



Optimasi Support Vector Machine Menggunakan Pendekatan Hybrid Kernel Linear-RBF Untuk Klasifikasi Penyakit Jantung

Mulyadi^{1*}, Dian Kasoni², Nurdiana Handayani³, Liesnaningsih³

¹Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Nurdin Hamzah, Jambi
Jalan Kolonel Abunjani RT.25 Selamat Danau Teluk, Selamat, Kec. Telanaipura, Kota Jambi, Jambi, Indonesia

²Program Studi Teknik Informatika, STMIK Antar Bangsa, Tangerang
Kawasan Bisnis CBD Ciledug, Jl. HOS Cokroaminoto No.29-35 Blok A5, Karang Tengah, Kec. Karang Tengah, Kota Tangerang, Banten, Indonesia

³Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Tangerang, Tangerang
Jl. Perintis Kemerdekaan I No.33, Babakan, Cikokol, Kec. Tangerang, Kota Tangerang, Banten, Indonesia
Email: ^{1*}mulyadiroesly@gmail.com, ²dhekalearning@gmail.com, ³nurdiana.handayani@ft-umt.ac.id,

⁴liesnaningsih@ft-umt.ac.id

Submitted: 10/01/2026; Accepted: 31/01/2026; Published: 31/01/2026

Abstrak—Penyakit jantung merupakan salah satu penyebab utama kematian global, sehingga deteksi dini menjadi langkah krusial untuk mencegah komplikasi serius. Keterbatasan metode diagnosis konvensional mendorong pemanfaatan machine learning guna menghasilkan prediksi yang lebih cepat dan akurat. Support Vector Machine (SVM) dikenal efektif untuk klasifikasi medis, namun performanya sangat dipengaruhi oleh jenis kernel yang digunakan. Penelitian ini mengevaluasi tiga model SVM single-kernel (Linear, RBF, dan Polynomial) serta dua konfigurasi hybrid kernel, yaitu Linear–RBF dan Linear–Polynomial, menggunakan dataset UCI Heart Disease Statlog yang terdiri atas 270 sampel dan 13 fitur prediktor. Pada pendekatan hybrid, prediksi probabilitas dari masing-masing kernel dasar dikombinasikan melalui strategi agregasi untuk membentuk fungsi keputusan yang lebih adaptif terhadap pola linear dan non-linear secara simultan. Untuk memastikan stabilitas performa pada dataset berukuran kecil, evaluasi dilakukan menggunakan Stratified K-Fold Cross Validation, sehingga hasil yang diperoleh tidak bergantung pada satu pembagian data tertentu. Hasil eksperimen menunjukkan bahwa SVM–Polynomial memiliki nilai ROC–AUC tertinggi sebesar 0.9420, namun tidak unggul pada metrik akurasi, precision, maupun F1-score. Pendekatan hybrid memberikan performa yang lebih konsisten, dengan kombinasi Linear–RBF menjadi model terbaik secara keseluruhan melalui capaian akurasi 0.8889, precision macro 0.8896, dan F1-score macro 0.8886. Temuan ini menunjukkan bahwa penggabungan karakteristik linear dan nonlinear mampu menghasilkan fungsi keputusan yang lebih seimbang dibandingkan penggunaan kernel tunggal. Sebaliknya, kombinasi Linear–Polynomial tidak memberikan peningkatan performa yang signifikan. Kontribusi utama penelitian ini terletak pada analisis komparatif terstruktur mengenai strategi kombinasi kernel pada SVM untuk klasifikasi penyakit jantung, yang berpotensi mendukung pengembangan sistem prediksi klinis yang lebih adaptif dan stabil.

Kata Kunci: Klasifikasi; Machine Learning; Multi-Kernel Learning; Penyakit Jantung; Support Vector Machine

Abstract—Heart disease remains one of the leading causes of mortality worldwide, making early detection crucial to prevent severe complications. The limitations of conventional diagnostic approaches have encouraged the adoption of machine learning techniques to enable faster and more accurate predictions. Support Vector Machine (SVM) is widely recognized as an effective method for medical classification tasks; however, its performance is highly dependent on the choice of kernel function. This study evaluates three single-kernel SVM models (Linear, RBF, and Polynomial) and two hybrid kernel configurations, namely Linear–RBF and Linear–Polynomial, using the UCI Heart Disease Statlog dataset, which consists of 270 samples and 13 predictive features. In the hybrid approach, the probabilistic outputs of the individual base kernels are combined through an aggregation strategy to construct a decision function capable of capturing both linear and nonlinear patterns simultaneously. To ensure performance stability on the relatively small dataset, model evaluation was conducted using Stratified K-Fold Cross Validation, ensuring that the reported results do not rely on a single data split. Experimental results indicate that the SVM–Polynomial model achieved the highest ROC–AUC value of 0.9420; however, it did not outperform other models in terms of accuracy, precision, or F1-score. The hybrid approach demonstrated more consistent overall performance, with the Linear–RBF combination emerging as the best-performing model, achieving an accuracy of 0.8889, macro precision of 0.8896, and macro F1-score of 0.8886. These findings suggest that integrating linear and nonlinear kernel characteristics produces a more balanced decision function compared to single-kernel models. In contrast, the Linear–Polynomial combination did not yield significant performance improvements. The main contribution of this study lies in presenting a structured comparative analysis of kernel combination strategies in SVM for heart disease classification, which may support the development of more adaptive and stable clinical prediction systems.

Keywords: Classification; Machine Learning; Multi-Kernel Learning; Heart Disease; Support Vector Machine

1. PENDAHULUAN

Secara global, kasus penyakit jantung tetap mendominasi sebagai penyebab kematian tertinggi dan menjadi perhatian utama dalam upaya peningkatan kualitas kesehatan masyarakat. Laporan World Health Organization (WHO) menunjukkan bahwa gangguan kardiovaskular menyebabkan hampir 18 juta kematian setiap tahun, atau lebih dari sepertiga total angka kematian dunia [1]. Deteksi dini terhadap risiko penyakit jantung memiliki peran penting dalam mencegah komplikasi serius seperti stroke, henti jantung, dan gagal jantung [2]. Namun, metode pemeriksaan medis konvensional umumnya memerlukan waktu, biaya, serta tenaga medis yang terampil, sehingga membatasi aksesibilitas terutama di wilayah dengan sumber daya terbatas. Keterbatasan tersebut mendorong



pengembangan sistem prediktif otomatis berbasis data untuk mendukung proses diagnosis secara lebih cepat dan akurat.

Teknik machine learning telah banyak diterapkan dalam bidang medis karena kemampuannya dalam mengenali pola tersembunyi dan hubungan nonlinier antar fitur klinis. Di antara berbagai algoritma machine learning, Support Vector Machine (SVM) dikenal sebagai salah satu model yang paling efektif untuk tugas klasifikasi medis [3]. Algoritma ini bekerja dengan mencari hyperplane optimal yang memisahkan kelas secara maksimal, sehingga tahan terhadap overfitting bahkan pada data berdimensi tinggi [4]. Berbagai penelitian sebelumnya telah menunjukkan efektivitas SVM dalam mendeteksi berbagai jenis penyakit. Misalnya, penelitian menggunakan SVM untuk mengidentifikasi penyakit rabies berhasil mencapai akurasi sebesar 79% [5]. Penelitian lain menggunakan SVM untuk klasifikasi penderita Gastroesophageal Reflux Disease (GERD) memperoleh akurasi 82,5% dengan F1-score 58,3% [6]. Pada pemodelan gagal jantung, kinerja SVM bervariasi tergantung kernel yang digunakan, dengan akurasi untuk kernel Polynomial sekitar 84,50%, sedangkan kernel Linear mendekati 85,96%, dan kernel RBF mencatat sekitar 85,84% [7]. Selain itu, dalam studi deteksi diabetes, penggunaan kernel Radial Basis Function (RBF) dilaporkan mampu mencapai akurasi hingga 91% [8]. Penelitian lain pada klasifikasi penyakit stroke menghasilkan akurasi mencapai 95% [9].

