Journal of Innovative and Creativity
Journal Homepage: https://joecy.org/index.php/joecy
e-mail: journaljoecy@gmail.com

Faculty of Education
University of Pahlawan Tuanku Tambusai
ISSN 2775-771X (Online)
ISSN 2962-570X (Printed)
5 (3) 2025, Page: 25936-25945

Penerapan Smote Pada Algoritma SVM Untuk Mengatasi Imbalance Data Kelayakan Donor Darah

Enriko Chiesa Sipahutar[1],TaghfirulAzhimaYoga[2]. Fendy Yulianto[3].

Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Kalimantan Timur.

Jl. Ir. H. Juanda No.15, Sidodadi, Kec. Samarinda Ulu, Kota Samarinda, Kalimantan Timur 75124
E-mail: 1811102441033 @umkt.ac.id[1], tay758@umkt.ac.id[2].fy415@umkt.ac.id

Published: September, 2025

ABSTRAK

Penelitian ini mengembangkan sistem klasifikasi kelayakan donor darah berbasis metode data mining dengan fitur penanganan ketidakseimbangan data untuk meningkatkan akurasi prediksi. Sistem ini menggunakan algoritma SVM (Support Vector Machine) sebagai model klasifikasi utama dan metode SMOTE (Synthetic Minority Over-sampling Technique) untuk menyeimbangkan distribusi data antar kelas. Dataset donor darah yang diperoleh dari PMI Samarinda tahun 2024–2025 diolah melalui tahap pembersihan, normalisasi, serta validasi silang (Cross-validation) untuk mencegah Overfitting. Prototipe model diuji untuk memastikan kinerja klasifikasi terhadap data minoritas dan mayoritas dapat berjalan optimal. Hasil pengujian menunjukkan bahwa penerapan SMOTE berhasil meningkatkan akurasi hingga 96,05%, serta mengurangi kesalahan klasifikasi pada data minoritas. Penelitian ini berkontribusi dalam menyediakan solusi analitik berbasis *Machine learning* yang dapat diterapkan untuk permasalahan serupa, khususnya dalam meningkatkan akurasi klasifikasi pada data yang tidak seimbang.

Kata kunci: Donor darah, Klasifikasi, SMOTE, SVM

"© The Author(s). 2021 Open Access This article is licensed under a Creative Commons Atibution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. To view a copy of this licence, visit" http://creativecommons.org/licenses/by/4.0

PENDAHULUAN

Donor darah memiliki peranan penting dalam menjaga ketersediaan darah bagi pasien yang membutuhkan. Namun, dalam praktiknya, klasifikasi kelayakan donor darah sering menghadapi masalah distribusi data yang tidak seimbang, di mana jumlah calon pendonor yang memenuhi syarat jauh lebih sedikit dibandingkan yang tidak memenuhi syarat. Kondisi ini dapat menyebabkan penurunan akurasi model klasifikasi yang diterapkan. Penelitian terdahulu telah memanfaatkan algoritma klasifikasi seperti *Naive Bayes*, KNN(K-Nearest Neighbor), dan SVM(*Support Vector Machine)* , dengan hasil yang bervariasi (Pradana et al., 2022 dan Desiani et al., 2023). Meskipun SVM dikenal memiliki akurasi tinggi, kinerjanya dapat menurun pada dataset tidak seimbang. Salah satu pendekatan untuk mengatasi masalah ini adalah metode SMOTE(*Synthetic Minority Oversampling Technique*), yang telah terbukti mampu meningkatkan akurasi pada berbagai kasus klasifikasi (Kristiawan et al., 2021). Namun, penerapan kombinasi SMOTE dan SVM secara khusus untuk klasifikasi kelayakan donor darah masih belum banyak dilakukan. Oleh karena itu, penelitian ini bertujuan untuk mengimplementasikan SMOTE pada algoritma SVM dalam rangka meningkatkan akurasi klasifikasi kelayakan donor darah.

