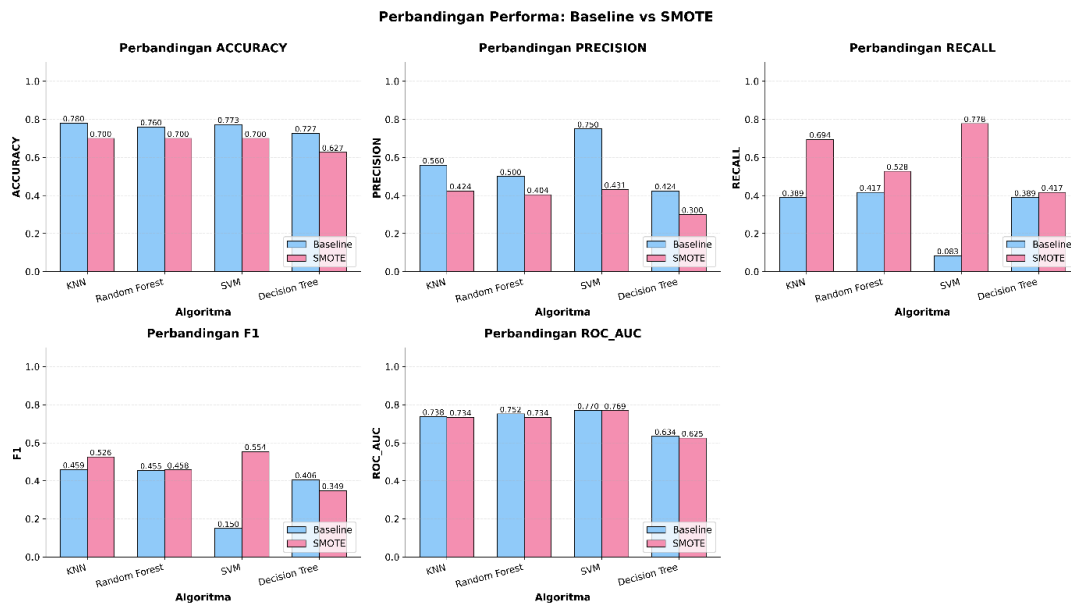
Tabel 2. Perbandingan Performa Algoritma Baseline vs SMOTE

Algoritma	Kondisi	Accuracy	Precision	Recall	F1	AUC
KNN	Baseline	0.7800	0.5600	0.3889	0.4590	0.7376
	SMOTE	0.7000	0.4237	0.6944	0.5263	0.7336
Random Forest	Baseline	0.7600	0.5000	0.4167	0.4545	0.7523
	SMOTE	0.7000	0.4043	0.5278	0.4578	0.7340
SVM	Baseline	0.7733	0.7500	0.0833	0.1500	0.7700
	SMOTE	0.7000	0.4308	0.7778	0.5545	0.7690
Decision Tree	Baseline	0.7267	0.4242	0.3889	0.4058	0.6338
	SMOTE	0.6267	0.3000	0.4167	0.3488	0.6246

Penurunan accuracy setelah SMOTE bukan merupakan indikasi penurunan kualitas model, melainkan mencerminkan koreksi terhadap bias prediksi yang terjadi pada kondisi baseline. Pada kondisi baseline, model cenderung memprediksi kelas mayoritas secara dominan sehingga menghasilkan accuracy yang tinggi secara semu. Hal ini terlihat jelas pada SVM

baseline yang mencapai accuracy 0.773 namun hanya mampu mendeteksi 8.3% donor potensial dengan Recall 0.083. Kondisi ini sejalan dengan temuan Widyanto dkk. [6] yang menunjukkan bahwa model yang dilatih pada data tidak seimbang cenderung mengabaikan kelas minoritas meskipun menghasilkan accuracy keseluruhan yang tinggi. Setelah SMOTE diterapkan, model tidak lagi didominasi oleh kelas mayoritas sehingga lebih banyak donor potensial yang berhasil dideteksi, meskipun dengan konsekuensi penurunan accuracy dan precision.