Meskipun beberapa penelitian pada penyakit lain melaporkan tingkat akurasi yang tinggi, karakteristik dataset penyakit jantung memiliki tantangan tersendiri. Dataset penyakit jantung terdiri atas kombinasi fitur klinis numerik dan kategorikal, seperti tekanan darah, kadar kolesterol, hasil elektrokardiografi, serta riwayat medis pasien, yang membentuk struktur data yang heterogen dan tidak sepenuhnya linier. Keberagaman karakteristik ini menyebabkan batas keputusan antar kelas menjadi lebih kompleks dibandingkan dataset medis lain yang relatif lebih homogen. Oleh karena itu, optimasi fungsi kernel pada SVM menjadi relevan untuk meningkatkan kemampuan model dalam menangkap variasi pola klinis yang bersifat campuran dan nonlinier. Sebagian besar penelitian terdahulu masih berfokus pada penggunaan satu jenis kernel tanpa mengevaluasi secara mendalam pengaruh kombinasi antar kernel terhadap performa klasifikasi. Padahal, pemilihan kernel sangat berpengaruh terhadap kemampuan SVM dalam memisahkan data yang memiliki karakteristik linier dan nonlinier secara bersamaan [10]. Satu jenis kernel saja sering kali tidak cukup untuk menangkap seluruh variasi pola data medis yang kompleks, sehingga dapat menurunkan kemampuan generalisasi model [11]. Untuk mengatasi keterbatasan tersebut, pendekatan hybrid kernel dikembangkan untuk menggabungkan dua fungsi kernel dalam satu kerangka klasifikasi. Dalam penelitian ini, penggabungan kernel dilakukan melalui kombinasi linier sederhana antar-kernel, di mana fungsi keputusan dibentuk dari agregasi kontribusi masing-masing kernel dasar. MKL memungkinkan model SVM untuk menyesuaikan diri terhadap struktur data yang beragam, baik yang bersifat linier maupun nonlinear, sehingga menghasilkan performa klasifikasi yang lebih akurat dan stabil [12].


Dalam penelitian ini, kombinasi Linear-RBF diusulkan sebagai konfigurasi multi-kernel karena memiliki keunggulan komplementer. Kernel Linear memiliki kemampuan generalisasi yang baik pada data dengan hubungan linier antar fitur, serta memberikan interpretasi yang lebih sederhana dan efisien secara komputasi [13]. Di sisi lain, kernel RBF mampu memetakan data ke ruang berdimensi tinggi dan menangkap pola nonlinier yang kompleks [14]. Dengan menggabungkan keduanya, diharapkan model dapat memanfaatkan stabilitas dan efisiensi kernel Linear sekaligus fleksibilitas kernel RBF dalam mengenali variasi data klinis yang tidak sepenuhnya linier. Pendekatan ini memungkinkan model menghasilkan batas keputusan yang lebih adaptif dan akurat, tanpa harus mengorbankan efisiensi komputasi.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan untuk mengoptimalkan kinerja algoritma SVM melalui pendekatan Linear-RBF hybrid kernel dalam klasifikasi risiko penyakit jantung menggunakan dataset klinis UCI Heart Disease Statlog. Tiga model SVM dengan satu kernel (Linear, RBF, dan Polynomial) dievaluasi bersama dua konfigurasi hybrid kernel (Linear-RBF dan Linear-Polynomial). Penilaian performa masing-masing model dilakukan melalui sejumlah indikator, termasuk precision, recall, F1-score, akurasi, dan kurva ROC-AUC. Kontribusi utama penelitian ini adalah penyajian analisis komparatif yang komprehensif terhadap strategi kombinasi kernel pada SVM untuk tugas klasifikasi medis. Secara keseluruhan, penelitian ini bertujuan memberikan pemahaman yang lebih mendalam mengenai efektivitas pendekatan hybrid kernel dalam meningkatkan kemampuan prediktif SVM pada data klinis yang heterogen.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Studi ini mengadopsi metode eksperimen kuantitatif untuk mengevaluasi performa SVM dengan tiga jenis kernel (Linear, RBF, Polynomial) dan dua kombinasi multi-kernel, yakni Linear-RBF dan Linear-Polynomial, dalam pemodelan klasifikasi penyakit jantung. Proses penelitian dilakukan secara sistematis melalui beberapa tahap, meliputi pengumpulan data, persiapan data, eksplorasi dan analisis deskriptif, pembangunan model klasifikasi, serta evaluasi kinerja model. Alur tahapan penelitian ditunjukkan secara konseptual pada Gambar 1.

**Gambar 1.** Alur Konseptual Penelitian

Rincian penjelasan dari masing-masing alur penelitian dijelaskan sebagai berikut:

1) Pengumpulan Data

Sumber data pada penelitian ini adalah Heart Disease Statlog Dataset yang diunduh dari repositori Kaggle [15]. Dataset ini terdiri atas 270 entri data pasien dengan 13 fitur prediktor yang mencerminkan kondisi klinis seperti usia (age), tekanan darah istirahat (resting blood pressure), kadar kolesterol (chol), frekuensi detak jantung maksimum (thalach), dan chest pain type, serta beberapa variabel fisiologis lain seperti oldpeak, slope, dan ca. Variabel target (target) bersifat biner, yang merepresentasikan dua kondisi, yaitu “1” untuk pasien dengan penyakit jantung dan “0” untuk pasien tanpa penyakit jantung. Dataset ini dipilih karena mencakup indikator medis penting yang sering digunakan dalam diagnosis penyakit jantung secara klinis, serta memiliki format yang sesuai untuk analisis berbasis pembelajaran mesin.

2) Persiapan Data

Tahapan ini dilakukan untuk menjamin bahwa data yang digunakan dalam proses pelatihan model memiliki kualitas yang memadai. Langkah pertama adalah pemeriksaan dan penanganan nilai yang hilang (missing value) menggunakan teknik imputasi median untuk fitur numerik dan modus untuk fitur kategorikal, guna menjaga konsistensi data tanpa menghapus sampel yang berharga. Selanjutnya, seluruh fitur numerik dinormalisasi menggunakan metode StandardScaler untuk menyetarakan skala antar variabel, karena algoritma SVM sensitif terhadap perbedaan rentang nilai antar fitur. Setelah proses normalisasi, dilakukan pembagian dataset menjadi dua subset menggunakan teknik stratified split, yakni 80% sebagai data pelatihan dan 20% sebagai data uji. Pembagian ini mempertahankan proporsi kelas yang seimbang pada kedua subset sehingga evaluasi kinerja model menjadi lebih representatif.

3) Eksplorasi dan Analisis Deskriptif

Analisis eksploratif dilakukan untuk memahami pola distribusi data serta korelasi antar fitur klinis. Tahapan ini mencakup analisis deskriptif terhadap karakteristik utama seperti distribusi usia, tekanan darah, kolesterol, dan detak jantung maksimum pada kedua kelas (No Disease dan Disease). Selain itu, dilakukan analisis hubungan antar variabel numerik menggunakan koefisien korelasi Pearson untuk mengidentifikasi fitur yang memiliki hubungan kuat terhadap diagnosis penyakit jantung. Hasil eksplorasi ini membantu dalam interpretasi performa model pada tahap evaluasi.