TINJAUAN PUSTAKA

Secara umum, Donor Darah adalah prosedur pengambilan satu kantong Darah oleh tenaga medis dari seorang Pendonor, yang selanjutnya disalurkan kepada penerima yang membutuhkan (Azzahra et al., 2024).Studi terdahulu menyebutkan bahwa ketidakseimbangan kelas dapat menurunkan kinerja Optimal algoritma klasifikasi, termasuk model SVM (Support Vector Machine). Meskipun tergolong Efisien dan mudah diterapkan, SVM memiliki keterbatasan saat digunakan pada data dengan distribusi kelas yang tidak seimbang (Caroline et al., 2024).Selaras dengan temuan tersebut, studi yang menerapkan algoritma *Naive Bayes* untuk klasifikasi data donor darah memperoleh akurasi sebesar 77% (Hutrim dkk, 2020).Pada studi lain yang juga membahas kasus Donor Darah, penerapan metode Decision Tree memperoleh akurasi sebesar 77,68% (Pangaribuan & Putra, 2024). Di antara algoritma tersebut, SVM memiliki pendekatan khusus, yaitu menentukan Hyperplane terbaik yang memisahkan data sehingga diperoleh margin pemisahan yang maksimal (Handayani & Taufiq, 2024).Sebagai contoh, dalam sebuah studi yang menerapkan algoritma *Naive Bayes* dan SVM (*Support Vector Machine)* untuk klasifikasi serangan jantung, diperoleh hasil bahwa SVM memiliki akurasi lebih tinggi, yakni sebesar *87%*, sedangkan *Naive Bayes* hanya mencapai akurasi *84%* (Pradana et al., 2022).Penelitian yang di lakukan dalam melakukan kombinasi antara Algorithm SMOTE dan SVM mampu meningkatkan akurasi klasifikasi hingga 96,01% (Kristiawan dkk , 2021).Penelitian yang dilakukan dilakukan A. Rahim dan rekan-rekan (2023) dengan menggunakan SMOTE dalam mengatasi ketidak seimbangan Kelas kekonsistenan bahwa metode SMOTE berhasil meningkatkan akurasi yang awalnya 90% meningkat menjadi 92%.Berdasarkan hasil-hasil penelitian tersebut, dapat disimpulkan bahwa penggunaan SMOTE untuk menyeimbangkan data dan SVM sebagai algoritma klasifikasi merupakan pendekatan yang potensial untuk meningkatkan akurasi prediksi kelayakan donor darah. Namun, penerapan khusus pada domain donor darah masih terbatas, sehingga penelitian ini dilakukan untuk menjawab celah tersebut.

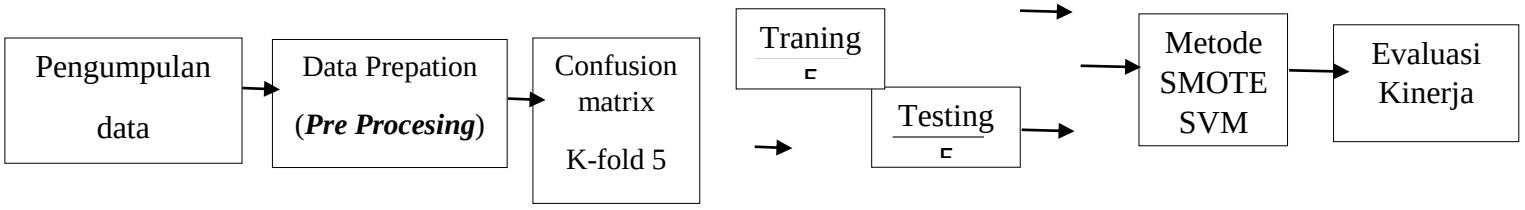
II.Metode Penelitian

2.1 Objek Penelitian

Penelitian ini menggunakan data donor darah tahun 2024-2025 dari Unit Donor Darah (UDD) Palang Merah Indonesia (PMI) Samarinda, mencakup variabel seperti umur, golongan darah, jenis kelamin, status, kadar hemoglobin, tekanan darah, dan berat badan.

2.2 Metode Penelitian

Metodologi penelitian ini terdiri dari empat tahap utama: pengumpulan data donor darah, oversampling menggunakan algoritma SMOTE, klasifikasi dengan SVM, dan evaluasi kinerja model.



Gambar 1 Prosedur Penelitian

2.3 Data Set

Dataset yang digunakan dalam penelitian ini berasal dari data donor darah yang dikumpulkan melalui Unit Donor Darah (UDD) Palang Merah Indonesia (PMI) Kota Samarinda Pada tahun 2024-2025 . Data tersebut memuat sejumlah 8 atribut utama yang menjadi fitur untuk proses klasifikasi kelayakan donor darah. Atribut-atribut tersebut meliputi nama pendonor darah, umur

pendonor, golongan darah yang dapat didonorkan kepada orang lain, serta jenis kelamin pendonor. Selain itu, terdapat pula atribut status yang menunjukkan berhasil atau tidaknya kelayakan pendonor, kadar hemoglobin sebagai protein dalam sel darah merah yang berfungsi membawa oksigen ke seluruh tubuh, tekanan darah pendonor pada saat pemeriksaan, dan berat badan pendonor yang telah ditetapkan sebagai volume darah yang dapat diambil. Keseluruhan.

