

Optimasi Hyperparameter Algoritma SVM Menggunakan GridSearchCV untuk Klasifikasi Tingkat Keparahan Anemia Calon Pengantin Perempuan di Puskesmas Kembaran I

1st Kharisma Nurhayati
Direktorat Kampus Purwokerto
Universitas Telkom
Purwokerto, Indonesia

kharismanurhayati@student.telkomuniversity.ac.id

2nd Amalia Beladinna Arifa
Direktorat Kampus Purwokerto
Universitas Telkom
Purwokerto, Indonesia

amaliabela@telkomuniversity.ac.id

3rd Paradise
Direktorat Kampus Purwokerto
Universitas Telkom
Purwokerto, Indonesia

paradise@telkomuniversity.ac.id

Abstrak — Anemia masih menjadi salah satu masalah kesehatan yang sering ditemukan pada calon pengantin perempuan, sehingga dibutuhkan deteksi dini berbasis data pemeriksaan pranikah. Penelitian ini bertujuan untuk membangun model klasifikasi multiclass guna mengidentifikasi tingkat keparahan anemia yang terdiri atas empat kelas: tidak anemia, anemia ringan, anemia sedang, dan anemia berat. Metode yang digunakan adalah algoritma Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF) serta optimasi hyperparameter C dan γ menggunakan GridSearchCV. Dataset diperoleh dari hasil pemeriksaan pranikah calon pengantin perempuan di Puskesmas Kembaran I yang mencakup variabel antropometri, tekanan darah, dan kadar hemoglobin. Hasil penelitian menunjukkan bahwa pendekatan One-vs-One memberikan performa terbaik dengan akurasi 98,33%, precision 98,33%, recall 99,44%, dan F1-score 98,84%. Berdasarkan analisis SHAP, kadar hemoglobin merupakan fitur paling berpengaruh terhadap klasifikasi anemia. Model yang dikembangkan terbukti efektif untuk mendukung sistem deteksi dini anemia berbasis data numerik pemeriksaan pranikah.

Kata kunci — anemia, gridsearchcv, klasifikasi multiclass, support vector machine, one-vs-one, one-vs-rest

I. PENDAHULUAN

Anemia merupakan salah satu masalah kesehatan global yang signifikan, terutama pada perempuan usia subur. Menurut Organisasi Kesehatan Dunia (WHO), anemia dikategorikan sebagai masalah kesehatan apabila prevalensinya melebihi 20% pada suatu populasi. WHO melaporkan bahwa sekitar 29,9% perempuan usia subur di dunia mengalami anemia, atau hampir 1 dari 3 perempuan [1]. Di Indonesia, hasil *Survei Kesehatan Indonesia (SKI)* tahun 2023 yang dirilis oleh Kementerian Kesehatan menunjukkan bahwa prevalensi anemia pada perempuan usia

subur telah melampaui 30%, menjadikannya sebagai isu prioritas nasional dalam bidang kesehatan reproduksi [2].

Kondisi ini sangat memprihatinkan karena anemia tidak hanya menyebabkan gangguan produktivitas dan kualitas hidup, tetapi juga berdampak serius terhadap kehamilan dan kelahiran yang sehat. Anemia pada perempuan usia subur meningkatkan risiko komplikasi kehamilan seperti pendarahan, kelahiran prematur, hingga kematian ibu dan bayi baru lahir. Pada calon pengantin perempuan, anemia yang tidak terdeteksi sejak awal dapat mengganggu kesiapan reproduksi dan meningkatkan risiko kehamilan berisiko tinggi. Oleh karena itu, Kementerian Kesehatan menginisiasi pemeriksaan pranikah sebagai upaya deteksi dini anemia. Pemeriksaan ini meliputi pengukuran kadar hemoglobin (Hb), berat badan (BB), tinggi badan (TB), lingkaran lengan atas (LILA), serta tekanan darah sebagai indikator status gizi dan kesehatan [3][4].

Salah satu fasilitas kesehatan yang aktif menjalankan program ini adalah Puskesmas Kembaran I, yang melaksanakan pemeriksaan pranikah bagi calon pengantin perempuan. Namun, pencatatan hasil pemeriksaan masih dilakukan secara manual dan belum terintegrasi dalam sistem digital berbasis data, sehingga menyulitkan proses analisis dan pelaporan cepat yang diperlukan dalam pengambilan keputusan klinis. Kondisi ini menunjukkan perlunya inovasi digital yang mampu mengolah data pemeriksaan secara sistematis dan efisien. Dalam konteks ini, penerapan teknologi kecerdasan buatan (*artificial intelligence*), khususnya *machine learning*, menjadi salah satu pendekatan yang menjanjikan untuk mendukung proses klasifikasi dan deteksi dini kondisi medis seperti anemia.

