

PENYEIMBANGAN DATA UNTUK KLASIFIKASI JENIS ANEMIA MENGUNAKAN SMOTE DAN PENGEMBANGAN DIAGNOSTIK STREAMLIT

BALANCING DATA FOR ANEMIA TYPES CLASSIFICATION USING SMOTE AND DEVELOPMENT DIAGNOSTIC STREAMLIT

Yulistiya Nur Hidayah¹, Erna Daniati^{1*}, Mochamad Abdul Azis¹

*E-mail: ernadaniati@unpkediri.ac.id

¹Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

Abstrak

Anemia adalah gangguan darah yang ditandai rendahnya kadar hemoglobin sehingga pasokan oksigen tubuh berkurang. Proses diagnosis manual melalui *Complete Blood Count* (CBC) sering memerlukan waktu, terutama dalam membedakan jenis anemia yang serupa. Penelitian ini bertujuan meningkatkan akurasi klasifikasi jenis anemia dengan menerapkan *Synthetic Minority Oversampling Technique* (SMOTE) pada dataset klasifikasi tipe anemia (1.281 sampel, 14 prediktor, 9 kategori). Model utama yang digunakan adalah ensemble yaitu random forest (bagging ensemble) dengan pembandingan XGBoost (boosting ensemble). Evaluasi menggunakan akurasi, presisi, *recall*, *F1-score*, dan *AUC ROC*, baik sebelum maupun sesudah SMOTE. Hasil diharapkan mampu meningkatkan performa kelas minoritas, khususnya *Leukemia* dengan *Thrombocytopenia*. Model terbaik kemudian diimplementasikan dalam aplikasi berbasis Streamlit untuk prediksi otomatis berdasarkan data CBC. Penelitian ini memberikan kontribusi akademis melalui peningkatan performa klasifikasi serta kontribusi praktis berupa alat bantu diagnosis sederhana.

Kata kunci: CBC, klasifikasi anemia, SMOTE, ensemble learning, random forest, XGBoost, streamlit

Abstract

Anemia is a blood disorder characterized by low hemoglobin levels, resulting in reduced oxygen supply to the body. Manual diagnosis through a *Complete Blood Count* (CBC) is often time-consuming, especially in differentiating between similar types of anemia. This study aims to improve the accuracy of anemia classification by applying the *Synthetic Minority Oversampling Technique* (SMOTE) to an anemia classification dataset (1,281 samples, 14 predictors, and 9 categories). The main model used is an ensemble (bagging) model random forest with XGBoost (boosting) as a comparator. Evaluation uses accuracy, precision, recall, *F1-score*, and *AUC ROC*, both before and after SMOTE. The results are expected to improve the performance of minority classes, especially *Leukemia* with *Thrombocytopenia*. The best model is then implemented in a Streamlit-based application for automatic prediction based on CBC data. This study provides academic contributions through improved classification performance and practical contributions in the form of a simple diagnostic tool.

Keywords: CBC, anemia classification, SMOTE, ensemble learning, random forest, XGBoost, streamlit

1. PENDAHULUAN

Pada era digital dewasa ini, penerapan *machine learning* di sektor kesehatan tidak lagi dipandang sekadar sebagai tren teknologi, melainkan telah bertransformasi menjadi kebutuhan

nyata untuk mempercepat proses diagnosis sekaligus meningkatkan ketepatan hasilnya. Teknologi pembelajaran mesin diyakini mampu mendukung kinerja tenaga medis dengan menghadirkan kecepatan analisis, konsistensi keputusan, serta efisiensi biaya, sehingga berperan penting dalam optimalisasi sistem pelayanan kesehatan [1]. Hal ini menjadi semakin relevan terutama pada penyakit dengan tingkat prevalensi tinggi, seperti anemia. Sejumlah studi terdahulu juga menegaskan bahwa penerapan algoritma pembelajaran mesin yang dikombinasikan dengan metode penyeimbangan data, misalnya SMOTE, terbukti dapat memperbaiki performa model dalam mengidentifikasi penyakit, sehingga memberikan dasar ilmiah yang kuat bagi penelitian ini [2], [3]. Sejalan dengan itu, penelitian [4] yang menekankan bahwa kualitas dataset, baik dari sisi distribusi maupun labeling, sangat memengaruhi performa model. Pada penelitian tersebut menunjukkan bahwa metode *weak supervision* dapat mempercepat *labeling* data besar, meskipun tantangannya adalah potensi label noisy yang dapat menurunkan akurasi model

Menurut estimasi WHO, sekitar 39,8% anak-anak usia 6–59 bulan menderita anemia (data terakhir tersedia tahun 2019), sementara 30,7% perempuan usia 15–49 tahun secara keseluruhan, dan 35,5% perempuan hamil pada rentang usia yang sama menderita anemia pada tahun 2023 [5]. Anemia merupakan kondisi medis yang muncul ketika kadar hemoglobin dalam darah berada di bawah batas normal, sehingga menurunkan kapasitas darah dalam mendistribusikan oksigen ke seluruh jaringan tubuh. Dalam konteks diagnosis, data *Complete Blood Count* (CBC) berperan sebagai sumber informasi yang krusial untuk mendeteksi keberadaan anemia sekaligus mengklasifikasikan jenis-jenisnya. Dataset *Anemia Types Classification* dari Kaggle yang digunakan oleh [6] berisi 1.281 sampel dengan 14 prediktor, mencakup delapan jenis anemia serta kategori sehat.