4) Pembangunan Model Klasifikasi

Pada fase ini, dirancang model klasifikasi penyakit jantung menggunakan pendekatan SVM (Support Vector Machine). Proses dimulai dengan pelatihan model menggunakan data latih yang telah melalui tahap normalisasi. Tiga model SVM dengan kernel tunggal, yaitu Linear, RBF (Radial Basis Function), dan Polynomial, dikembangkan terlebih dahulu untuk mengukur performa dasar masing-masing fungsi pemetaan. Selanjutnya, dua konfigurasi hybrid kernel, yaitu Linear–RBF dan Linear–Polynomial, dibangun menggunakan kombinasi linier berbobot dengan bobot tetap (0.5 : 0.5). Implementasi kombinasi kernel dilakukan melalui pendekatan precomputed kernel matrix, di mana matriks kernel Linear dan kernel kedua dihitung secara terpisah, kemudian dijumlahkan sesuai bobot yang telah ditentukan. Setiap model SVM dilatih menggunakan parameter dasar dengan nilai $C = 1.0$, yang berfungsi sebagai regularisasi untuk menyeimbangkan margin keputusan dan tingkat kesalahan klasifikasi. Untuk kernel nonlinier, digunakan pengaturan $\gamma = \text{"scale"}$ agar model dapat menyesuaikan kompleksitas batas keputusan secara adaptif terhadap distribusi data. Untuk memastikan stabilitas performa pada dataset berukuran kecil, evaluasi dilakukan menggunakan Stratified K-Fold Cross Validation, sehingga distribusi kelas tetap proporsional pada setiap lipatan data. Pendekatan ini bertujuan mengurangi bias akibat satu pembagian data tertentu serta meningkatkan reliabilitas estimasi performa model.

5) Evaluasi Kinerja Model

Penilaian performa dilakukan melalui lima indikator, yaitu akurasi, presisi, recall, F1-score, serta ROC-AUC, yang semuanya diturunkan dari hasil confusion matrix. Penelitian ini juga menerapkan 5-fold cross-validation guna memastikan bahwa performa model tetap stabil ketika data dibagi ke dalam beberapa subset berbeda. Kurva Receiver Operating Characteristic (ROC) digunakan untuk menggambarkan kemampuan model dalam membedakan antara pasien dengan dan tanpa penyakit jantung, sedangkan nilai Area Under Curve (AUC) menjadi indikator kuantitatif terhadap kinerja keseluruhan model. Perbandingan hasil antar model dilakukan untuk menentukan konfigurasi kernel tunggal dan multi-kernel yang memberikan hasil paling optimal. Analisis komparatif ini menjadi dasar untuk menilai efektivitas pendekatan Linear–RBF Multi-Kernel dalam meningkatkan akurasi dan stabilitas prediksi penyakit jantung.



2.2 Fungsi Kernel pada Support Vector Machine (SVM)

Algoritma Support Vector Machine (SVM) merupakan metode klasifikasi berbasis margin yang bekerja dengan mencari bidang keputusan (hyperplane) yang memisahkan dua kelas data secara optimal [16]. Model ini berupaya memaksimalkan jarak antara titik data dari kelas berbeda terhadap batas pemisah, sehingga meningkatkan kemampuan generalisasi terhadap data baru [17]. Dalam kasus di mana data tidak dapat dipisahkan secara linier pada ruang aslinya, SVM menggunakan fungsi kernel untuk memetakan data ke ruang berdimensi lebih tinggi agar pemisahan linier menjadi memungkinkan [18]. Secara umum, fungsi keputusan SVM dapat dituliskan menggunakan persamaan (1).

$$f(x) = \text{sign}(\sum_{i=1}^n \alpha_i y_i K(x_i, x) + b) \quad (1)$$

di mana x_i merupakan vektor fitur dari sampel pelatihan ke- i , $y_i \in \{-1, 1\}$ adalah label kelas, α_i adalah koefisien hasil optimasi, $K(x_i, x)$ adalah fungsi kernel yang mengukur kesamaan antar dua sampel, dan b merupakan bias model.

Algoritma Support Vector Machine (SVM) bekerja dengan membangun batas keputusan yang memaksimalkan margin pemisah antara dua kelas data [19]. Namun, efektivitas SVM sangat dipengaruhi oleh fungsi kernel, karena kernel menentukan bagaimana data dipetakan ke ruang fitur berdimensi lebih tinggi [20]. Pada ruang baru tersebut, pemisahan linier menjadi lebih mungkin terjadi meskipun pola awal data bersifat nonlinier. Tiga jenis kernel yang digunakan dalam penelitian ini adalah Linear, Radial Basis Function (RBF), dan Polynomial.

Kernel Linear digunakan untuk data dengan hubungan antar fitur yang cenderung linier. Kernel ini mengasumsikan bahwa data dapat dipisahkan secara linier pada ruang fitur asli tanpa perlu transformasi ke ruang berdimensi lebih tinggi [21]. Karena tidak memerlukan pemetaan eksplisit (feature expansion), kernel Linear memiliki kompleksitas komputasi paling rendah dibanding kernel lain. Fungsi ini menghitung kesamaan antar dua vektor fitur menggunakan perkalian titik (dot product) sederhana, seperti yang ditunjukkan pada persamaan (2).

$$K(x_i, x_j) = x_i^T x_j \quad (2)$$

di mana $x_i^T x_j$ menyatakan hasil perkalian titik (dot product) antara dua vektor fitur x_i dan x_j . Kernel RBF (Radial Basis Function) adalah kernel nonlinier yang memetakan data ke ruang fitur dengan dimensi sangat tinggi menggunakan fungsi Gaussian [22]. Kernel ini mengukur kemiripan antar titik berdasarkan jarak Euclidean berdasarkan persamaan (3).

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (3)$$

di mana γ mengontrol tingkat kelengkungan batas keputusan. Nilai γ kecil menghasilkan pemisahan yang halus, sedangkan nilai besar membuat model lebih sensitif terhadap variasi lokal. Kernel Polynomial memproyeksikan data ke ruang fitur yang berisi kombinasi polinomial antar variabel hingga derajat tertentu [23]. Fungsi kernel ini dirumuskan seperti pada persamaan (4).

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d \quad (4)$$

di mana γ adalah faktor skala, r merupakan konstanta bias, dan d menentukan tingkat kompleksitas fungsi. Kernel ini berguna untuk data yang menunjukkan interaksi nonlinier antar variabel.