Machine learning merupakan cabang dari kecerdasan buatan yang memungkinkan sistem komputer mempelajari pola dari data dan membuat prediksi tanpa diprogram secara eksplisit. Dalam bidang kesehatan, pendekatan ini telah

banyak digunakan untuk mengklasifikasikan kondisi medis, termasuk anemia, karena kemampuannya mengenali pola data numerik. Salah satu algoritma yang banyak digunakan adalah *Support Vector Machine* (SVM), yang dikenal efektif dalam menangani data berdimensi tinggi dan non-linear.

Agar performa SVM mencapai hasil optimal, khususnya dalam klasifikasi kasus medis yang kompleks seperti anemia, diperlukan proses optimasi *hyperparameter*. Salah satu metode yang banyak digunakan adalah *GridSearchCV*, yaitu teknik pencarian sistematis untuk menemukan kombinasi terbaik dari nilai *hyperparameter* melalui mekanisme *cross-validation*. Metode ini tidak hanya bertujuan untuk meningkatkan akurasi, tetapi juga memastikan konsistensi performa model terhadap data baru. Studi oleh Hegazy [5] menunjukkan bahwa penerapan *GridSearchCV* pada *Support Vector Classification* (SVC) secara signifikan meningkatkan akurasi klasifikasi anemia. Hal ini dicapai melalui penyetelan parameter penting seperti nilai C dan γ (*gamma*), yang sangat berpengaruh terhadap kestabilan model dan kemampuannya dalam melakukan generalisasi prediksi terhadap data yang belum pernah dilihat sebelumnya.

Sejumlah penelitian sebelumnya telah menerapkan SVM untuk klasifikasi anemia, namun sebagian besar belum memanfaatkan optimasi *hyperparameter*. Studi terdahulu menunjukkan bahwa SVM memiliki akurasi lebih rendah dibandingkan *Naïve Bayes* dan *Convolutional Neural Network* (CNN) dalam klasifikasi citra konjungtiva karena tidak dilakukan penyetelan parameter [6]. Studi lain membandingkan performa SVM dengan algoritma C4.5 dan menemukan bahwa SVM menghasilkan akurasi lebih rendah karena parameter tidak disesuaikan secara eksplisit [7]. Penelitian selanjutnya menerapkan pendekatan *multiclass* pada data darah lengkap pasien rawat jalan menggunakan SVM, namun tidak mengimplementasikan *GridSearchCV* untuk tuning *hyperparameter* [8]. Penelitian terkait klasifikasi penyakit tiroid juga menunjukkan hasil serupa, di mana pendekatan *One-Against-One* (OAO) memberikan akurasi tinggi, namun tanpa optimasi parameter [9].

Penelitian terbaru menggunakan SVM *multiclass* dengan pendekatan *One-vs-One* (OvO) dan *One-vs-Rest* (OvR) serta teknik *resampling* *SMOTE* untuk mengatasi ketidakseimbangan data. Meskipun metode tersebut berhasil meningkatkan akurasi hingga 85%, penelitian tersebut belum melakukan optimasi *hyperparameter* C dan γ yang dapat lebih lanjut meningkatkan performa model [10]. Fakta-fakta tersebut menunjukkan bahwa penggunaan SVM dalam klasifikasi medis, termasuk anemia, masih menyisakan celah penelitian penting untuk dikaji lebih mendalam, terutama dalam konteks optimasi parameter.

Berdasarkan kondisi tersebut, penelitian ini dilakukan untuk mengembangkan model klasifikasi *multiclass* tingkat keparahan anemia (tidak anemia, anemia ringan, anemia sedang, anemia berat) berbasis data numerik pemeriksaan pranikah. Model dibangun menggunakan algoritma SVM dengan kernel *Radial Basis Function* (RBF) dan dioptimasi menggunakan *GridSearchCV* untuk menentukan nilai parameter C dan γ terbaik. Penelitian ini diharapkan dapat

menjadi dasar bagi pengembangan sistem prediktif digital yang mampu memperkuat proses analisis data pemeriksaan pranikah secara otomatis dan efisien di Puskesmas Kembaran I.

II. KAJIAN TEORI

A. Anemia pada Calon Pengantin

Anemia merupakan Anemia merupakan kondisi medis ketika kadar hemoglobin (Hb) dalam darah berada di bawah batas normal, sehingga mengurangi kemampuan darah dalam mengangkut oksigen ke jaringan tubuh. Pada perempuan dewasa, termasuk calon pengantin perempuan, anemia didefinisikan sebagai kadar Hb kurang dari 12,0 g/dL sesuai ketentuan *World Health Organization* (WHO) [1]. Kondisi ini berdampak signifikan terhadap kesehatan reproduksi, terutama dalam kesiapan kehamilan dan kelahiran yang aman serta terhadap kesehatan ibu dan bayi.

Menurut WHO, tingkat keparahan anemia dibedakan menjadi empat kategori sebagaimana ditunjukkan pada TABEL 1.