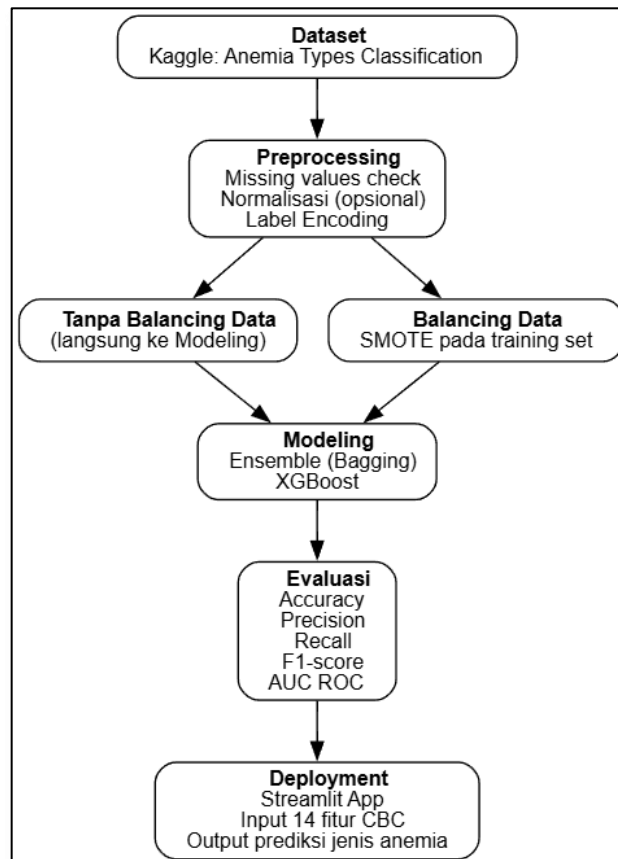
Permasalahan mendasar dari dataset ini adalah ketidakseimbangan jumlah data antar kelas. Misalnya, kategori *Leukemia with Thrombocytopenia* hanya memiliki 11 sampel, jauh lebih sedikit dibanding kategori sehat yang mencapai 336 sampel. Ketidakseimbangan ini dapat membuat model bias terhadap kelas mayoritas, sehingga akurasi global tampak tinggi, tetapi performa pada kelas minoritas sangat rendah. Untuk mengatasi hal tersebut, pendekatan *Synthetic Minority Oversampling Technique* (SMOTE) dapat digunakan guna memperbanyak sampel sintetis di kelas minoritas sehingga distribusi data menjadi lebih seimbang. Sejumlah penelitian di Indonesia membuktikan efektivitas SMOTE dalam berbagai kasus medis, seperti prediksi penyakit jantung [7], [8], diabetes [9], hingga hepatitis [10].

Artikel [6] menunjukkan bahwa dari sembilan model *machine learning* yang diuji, metode *Ensemble (bagging)* menghasilkan akurasi validasi 99,22% dan akurasi uji 100%. Meski demikian, mereka juga menekankan rendahnya nilai *Positive Predictive Value* (PPV) pada kategori minoritas, khususnya *Leukemia with Thrombocytopenia* (hanya 76,9%). Hal ini membuka peluang penelitian lanjutan dengan penerapan teknik *balancing data* seperti *Synthetic Minority Oversampling Technique* (SMOTE) terhadap performa klasifikasi anemia, membandingkan hasil sebelum dan sesudah *balancing*. Hal ini juga diperkuat oleh penelitian [11] yang menunjukkan bahwa proses *balancing data* melalui pendekatan *hybrid* mampu menyeimbangkan nilai akurasi, presisi, *recall*, dan *F1-score* pada berbagai algoritma klasifikasi, meskipun akurasi rata-rata sedikit menurun. Hasil ini menegaskan pentingnya *balancing* dalam mengurangi bias terhadap kelas mayoritas dan meningkatkan keandalan model klasifikasi. Sejalan dengan penelitian [3] yang berhasil memanfaatkan SMOTETomek untuk menangani data tidak seimbang sekaligus melakukan *deployment* ke aplikasi Streamlit dengan akurasi 96%, penelitian ini diharapkan mampu menghadirkan kontribusi akademik sekaligus praktis berupa alat bantu diagnostik berbasis data CBC. Hal ini sejalan dengan tren penelitian terbaru di Indonesia yang tidak hanya berfokus pada pengembangan model, tetapi juga *deployment* dalam bentuk aplikasi berbasis Streamlit agar dapat dimanfaatkan secara langsung oleh pengguna [3], [12].