Dalam konteks prediksi retensi donor darah, trade-off ini dapat dibenarkan secara praktis. Kegagalan mendeteksi donor potensial yang sebenarnya akan berdonasi (false negative) berdampak langsung pada berkurangnya pasokan darah, sedangkan kesalahan memprediksi non-donor sebagai donor potensial (false positive) hanya mengakibatkan upaya rekrutmen yang tidak perlu namun tidak menimbulkan dampak kritis. Oleh karena itu, peningkatan Recall menjadi prioritas utama dalam evaluasi model pada domain ini.

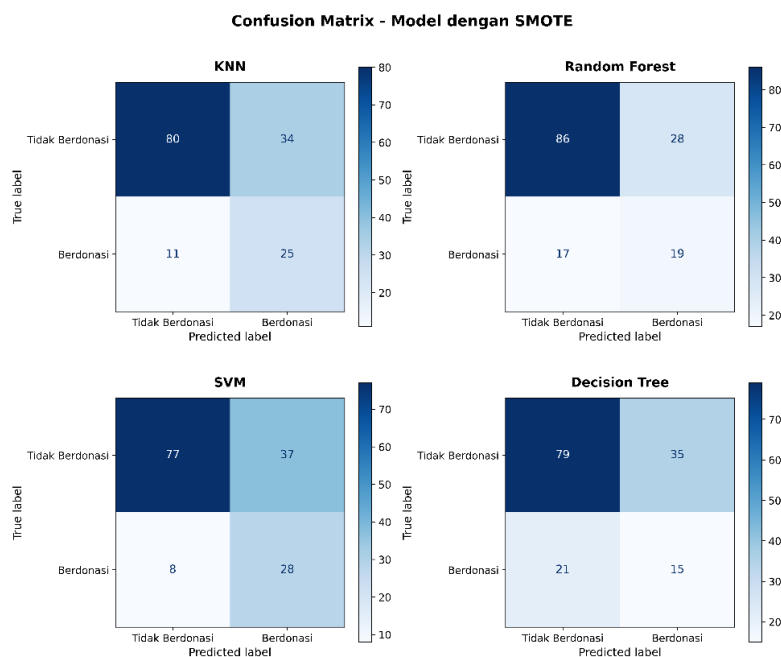


Gambar 4. Perbandingan Performa Algoritma Machine Learning pada Kondisi Baseline dan SMOTE

Penurunan accuracy yang terjadi setelah penerapan SMOTE perlu dipahami dalam konteks yang lebih luas, khususnya pada domain kesehatan seperti prediksi retensi donor darah. Secara matematis, accuracy mengukur proporsi prediksi benar secara keseluruhan tanpa membedakan kesalahan pada kelas minoritas atau mayoritas [7]. Pada kondisi baseline, model mencapai accuracy tinggi (misalnya SVM dengan 0,7733) karena cenderung memprediksi kelas mayoritas (tidak berdonasi) yang mendominasi 76,2% dataset, sehingga meskipun hampir seluruh kelas minoritas gagal terdeteksi, accuracy keseluruhan tetap terlihat baik [6]. Fenomena ini disebut sebagai accuracy paradox pada imbalanced data [7]. Setelah SMOTE diterapkan, model menjadi lebih sensitif terhadap kelas minoritas sehingga lebih banyak memprediksi kelas positif (berdonasi), yang meningkatkan True Positive namun juga meningkatkan False Positive, sehingga accuracy turun menjadi 0,7000 [11]. Namun dalam bidang kesehatan, khususnya manajemen bank darah, konsekuensi dari kedua jenis kesalahan sangat berbeda [3]. False Negative (gagal mendeteksi donor yang akan kembali berdonasi) menyebabkan hilangnya kesempatan untuk mengamankan pasokan darah, yang dapat berakibat fatal pada situasi kekurangan stok darah untuk pasien yang membutuhkan transfusi darurat [2]. Sebaliknya, False Positive (salah memprediksi non-donor sebagai donor potensial) hanya mengakibatkan sumber daya rekrutmen terbuang untuk menghubungi donor yang tidak akan berdonasi, yang merupakan biaya operasional yang dapat ditoleransi [3]. Dari perspektif kesehatan masyarakat, lebih baik mengorbankan sedikit accuracy untuk mendapatkan Recall yang tinggi (0,7778), karena kemampuan mendeteksi 77,8% donor potensial jauh lebih bernilai daripada accuracy 77,33% yang hanya mendeteksi 8,3% donor potensial. Prioritas pada Recall ini sejalan dengan prinsip precautionary principle dalam kesehatan masyarakat, di mana mencegah kekurangan pasokan darah lebih penting daripada efisiensi operasional semata [2]. Oleh karena itu, penurunan accuracy dari 0,7733 menjadi 0,7000 pada SVM merupakan trade-off yang dapat dibenarkan secara etis dan praktis dalam konteks sistem prediksi retensi donor darah [6], [7].