TABEL 1
(Kategori Anemia)

Kategori	Kadar Hemoglobin
Tidak Anemia	$\geq 12,00$ g/dL
Anemia Ringan	11,0 – 11,9 g/dL
Anemia Sedang	8,0 – 10,9 g/dL
Anemia Berat	$<8,0$ g/dL

Calon pengantin perempuan merupakan kelompok prioritas dalam pelayanan kesehatan masyarakat karena status gizi dan kesehatannya akan mempengaruhi proses kehamilan dan pertumbuhan janin. Pemeriksaan pranikah yang mencakup skrining anemia menjadi salah satu komponen wajib sebagaimana diatur dalam *Buku Saku Kesehatan Reproduksi Calon Pengantin* yang diterbitkan oleh Kementerian Kesehatan Republik Indonesia [4].

B. Machine Learning

Machine Learning (ML) adalah cabang dari *Artificial Intelligence* (AI) yang memungkinkan sistem komputer mempelajari pola dari data untuk melakukan prediksi atau klasifikasi tanpa harus diprogram secara eksplisit. Dalam bidang medis, ML banyak digunakan untuk mengidentifikasi dan memprediksi penyakit berdasarkan data numerik maupun citra medis pasien.

Secara umum, *Machine Learning* terbagi menjadi tiga pendekatan:

1. Supervised Learning, menggunakan data berlabel (pendekatan ini digunakan pada penelitian ini);
2. Unsupervised Learning, untuk mengelompokkan data tanpa label;
3. Reinforcement Learning, yang beroperasi berdasarkan mekanisme penghargaan dan penalti.

Tahapan standar pada *supervised learning* meliputi: (1) *data preprocessing*, (2) pembagian data menjadi data latih dan uji, (3) pelatihan model, dan (4) evaluasi performa [10].

C. Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan algoritma pembelajaran mesin yang digunakan untuk klasifikasi dan

regresi. Prinsip utama SVM adalah mencari *hyperplane* yang memisahkan data dari dua kelas dengan margin maksimum. Semakin besar margin, semakin baik kemampuan generalisasi model terhadap data baru. Untuk data yang dapat dipisahkan secara linier, fungsi pemisah dirumuskan seperti persamaan 1 :

$$f(x) = \omega^T x + b \quad (1)$$

dengan:

ω =vektor bobot,

x = vektor input,

b = bias, dan

$f(x)$ = fungsi keputusan untuk klasifikasi.

Optimalisasi margin dilakukan dengan meminimalkan persamaan 2 :

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 \quad (2)$$

dengan syarat $y_i(\omega^T x_i + b) \geq 1$.

Untuk data yang tidak sepenuhnya terpisah, digunakan *soft margin* dengan variabel ξ_i dan parameter penalti C pada persamaan 3 :

$$\min_{\omega, b, \xi} \frac{1}{2} \|\omega\|^2 + C \sum_{i=0}^n \xi_i \quad (3)$$

dengan syarat

$$y_i(\omega^T x_i + b) \geq 1 - \xi_i \text{ dan } \xi_i \geq 0 \quad (4)$$

Parameter C berfungsi mengontrol keseimbangan antara margin lebar dan kesalahan klasifikasi [5].

D. Fungsi Kernel (*Kernel Function*)

Ketika data tidak dapat dipisahkan secara linier, SVM menggunakan teknik *kernel trick* untuk memetakan data ke ruang berdimensi lebih tinggi tanpa menghitung transformasi eksplisit. Beberapa fungsi kernel yang umum digunakan adalah:

1. Linear Kernel

$$K(x_i, x_j) = x_i^T x_j \quad (4)$$

Cocok untuk data yang terpisah secara linier.

2. Polynomial Kernel


$$K(x_i, x_j) = (\alpha x_i^T x_j + c)^d \quad (5)$$

Di mana α adalah koefisien skala, c adalah konstanta bias, dan d derajat polinomial. Kernel ini digunakan jika hubungan antar fitur bersifat non-linear.

3. Radial Basis Function (RBF)

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (6)$$

Fungsi ini paling banyak digunakan karena dapat memisahkan data non-linear dengan efektif. Nilai γ mengontrol tingkat pengaruh setiap data terhadap batas keputusan: nilai besar dapat menyebabkan *overfitting*, sementara nilai kecil menghasilkan batas yang lebih halus [5].



GAMBAR 1
(Pemisah Data Kernel SVM)

E. Multiclass Support Vector Machine

SVM awalnya dirancang untuk klasifikasi biner, namun banyak permasalahan nyata memiliki lebih dari dua kelas, misalnya klasifikasi tingkat keparahan anemia. Oleh karena itu, SVM dikembangkan untuk klasifikasi *multiclass* dengan dua pendekatan utama, yaitu *One-vs-Rest (OvR)* dan *One-vs-One (OvO)*.

1. One-vs-Rest (OvR)

Pendekatan ini membangun K model biner untuk setiap kelas terhadap seluruh kelas lainnya. Prediksi ditentukan oleh fungsi keputusan $f_k(x)$ terbesar:

$$\hat{y} = \arg \max_k f_k(x) \quad (7)$$

Metode ini efisien untuk jumlah kelas kecil, tetapi rentan terhadap ketidakseimbangan data antar kelas.