2. METODOLOGI

Penelitian ini menggunakan metodologi yang difokuskan pada pengembangan sistem klasifikasi jenis anemia dengan pendekatan *machine learning* berbasis data *Complete Blood Count* (CBC). Fokus utama penelitian ini adalah meningkatkan akurasi proses diagnosis dengan cara

mengatasi permasalahan ketidakseimbangan data. Pendekatan ini dibangun atas dasar studi sebelumnya [6] yang menunjukkan efektivitas *machine learning* dalam prediksi dan klasifikasi anemia, termasuk penggunaan teknik *oversampling* untuk mengatasi data tidak seimbang dan mencapai akurasi tinggi dalam konteks medis. Alur penelitian dilaksanakan terdapat pada gambar berikut:



Gambar 1. Work Flow ML Anemia Type Classification

2.1 Dataset

Penelitian ini menggunakan dataset *Anemia Types Classification* yang tersedia di [13] dengan total 1.281 sampel yang mencakup 14 fitur prediktor dari hasil *Complete Blood Count (CBC)* serta 1 label target berupa kategori anemia. Label target terdiri dari 9 kelas, yaitu delapan jenis anemia (misalnya *Iron Deficiency Anemia*, *Macrocytic Anemia*, *Leukemia*, dll.) serta satu kelas sehat. Dataset ini dipilih karena memiliki variasi kelas yang cukup luas, sehingga dapat merepresentasikan kondisi nyata pasien. Penelitian sebelumnya oleh [6] menunjukkan bahwa dataset ini relevan untuk evaluasi berbagai model *machine learning*, meskipun masih terdapat kendala serius pada ketidakseimbangan distribusi data antar kelas.

2.2 Preprocessing

Tahap *preprocessing* dilakukan untuk memastikan data berada dalam kondisi siap diolah oleh algoritma. Langkah pertama adalah pemeriksaan kelengkapan data, yaitu memastikan tidak terdapat nilai kosong (missing values) yang dapat mengganggu performa model. Selanjutnya dilakukan normalisasi (opsional) karena model ensemble tidak terlalu sensitif terhadap perbedaan skala data. Namun demikian, normalisasi tetap dipertimbangkan untuk menjaga konsistensi apabila model dikembangkan lebih lanjut menggunakan metode lain [14]. Terakhir, dilakukan encoding pada target, yaitu mengubah label kategori anemia yang semula berbentuk teks menjadi nilai

numerik. Proses ini penting karena sebagian besar algoritma klasifikasi tidak dapat memproses data non-numerik.

2.3 Balancing Data

Ketidakseimbangan kelas (*imbalanced data*) menjadi masalah paling signifikan dalam dataset ini. Contohnya, kelas *Leukemia with Thrombocytopenia* hanya memiliki 11 sampel (0,86%), sedangkan kelas sehat memiliki 336 sampel (26,2%) [6]. Hal ini menimbulkan bias model, di mana algoritma cenderung lebih akurat mengenali kelas mayoritas tetapi gagal mengklasifikasi kelas minoritas. Untuk mengatasi hal tersebut digunakan *Synthetic Minority Oversampling Technique* (SMOTE), sebuah teknik *oversampling* yang membuat data sintetis baru untuk kelas minoritas dengan cara interpolasi nilai antar sampel. Prosedur dilakukan sebagai berikut:

1. Data dibagi menjadi 80% *training* dan 20% *testing*.
2. SMOTE diterapkan hanya pada *data training* untuk mencegah *data leakage*.
3. *Data training* hasil SMOTE kemudian digunakan untuk pelatihan model.

SMOTE dipilih karena terbukti efektif dalam meningkatkan performa model pada kasus medis dengan data tidak seimbang. Penelitian terbaru seperti [15] memperkenalkan SMOTE-MRS (kombinasi SMOTE, *clustering*, dan *oversampling*), yang mampu meningkatkan akurasi prediksi anemia hingga 97,3% dan *F1-score* 97,9%. Sementara itu, [14], [16] juga menegaskan pentingnya *balancing data* dengan SMOTE maupun ADASYN dalam klasifikasi berbasis CBC untuk mencegah bias prediksi.

2.4 Modeling

Pemodelan dalam konteks *machine learning* adalah proses membangun model untuk memprediksi atau mengklasifikasikan data berdasarkan pola yang ada. Tujuan utama *modeling* adalah menghasilkan model yang akurat dan mampu melakukan generalisasi terhadap data baru.