2.4 Data Procesing

Penelitian ini melakukan persiapan data dengan membersihkan entri tidak lengkap, normalisasi atribut numerik, dan transformasi data untuk menjamin kualitas hasil analisis, sebagaimana pentingnya tahap ini dalam menjamin kualitas hasil data mining (Akhmad, 2022).

a. Data *Selection*

Seleksi data dilakukan dengan memilih 8 atribut relevan dari 10 kolom yang ada, dengan 7 atribut digunakan sebagai fitur dan 1 atribut (Status) sebagai kelas untuk klasifikasi donor darah.

b. Data *Cleaning*

Proses data cleaning dilakukan untuk meningkatkan kualitas data dengan mengidentifikasi dan memperbaiki kesalahan, inkonsistensi, dan ketidakakuratan dalam dataset, mencakup atribut seperti Nama, Usia, Jenis Kelamin, Status, Hemoglobin, dan Tensi

c. Data Transformasi

Proses transformasi data mencakup konversi data kategorikal (Golongan Darah, Jenis Kelamin, Status) menjadi numerik, splitting kolom Tensi, dan normalisasi data Hemoglobin untuk memastikan data siap digunakan dalam model Machine Learning.

2.5 SMOTE (*Synthetic Minority Oversampling Technique)*

Penelitian ini menggunakan metode SMOTE untuk mengatasi ketidakseimbangan kelas pada dataset donor darah dengan menciptakan sampel baru secara artifisial di antara titik data minoritas dan tetangga terdekatnya. Dengan cara ini, model dapat mempelajari lebih banyak variasi data sekaligus mengurangi potensi overfitting. Penggunaan SMOTE telah terbukti efektif dalam meningkatkan performa klasifikasi di berbagai bidang (Wijayanti et al., 2021; Ridwan et al., 2024). Dalam penelitian ini, metode SMOTE dikombinasikan dengan algoritma SVM untuk meningkatkan akurasi dalam mengklasifikasikan data donor darah yang tidak seimbang.

2.6 Confusion *Matrix K-fold 5*

Penelitian ini membagi data menjadi dua bagian utama, yaitu training dataset untuk mempelajari pola dan hubungan dalam data, dan testing dataset untuk menguji serta menilai performa model. Metode Cross Validation digunakan untuk mengevaluasi performa model dengan membagi data menjadi subset latih dan uji, sehingga dapat memastikan model mampu melakukan prediksi dengan akurat pada data baru (Thoriq, 2023). Pemilihan jenis Cross Validation biasanya disesuaikan dengan ukuran dataset yang digunakan untuk memastikan evaluasi yang efektif dan akurat.

2.7 Pemodelan

Pengembangan model ini mencakup penggunaan metode SMOTE untuk mengatasi masalah ketidakseimbangan data serta pengoptimalan parameter melalui algoritma SVM, dengan tujuan meningkatkan kinerja model dalam mengklasifikasikan kelayakan donor darah. Dengan menggabungkan kedua metode ini, diharapkan dapat tercipta model yang lebih efisien dalam memprediksi kelas minoritas dan meningkatkan akurasi klasifikasi secara keseluruhan.

a. Pemodelan SVM

SVM (*Support Vector Machine*) adalah algoritma klasifikasi yang kuat dan efektif dalam menangani data berdimensi tinggi dan *non-linear* melalui penggunaan fungsi *kernel*. SVM bekerja dengan mencari hyperplane optimal yang memisahkan kelas-kelas data dengan margin terbesar. Namun, SVM juga memiliki keterbatasan, seperti proses pelatihan yang lambat pada dataset besar

dan kesulitan dalam memilih fungsi kernel dan parameter yang tepat. Oleh karena itu, pemilihan kernel dan *tuning parameter* yang tepat sangat penting untuk mencapai kinerja optimal.Penerapan metode SMOTE (*Synthetic Minority Oversampling Technique*) dan SVM (*Support Vector Machine*) dalam penelitian ini bertujuan untuk mengatasi ketidakseimbangan data donor darah dan meningkatkan akurasi klasifikasi. SMOTE bekerja dengan menciptakan data sintetik dari kelas minoritas dengan memilih sampel acak dan menganalisis karakteristiknya, kemudian menghasilkan titik data baru di antara sampel-sampel yang memiliki kemiripan fitur menggunakan rumus *X_new = X_i + δ(Z_i - X_i)* (W. A. Kurniawan dkk, 2024).

$$\mathcal{X}_{new} = \mathcal{X}_{\mathrm{i}+(\ \mathcal{Z}_{\mathrm{i}}-\ x_i)\ \times\ \boldsymbol{\delta}} \qquad (2.1)$$

Keterangan :