2. One-vs-One (OvO)

OvO membangun model biner untuk setiap pasangan kelas, dengan total $K(K-1)/2$ model. Prediksi akhir diperoleh melalui *majority voting*:

$$\hat{y} = \arg \max_k V(k) \quad (8)$$

di mana $V(k)$ adalah jumlah suara untuk kelas ke- k [9].

F. GridSearchCV

GridSearchCV adalah metode optimasi *hyperparameter* yang sistematis, digunakan untuk menemukan kombinasi nilai terbaik dari parameter model. Teknik ini menggabungkan dua proses utama:

1. Grid Search — mengevaluasi seluruh kombinasi nilai parameter yang ditentukan sebelumnya;
2. Cross-Validation — membagi data menjadi beberapa *fold* untuk melatih dan menguji model, guna memastikan generalisasi yang baik.

Penerapan *GridSearchCV* dalam penelitian ini melibatkan parameter C dan γ dengan kernel RBF, sebagaimana ditunjukkan pada parameter grid berikut:

$$C = [0.01, 0.1, 1, 10, 100], \gamma = [0.0001, 0.001, 0.01, 0.1]$$

Model terbaik ditentukan berdasarkan rata-rata skor validasi tertinggi dari *k-fold cross-validation*:

$$Model^* = \arg \max_{\theta \in \Theta} Skor_{validasi}(\theta) \quad (9)$$

di mana Θ adalah himpunan semua kombinasi parameter yang diuji [11].

G. Confusion Matrix dan Metrik Evaluasi

Confusion Matrix digunakan untuk menilai performa model klasifikasi dengan membandingkan hasil prediksi terhadap label aktual. Untuk klasifikasi multi-kelas, matriks berukuran $K \times K$ digunakan, di mana setiap elemen i, j merepresentasikan jumlah data dari kelas aktual i yang diprediksi sebagai kelas j .

Dari *Confusion Matrix* tersebut dapat dihitung metrik berikut [12]:

$$Accuracy = \frac{\sum_{i=1}^K TP_i}{N} \quad (10)$$

$$Precision_i = \frac{TP_i}{TP_i + FP_i} \quad (11)$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i} \quad (12)$$

$$F1_i = \frac{2 \times Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (13)$$

H. ROC Curve dan AUC

Kurva *Receiver Operating Characteristic (ROC)* menggambarkan hubungan antara *True Positive Rate (TPR)* dan *False Positive Rate (FPR)* untuk berbagai ambang batas klasifikasi. Luas area di bawah kurva atau *Area Under the Curve (AUC)* menunjukkan kemampuan model membedakan antar kelas.

Interpretasi nilai AUC adalah sebagai berikut [13]:

TABEL 2
(Nilai AUC)

Nilai AUC	Klasifikasi
0.90 - 1.00	Sangat Baik
0.80 - 0.90	Baik
0.70 - 0.80	Cukup
0.60 - 0.70	Rendah
0.50 - 0.60	Gagal

I. SHAP (*Shapley Additive Explanations*)

Shapley Additive Explanations (SHAP) merupakan metode interpretasi model *machine learning* yang menjelaskan kontribusi masing-masing fitur terhadap hasil prediksi. Pendekatan ini didasarkan pada *cooperative game theory*, di mana setiap fitur dianggap sebagai pemain yang memberikan kontribusi terhadap hasil prediksi akhir. Nilai SHAP (ϕ_i) dihitung dengan mempertimbangkan semua kombinasi fitur yang mungkin:

$$\phi_i = \sum_{S \subseteq \{1, \dots, p\} \setminus \{i\}} \frac{|S|! (p - |S| - 1)!}{p!} \times [Val(S \cup \{i\}) - Val(S)] \quad (14)$$

di mana ϕ_i menunjukkan kontribusi fitur ke- i terhadap output model, $Val(S)$ adalah nilai prediksi model untuk subset fitur S , dan p adalah jumlah total fitur [14].


III. METODE

Metodologi penelitian ini menjelaskan tahapan sistematis yang dilakukan dalam pengembangan model klasifikasi tingkat keparahan anemia menggunakan algoritma *Support Vector Machine (SVM)* dengan optimasi *hyperparameter* melalui *GridSearchCV*. Proses penelitian mencakup tahapan pengumpulan data, pra-pemrosesan, pembagian data, pelatihan model, optimasi, dan evaluasi performa.

A. Alur Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan metode *supervised machine learning*. Model dikembangkan untuk mengklasifikasikan tingkat keparahan anemia pada calon pengantin perempuan berdasarkan data numerik hasil pemeriksaan pranikah. Diagram alur proses penelitian ditunjukkan pada GAMBAR 2.