1. Ensemble (*bagging*) dipilih sebagai model utama, karena penelitian [6] menunjukkan model *ensemble* menghasilkan akurasi validasi 99,22% dan akurasi uji 100%. *Bagging* bekerja dengan melatih banyak pohon keputusan (*decision trees*) pada subset data berbeda, lalu menggabungkan hasil prediksi untuk mengurangi varians dan meningkatkan akurasi global.
2. XGBoost digunakan sebagai model pembanding. XGBoost adalah algoritma *gradient boosting* yang terkenal unggul dalam menangani data tabular dengan jumlah fitur moderat. XGBoost dilengkapi dengan mekanisme regularisasi dan optimisasi yang membuatnya efisien serta akurat, bahkan pada dataset yang cenderung tidak seimbang [17], [18].

Model dilatih dalam dua skenario yaitu tanpa dan dengan SMOTE. Perbandingan hasil kedua skenario menjadi dasar analisis pengaruh SMOTE terhadap performa klasifikasi.

2.5 Evaluasi

Evaluasi model dilakukan menggunakan beberapa metrik agar performa dapat dilihat dari berbagai sudut. *Accuracy* mengukur persentase total prediksi benar, sementara *precision* menilai ketepatan prediksi pada setiap kelas. *Recall* menilai kemampuan model mendeteksi seluruh sampel pada kelas tertentu, penting untuk kelas minoritas. *F1-score* (macro & weighted) menggabungkan *precision* dan *recall* untuk memberikan gambaran performa yang seimbang, baik pada kelas minoritas maupun keseluruhan. Lebih lanjut, AUC-ROC (Area Under the Receiver Operating Characteristic Curve) digunakan untuk mengevaluasi *trade-off* antara *true positive rate* dan *false positive rate* pada berbagai ambang batas keputusan. Metrik ini memberikan pandangan yang lebih komprehensif tentang kemampuan model membedakan kelas, terutama pada data yang tidak seimbang [19]. Fokus utama tetap pada kelas minoritas, untuk menilai sejauh mana SMOTE mampu memperbaiki kemampuan model dalam mengenali kategori dengan data terbatas. Studi evaluasi terbaru menegaskan bahwa kombinasi metrik berbasis *precision-recall* lebih informatif dibanding hanya mengandalkan akurasi pada dataset *imbalanced* [20].

2.6 Deployment

Tahap akhir penelitian adalah penerapan model terbaik ke dalam aplikasi berbasis Streamlit.

Alur aplikasi meliputi:


1. Input: pengguna memasukkan 14 fitur CBC.
2. Proses: model *machine learning* melakukan klasifikasi jenis anemia.
3. Output: aplikasi menampilkan kategori anemia hasil prediksi beserta probabilitas masing-masing kelas.

Fitur tambahan berupa visualisasi probabilitas prediksi ditampilkan dalam bentuk grafik batang agar pengguna dapat memahami tingkat keyakinan model. Langkah ini mengikuti tren penelitian terbaru yang tidak hanya membangun model, tetapi juga menyediakannya dalam aplikasi interaktif berbasis Streamlit agar dapat dimanfaatkan secara langsung oleh pengguna [3], [21].


3 HASIL DAN PEMBAHASAN

3.1 Perbandingan Dua Skenario Dataset (imbalance vs balanced)

Dataset Anemia Types Classification berisi 1.281 sampel hasil tes darah lengkap (CBC) dengan atribut seperti hemoglobin (HGB), hematokrit (HCT), MCV, MCH, MCHC, dan parameter sel darah merah lainnya. *Pre-processing* dilakukan dengan pembersihan data, normalisasi, dan pemisahan *train-test set*. Dataset asli menunjukkan ketidakseimbangan kelas (Gambar 1), dengan kelas mayoritas mendominasi, yang dapat menyebabkan bias model terhadap kelas dominan. Untuk mengatasinya, SMOTE digunakan untuk menyeimbangkan distribusi kelas, seperti ditunjukkan pada (Gambar 2), sehingga model dapat belajar secara lebih adil untuk semua kategori anemia.



Gambar 2. Grafik sebelum SMOTE



Gambar 3. Grafik sesudah SMOTE

3.2 Analisis Pengaruh SMOTE pada Klasifikasi Anemia (Random Forest dan XGBoost)

Random Forest merupakan algoritma *ensemble bagging* yang menggabungkan banyak pohon keputusan secara paralel, sedangkan XGBoost termasuk *ensemble boosting* yang membangun pohon secara bertahap dengan fokus memperbaiki kesalahan sebelumnya. Pada penelitian ini, kedua algoritma diuji dengan dan tanpa penerapan SMOTE untuk melihat pengaruh teknik *balancing* data terhadap performa klasifikasi anemia.