## Analisis Per Algoritma

Analisis lebih mendalam terhadap masing-masing algoritma menunjukkan pola respons yang berbeda-beda terhadap penerapan SMOTE, sebagaimana ditunjukkan pada Gambar 5.



Gambar 5. Confusion Matrix

K-Nearest Neighbor menunjukkan peningkatan yang moderat dan konsisten setelah SMOTE. Recall meningkat signifikan dari 0.3889 menjadi 0.6944 dan F1-score meningkat dari 0.4590 menjadi 0.5263, sementara accuracy turun dari 0.7800 menjadi 0.7000. Dari confusion matrix, KNN berhasil mendeteksi 25 dari 36 donor potensial setelah SMOTE dibandingkan hanya mendeteksi 14 pada kondisi baseline. Peningkatan ini konsisten dengan karakteristik KNN yang sensitif terhadap distribusi kelas di sekitar titik query, sehingga penambahan sampel sintetis pada kelas minoritas memperluas wilayah keputusan yang dikenali sebagai kelas berdonasi.

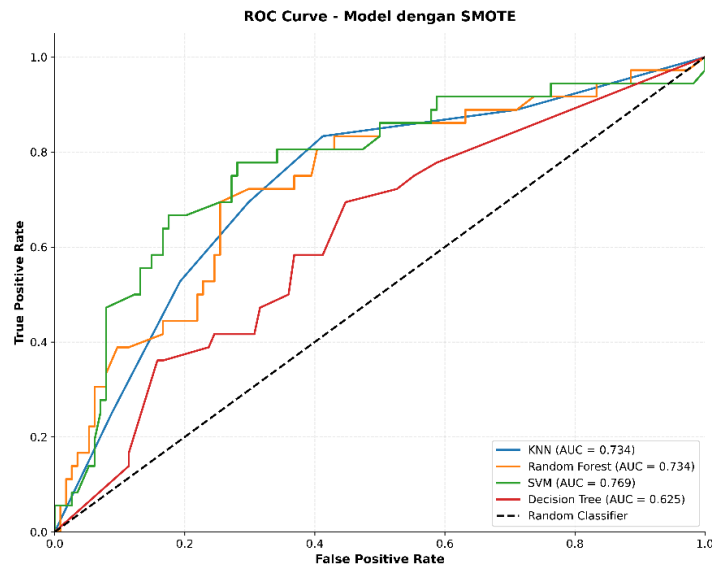
Random Forest menunjukkan perubahan yang paling minimal di antara keempat algoritma. F1-score hanya meningkat dari 0.4545 menjadi 0.4578, selisih yang hampir tidak signifikan. Hal ini mengindikasikan bahwa Random Forest secara inheren lebih robust terhadap ketidakseimbangan kelas dibandingkan algoritma lainnya. Mekanisme bagging yang membangun banyak pohon keputusan secara paralel pada subset data yang berbeda memberikan efek diversifikasi alami sehingga SMOTE memberikan dampak yang sangat terbatas atau diminishing return pada algoritma ini.

Support Vector Machine menunjukkan perubahan paling dramatis di antara seluruh algoritma. Pada kondisi baseline, SVM hanya mampu mendeteksi 3 dari 36 donor potensial dengan Recall 0.0833 fenomena yang identik dengan temuan Widyanto dkk. [6] yang melaporkan Recall SVM sebesar 2.8% pada kondisi data tidak seimbang. Setelah SMOTE diterapkan, Recall melonjak drastis menjadi 0.7778 dan F1-score meningkat dari 0.1500 menjadi 0.5545. Peningkatan ekstrem ini terjadi karena SVM bekerja dengan mencari hyperplane optimal yang sangat dipengaruhi oleh distribusi data di sekitar margin keputusan. Pada data tidak seimbang, hyperplane SVM terdorong mendekati kelas minoritas sehingga hampir seluruh sampel diklasifikasikan sebagai kelas mayoritas. SMOTE memperbaiki kondisi ini dengan memperluas representasi kelas minoritas di sekitar margin sehingga hyperplane dapat terbentuk secara lebih seimbang.