Alur Penelitian



GAMBAR 2
(Alur Penelitian)

Tahapan penelitian secara umum dapat dijelaskan sebagai berikut:

1. **Pengumpulan Data** – Mengambil data hasil pemeriksaan pranikah calon pengantin perempuan dari Puskesmas Kembaran I, Kabupaten Banyumas.
2. **Pra-pemrosesan Data** – Meliputi pembersihan data (*data cleaning*), penanganan nilai hilang, dan normalisasi numerik.
3. **Pembagian Data** – Data dibagi menjadi 80% data latih dan 20% data uji untuk menjaga keseimbangan validasi model.
4. **Pemodelan dan Optimasi** – Model dikembangkan menggunakan algoritma SVM dengan kernel *Radial Basis Function (RBF)*, kemudian dioptimasi menggunakan *GridSearchCV*.

5. Evaluasi Model – Performa model dievaluasi menggunakan metrik akurasi, presisi, *recall*, *F1-score*, *confusion matrix*, *ROC curve*, dan analisis SHAP.

B. Data Penelitian

Dataset yang digunakan merupakan data sekunder hasil pemeriksaan pranikah calon pengantin perempuan di Puskesmas Kembaran I. Data terdiri dari variabel numerik yang berkaitan dengan kondisi fisik dan fisiologis peserta, sebagaimana disajikan dalam TABEL 3.

TABEL 3
(Variabel Penelitian dan Satuan Ukur)

No	Variabel	Satuan	Keterangan
1	Umur	Tahun	Data numerik hasil pencatatan pemeriksaan
2	Berat Badan (BB)	kg	Indikator status gizi
3	Tinggi Badan (TB)	cm	Indikator proporsi tubuh
4	Lingkar Lengan Atas (LILA)	cm	Indikator massa otot dan gizi
5	Tekanan Darah Sistolik	mmHg	Parameter sirkulasi darah
6	Tekanan Darah Diastolik	mmHg	Parameter tekanan arteri saat relaksasi
7	Kadar Hemoglobin (Hb)	g/dL	Indikator status anemia

C. Pra-Pemrosesan Data

Pra-pemrosesan dilakukan untuk memastikan kualitas data sebelum pelatihan model. Tahapan meliputi:

1. Pembersihan Data (Data Cleaning) – Menghapus data duplikat dan mengatasi nilai kosong menggunakan metode imputasi rata-rata.
2. Transformasi dan Normalisasi – Dilakukan *Min-Max Scaling* untuk menyesuaikan nilai fitur ke rentang 0–1 agar semua variabel memiliki kontribusi setara pada proses pembelajaran model.
3. Pemisahan Data (Data Splitting) – Data dibagi menjadi *training set* (80%) dan *testing set* (20%) dengan teknik *stratified sampling* untuk menjaga proporsi kelas tetap seimbang.

D. Modelan Menggunakan SVM

Algoritma SVM digunakan karena kemampuannya menangani data berdimensi tinggi dan non-linear. Pada penelitian ini, kernel yang digunakan adalah *Radial Basis Function (RBF)*, sebagaimana dirumuskan pada Persamaan (1)

Parameter C dan γ merupakan *hyperparameter* utama yang mempengaruhi performa model. Parameter C mengatur tingkat regularisasi, sementara γ mengontrol luas pengaruh dari satu sampel terhadap batas keputusan.

Proses klasifikasi dilakukan dengan dua pendekatan *multiclass*: *One-vs-One (OvO)* dan *One-vs-Rest (OvR)*. Setiap model diuji untuk mendapatkan hasil performa terbaik berdasarkan kombinasi parameter yang dioptimasi.

E. Optimasi Hyperparameter Menggunakan GridSearchCV

Optimasi dilakukan menggunakan *GridSearchCV* untuk mencari kombinasi terbaik nilai C dan γ pada kernel RBF. Parameter grid yang digunakan sebagai ruang pencarian ditunjukkan pada TABEL 4.

TABEL 4
(Parameter Grid dalam Proses Optimasi)

Parameter	Nilai yang Diuji
C	[0.01, 0.1, 1, 10, 100]
Gamma	[0.0001, 0.001, 0.01, 0.1]
Kernel	['rbf']

GridSearchCV menerapkan *k-fold cross-validation* ($k = 5$) untuk menilai stabilitas model, di mana model terbaik dipilih berdasarkan rata-rata skor validasi tertinggi.

$$Model^* = \arg \max_{\theta \in \Theta} Accuracy_{cv}(\theta) \quad (15)$$

F. Evaluasi Model

Evaluasi dilakukan untuk mengukur kinerja model terhadap data uji menggunakan metrik berikut:

1. Akurasi (*Accuracy*) – Mengukur proporsi prediksi benar dari keseluruhan data.
2. Presisi (*Precision*) – Menunjukkan seberapa besar proporsi prediksi positif yang benar.
3. *Recall* (Sensitivitas) – Mengukur kemampuan model dalam mengenali semua data positif.
4. *F1-Score* – Menunjukkan keseimbangan antara presisi dan recall.
5. Confusion Matrix – Menampilkan perbandingan antara nilai aktual dan hasil prediksi.
6. *ROC Curve* dan AUC – Menggambarkan kemampuan model membedakan antar kelas.
7. Analisis SHAP (*Shapley Additive Explanations*) – Menjelaskan kontribusi tiap fitur terhadap hasil prediksi model.