3.2.1 Random Forest Classifier (Tanpa SMOTE)

Model cenderung overfit pada kelas mayoritas sehingga terlihat akurasi tinggi, namun *recall* dan *F1-score* pada kelas minoritas sangat rendah. Sehingga banyak kasus anemia langka salah terdeteksi sebagai kelas mayoritas (misalnya Leukemia diprediksi sebagai Healthy). Tanpa *oversampling*, performa model menjadi kurang andal untuk diagnosis medis.

Tabel 1. Tabel kelas random forest tanpa SMOTE

Kelas	Precision	Recall	F1-score	Support
Healthy	0.99	1.00	0.99	67
Iron deficiency anemia	0.97	0.97	0.97	38
Leukemia	1.00	0.89	0.94	9
Leukemia with thrombocytopenia	1.00	1.00	1.00	2

Kelas	Precision	Recall	F1-score	Support
<i>Macrocytic anemia</i>	1.00	1.00	1.00	4
<i>Normocytic hypochromic anemia</i>	0.98	1.00	0.99	56
<i>Normocytic normochromic anemia</i>	1.00	1.00	1.00	54
<i>Other microcytic anemia</i>	1.00	0.92	0.96	12
<i>Thrombocytopenia</i>	1.00	1.00	1.00	15

3.2.2 Random Forest Classifier (Dengan SMOTE)

SMOTE menghasilkan sampel sintetis, menyeimbangkan distribusi, sehingga *recall minority* meningkat signifikan tanpa mengorbankan terlalu banyak *precision*.

Tabel 2. Tabel kelas random forest dengan SMOTE

Kelas	Precision	Recall	F1-score	Support
<i>Healthy</i>	1.00	1.00	1.00	67
<i>Iron deficiency anemia</i>	0.97	1.00	0.99	38
<i>Leukemia</i>	1.00	1.00	1.00	9
<i>Leukemia with thrombocytopenia</i>	1.00	1.00	1.00	2
<i>Macrocytic anemia</i>	1.00	1.00	1.00	4
<i>Normocytic hypochromic anemia</i>	1.00	1.00	1.00	56
<i>Normocytic normochromic anemia</i>	1.00	1.00	1.00	54
<i>Other microcytic anemia</i>	1.00	0.92	0.96	12
<i>Thrombocytopenia</i>	1.00	1.00	1.00	15

3.2.3 XGBoost Classifier (Tanpa SMOTE)

XGBoost lebih unggul dari Random Forest dalam menangani ketidakseimbangan data tetapi tanpa SMOTE, model tetap bias ke kelas mayoritas

Tabel 3. kelas XGBoost Classifier tanpa SMOTE

Kelas	Precision	Recall	F1-score	Support
<i>Healthy</i>	1.00	0.99	0.99	67
<i>Iron deficiency anemia</i>	1.00	1.00	1.00	38
<i>Leukemia</i>	0.90	1.00	0.95	9
<i>Leukemia with thrombocytopenia</i>	1.00	0.50	0.67	2
<i>Macrocytic anemia</i>	1.00	1.00	1.00	4
<i>Normocytic hypochromic anemia</i>	0.98	1.00	0.99	56
<i>Normocytic normochromic anemia</i>	1.00	1.00	1.00	54
<i>Other microcytic anemia</i>	0.92	0.92	0.92	12
<i>Thrombocytopenia</i>	1.00	1.00	1.00	15

3.2.4 XGBoost Classifier (Dengan SMOTE)

Peningkatan SMOTE membantu XGBoost dengan menyediakan lebih banyak sampel *minority* untuk *boosting*, meningkatkan recall tanpa overfit berlebih

Tabel 4. Tabel kelas XGBoost Classifier dengan SMOTE

Kelas	Precision	Recall	F1-score	Support
<i>Healthy</i>	1.00	0.99	0.99	67
<i>Iron deficiency anemia</i>	1.00	1.00	1.00	38
<i>Leukemia</i>	1.00	0.78	0.88	9
<i>Leukemia with thrombocytopenia</i>	1.00	1.00	1.00	2
<i>Macrocytic anemia</i>	0.67	1.00	0.80	4
<i>Normocytic hypochromic anemia</i>	0.98	1.00	0.99	56
<i>Normocytic normochromic anemia</i>	1.00	1.00	1.00	54
<i>Other microcytic anemia</i>	0.92	0.92	0.92	12
<i>Thrombocytopenia</i>	1.00	1.00	1.00	15

3.3 Performa Algoritma Random Forest vs XGBoost

Dalam hal performa algoritma, Ensemble (bagging) tetap menunjukkan akurasi tertinggi secara keseluruhan, dengan validasi mencapai 99,22% dan akurasi uji 100% [6]. Hal ini menunjukkan kekuatan *ensemble* dalam menggabungkan banyak pohon keputusan untuk mengurangi varians dan meningkatkan stabilitas prediksi. Namun, XGBoost menunjukkan keunggulan khusus dalam menangani kelas minoritas setelah *balancing* dilakukan. Mekanisme *gradient boosting* yang dilengkapi regularisasi membuat XGBoost lebih sensitif terhadap kelas minoritas dan mampu menyesuaikan bobot kesalahan secara dinamis. Oleh karena itu, XGBoost menjadi model pembandingan yang ideal untuk menilai peningkatan performa setelah penerapan SMOTE, khususnya pada dataset yang tidak seimbang dan memiliki kelas minoritas.