2.3 Pendekatan Multi-Kernel Learning (MKL)

Pendekatan Multi-Kernel Learning (MKL) merupakan perluasan dari SVM konvensional yang hanya menggunakan satu fungsi kernel. Dalam MKL, dua atau lebih kernel digabungkan untuk membentuk fungsi kesamaan gabungan, yang memungkinkan model menangkap pola data linier dan nonlinier secara bersamaan [24]. Secara umum, formulasi MKL dapat dinyatakan dalam persamaan (5).

$$K_{MKL}(x_i, x_j) = \sum_{m=1}^M \beta_m K_m(x_i, x_j) \quad (5)$$

di mana K_m adalah fungsi kernel ke- m , M adalah jumlah kernel yang digunakan, dan β_m adalah bobot kontribusi dari masing-masing kernel, dengan $\sum \beta_m = 1$ dan $\beta_m \geq 0$. Dalam penelitian ini, kombinasi kernel dilakukan menggunakan penjumlahan linier berbobot dengan bobot statis yang dibagi rata menggunakan persamaan (6).

$$\beta_1 = \beta_2 = 0,5 \quad (6)$$

Pemilihan bobot yang sama (0.5 : 0.5) dilakukan untuk menjaga keseimbangan kontribusi antara kernel Linear dan kernel nonlinier tanpa menambahkan kompleksitas optimasi tambahan. Mengingat ukuran dataset yang relatif kecil (270 sampel), penggunaan bobot statis dipilih untuk menghindari risiko overfitting yang dapat terjadi apabila bobot dioptimasi secara eksplisit melalui prosedur Multiple Kernel Learning (MKL) formal. Dengan pendekatan ini, penelitian berfokus pada evaluasi efek kombinasi karakteristik kernel, bukan pada optimasi bobot kernel itu sendiri. Dua konfigurasi kombinasi kernel yang diuji adalah:

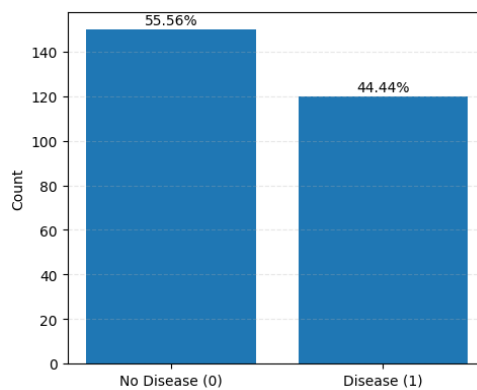
- 1) Linear–RBF Hybrid, yang menggabungkan kemampuan generalisasi kernel Linear dengan fleksibilitas kernel RBF dalam memodelkan pola nonlinier.
- 2) Linear–Polynomial Hybrid, yang mengombinasikan pemisahan linier yang efisien dengan kemampuan kernel Polynomial dalam menangkap interaksi fitur tingkat tinggi.

Pendekatan MKL memberikan fleksibilitas yang lebih besar karena model dapat menyesuaikan bobot masing-masing kernel secara otomatis berdasarkan karakteristik data [25]. Pendekatan hybrid ini memungkinkan model memperoleh batas keputusan yang lebih adaptif dibandingkan kernel tunggal, tanpa menambah kompleksitas parameter secara signifikan.

3. HASIL DAN PEMBAHASAN

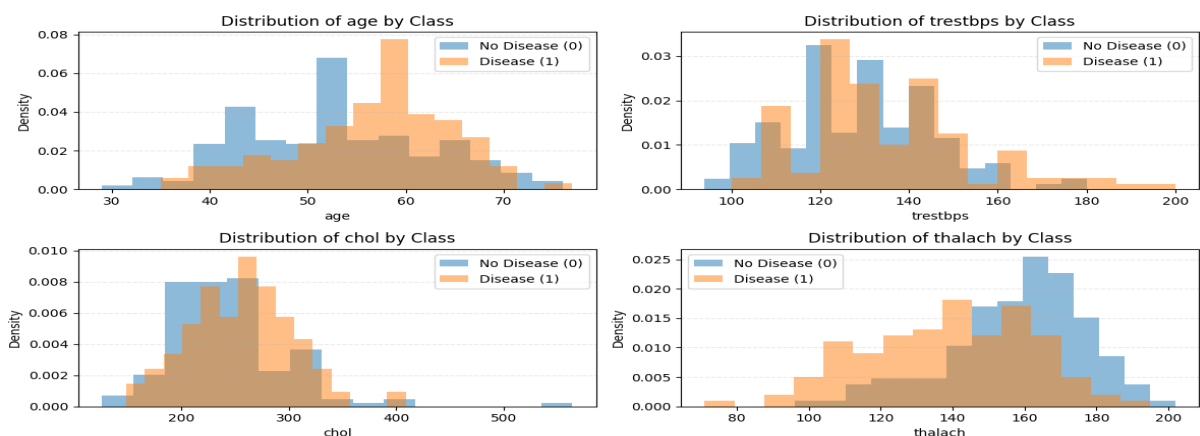
Dataset penyakit jantung yang digunakan dalam penelitian ini berasal dari Kaggle dengan nama Heart Disease Statlog Dataset. Dataset ini memuat 270 sampel dan terdiri atas 13 fitur klinis, termasuk age, trestbps (tekanan darah istirahat), chol (kolesterol total), thalach (detak jantung maksimum), oldpeak, dan beberapa atribut kategori seperti cp (chest pain type), fbs, restecg, dan exang. Variabel target bernama target yang menunjukkan status penyakit jantung dengan dua kategori, yaitu 0 = No Disease dan 1 = Disease. Dataset ini dipilih karena banyak digunakan dalam studi diagnosis penyakit jantung dan memiliki kombinasi fitur klinis yang relevan untuk membangun model klasifikasi berbasis SVM dan Multi-Kernel Learning (MKL).

Sebelum model dilatih, dilakukan tahap praproses data yang mencakup pemeriksaan nilai hilang, normalisasi skala fitur, dan konversi variabel kategorikal ke bentuk numerik. Berdasarkan pemeriksaan awal, tidak ditemukan nilai hilang, sehingga proses imputasi tidak diperlukan. Seluruh fitur numerik kemudian dinormalisasi menggunakan StandardScaler agar SVM dapat bekerja optimal karena algoritma ini sensitif terhadap perbedaan skala antarvariabel. Setelah tahap praproses selesai, dilakukan eksplorasi awal untuk memahami komposisi kelas pada variabel target. Visualisasi distribusi kelas ditampilkan pada Gambar 1.




Gambar 1. Distribusi Kelas pada Dataset Heart Disease Statlog

Gambar 1 menunjukkan bahwa dataset relatif seimbang, dengan proporsi No Disease sebesar 55.56% dan Disease sebesar 44.44%. Kondisi ini menguntungkan proses klasifikasi karena tidak diperlukan teknik penyeimbangan seperti SMOTE, sehingga model dapat dilatih langsung tanpa risiko menghasilkan sampel sintesis yang mungkin mengubah pola asli data. Langkah berikutnya adalah menganalisis distribusi variabel numerik terhadap dua kategori target untuk memahami pola perbedaan antara pasien sehat dan pasien dengan penyakit jantung. Variabel yang diamati meliputi age, trestbps, chol, dan thalach, yang divisualisasikan pada Gambar 2.