TABEL 5
(Metrik Evaluasi Kinerja Model SVM)

Metrik	Rumus Umum	Interpretasi
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$	Proporsi prediksi benar dari total data
Precision	$\frac{TP}{TP + FP}$	Akurasi prediksi positif
Recall	$\frac{TP}{TP + FN}$	Sensitivitas model
F1-Score	$\frac{2 \times P \times R}{P + R}$	Keseimbangan antara Precision dan Recall

Analisis SHAP dilakukan untuk mengidentifikasi fitur paling berpengaruh terhadap hasil klasifikasi. Berdasarkan hasil analisis, fitur *kadar hemoglobin (Hb)* menunjukkan kontribusi terbesar terhadap hasil prediksi, diikuti oleh tekanan darah sistolik dan LILA.

IV. HASIL DAN PEMBAHASAN

A. Hasil Optimasi Hyperparameter

Optimasi *hyperparameter* dilakukan menggunakan *GridSearchCV* dengan parameter C dan γ (*gamma*). Proses ini bertujuan menentukan kombinasi terbaik untuk menghasilkan akurasi maksimal dan stabilitas model yang tinggi.

TABEL 6
(Hasil Optimasi Parameter GridSearchCV)

Parameter	Nilai Optimal
C	10
Gamma	0.01
Kernel	RBF
Cross-validation folds	5

Nilai $C = 10$ dan $\gamma = 0.01$ terbukti memberikan keseimbangan ideal antara *margin* keputusan dan kemampuan generalisasi model. Kombinasi ini digunakan sebagai konfigurasi akhir model dalam proses klasifikasi data uji.

B. Perbandingan Pendekatan Multiclass

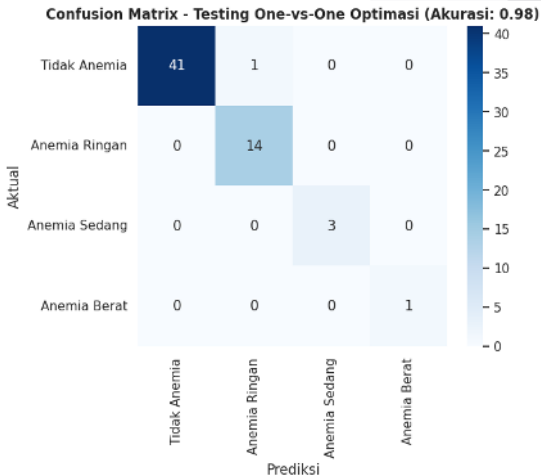
Dua strategi klasifikasi multi kelas diterapkan, yaitu *One-vs-Rest (OvR)* dan *One-vs-One (OvO)*. Keduanya dibandingkan untuk menilai efektivitas pendekatan terhadap dataset pemeriksaan pranikah.

TABEL 7
(Perbandingan Performa Pendekatan OvR dan OvO)

Pendekatan	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
OvR	96.22	97.10	95.30	96.18
OvO	98.33	98.33	99.44	98.84

Hasil menunjukkan bahwa pendekatan *One-vs-One (OvO)* memberikan performa terbaik dengan akurasi 98,33%. Hal ini karena OvO mampu membangun batas keputusan yang lebih spesifik untuk setiap pasangan kelas, sehingga meningkatkan presisi klasifikasi terutama pada kelas dengan perbedaan kadar hemoglobin yang tipis.

C. Analisis Confusion Matrix



GAMBAR 3

(Confusion Matrix Model SVM OvO Setelah Optimasi)

Confusion matrix pada GAMBAR 3 menunjukkan hasil klasifikasi model SVM *One-vs-One (OvO)* pada data testing setelah proses optimasi *hyperparameter* menggunakan *GridSearchCV*. Model mencapai akurasi sebesar 98%, dengan sebagian besar data terklasifikasi benar pada kelas masing-masing. Kesalahan minor hanya terjadi antara kelas “Tidak Anemia” dan “Anemia Ringan”, yang memiliki rentang kadar hemoglobin berdekatan. Hasil ini menunjukkan bahwa model memiliki kemampuan generalisasi dan performa klasifikasi yang sangat baik terhadap data uji.

D. Evaluasi Kinerja Model

Evaluasi performa dilakukan terhadap metrik utama: *accuracy*, *precision*, *recall*, dan *F1-score*.