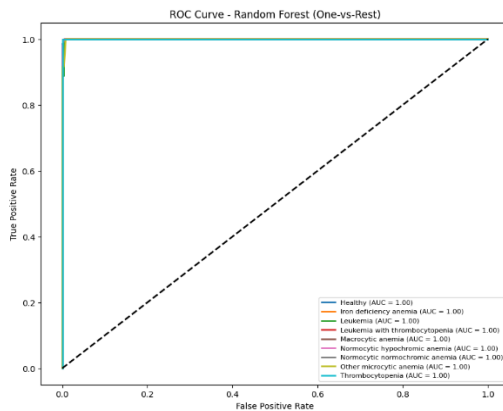
Tabel 5. Tabel ringkasan hasil metrik untuk Ensemble Bagging vs XGBoost

Algoritma	Skenario	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Random Forest (ensemble bagging)	Tanpa SMOTE	99,0	99,0	99,0	99,0
	Dengan SMOTE	100,0	100,0	99,0	100,0
XGBoost (ensemble boosting)	Tanpa SMOTE	99,9	98,0	93,0	99,0
	Dengan SMOTE	98,0	95,0	96,0	95,0

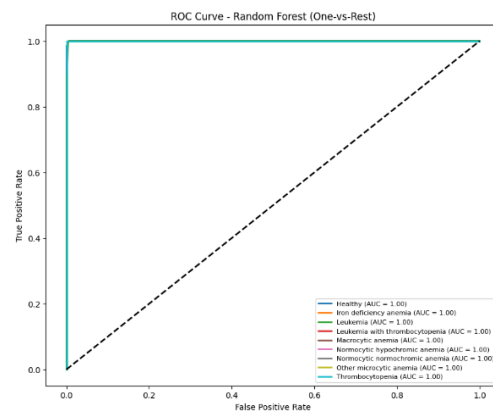
Tabel di atas membandingkan performa Random Forest dan XGBoost dengan dan tanpa SMOTE. Random Forest tanpa SMOTE akurasinya tinggi (99%) namun *recall* kelas minoritas menurun, sedangkan setelah SMOTE performanya hampir sempurna (100%). XGBoost juga serupa, tanpa SMOTE akurasi tinggi (99,9%) tapi *recall* kelas minoritas rendah, sementara dengan SMOTE akurasi sedikit turun (98%) namun hasil lebih merata antar kelas. Hal ini menegaskan bahwa SMOTE efektif menyeimbangkan performa, terutama pada kelas dengan data terbatas.

3.4 Evaluasi Performa Model dengan ROC AUC

Evaluasi menggunakan ROC AUC menunjukkan perbedaan yang jelas antara model tanpa *balancing* dan model dengan SMOTE. Meskipun secara visual kedua ROC *curve* tampak hampir sama dengan nilai AUC mendekati 1 pada semua kelas, hasil perhitungan per kelas menunjukkan perbedaan. Pada model tanpa SMOTE, peningkatan AUC lebih dominan pada kelas mayoritas sehingga kurva kelas minoritas kurang stabil. Sebaliknya, setelah dilakukan *balancing* dengan SMOTE, kurva ROC setiap kelas lebih konsisten dan nilai AUC pada kelas minoritas meningkat, menandakan kemampuan model dalam membedakan kategori langka menjadi lebih baik.



Gambar 4. Kurva tanpa SMOTE



Gambar 5. Kurva dengan SMOTE

3.5 Implementasi Aplikasi Streamlit

Penelitian ini berhasil mengimplementasikan model Random Forest yang dilatih dengan data hasil balancing SMOTE ke dalam aplikasi berbasis Streamlit. Aplikasi memungkinkan input 14 fitur CBC untuk menghasilkan prediksi jenis anemia beserta probabilitas tiap kelas. Implementasi ini menegaskan kontribusi akademis berupa bukti efektivitas SMOTE dalam meningkatkan performa prediksi kelas minoritas, sekaligus kontribusi praktis berupa alat diagnostik interaktif yang cepat, mudah diakses, dan relevan untuk praktik klinis.