Decision Tree adalah satu-satunya algoritma yang mengalami penurunan F1-score setelah SMOTE, dari 0.4058 menjadi 0.3488. Meskipun Recall sedikit meningkat dari 0.3889 menjadi 0.4167, penurunan precision yang signifikan dari 0.4242 menjadi 0.3000 menyebabkan F1-score keseluruhan memburuk. Hal ini konsisten dengan karakteristik Decision Tree yang rentan terhadap overfitting pada sampel sintetis batas keputusan yang dihasilkan terlalu mengikuti pola artifisial dari data sintetis SMOTE sehingga kemampuan generalisasi pada data testing yang mencerminkan distribusi asli justru menurun [8].

### Analisis ROC dan Kemampuan Diskriminasi Model

Kemampuan diskriminasi keempat model dengan SMOTE dievaluasi menggunakan kurva ROC dan nilai AUC sebagaimana ditunjukkan pada Gambar 6. Secara keseluruhan, seluruh model menunjukkan kemampuan diskriminasi di atas random classifier yang ditandai dengan kurva ROC yang berada di atas garis diagonal, mengindikasikan bahwa keempat model memiliki kemampuan membedakan kelas berdonasi dan tidak berdonasi yang lebih baik dari tebakan acak.



Gambar 6. Receiver Operating Characteristic (ROC) Curves - Model dengan SMOTE

SVM mencapai nilai AUC tertinggi sebesar 0.769, diikuti KNN dan Random Forest yang memiliki nilai AUC identik sebesar 0.734, serta Decision Tree dengan AUC terendah sebesar 0.625. Keunggulan SVM pada metrik AUC mengkonfirmasi bahwa model ini tidak hanya unggul pada threshold klasifikasi tunggal yang digunakan untuk menghitung Recall dan F1, melainkan juga secara konsisten unggul dalam membedakan kedua kelas pada berbagai threshold. Ini menjadikan SVM sebagai model yang paling andal secara keseluruhan untuk dataset ini.

Nilai AUC KNN dan Random Forest yang identik sebesar 0.734 menarik untuk dicermati. Meskipun kedua model menunjukkan kemampuan diskriminasi yang setara secara keseluruhan, bentuk kurva ROC keduanya berbeda. Random Forest menunjukkan kurva yang lebih mulus dibandingkan KNN yang lebih bergerigi. Bentuk kurva yang bergerigi pada KNN dan Random Forest merupakan konsekuensi dari ukuran test set yang terbatas, khususnya kelas minoritas yang hanya terdiri dari 36 sampel, sehingga setiap perubahan threshold hanya menggeser sejumlah kecil sampel dan menghasilkan loncatan diskret pada kurva. Hal ini merupakan keterbatasan yang inherent pada dataset berukuran kecil dan bukan merupakan indikasi kesalahan model.

Decision Tree menunjukkan AUC terendah sebesar 0.625 yang mendekati batas kemampuan diskriminasi minimal. Nilai ini konsisten dengan penurunan performa Decision Tree pada metrik lainnya setelah SMOTE dan semakin memperkuat kesimpulan bahwa Decision Tree merupakan pilihan yang kurang optimal untuk dataset ini.

### Pemilihan Model Terbaik

Berdasarkan hasil evaluasi pada seluruh metrik, SVM dengan SMOTE diidentifikasi sebagai model terbaik untuk prediksi retensi donor darah pada dataset ini. Keunggulan SVM+SMOTE bersifat konsisten di tiga metrik utama sekaligus Recall tertinggi sebesar 0.7778, F1-score tertinggi sebesar 0.5545, dan AUC tertinggi sebesar 0.769 menjadikannya pilihan yang tidak hanya unggul pada satu aspek tertentu melainkan secara menyeluruh.