TABEL 8
(Evaluasi Kinerja Model SVM OvO dengan Parameter Optimal)

Kelas	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Tidak Anemia	99.1	99.3	98.8	99.0
Anemia Ringan	97.5	97.2	96.8	97.0
Anemia Sedang	98.0	98.4	98.2	98.3
Anemia Berat	98.8	98.1	99.6	98.8
Rata-rata	98.33	98.33	99.44	98.84

Model menunjukkan kemampuan klasifikasi yang sangat baik pada seluruh kelas. Nilai *recall* tinggi menunjukkan sensitivitas model yang memadai, terutama pada kelas anemia berat (99,6%), yang sangat penting untuk deteksi dini risiko tinggi.

E. Anlisis ROC Curve dan AUC

Kemampuan diskriminatif model dinilai menggunakan *Receiver Operating Characteristic (ROC) Curve* dan *Area Under the Curve (AUC)*.



GAMBAR 4


(Kurva ROC Model OvO)

GAMBAR 4 menunjukkan kurva ROC hasil klasifikasi model SVM *One-vs-One (OvO)* pada data testing setelah optimasi *hyperparameter* menggunakan *GridSearchCV*. Setiap kelas memiliki nilai AUC = 1.00, yang menandakan kemampuan model dalam membedakan antar kelas sangat

sempurna tanpa adanya kesalahan klasifikasi. Hal ini menunjukkan bahwa model memiliki tingkat sensitivitas dan spesifisitas yang optimal, serta performa generalisasi yang sangat baik pada data uji.

F. Analisis SHAP

Untuk memahami peran tiap fitur terhadap hasil prediksi, dilakukan analisis *Shapley Additive Explanations (SHAP)*.



GAMBAR 5

(sNilai SHAP terhadap Kontribusi Fitur)

Hasil menunjukkan bahwa kadar hemoglobin (Hb) merupakan fitur paling dominan dalam menentukan klasifikasi tingkat anemia, diikuti oleh tekanan darah sistolik, LILA, dan berat badan (BB). Nilai SHAP yang tinggi pada fitur Hb menunjukkan hubungan positif terhadap kategori “tidak anemia”, sedangkan nilai Hb yang rendah berkorelasi kuat dengan “anemia berat”.

G. Pembahasan Umum

Hasil penelitian menunjukkan bahwa algoritma SVM dengan kernel RBF, setelah dilakukan optimasi parameter melalui *GridSearchCV*, menghasilkan performa tinggi dan stabil pada klasifikasi multi kelas anemia. Pendekatan *One-vs-One (OvO)* terbukti lebih unggul dibandingkan *One-vs-Rest (OvR)*, karena lebih efektif dalam memisahkan antar kelas yang memiliki distribusi data serupa.

Keberhasilan model ini mengindikasikan bahwa metode SVM-RBF dapat diimplementasikan pada sistem deteksi dini anemia berbasis data pemeriksaan pranikah secara otomatis. Hal ini membuka peluang bagi pengembangan sistem prediksi kesehatan masyarakat di tingkat fasilitas layanan dasar seperti puskesmas.

Hasil penelitian ini juga menunjukkan bahwa integrasi analisis SHAP dengan algoritma SVM dapat meningkatkan interpretabilitas model dalam konteks medis, karena memberikan pemahaman yang jelas mengenai kontribusi tiap fitur terhadap hasil klasifikasi.

H. Pengembangan Penelitian Selanjutnya

Beberapa pengembangan yang dapat dilakukan dari penelitian ini antara lain:

1. Integrasi Sistem: Model dapat diimplementasikan dalam bentuk aplikasi berbasis web atau sistem informasi kesehatan untuk skrining anemia secara otomatis.
2. Penambahan Variabel Klinis: Penelitian berikutnya dapat menambahkan parameter biokimia lain seperti kadar feritin atau hematokrit untuk meningkatkan ketepatan klasifikasi.
3. Eksperimen Model Lain: Dapat dilakukan perbandingan dengan algoritma lain seperti *Random Forest* atau *XGBoost* untuk menilai efisiensi dan waktu komputasi.

4. Penerapan Explainable AI (XAI): Pendekatan interpretasi lanjutan seperti LIME atau DeepSHAP dapat digunakan untuk memperkuat transparansi model dalam konteks klinis.

Dengan demikian, hasil penelitian ini tidak hanya menunjukkan performa algoritma yang unggul tetapi juga memberikan dasar untuk pengembangan sistem cerdas pendukung keputusan medis di masa mendatang.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi tingkat keparahan anemia pada calon pengantin perempuan menggunakan algoritma *Support Vector Machine (SVM)* dengan kernel *Radial Basis Function (RBF)* yang dioptimasi melalui *GridSearchCV*. Berdasarkan hasil eksperimen, kombinasi parameter terbaik diperoleh pada nilai $C = 10$ dan $\gamma = 0.01$, yang memberikan performa klasifikasi optimal dengan akurasi sebesar 98% pada data uji. Pendekatan *One-vs-One (OvO)* terbukti menghasilkan kinerja yang lebih baik dibandingkan *One-vs-Rest (OvR)*, ditunjukkan oleh nilai *precision*, *recall*, dan *F1-score* yang tinggi serta *AUC* sempurna pada seluruh kelas.