Xnew : *Data Sintetis*
Xi : *Data yang di replikasi*
Zi : *Data yang memiliki jarak terdekat dengan data Xi*
∂ : Nilai random antara 0 dan 1

SVM kemudian digunakan untuk mengklasifikasikan data dengan membangun hyperplane optimal yang memisahkan kelas-kelas data dengan *margin* terbesar menggunakan rumus *F(X) = WX + B = 0*. Dengan penggabungan kedua metode ini, penelitian ini berupaya menciptakan model klasifikasi yang efektif dan akurat dalam memprediksi kelayakan donor darah (Cindy et al., 2024; Aminullah, 2021).

$$\mathcal{F}_{(\mathcal{X})} = \mathcal{W}\ \mathcal{X} + \mathcal{B}\ = 0 \qquad (2.2)$$

Keterangan :

w : *Fektor bobot (Weight Vektor)*
X : *Vektor Input (input data)*
b : *Bias*

SVM (*Support Vector Machine*) adalah algoritma klasifikasi yang tangguh dan efektif dalam membangun hyperplane optimal untuk memisahkan kelas-kelas data dengan margin terbesar dan kesalahan klasifikasi yang minimal. Dengan mengoptimalkan *vektor bobot (w)*, data *masukan (x), dan konstanta pemindah (b)*, SVM menciptakan model klasifikasi yang akurat dan memiliki generalisasi baik terhadap data baru. SVM sangat berguna dalam menangani data berdimensi tinggi dan *non-linear* melalui penggunaan fungsi *kernel* yang tepat. Dengan demikian, SVM dapat menjadi pilihan yang baik untuk berbagai masalah klasifikasi dalam machine learning (Gusti, 2023).

2.8 SVM DAN SMOTE

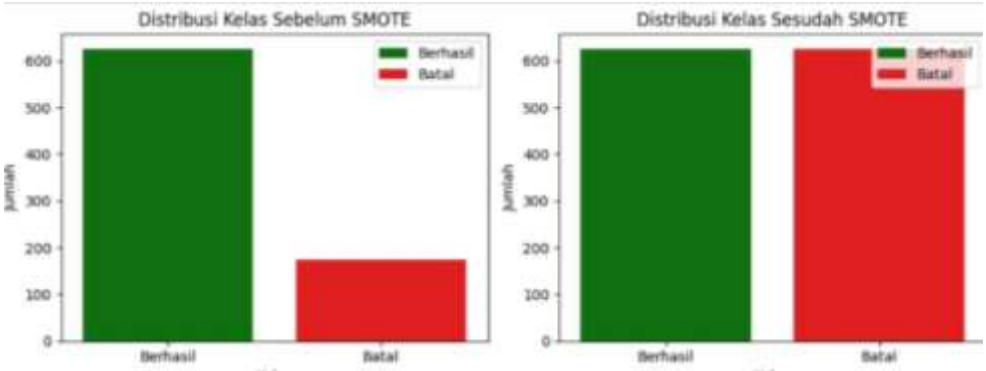
Implementasi algoritma SVM dan SMOTE dapat meningkatkan akurasi prediksi dan efektivitas model dalam mengenali pola kompleks pada dataset yang tidak seimbang. Dengan menggunakan SMOTE untuk menyeimbangkan kelas dan SVM untuk klasifikasi, model dapat mempelajari pola data dengan lebih baik dan meningkatkan akurasi prediksi. Proses ini melibatkan penerapan SMOTE untuk meningkatkan jumlah sampel pada kelas minoritas, diikuti dengan klasifikasi menggunakan SVM dan evaluasi model menggunakan metode *Cross-Validation* untuk mengukur akurasi pada setiap kelas dan rata-rata akurasi keseluruhan. Dengan demikian, integrasi antara teknik *Machine Learning* dan penyeimbangan data dapat meningkatkan performa model secara signifikan.

2.9 Evaluasi Kinerja

Evaluasi model klasifikasi menggunakan Confusion Matrix dan metrik performa seperti akurasi, presisi, recall, dan F1-score untuk memberikan gambaran menyeluruh tentang kemampuan model dalam klasifikasi data tidak seimbang. Berdasarkan penelitian yang dilakukan (Ni Putu Anik et al., 2024) dan (Harriz, 2025), metrik-metrik ini dipilih untuk menilai kinerja model secara komprehensif, terutama dalam menghadapi distribusi kelas yang tidak seimbang. Dengan menggunakan metrik-metrik ini, evaluasi model dapat memberikan hasil prediksi yang lebih akurat dan menyeluruh.