Pemilihan model terbaik pada penelitian ini tidak didasarkan pada accuracy semata mengingat keterbatasan metrik tersebut pada dataset yang tidak seimbang. Model dengan accuracy tertinggi belum tentu merupakan model yang paling berguna secara praktis, sebagaimana ditunjukkan oleh SVM baseline yang memiliki accuracy 0.7733 namun hanya mampu mendeteksi 8.3% donor potensial. Sebaliknya, SVM+SMOTE dengan accuracy 0.7000 mampu mendeteksi 77.8% donor potensial yang merupakan peningkatan deteksi sebesar 9 kali lipat dibandingkan kondisi baseline.

Dalam konteks prediksi retensi donor darah, Recall menjadi metrik yang paling relevan secara praktis karena mencerminkan kemampuan model mendeteksi donor yang berpotensi berdonasi kembali. F1-score dipilih sebagai metrik pembandingan utama karena memberikan keseimbangan antara precision dan Recall, sementara AUC digunakan untuk mengevaluasi kemampuan diskriminasi model secara menyeluruh tanpa bergantung pada satu threshold tertentu. Berdasarkan ketiga metrik tersebut, SVM+SMOTE secara konsisten mengungguli ketiga algoritma lainnya dan direkomendasikan sebagai algoritma yang paling optimal untuk diimplementasikan dalam sistem prediksi retensi donor darah.

Keunggulan SVM dengan SMOTE sebagai model terbaik dapat dijelaskan melalui karakteristik algoritma SVM yang sangat sesuai dengan sifat dataset donor darah UCI. Pertama, SVM bekerja dengan mencari hyperplane yang memaksimalkan margin antara kelas positif dan negatif, yang membuatnya sangat efektif pada dataset dengan dimensi rendah namun memiliki pola pemisahan yang kompleks [8]. Dataset donor darah UCI memiliki empat fitur numerik (Recency, Frequency, Monetary, Time) yang saling berkorelasi dan membentuk pola non-linear dalam ruang fitur [9], di mana SVM dengan kernel RBF (Radial Basis Function) mampu memetakan data ke dimensi yang lebih tinggi untuk menemukan pemisahan optimal. Kedua, mekanisme margin maksimal SVM memungkinkan algoritma ini fokus pada sampel-sampel di perbatasan kelas (support vectors) yang paling informatif untuk membedakan donor yang akan kembali berdonasi dengan yang tidak. Setelah SMOTE diterapkan, sampel sintesis yang dihasilkan memperkaya representasi kelas minoritas di sekitar wilayah margin [11], sehingga hyperplane SVM dapat terbentuk dengan lebih seimbang dan tidak lagi bias terhadap kelas mayoritas [6]. Ketiga, karakteristik dataset dengan rasio ketidakseimbangan 1:3,2 dan ukuran sampel yang terbatas (748 sampel) [9] sangat cocok dengan SVM yang dikenal robust terhadap overfitting pada dataset kecil dibandingkan algoritma ensemble seperti Random Forest yang membutuhkan lebih banyak data untuk membangun pohon-pohon keputusan yang beragam [8]. Kombinasi karakteristik ini menjelaskan mengapa SVM menunjukkan peningkatan paling dramatis setelah SMOTE (Recall dari 0,0833 menjadi 0,7778) dan konsisten unggul pada seluruh metrik evaluasi dibandingkan ketiga algoritma lainnya.

### ***Perbandingan dengan Penelitian Sebelumnya***

Hasil penelitian ini secara umum mengkonfirmasi sekaligus memperluas temuan Widyanto dkk. [6] yang menjadi rujukan utama penelitian ini. Widyanto dkk. [6] melaporkan bahwa penerapan SMOTE pada dataset donor darah UCI mampu meningkatkan Recall SVM secara drastis dari 2.8% menjadi 75.6% berdasarkan evaluasi 10-fold cross-validation menggunakan WEKA. Penelitian ini mereplikasi fenomena serupa dengan peningkatan Recall SVM dari 0.0833 menjadi 0.7778 menggunakan pendekatan hold-out test set pada scikit-learn, yang mengkonfirmasi bahwa fenomena tersebut bukan artefak dari tool atau skema evaluasi tertentu melainkan mencerminkan karakteristik inheren SVM terhadap ketidakseimbangan kelas.