Gambar 2. Distribusi Variabel Numerik Berdasarkan Kelas

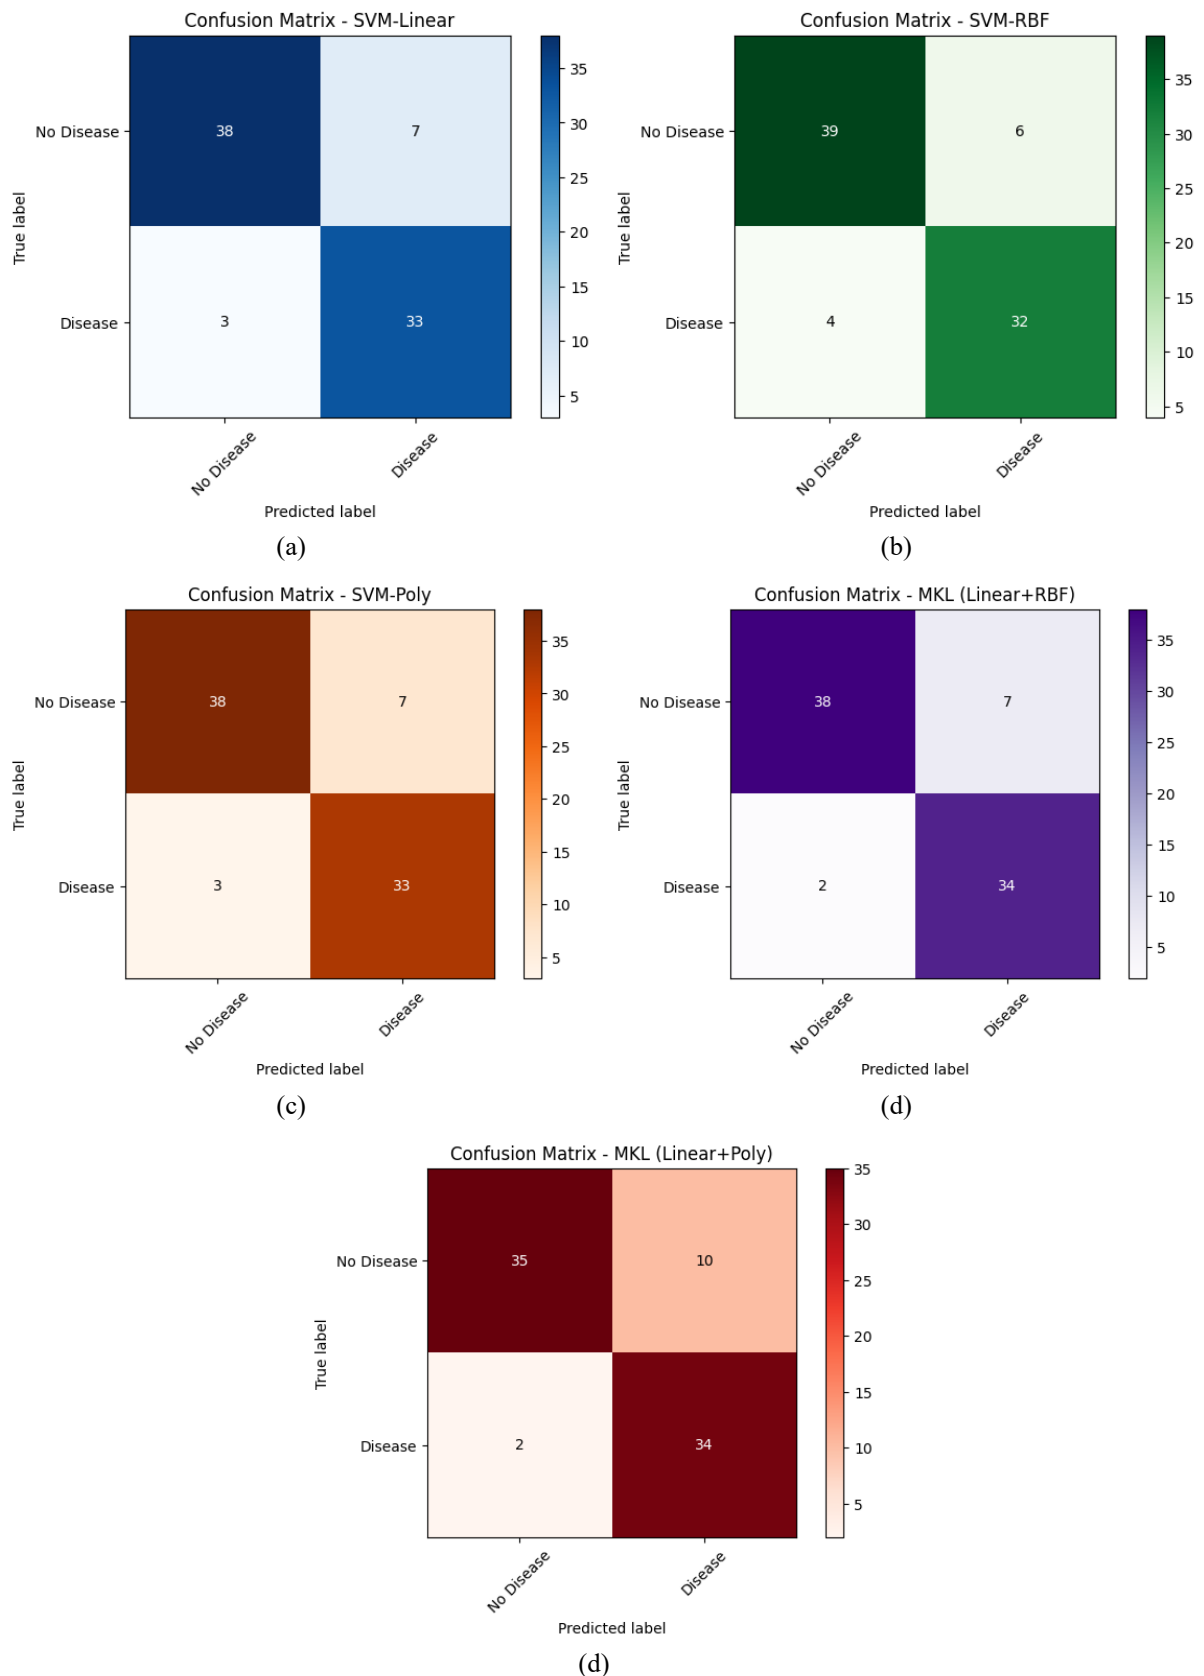
Berdasarkan Gambar 2, terlihat bahwa terdapat pola perbedaan yang jelas antara kedua kelas. Pada variabel age, kelompok Disease cenderung memiliki distribusi usia lebih tinggi dibanding No Disease. Variabel trestbps dan chol juga memperlihatkan nilai yang sedikit lebih tinggi pada pasien dengan penyakit jantung. Sebaliknya, pada variabel thalach, kelompok No Disease menunjukkan detak jantung maksimum yang lebih tinggi, yang secara fisiologis menggambarkan kemampuan jantung yang lebih baik. Pola-pola ini mengindikasikan bahwa tekanan darah, kolesterol, dan kapasitas detak jantung berperan penting dalam membedakan kondisi pasien. Untuk memahami hubungan antarvariabel secara menyeluruh, dilakukan analisis korelasi Pearson pada seluruh fitur numerik. Hasil visualisasinya ditampilkan pada Gambar 3.



Gambar 3. Heatmap Korelasi Pearson Antar Variabel Numerik

Gambar 3 menunjukkan bahwa beberapa variabel memiliki korelasi yang kuat, misalnya thalach memiliki korelasi negatif tinggi terhadap age dan oldpeak, sedangkan variabel ca dan thal memiliki korelasi positif terhadap target. Fitur-fitur yang memiliki korelasi signifikan terhadap target diperkirakan akan memberikan kontribusi penting dalam proses klasifikasi, khususnya thalach, oldpeak, ca, dan thal, yang secara klinis memang berkaitan dengan fungsi jantung dan indikasi penyakit jantung iskemik.