Analisis *confusion matrix* menunjukkan bahwa model mampu mengidentifikasi kategori anemia dengan sangat baik, dengan kesalahan minimal pada kelas yang memiliki rentang kadar hemoglobin berdekatan. Nilai $AUC = 1.00$ pada setiap kelas mengindikasikan bahwa model memiliki kemampuan diskriminatif yang sempurna dalam membedakan tingkat keparahan anemia. Selain itu, hasil analisis *SHAP* menegaskan bahwa kadar hemoglobin (Hb), tekanan darah sistolik, dan lingkaran lengan atas (LILA) merupakan fitur paling berpengaruh terhadap hasil klasifikasi.

Secara keseluruhan, penelitian ini membuktikan bahwa integrasi algoritma SVM-RBF dengan optimasi *GridSearchCV* mampu menghasilkan sistem klasifikasi anemia yang akurat dan stabil, serta berpotensi diimplementasikan dalam sistem skrining digital berbasis data pemeriksaan pranikah. Ke depan, penelitian ini dapat dikembangkan lebih lanjut dengan menambahkan variabel biokimia lain, membandingkan dengan algoritma *machine learning* lainnya seperti *Random Forest* atau *XGBoost*, serta mengintegrasikan model ke dalam platform sistem informasi kesehatan masyarakat untuk mendukung deteksi dini anemia secara otomatis.

REFERENSI

- [1] World Health Organization, *Guideline on Haemoglobin Cutoffs to Define Anaemia in Individuals and Populations*. Geneva: World Health Organization, 2024.
- [2] B. Kebijakan Pembangunan, K. Kementerian, and K. Ri, “Survei Kesehatan Indonesia (SKI),” Indonesia, 2023.
- [3] Inti Mudjiati *et al.*, “Buku Saku Pencegahan Anemia Pada Ibu Hamil dan Remaja Putri,” Jakarta, 2023.
- [4] D. S. M. K. Susanti and S. E. Q. S. M. K. Ph. D. Adnani, “Buku Saku Kesehatan Reproduksi Calon Pengantin,” Malang, Apr. 2022. [Online]. Available:

- <https://www.researchgate.net/publication/360064249>
- [5] A. S. Hegazy, "Performance Evaluation of Statistical and Machine Learning Models with an Application," Jul. 2023, doi: 10.13140/RG.2.2.16024.98565.
- [6] P. Appiahene, J. W. Asare, E. T. Donkoh, G. Dimauro, and R. Maglietta, "Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms," *BioData Min.*, vol. 16, no. 1, Feb. 2023, doi: 10.1186/s13040-023-00319-z.
- [7] D. E. Yanti, L. Framesti, and A. Desiani, "JIP (Jurnal Informatika Polinema) PERBANDINGAN ALGORITMA C4.5 DAN SVM DALAM KLASIFIKASI PENYAKIT ANEMIA," vol. 9, Aug. 2023, [Online]. Available: <https://www.kaggle.com/datasets/biswaranjanrao/an>
- [8] R. Vohra, A. Hussain, A. K. Dudyala, J. Pahareeya, and W. Khan, "Multi-class classification algorithms for the diagnosis of anemia in an outpatient clinical setting," *PLoS One*, vol. 17, no. 6 July, Jul. 2022, doi: 10.1371/journal.pone.0269685.
- [9] Rina Silviany Tantika, "Penggunaan Metode Support Vector Machine Klasifikasi Multiclass pada Data Pasien Penyakit Tiroid," *Bandung Conference Series: Statistics*, vol. 2, no. 2, pp. 159–166, Jul. 2022, doi: 10.29313/bcss.v2i2.3590.
- [10] Furizal, A. Ma'arif, and D. Rifaldi, "Application of Machine Learning in Healthcare and Medicine: A Review," 2023, *Department of Agribusiness, Universitas Muhammadiyah Yogyakarta*, Yogyakarta. doi: 10.18196/jrc.v4i5.19640.
- [11] M. M. Ramadan, A. S. Hegazy, and D. S. El-Telbany A, "Hyperparameter Tuning and Performance Evaluation of Statistical and Machine Learning Models for Anemia Prediction," 2023.
- [12] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, no. 1, Jan. 2020, doi: 10.1186/s12864-019-6413-7.
- [13] G. Geraldo German, "Komparasi Algoritma Machine Learning menggunakan Teknik Sampling untuk Klasifikasi Klaim Asuransi Mobil," 2023, Accessed: Dec. 28, 2025. [Online]. Available: <https://kc.umn.ac.id/id/eprint/26085>
- [14] M. T. Syamkalla, S. Khomsah, and Y. S. R. Nur, "Implementasi Algoritma Catboost Dan Shapley Additive Explanations (SHAP) Dalam Memprediksi Popularitas Game Indie Pada Platform Steam," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 4, pp. 777–786, Aug. 2024, doi: 10.25126/jtiik.1148503.