Kontribusi utama penelitian ini terletak pada perluasan evaluasi ke tiga algoritma tambahan yang tidak dieksplorasi oleh Widyanto dkk. [6]. Temuan bahwa respons setiap algoritma terhadap SMOTE bervariasi secara signifikan merupakan informasi baru yang tidak tersedia pada studi sebelumnya. Random Forest terbukti paling tidak responsif terhadap SMOTE dengan peningkatan F1 yang hampir nol, mengindikasikan robustness inheren terhadap ketidakseimbangan kelas. Sebaliknya, Decision Tree justru mengalami penurunan F1 setelah SMOTE, menunjukkan bahwa penerapan SMOTE tidak selalu menghasilkan peningkatan performa pada semua algoritma. Temuan ini sejalan dengan pernyataan Mujahid dkk. [8] yang menegaskan bahwa tidak ada satu kombinasi teknik oversampling dan algoritma yang secara universal unggul di semua konteks, sehingga komparasi empiris pada domain spesifik tetap diperlukan.

Hasil penelitian ini juga konsisten dengan temuan Agyemang dkk. [7] yang membuktikan bahwa SMOTE secara konsisten meningkatkan kemampuan KNN, SVM, Random Forest, dan Decision Tree dalam mengklasifikasikan kelas minoritas pada data kesehatan yang tidak seimbang. Meskipun demikian, penelitian ini menunjukkan bahwa tingkat peningkatan antar algoritma sangat bervariasi dari peningkatan dramatis pada SVM hingga penurunan pada Decision Tree yang menambahkan nuansa penting pada kesimpulan yang lebih general dari Agyemang dkk. [7].

### ***Implikasi Praktis dan Keterbatasan Penelitian***

Hasil penelitian ini memiliki implikasi praktis yang relevan bagi bank darah dan lembaga transfusi darah dalam merancang strategi retensi donor yang lebih efektif. SVM+SMOTE yang mampu mendeteksi 77.8% donor potensial dapat diimplementasikan sebagai sistem pendukung keputusan untuk mengidentifikasi donor yang perlu diprioritaskan dalam kampanye rekrutmen ulang. Pendekatan berbasis machine learning ini memungkinkan bank darah untuk mengalokasikan

sumber daya rekrutmen secara lebih efisien dengan menargetkan donor yang memiliki probabilitas tinggi untuk berdonasi kembali, dibandingkan pendekatan konvensional yang menghubungi seluruh database donor tanpa diferensiasi [4].

Meskipun demikian, penelitian ini memiliki beberapa keterbatasan yang perlu diperhatikan dalam menginterpretasikan hasil dan menentukan arah penelitian selanjutnya. Pertama, dataset yang digunakan terbatas pada 748 sampel dari satu pusat transfusi darah di Kota Hsin-Chu, Taiwan, sehingga generalisasi model ke konteks yang berbeda, termasuk Indonesia, memerlukan validasi lebih lanjut menggunakan data lokal yang mencerminkan karakteristik populasi donor setempat. Kedua, seluruh algoritma dijalankan menggunakan konfigurasi hyperparameter default tanpa optimasi lebih lanjut, sehingga terdapat potensi peningkatan performa yang belum tergalai melalui proses tuning. Ketiga, ukuran test set yang terbatas khususnya kelas minoritas yang hanya terdiri dari 36 sampel menyebabkan estimasi metrik evaluasi memiliki variansi yang relatif tinggi, sebagaimana terlihat pada bentuk kurva ROC yang bergerigi. Penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan beragam, mengeksplorasi optimasi hyperparameter, serta mempertimbangkan teknik oversampling alternatif seperti ADASYN atau Borderline-SMOTE sebagai pembanding.

## KESIMPULAN DAN SARAN

Penelitian ini telah membandingkan performa empat algoritma machine learning, yaitu K-Nearest Neighbor, Random Forest, Support Vector Machine, dan Decision Tree, dalam memprediksi retensi donor darah pada dataset Blood Transfusion Service Center UCI dengan dan tanpa penerapan SMOTE. Berdasarkan hasil eksperimen, beberapa kesimpulan dapat ditarik.