Fase berikutnya mencakup pengembangan model SVM untuk klasifikasi penyakit jantung dengan dua strategi, yaitu kernel tunggal dan pendekatan hybrid berbasis ensemble. Pada pendekatan single-kernel, tiga jenis kernel digunakan, yaitu Linear, Radial Basis Function (RBF), dan Polynomial. Selain itu, penelitian ini menerapkan pendekatan hybrid kernel melalui mekanisme soft voting ensemble, di mana probabilitas prediksi dari dua model SVM dengan kernel berbeda digabungkan menggunakan rata-rata probabilitas. Dengan pendekatan ini, keputusan akhir model ditentukan berdasarkan agregasi probabilitas dari dua fungsi keputusan yang berbeda, sehingga mampu menangkap pola linier maupun nonlinier secara simultan tanpa melakukan fusi matriks kernel sebelum pelatihan. Pendekatan ini secara konseptual berbeda dari Multi-Kernel Learning (MKL) formal yang menggabungkan matriks kernel pada tahap pelatihan. Dalam penelitian ini, kombinasi dilakukan pada level probabilitas prediksi untuk menjaga stabilitas model pada dataset berukuran kecil. Dataset hasil praproses selanjutnya dibagi menjadi 80% data latih dan 20% data uji menggunakan teknik stratified split agar proporsi kelas No Disease dan Disease tetap seimbang. Seluruh model single-kernel dilatih menggunakan parameter yang seragam, yaitu $C = 1.0$, $\gamma = \text{scale}$ untuk kernel nonlinear, serta $\text{degree} = 3$ untuk kernel Polynomial. Pengaturan ini dipilih untuk menjaga kestabilan model dan mencegah overfitting pada dataset yang relatif kecil. Pada tahap pascapelatihan, performa masing-masing model dianalisis menggunakan confusion matrix, yang memetakan jumlah klasifikasi yang tepat maupun keliru untuk setiap kategori. Representasi visual dari confusion matrix seluruh model dapat dilihat pada Gambar 4.

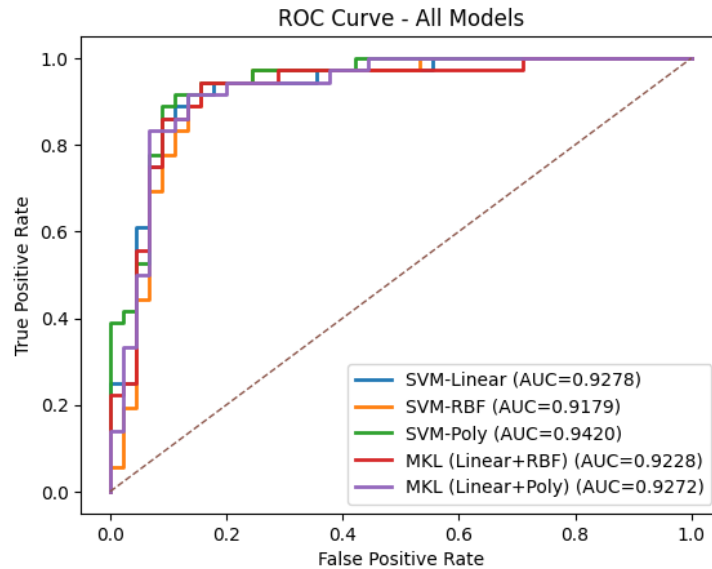


Gambar 4. Confusion Matrix untuk Masing-masing Model: (a) SVM-Linear, (b) SVM-RBF, (c) SVM-Polynomial, (d) MKL Linear-RBF, (e) MKL Linear-Polynomial

Berdasarkan Gambar 4, terlihat bahwa pola klasifikasi yang dihasilkan ketiga model SVM relatif serupa. Model SVM-Linear dan SVM-Polynomial menunjukkan hasil yang identik, masing-masing dengan 38 True Negative dan 33 True Positive, serta jumlah kesalahan yang relatif kecil pada False Positive dan False Negative.

Model SVM-RBF memberikan hasil yang hampir sama, dengan perbedaan satu kesalahan tambahan pada prediksi kelas Disease. Pendekatan MKL Linear–RBF menunjukkan peningkatan kinerja, khususnya pada kelas Disease, dengan 34 True Positive dan hanya 2 False Negative, sehingga lebih baik dalam mendeteksi pasien dengan penyakit jantung. Sebaliknya, metode MKL Linear–Polynomial menunjukkan penurunan performa pada kelas No Disease dengan meningkatnya False Positive sehingga akurasinya menjadi sedikit lebih rendah dibanding metode lainnya.

Untuk melihat performa model pada berbagai nilai ambang batas (threshold), dilakukan analisis Receiver Operating Characteristic (ROC) Curve. Kurva ROC memperlihatkan hubungan antara tingkat deteksi benar (True Positive Rate) dan tingkat kesalahan positif (False Positive Rate). Visualisasi ROC untuk seluruh model ditunjukkan pada Gambar 5.



Gambar 5. Kurva ROC untuk Semua Model

Gambar 5 memperlihatkan bahwa seluruh model memberikan performa klasifikasi yang baik dengan nilai Area Under the Curve (AUC) di atas 0.91. Model SVM-Polynomial mencapai AUC tertinggi yaitu 0.9420, menunjukkan kemampuan paling baik dalam memisahkan kedua kelas secara keseluruhan. Model SVM-Linear dan MKL Linear–Polynomial memiliki nilai AUC yang sangat berdekatan (0.9278 dan 0.9272), sedangkan MKL Linear–RBF mencatat AUC sebesar 0.9228 namun memiliki F1-score tertinggi, menandakan keseimbangan terbaik antara ketepatan dan sensitivitas. Model SVM-RBF mencatat AUC terendah di antara seluruh model, namun tetap berada pada kategori sangat baik dengan nilai 0.9179.

Dalam menilai efektivitas model klasifikasi penyakit jantung, seluruh algoritma SVM single kernel dan pendekatan Multi-Kernel Learning (MKL) dievaluasi menggunakan lima metrik utama, yaitu Precision Macro, Recall Macro, F1-score Macro, Accuracy, dan ROC-AUC. Metrik-metrik ini dipilih karena mampu memberikan gambaran kinerja yang menyeluruh terhadap model, terutama pada dataset dengan dua kelas yang relatif seimbang. Hasil evaluasi secara lengkap disajikan pada Tabel 1.

Tabel 1. Hasil Evaluasi Performa Model SVM Single Kernel dan Multi-Kernel Learning (MKL)

Model	Precision (Macro)	Recall (Macro)	F1-score (Macro)	Accuracy	ROC-AUC
SVM-Linear	0.8759	0.8806	0.8761	0.8765	0.9278
SVM-RBF	0.8745	0.8778	0.8756	0.8765	0.9179
SVM-Polynomial	0.8759	0.8806	0.8761	0.8765	0.9420
MKL (Linear–RBF)	0.8896	0.8944	0.8886	0.8889	0.9228
MKL (Linear–Polynomial)	0.8593	0.8611	0.8518	0.8519	0.9272

Tabel 1 menunjukkan bahwa seluruh model memiliki performa yang cukup kompetitif, dengan nilai akurasi dan F1-score yang berada pada kisaran 0.85 hingga 0.89. Di antara model SVM single-kernel, SVM-Polynomial menampilkan kemampuan pemisahan kelas yang paling baik dengan nilai ROC-AUC sebesar 0.9420. Hal ini mengindikasikan bahwa kernel Polynomial mampu menangkap variasi nonlinier pada data penyakit jantung dengan lebih efektif dibandingkan kernel Linear maupun RBF, sehingga menghasilkan fungsi keputusan yang lebih sensitif terhadap perubahan pola antar fitur. Namun, performa SVM-Polynomial pada metrik lain relatif



serupa dengan SVM-Linear, menunjukkan bahwa peningkatan ROC-AUC tidak selalu diikuti peningkatan signifikan pada akurasi atau F1-score.