HASIL DAN PEMBAHASAN

Penelitian ini menguji efektivitas kombinasi SMOTE dan SVM untuk klasifikasi kelayakan donor darah menggunakan dataset PMI Samarinda (2024–2025) yang berisi 1000 data pendonor. Dataset terdiri dari atribut seperti umur, golongan darah, jenis kelamin, status kelayakan, *Hemoglobin*, tekanan darah, dan berat badan.Tahap pra-pemrosesan data meliputi seleksi fitur yang relevan, pembersihan data duplikat dan kosong, normalisasi nilai *Numerik,* serta transformasi data kategorikal menjadi *Numerik*. Kolom tensi juga dipecah menjadi *sistolik dan diastolik* untuk analisis lebih detail. Setelah proses ini, diperoleh 827 data bersih yang siap dianalisis.Penerapan SMOTE berhasil menyeimbangkan distribusi kelas, dari awalnya tidak seimbang (kelas minoritas hanya 91 data) menjadi seimbang dengan masing-masing kelas memiliki 200 data.



Gambar 1 Hasil Distribusi Sebelum dan sesudah SMOTE

Tabel 1 Hasil Sebelum dan Sesudah Memakai SMOTE

Kelas	Sebelum Pake SMOTE	Sesudah Pake SMOTE
0	91	200
1	91	200

a. Hasil Kerja Sebelum distribusi dan Sesudah SMOTE.

Tabel 1 memperlihatkan distribusi kelas pada dataset sebelum dan sesudah penerapan SMOTE. Sebelum dilakukan SMOTE, jumlah sampel pada Kelas 0 dan Kelas 1 sama-sama sebanyak 91, sehingga distribusinya relatif seimbang. Untuk meningkatkan keragaman data, dilakukan teknik oversampling menggunakan SMOTE hingga masing-masing kelas memiliki 200 sampel. Hasilnya, distribusi kelas menjadi seimbang dengan jumlah sampel yang setara, sehingga model dapat belajar lebih optimal tanpa kecenderungan bias terhadap salah satu kelas.

Tabel 2 Hasil Dari *K-Fold*

Fold	*TP*	*FN*	*TN*	*FP*	*Akurasi*
1	27	16	157	0	92.00%
2	30	13	157	0	93.50%
3	27	16	157	0	92.00%

4	31	13	156	0	93.50%
5	28	16	155	1	91.50%

Hasil Evaluasi model SVM SMOTE yang diterapkan pada data tanpa menggunakan *Oversampling* melalui metode *Cross-validation* terdapat lima kolom ditunjukkan dalam Tabel 2 Evaluasi ini menghasilkan metrik yang menunjukkan kinerja model pada masing-masing *Fold*. Dalam kebanyakan kasus, model menunjukkan kinerja yang sangat Tidak Stabil dengan akurasi tinggi, mencapai 93,50%

Tabel 3 Hasil Evaluasi

	TP	FP	TN	FN	Average Accuracy
Total Value Each Fold	143	1	782	74	92.05%

$$\text{Accuracy} = \frac{143+782}{143+782+1+74} = \frac{928}{1004} = 92.5\ \%$$

$$Accuracy = 92.5 \times 100\% = 92.50\%$$

b. Hasil Kerja Kinerja SMOTE

Tabel 4 Hasil Nilai Dari *K-Fold SMOTE*

Fold	TP	FP	TN	FN	Akurasi
1	155	17	26	2	90.50%
2	157	14	26	3	91.00%
3	150	15	30	5	90.00%
4	151	18	29	1	92.00%
5	152	12	30	6	92.05%

Tabe 4 Hasil Akurasi *SMOTE*

	TP	FP	TN	FN	Average Accuracy
Total Value Each Fold	765	76	141	17	90.69%

$$Accuracy = \frac{765+141}{765+141+76+17} = \frac{906}{999} = = 0.9069$$

$$Accuracy = 0.9069 \times 100\% = 90.69\ \%$$

Berdasarkan hasil pada Tabel 5 model ini mampu mengklasifikasikan sebagian besar data dengan benar, dengan rincian TP(*True Positive*) 765, FP (*False Positive*) 76, TN (*True Negative)* 141, dan FN(*False Negative*) 17. Akurasi rata-rata yang diperoleh adalah 90,69%.

c. Hasil Kerja Kinerja SMOTE dan SVM

Tabel 5 Hasil Nilai K-Fold

Fold	TP	FP	TN	FN	Akurasi
1	155	17	26	2	91.00 %
2	155	1	26	2	91.00%
3	155	1	26	1	91.00 %

4	154	2	25	3	92.00%
5	155	1	26	2	90.05%

Cross-validation lima baris membagi data menjadi 4 bagian bagian. mendalam. Hasilnya menunjukkan bahwa pada empat dari lima Fold, model mencapai akurasi 92.00 %.