Anemia Detection System (Random Forest + SMOTE)

Masukkan hasil Complete Blood Count (CBC) untuk memprediksi jenis anemia.

Input Data CBC

WBC	LYMp
10,00	43,20
NEUTp	LYMn
50,10	4,30
NEUTn	RBC
5,00	2,77
HGB	HCT
7,30	24,20
MCV	MCH
87,70	26,30
MCHC	PLT
30,10	189,00
PDW	PCT
12,50	0,17

Hasil Prediksi

Prediksi Jenis Anemia

Diagnosis: Normocytic hypochromic anemia

Probabilitas Tiap Kelas

Healthy: 0.0000
Iron deficiency anemia: 0.0100
Leukemia: 0.0000
Leukemia with thrombocytopenia: 0.0000
Macrocytic anemia: 0.0000
Normocytic hypochromic anemia: 0.9700
Normocytic normochromic anemia: 0.0100
Other microcytic anemia: 0.0100
Thrombocytopenia: 0.0000

Gambar 6. Input 14 form CBC dan hasil diagnosis

4 KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa penerapan SMOTE berperan penting dalam meningkatkan performa klasifikasi jenis anemia, terutama pada kelas minoritas yang sebelumnya sulit dikenali. Tanpa SMOTE, model seperti Random Forest maupun XGBoost memang mencatat akurasi tinggi, namun cenderung bias terhadap kelas mayoritas sehingga *recall* pada kategori langka rendah. Setelah dilakukan *balancing* dengan SMOTE, performa model menjadi lebih seimbang, dengan Random Forest + SMOTE memberikan hasil terbaik karena mampu menjaga

akurasi tinggi sekaligus meningkatkan deteksi kelas minoritas secara signifikan. Model terbaik ini kemudian berhasil diimplementasikan dalam aplikasi berbasis Streamlit yang memungkinkan input data CBC untuk menghasilkan prediksi otomatis beserta probabilitas tiap kelas, sehingga berkontribusi baik secara akademis maupun praktis sebagai alat bantu diagnosis sederhana dan interaktif. Untuk penelitian selanjutnya, disarankan mengeksplorasi metode *balancing* lain seperti ADASYN atau SMOTE-ENN, menguji model *deep learning* untuk meningkatkan generalisasi, serta memperluas dataset agar lebih representatif terhadap kondisi klinis nyata.

5 DAFTAR RUJUKAN

- [1] C. Bulut, "Artificial Intelligence and Cost Reduction Strategies for Healthcare Management: Opportunities and Limitations," *Acta Infologica*, vol. 0, no. 0, pp. 0–0, 2025, doi: 10.26650/acin.1631851.
- [2] N. Wulandari and B. Badieah, "Implementasi Teknik Resampling Untuk Mengatasi Ketidakseimbangan Data Terhadap Klasifikasi Anemia Menggunakan Support Vector Machine," *J. Rekayasa Sist. Inf. dan Teknol.*, vol. 2, no. 3, pp. 942–951, 2025, doi: 10.70248/jrsit.v2i3.1856.
- [3] T. K. Amarya, R. Firliana, and A. Ristyawan, "Aplikasi Deteksi Dini Penyakit Stroke Menggunakan Stramlit," *INOTEK, Vol. 9*, vol. 9, pp. 453–462, 2025.
- [4] H. Utama, E. Daniati, and A. Masruro, "Weak Supervision Dengan Pendekatan Labeling Function Untuk Analisis Sentimen Pada Twitter," *Indones. J. Comput. Sci. Res.*, vol. 3, no. 1, pp. 49–57, 2024, doi: 10.59095/ijcsr.v3i1.93.
- [5] WHO, "Anaemia," 2023. [Online]. Available: https://www.who.int/data/gho/data/themes/topics/anaemia_in_women_and_children
- [6] A. Végh, L. Takáč, O. Czákóová, K. Dansca, and D. Nagy, "Evaluating Optimizable Machine Learning Models for Anemia Type Prediction from Complete Blood Count Data," *Int. J. Adv. Nat. Sci. Eng. Res.*, vol. 7, no. 7, pp. 108–119, 2024, [Online]. Available: <https://as-proceeding.com/index.php/ijanser>
- [7] M. Dewi, T. H. Saragih, and R. Herteno, "Penerapan SMOTE-NCL untuk Mengatasi Ketidakseimbangan Kelas pada Klasifikasi Penyakit Jantung Koroner," *J. Inform. Polinema*, vol. 10, no. 1, pp. 27–34, 2023, doi: 10.33795/jip.v10i1.1394.
- [8] A. E. Pranajaya and E. R. Susanto, "Optimasi Random Forest untuk Prediksi Penyakit Jantung Menggunakan SMOTEENN dan Grid Search Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat Indonesia, Indonesia Random Forest Optimization for Heart Disease Prediction Using SM," *J. Pendidik. dan Teknol. Indones.*, vol. 5, no. 7, pp. 1965–1979, 2025, doi: 10.52436/1.jpti.855.
- [9] N. Fitriyani, D. R. Amalia, H. H. Handayani, A. Fitri, and N. Masruriyah, "Aplikasi Berbasis Web Berdasarkan Model Klasifikasi Algoritma SVM dan Logistic Regression Terhadap Data Diabetes," *Ris. dan E-Jurnal Manaj. Inform. Komput.*, vol. 7, pp. 1762–1771, 2023, [Online]. Available: <http://doi.org/10.33395/remik.v7i4.13001%0D>
- [10] D. P. Prianggi, A. Nilogiri, and ..., "Pengaruh Teknik SMOTE Terhadap Prediksi Harapan Hidup Penderita Penyakit Hepatitis Menggunakan Algoritma K-Nearest Neighbor," ... *Sist. Inf. dan ...*, vol. 3, no. 2, pp. 76–85, 2021, [Online]. Available: <http://jurnal.unmuhjember.ac.id/index.php/JASIE/article/view/8910%0Ahttp://jurnal.unmuhjember.ac.id/index.php/JASIE/article/download/8910/4624>
- [11] T. K. Amarya, A. C. A. Galuh, R. Achmad, E. Daniati, and A. Ristyawan, "Analisa Perbandingan Algoritma Classification Berdasarkan Komposisi Label," *Pros. SEMNAS INOTEK*, vol. 8, no. 1, pp. 32–40, 2024, [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek>
- [12] R. Peranginangin, E. J. G. Harianja, I. K. Jaya, and B. Rumahorbo, "Penerapan Algoritma Safe-Level-Smote Untuk Peningkatan Nilai G-Mean Dalam Klasifikasi Data Tidak Seimbang," *METHOMIKA J. Manaj. Inform. dan Komputerisasi Akunt.*, vol. 4, no. 1, pp. 67–72, 2020, doi: 10.46880/jmika.vol4no1.pp67-72.