Pendekatan MKL memberikan hasil yang lebih menarik. Kombinasi kernel Linear-RBF menjadi model yang paling konsisten memberikan performa tinggi pada sebagian besar metrik evaluasi. Model ini menghasilkan akurasi sebesar 0.8889, precision macro 0.8896, serta F1-score macro 0.8886, yang merupakan nilai tertinggi di antara seluruh model dalam tiga metrik tersebut. Hasil ini menunjukkan bahwa penggabungan karakteristik linear dan nonlinear memungkinkan fungsi keputusan yang lebih adaptif terhadap variasi pola data, sehingga meningkatkan kemampuan model dalam mengenali kedua kelas secara lebih seimbang. Sebaliknya, kombinasi Linear-Polynomial tidak menunjukkan peningkatan performa. Model MKL ini justru mengalami penurunan akurasi dan F1-score dibandingkan pendekatan kernel tunggal. Penurunan tersebut dapat disebabkan oleh sifat polynomial yang lebih kompleks, di mana ketika digabungkan dengan kernel Linear pada dataset berukuran kecil seperti penelitian ini dapat menghasilkan model yang kurang stabil dan berpotensi mengalami overfitting.

Hasil penelitian ini juga dapat dibandingkan dengan beberapa studi sebelumnya. Penelitian sebelumnya yang menggunakan SVM dengan kernel Linear dan RBF pada kasus gagal jantung mencapai akurasi sekitar 85–86% [7]. Terdapat penelitian yang mendeteksi diabetes melaporkan akurasi hingga 91% menggunakan kernel RBF [8], sementara studi lainnya pada klasifikasi stroke mencapai 95% [9]. Perbedaan capaian tersebut dapat dijelaskan oleh karakteristik dataset penyakit jantung yang digunakan dalam penelitian ini. Dataset Heart Disease Statlog memiliki kombinasi fitur klinis numerik dan kategorikal yang heterogen, serta ukuran sampel yang relatif kecil (270 sampel), sehingga menghasilkan kompleksitas pola yang lebih menantang. Heterogenitas ini membuat optimasi kernel menjadi lebih relevan dibandingkan pada dataset penyakit lain yang cenderung memiliki pola lebih homogen atau ukuran data yang lebih besar. Dalam konteks tersebut, pendekatan hybrid Linear-RBF dalam penelitian ini berhasil meningkatkan akurasi hingga 0.8889 dan F1-score hingga 0.8886, yang menunjukkan peningkatan stabilitas klasifikasi dibandingkan model single-kernel. Meskipun nilai ROC-AUC tertinggi dicapai oleh SVM-Polynomial, pendekatan hybrid menunjukkan keseimbangan metrik yang lebih konsisten, yang secara praktis lebih relevan untuk sistem prediksi klinis.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa pendekatan hybrid Linear-RBF merupakan konfigurasi paling stabil berdasarkan kombinasi akurasi, precision, dan F1-score. Sementara itu, SVM-Polynomial tetap menjadi model terbaik dari segi kemampuan diskriminatif berdasarkan ROC-AUC terbesar. Temuan ini menegaskan bahwa penggabungan kernel dapat meningkatkan performa klasifikasi, namun efektivitas kombinasi sangat bergantung pada kompleksitas kernel, ukuran dataset, serta karakteristik distribusi fitur klinis yang digunakan.

4. KESIMPULAN

Penelitian ini telah mengevaluasi performa model Support Vector Machine (SVM) dengan pendekatan single-kernel dan pendekatan hybrid-kernel pada tugas klasifikasi penyakit jantung menggunakan dataset Heart Disease Statlog. Berdasarkan hasil eksperimen, seluruh model menunjukkan performa yang baik. SVM-Polynomial menjadi model single-kernel paling unggul berdasarkan nilai ROC-AUC sebesar 0.9420, yang menunjukkan kemampuan diskriminatif tertinggi dalam memisahkan kelas. Namun demikian, perbedaannya dengan SVM-Linear dan SVM-RBF pada metrik akurasi, precision, dan F1-score relatif kecil, sehingga tidak menunjukkan keunggulan yang konsisten pada seluruh indikator evaluasi. Pendekatan hybrid Linear-RBF menghasilkan performa terbaik secara keseluruhan berdasarkan keseimbangan metrik evaluasi, dengan akurasi sebesar 0.8889, precision macro 0.8896, dan F1-score macro 0.8886. Dibandingkan model single-kernel dengan akurasi sekitar 0.8765, peningkatan ini menunjukkan bahwa kombinasi karakteristik linear dan nonlinier mampu meningkatkan konsistensi klasifikasi pada dataset dengan fitur klinis yang heterogen. Meskipun peningkatan akurasi terlihat moderat secara numerik, dalam konteks sistem prediksi medis, peningkatan tersebut dapat berkontribusi pada pengurangan kesalahan klasifikasi pasien, sehingga mendukung peningkatan keandalan sistem deteksi dini penyakit jantung sebagai alat bantu keputusan klinis. Berbeda dengan kombinasi Linear-RBF, pendekatan Linear-Polynomial tidak menunjukkan peningkatan performa dan cenderung mengalami penurunan pada beberapa metrik evaluasi. Hal ini mengindikasikan bahwa tidak semua kombinasi kernel memberikan manfaat, terutama pada dataset berukuran relatif kecil. Secara keseluruhan, penelitian ini menunjukkan bahwa strategi penggabungan kernel dapat meningkatkan keseimbangan performa klasifikasi dibandingkan penggunaan kernel tunggal. Namun demikian, klaim mengenai stabilitas model masih perlu didukung oleh evaluasi tambahan seperti Stratified K-Fold Cross Validation dan analisis variansi performa. Oleh karena itu, penelitian selanjutnya disarankan untuk menerapkan validasi silang secara sistematis, melakukan optimasi hyperparameter menggunakan grid search atau Bayesian optimization, serta mengeksplorasi pembobotan kernel adaptif guna meningkatkan efektivitas pendekatan hybrid pada dataset klinis yang lebih besar dan heterogen.

REFERENCES

- [1] W. Handayani, "Faktor-Faktor Risiko Penyakit Kardiovaskular: Artikel Review," *J. Pengemb. Ilmu dan Prakt. Kesehat.*, vol. 4, no. 3, pp. 139–158, 2025, doi: <https://doi.org/10.56586/pipk.v4i3.465>.