Tabel 5 Perbandingan Evaluasi

Total Value Each Fold	TP	FP	TN	FN	Average Accuracy
	774	22	129	10	99.94%

tabel 5 menunjukkan nilai rata-rata akurasi model SVM setelah *Oversampling* data; nilai 96.94% menunjukkan hasil yang sangat baik sebesar 96.94%.

d. Hasil Kinerja Akurasi SVM dan SMOTE

Tabel 6 Perbandingan Akurasi

FOLD	SMOTE	SMOTE SVM	Kenaikan Akurasi
1	92.00%	90.00%	**2 %**
2	93.50%	92.00%	**15 %**
3	92.00%	93.05%	**10,5 %**
4	93.50 %	94.00%	**0,5%**
5	91.50%	96.00%	**4,5 %**

Penerapan SMOTE dan SVM pada dataset menunjukkan hasil bervariasi, dengan akurasi SMOTE-SVM mencapai 96,00% pada beberapa *fold*. Kombinasi ini dapat meningkatkan akurasi, meskipun tidak selalu konsisten. Secara keseluruhan, SMOTE-SVM memberikan performa yang lebih baik dengan akurasi sekitar 96,50%.

e. Hasil Akurasi SVM dan SMOTE

Tabel 7 Hasil Akurasi

	SMOTE	SVM SMOTE	Kenaikan Akurasi
Avarage Accuracy	93.50 %	96.05 %	2,55 %

Penerapan SMOTE saja menghasilkan rata-rata akurasi sebesar 93,50%, sedangkan kombinasi SMOTE dengan algoritma tambahan meningkatkan akurasi menjadi 96,05%, dengan peningkatan sebesar 2,55%. Hasil ini menunjukkan bahwa penggunaan SMOTE bersama algoritma tambahan dapat meningkatkan performa model dalam mengatasi ketidakseimbangan data.

KESIMPULAN

Penerapan kombinasi SMOTE dan SVM pada klasifikasi kelayakan donor darah berhasil meningkatkan akurasi dan stabilitas model. Dengan menyeimbangkan jumlah sampel pada kelas minoritas dan mayoritas dari 91 sampel menjadi 200 sampel, SMOTE membantu meningkatkan

nilai *recall dan F1-Score* pada kelas minoritas. Hasil evaluasi menggunakan *K-Fold Cross Validation* menunjukkan rata-rata akurasi model sebesar 92,50% dengan akurasi tertinggi 96,05 % dan peningkatan akurasi sekitar 3-4% dibandingkan penggunaan SVM tanpa *oversampling*. Model klasifikasi yang dihasilkan lebih sensitif dalam mendeteksi pendonor darah yang layak dengan jumlah *True Positive* tertinggi sebesar *31* dan *false negative* terendah sebesar 13. Dengan demikian, penerapan SMOTE dan SVM dapat meningkatkan performa model klasifikasi kelayakan donor darah dan membantu meningkatkan kesadaran masyarakat akan pentingnya donor darah sukarela, terutama di Indonesia yang masih membutuhkan sekitar 7 juta kantong darah per tahun.

REFRENSI

A. Rahim, A. M., Inggrid Yanuar Risca Pratiwi, & Muhammad Ainul Fikri. (2023). Klasifikasi Penyakit Jantung Menggunakan Metode Synthetic Minority Over-Sampling Technique Dan Random Forest Clasifier. *Indonesian Journal of Computer Science*, *12*(5), 2995–3011. https://doi.org/10.33022/ijcs.v12i5.3413

A'la, F. Y. (2025). Optimasi Klasifikasi Sentimen Ulasan Game Berbahasa Indonesia: IndoBERT dan SMOTE untuk Menangani Ketidakseimbangan Kelas. *Edumatic: Jurnal Pendidikan Informatika*, *9*(1), 256–265. https://doi.org/10.29408/edumatic.v9i1.29666

Akhmad, M. R. (2022). Implementasi K-Nearest Neighbor Dalam Memprediksi Keterlambatan Pembayaran Biaya Kuliah Di Perguruan Tinggi. *Progresif: Jurnal Ilmiah Komputer*, *18*(2), 185–192.

Alam, S., Makalew, L., Losu, F. N., Purwandari, A., Tuju, S., Pratiwi, D., Solang, S., Lumy, F., & Pasambo, Y. (2024). Pemberdayaan Pegawai Dan Mahasiswa Poltekkes Kemenkes Manado Dalam Meningkatkan Ketersediaan Darah Melalui Donor Darah. *JMM (Jurnal Masyarakat Mandiri)*, *8*(1), 809. https://doi.org/10.31764/jmm.v8i1.20402

Aminullah, M. (2021). Perbandingan Performa Klasifikasi Machine Learning dengan Teknik Resampling pada Dataset Tidak Seimbang. In *Repository.Uinjkt.Ac.Id*.