Pertama, penerapan SMOTE terbukti memberikan pengaruh yang signifikan terhadap kemampuan model dalam mendeteksi donor potensial. Secara umum, SMOTE meningkatkan Recall dan F1-score pada tiga dari empat algoritma dengan konsekuensi penurunan accuracy dan precision yang dapat dibenarkan secara praktis dalam konteks prediksi retensi donor darah.

Kedua, respons setiap algoritma terhadap SMOTE bervariasi secara signifikan. SVM menunjukkan peningkatan paling dramatis dengan Recall meningkat dari 0.0833 menjadi 0.7778, sementara Random Forest hampir tidak terpengaruh karena robustness inheren terhadap ketidakseimbangan kelas. Decision Tree menjadi satu-satunya algoritma yang mengalami penurunan F1-score setelah SMOTE, mengindikasikan sensitivitasnya terhadap sampel sintetis.

Ketiga, SVM dengan SMOTE diidentifikasi sebagai algoritma yang paling optimal untuk prediksi retensi donor darah pada dataset ini berdasarkan tiga metrik utama sekaligus Recall 0.7778, F1-score 0.5545, dan AUC 0.769 yang secara konsisten mengungguli ketiga algoritma lainnya.

Penelitian ini mengkonfirmasi dan memperluas temuan Widyanto dkk. yang sebelumnya hanya mengevaluasi SMOTE pada SVM, dengan membuktikan bahwa dampak SMOTE tidak seragam pada semua algoritma. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi optimasi hyperparameter, teknik oversampling alternatif, serta validasi menggunakan dataset donor darah lokal untuk meningkatkan generalisabilitas hasil.

## DAFTAR PUSTAKA

- [1] W. H. O. "Blood safety and availability," World Health Organization, [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/blood-safety-and-availability>. [Diakses 18 February 2026].
- [2] L. C. Hoorn, C. Graf, and E.-M. Merz, "Money matters: The association between blood donation rates and healthcare system quality across 171 countries," *Transfusion*, vol. 64, no. 8, p. 1448–1458, 2024.
- [3] E. Shehu, B. Veseli, M. Clement, and K. P. Winterich, "Improving blood donor retention and donor relationships with past donation use appeals," *Journal of Service Research*, vol. 27, no. 3, p. 346–363, 2024.
- [4] M. A. Badawi, "Artificial intelligence in blood donor management: A narrative review," *Vox Sanguinis*, 2025.
- [5] H. Wu, Z. Li, X. Sun, W. Bai, A. Wang, and Y. Ma, "Predicting willingness to donate blood based on machine learning: Two blood donor recruitments during COVID-19 outbreaks," *Scientific Reports*, 2022.

- [6] A. Widyanto, Kusrini, and Kusnawi, "Pengaruh keseimbangan data terhadap akurasi model support vector machine pada data set donor darah," *Jurnal Teknologi Terpadu*, vol. 9, no. 2, p. 79–88, 2023.
- [7] E. F. Agyemang *dkk.*, "Addressing class imbalance problem in health data classification: Practical application from an oversampling viewpoint," *Applied Computational Intelligence and Soft Computing*, vol. 2025, p. 1–20, 2025.
- [8] M. Mujahid *dkk.*, "Data oversampling and imbalanced datasets: An investigation of performance for machine learning and feature engineering," *Journal of Big Data*, 2024.
- [9] I. Yeh, "Blood Transfusion Service Center," 2026. [Online]. Available: <https://doi.org/10.24432/C5GS39>.
- [10] S. Sinsomboonthong, "Performance Comparison of New Adjusted Min-Max with Decimal Scaling and Statistical Column Normalization Methods for Artificial Neural Network Classification," *International Journal of Mathematics and Mathematical Sciences*, vol. 2022, p. 1–9, 2022.
- [11] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE : Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, p. 321–357, 2002.
- [12] P. J. M. Ali, "Investigating the Impact of Min-Max Data Normalization on the Regression Performance of K-Nearest Neighbor with Different Similarity Measurements," *ARO – The Scientific Journal of Koya University*, vol. 10, no. 1, p. 85–91, 2022.