- [2] D. Saraswati, “Inovasi Pelayanan Kesehatan: Deteksi Dini Penyakit Jantung Koroner melalui Posbindu PTM,” *J. Kesehat. dan Kebidanan Nusantara*, vol. 2, no. 1, pp. 10–16, 2024, doi: <https://doi.org/10.69688/jkn.v2i1.81>.
- [3] T. Septiana, M. A. Muda, D. Budiyo, M. Pratama, and W. P. Jaya, “Analisis Penggunaan Support Vector Machine pada Deteksi Dini Penyakit Diabetes Melitus,” *J. Penelit. Inov.*, vol. 4, no. 3, pp. 1631–1640, 2024, doi: <https://doi.org/10.54082/jupin.643>.
- [4] S. Arifin, R. Satria, and T. Tarwoto, “Pengembangan Algoritma Support Vector Machine (SVM) untuk Mengklasifikasi Penyakit Diabetes,” *J. Informatics Interact. Technol.*, vol. 1, no. 2, pp. 140–147, 2024, doi: <https://doi.org/10.63547/jiite.v1i2.39>.
- [5] A. Pratama, A. H. Siregar, and M. R. D. Cahyo, “Analisis Penyakit Rabies Menggunakan Algoritma Support Vector Machine (SVM),” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 13, no. 2, pp. 422–429, 2025, doi: <https://doi.org/10.23960/jitet.v13i2.6229>.
- [6] T. F. Ramadhan, A. Asrianda, and R. Risawandi, “Penerapan Metode Algoritma SVM (Support Vector Machine) Untuk Klasifikasi Penderita Penyakit Gastroesophageal Reflux Disease,” *RABIT J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 1212–1219, 2025, doi: <https://doi.org/10.36341/rabit.v10i2.6466>.
- [7] L. N. Farida and S. Bahri, “Klasifikasi Gagal Jantung Menggunakan Metode SVM (Support Vector Machine),” *Komputika J. Sist. Komput.*, vol. 13, no. 2, pp. 149–156, 2025, doi: <https://doi.org/10.34010/komputika.v13i2.11330>.
- [8] M. R. Pradana, W. Witanti, and A. Komarudin, “Prediksi Tingkat Keparahan Diabetes Melitus Menggunakan Support Vector Machine (SVM) dengan Kernel Polinomial dan RBF,” *J. LOCUS Penelit. Pengabd.*, vol. 4, no. 8, pp. 7521–7533, 2025, doi: <https://doi.org/10.58344/locus.v4i8.4357>.
- [9] A. Alexander, A. Nazri, R. A. Panbudi, and J. Junadhi, “Implementasi Algoritma SVM dalam Memprediksi Penyakit Stroke,” *J. Zetroem*, vol. 06, no. 02, pp. 1–5, 2024, doi: <https://doi.org/10.36526/ztr.v6i2.3676>.
- [10] Z. Arifin, D. F. Rahman, B. S. Rintyama, and D. Daryanto, “Penerapan Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function dalam Klasifikasi Sel Kanker,” *BIOS J. Teknol. Inf. dan Rekayasa Komput.*, vol. 4, no. 2, pp. 100–106, 2023, doi: <https://doi.org/10.37148/bios.v4i2.165>.
- [11] R. Mukarramah, D. Atmajaya, and L. Budi, “Performance comparison of support vector machine (SVM) with linear kernel and polynomial kernel for multiclass sentiment analysis on twitter,” *Ilk. J. Ilm.*, vol. 13, no. 2, pp. 168–174, 2021, doi: <https://doi.org/10.33096/ilkom.v13i2.851.168-174>.
- [12] M. Rafidianto, D. A. Fatah, and Y. D. P. Negara, “Analisis Sentimen Aplikasi Mpstore Menggunakan Metode Support Vector Machine Multi Kernel,” *Innov. J. Soc. Sci. Res.*, vol. 5, no. 1, pp. 6253–6263, 2025, doi: <https://doi.org/10.31004/innovative.v5i1.17930>.
- [13] A. G. Sooi, P. A. Nani, N. M. R. Mamulak, C. O. Sianturi, S. C. Sianturi, and A. H. Mondolang, “Klasifikasi Citra Daun Anggur Menggunakan SVM Kernel Linear,” *JOINTECS (Journal Inf. Technol. Comput. Sci.)*, vol. 7, no. 1, pp. 19–26, 2022, doi: <https://doi.org/10.31328/jointecs.v8i1.4496>.
- [14] I. Putri, F. Fadlisyah, and A. Razi, “Implementasi Metode SVM RBF (Radial Basis Function) Kernel Untuk Klasifikasi Status Gizi Pada Balita,” *J. Teknol. Terap. Sains* 4.0, vol. 5, no. 2, pp. 43–56, 2024, doi: <https://doi.org/10.29103/tts.v5i2.19156>.
- [15] R. Ritwik, “Heart Disease Statlog,” *Kaggle*. Accessed: Sep. 08, 2025. [Online]. Available: <https://www.kaggle.com/datasets/ritwikb3/heart-disease-statlog>
- [16] D. E. Yanti, L. Framesti, and A. Desiani, “Perbandingan Algoritma C4.5 dan SVM dalam Klasifikasi Penyakit Anemia,” *JIP (Jurnal Inform. Polinema)*, vol. 9, no. 4, pp. 449–456, 2023, doi: <https://doi.org/10.33795/jip.v9i4.1381>.
- [17] A. W. Anggraeni, A. S. Fitriani, and A. Eviyanti, “Penerapan Algoritma Support Vector Machine untuk Memprediksi Tingkat Partisipasi Pemilih terhadap Kualitas Pendidikan,” *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 21–27, 2024, doi: <https://doi.org/10.21070/ups.9670>.
- [18] M. M. Lasiyono, N. Nurhayati, T. G. Soares, and M. Mulyadi, “Enhancing Support Vector Machine Performance for Heart Attack Prediction using RobustScaler-Based Outlier Handling,” vol. 4, no. 1, pp. 1–9, 2025, doi: <http://dx.doi.org/10.61944/bids.v4i1.94>.
- [19] S. Adi and A. Wintarti, “Komparasi Metode Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest (RF) Untuk Prediksi Penyakit Gagal Jantung,” *MATHunesa J. Ilm. Mat.*, vol. 10, no. 02, pp. 258–268, 2022, doi: <https://doi.org/10.26740/mathunesa.v10n2.p258-268>.
- [20] A. F. Rochim, K. Widyaningrum, and D. Eridani, “Performance Comparison of Support Vector Machine Kernel Functions in Classifying COVID-19 Sentiment,” in *4th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, 2021, pp. 224–228. doi: 10.1109/ISRITI54043.2021.9702845.
- [21] E. R. M. Sholihah, I. G. S. M. Diyasa, and E. Y. Puspaningrum, “Perbandingan Kinerja Kernel Linear dan RBF Support Vector Machine Untuk Analisis Sentimen Ulasan Pengguna KAI Access Pada Google Play Store,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 728–733, 2024, doi: <https://doi.org/10.36040/jati.v8i1.8800>.
- [22] C. V. Angkoso, K. Asror, A. Kusumaningsih, and A. K. Nugroho, “Optimasi Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function (RBF) Menggunakan Metode Particle Swarm Optimization Untuk Analisis Sentimen,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 3, pp. 705–718, 2025, doi: <https://doi.org/10.25126/jtiik.2025129317>.
- [23] A. Faradisya and M. A. I. Pakereng, “Analisis Komparatif Kernel Linear, Polynomial, RBF, dan Sigmoid pada Support Vector Machine untuk Klasifikasi Penyakit Jantung,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 4, pp. 1531–1537, 2025, doi: <https://doi.org/10.57152/malcom.v5i4.2321>.
- [24] K. Paranjothi, F. Ghouse, and R. Vaithianathan, “Detection of Parkinson’s Disease on DaTSCAN Image Using Multi-kernel Support Vector Machine,” *Int. J. Intell. Eng. Syst.*, vol. 17, no. 5, pp. 45–55, 2024, doi: 10.22266/ijies2024.1031.05.
- [25] A. K. Jhapate and H. Shrivastava, “GAIT based human Parkinson’s disease detection using fused features with multi-kernel support vector machine,” *Int. J. Inf. Technol.*, vol. 17, no. 3, pp. 1387–1395, 2025, doi: 10.1007/s41870-024-02099-z.