Azzahra, K., Rofiq, I. A., Putri, N., & Farikhah, L. K. (2024). *Kegiatan Donor Darah untuk Membantu Urusan Kemanusiaan di Desa Tinjomoyo*. *02*(01), 17–23.

Budi Utomo, P., Faruqziddan, M., Herdika Septa AuBudi Utomo, P., Faruqziddan, M., Herdika Septa Aulia, E., & Dini Azzahra, S. (2024). Perbandingan Skenario Balancing Oversampling dan Undersampling dalam Klasifikasi Resiko Kambuh Kanker Tiroid menggunakan Algoritma SVM Linear. JAMI: Jurna, E., & Dini Azzahra, S. (2024). Perbandingan Skenario Balancing Oversampling dan Undersampling dalam Klasifikasi Resiko Kambuh Kanker Tiroid menggunakan Algoritma SVM Linear. *JAMI: Jurnal Ahli Muda Indonesia*, *5*(2), 172–182. https://doi.org/10.46510/jami.v5i2.320

Caroline, F., Budi, R. G. S., & Rivan, M. E. Al. (2024). Analisis Sentimen Masyarakat terhadap Kasus Korupsi PT. Timah Menggunakan Metode Support Vector Machine. *Jurnal Ilmu Komputer Dan Informatika*, *4*(1), 43–50. https://doi.org/10.54082/jiki.141

Cindy, Sabatini, T., & Itan, V. (2024). Implementasi Support Vector Machine untuk Klasifikasi Kasus Monkeypox: Pendekatan Oversampling dan Undersampling untuk Mengatasi Ketidakseimbangan Kelas. *Journal of Digital Ecosystem for Natural Sustainability*, *4*(1), 38–43. https://doi.org/10.63643/jodens.v4i1.234

Desiani, A., Indra Maiyanti, S., Andriani, Y., Suprihatin, B., Amran, A., Marselina, N. C., & Salsabila, A. (2023). Perbandingan Klasifikasi Penyakit Kanker Paru-Paru menggunakan

Support Vector Machine dan K-Nearest Neighbor. *Jurnal PROCESSOR*, *18*(1), 54–62. https://doi.org/10.33998/processor.2023.18.1.700

Fathah, A., & Juliane, C. (2025). Kajian Data Mining untuk Klasifikasi Gender Menggunakan Data Wajah dengan Algoritma Naive Bayes dan K Nearest Neighbor (KNN). *Jurnal Teknologi Informasi Dan Ilmu Komputer*, *12*(1), 99–110. https://doi.org/10.25126/jtiik.2025128724

Franseda, A., Kurniawan, W., Anggraeni, S., & Gata, W. (2020). Integrasi Metode Decision Tree dan SMOTE untuk Klasifikasi Data Kecelakaan Lalu Lintas. *Jurnal Sistem Dan Teknologi Informasi (Justin)*, *8*(3), 282. https://doi.org/10.26418/justin.v8i3.40982

Gunawan, L. S., Pratiwi, R., Puspita, R. C., & Santoso, A. D. P. (2024). Pemenuhan Syarat Donor Untuk Menjamin Keberlangsungan Donor Lestari. *Health Care Journal of Community Service*, *2*(1), 79–91.

Gusti, K. W. (2023). Perbandingan metode Support Vector Machine dan Logistic Regression untuk klasifikasi bencana alam. *Informatik: Jurnal Ilmu Komputer*, *19*(2), 134–140.

Handayani, F., & Taufiq, R. M. (2024). *Jurnal Computer Science and Information Technology (CoSciTech) Komparasi Algoritma Menggunakan Teknik SMOTE Dalam Melakukan Klasifikasi Penyakit*. *5*(2), 367–372.

Harriz, M. A. (2025). Implementasi Random Forest dan SMOTE untuk Prediksi Risiko Putus Sekolah Dasar Menuju Indonesia Emas 2045. *Bridge: Jurnal Publikasi Sistem Informasi Dan Telekomunikasi*, *3*(2), 11–23.

Hutrim, H. P., & Nurahman. (2020). Penerapan Data Mining Untuk Penentuan (Studi Kasus Pmi Kabupaten Kotawaringin Timur). *Jurnal Informatika Dan Sistem Informasi*, *06*(02), 1–10.