-
- [13] Ö. F. Y. Merfarukyce, "Anemia Types Classification Dataset," 2025. [Online]. Available: <https://www.kaggle.com/code/merfarukyce/anemia-types-classification-eda-prediction-keras#Model-Building>
 - [14] N. B. Bahadure, R. Khomane, and A. Nittala, "Anemia detection and classification from blood samples using data analysis and deep learning*," *Automatika*, vol. 65, no. 3, pp. 1163–1176, 2024, doi: 10.1080/00051144.2024.2352317.
 - [15] D. Chaerul Ekty Saputra, K. Sunat, and T. Ratnaningsih, "SMOTE-MRS: A Novel SMOTE-Multiresolution Sampling Technique for Imbalanced Distribution to Improve Prediction of Anemia," *IEEE Access*, vol. 12, no. January, pp. 154675–154699, 2024, doi: 10.1109/ACCESS.2024.3482968.
 - [16] L. VÉGH, N. ANNUŠ, K. CZAKÓOVÁ, and O. TAKÁČ, "Improving Machine Learning Classification Models for Anaemia Type Prediction By Oversampling Imbalanced Complete Blood Count Data With Smote-Based Algorithms," *AD ALTA J. Interdiscip. Res.*, vol. 14, no. 2, pp. 469–475, 2024, doi: 10.33543/j.1402.469475.
 - [17] F. Nurrahman, H. Wijayanto, A. H. Wigena, and N. Nurjanah, "Pre-Processing Data on Multiclass Classification of Anemia and Iron Deficiency With the Xgboost Method," *Barekeng*, vol. 17, no. 2, pp. 767–774, 2023, doi: 10.30598/barekengvol17iss2pp0767-0774.
 - [18] D. T. Mardiansyah, "Prediksi Stroke Menggunakan Extreme Gradient Boosting," *JIKO (Jurnal Inform. dan Komputer)*, vol. 8, no. 2, p. 419, 2024, doi: 10.26798/jiko.v8i2.1295.
 - [19] T. Yang and Y. Ying, "AUC Maximization in the Era of Big Data and AI: A Survey," *ACM Comput. Surv.*, vol. 55, no. 8, 2023, doi: 10.1145/3554729.
 - [20] M. Abdelhamid and A. Desai, "Balancing the Scales: A Comprehensive Study on Tackling Class Imbalance in Binary Classification," 2024, [Online]. Available: <http://arxiv.org/abs/2409.19751>
 - [21] M. S. S.A, "Chronic Kidney Disease Prediction Using Federated Learning," *Int. J. Sci. Res. Eng. Trends*, vol. 10, no. 6, pp. 2524–2529, 2024, doi: 10.61137/ijrsret.vol.10.issue6.361.