Jasmarizal, Junadhi, Rahmaddeni, & M. Khairul Anam. (2024). Penerapan Metode Support Vector Machine Untuk Analisis Sentimen Terhadap Produk Skincare. *Indonesian Journal of Computer Science*, *13*(1), 1438–1450. https://doi.org/10.33022/ijcs.v13i1.3654

Kristiawan, K., & Widjaja, A. (2021). Perbandingan Algoritma Machine Learning dalam Menilai Sebuah Lokasi Toko Ritel. *Jurnal Teknik Informatika Dan Sistem Informasi*, *7*(1), 35–46. https://doi.org/10.28932/jutisi.v7i1.3182

Kurniawan, R. A., G, F. I. N., & Pribadi, M. R. (2024). Sentimen Analisis Presiden Terpilih Menggunakan Algoritma Support Vector Machine. *The Indonesian Journal of Computer Science Research*, *3*(14), 68–73.

Kurniawan, W. A., & Salam, A. (2024). Penggunaan Feature Space SMOTE Untuk Mengurangi Overfitting Akibat Imbalance Dataset. *Techno.Com*, *23*(2), 328–337. https://doi.org/10.62411/tc.v23i2.10215

Monika Parapat, I., & Tanzil Furqon, M. (2018). Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, *2*(10), 3163–3169.

Mulianti, A., Chrisnanto, Y. H., & Ashaury, H. (2024). *Optimalisasi Klasifikasi Support Vector Machine dengan SMOTE : Studi Kasus Ulasan Pengguna Aplikasi Alfagift Optimizing Support Vector Machine Classification with SMOTE : Case Study of Alfagift Application User Reviews*. 249–258. https://doi.org/10.56873/jpkm.v9i2.5583

Nailatun Nimah, & Gendut Sukarno. (2024). Pengabdian Donor Darah Pada Masyarakat Di Kabupaten Sidoarjo Oleh PT Telkom Akses. *Pelayanan Unggulan : Jurnal Pengabdian Masyarakat Terapan*, *1*(3), 27–32. https://doi.org/10.62951/unggulan.v1i3.294

Normah, Rifai, B., Vambudi, S., & Maulana, R. (2022). Analisa Sentimen Perkembangan Vtuber Dengan Metode Support Vector Machine Berbasis SMOTE. *Jurnal Teknik Komputer AMIK BSI*, *8*(2), 174–180. https://doi.org/10.31294/jtk.v4i2

Nugraha, M. A., Mazdadi, M. I., Farmadi, A., Muliadi, & Saragih, T. H. (2023). Penyeimbangan Kelas SMOTE dan Seleksi Fitur Ensemble Filter pada Support Vector Machine untuk Klasifikasi Penyakit Liver. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, *10*(6), 1273–1284. https://doi.org/10.25126/jtiik.2023107234

Pangaribuan, J. J., & Putra, A. (2024). Blood Donation Classification with Decision Tree Method using C4.5 Algorithm. *International Journal of Multidisciplinary Approach Research and Science*, *2*(03), 1248–1259. https://doi.org/10.59653/ijmars.v2i03.961

Pradana, M. G., Saputro, P. H., & Wijaya, D. P. (2022). Komparasi Metode Support Vector Machine Dan Naïve Bayes Dalam Klasifikasi Peluang Penyakit Serangan Jantung. *Indonesian Journal of Business Intelligence (IJUBI)*, *5*(2), 87. https://doi.org/10.21927/ijubi.v5i2.2659

Ramadhan, I. S., & Salam, A. (2024). Teknik Random Undersampling untuk Mengatasi Ketidakseimbangan Kelas pada CT Scan Kista Ginjal. *Techno.Com*, *23*(1), 20–28. https://doi.org/10.62411/tc.v23i1.9738

Ridwan, R., Hermaliani, E. H., & Ernawati, M. (2024). Penerapan: Penerapan Metode SMOTE Untuk Mengatasi Imbalanced Data Pada Klasifikasi Ujaran Kebencian. *Computer Science (CO-SCIENCE)*, *4*(1), 80–88.

Sir, Y. A., & Soepranoto, A. H. H. (2022). Pendekatan Resampling Data Untuk Menangani Masalah Ketidakseimbangan Kelas. *Jurnal Komputer Dan Informatika*, *10*(1), 31–38. https://doi.org/10.35508/jicon.v10i1.6554

Thoriq, M. F. (2023). *Penerapan Seleksi Fitur Analysis of Variance pada Algoritma Random Forest Classifier dalam Klasifikasi Nilai Mahasiswa Studi Kasus: Universitas Muhammadiyah Kalimantan Timur*.

WIJAYANTI, N. P. Y. T., N. KENCANA, E., & SUMARJAYA, I. W. (2021). Smote: Potensi Dan Kekurangannya Pada Survei. *E-Jurnal Matematika*, *10*(4), 235. https://doi.org/10.24843/mtk.2021.v10.i04.p348