



Support Vector Machine sebagai Sistem Pendukung Keputusan Pemilihan Jurusan Berbasis Website pada SMK NU Hasyim Asy'ari Tarub

Rizal Nurzuli¹, Fadilah Falah Syifa², Robiatul Adawiyah³

^{1,2,3}Pendidikan Informatika, STKIP NU Kabupaten Tegal, Tegal, Indonesia

Email: ¹rizalnurzuli@gmail.com ²ffalahsyifa91@gmail.com, ³robiiadwyh@gmail.com

Informasi Artikel

Diterima : 18-09-2025

Disetujui : 26-10-2025

Diterbitkan : 15-11-2025

ABSTRACT

The process of determining students' majors in vocational high schools plays a crucial role in shaping their academic development and future career readiness. However, manual decision-making often leads to inaccuracies due to subjective judgments and limited data analysis. This study aims to develop a more accurate and objective major classification model by integrating the Support Vector Machine (SVM) method with Particle Swarm Optimization (PSO). The dataset consists of 292 student records, including academic scores in Mathematics, Indonesian Language, English, and Science, as well as interest questionnaire results. Initial testing using SVM produced an accuracy of 79.76%, indicating that the model's parameters were not yet optimal. PSO was then applied to optimize the key parameters C and Gamma, resulting in a significant improvement in model performance. The optimized SVM-PSO model achieved an accuracy of 97.20%, with a precision of 96.33%, recall of 95.22%, and an F1-score of 95.77%. These results demonstrate the capability of PSO to enhance SVM's pattern-recognition performance and address class imbalance issues, particularly for minority majors. Overall, the integration of SVM and PSO is proven to be effective as a Decision Support System, providing schools with accurate, data-driven recommendations for student major placement.

Keywords: *Support Vector Machine, Particle Swarm Optimization, Classification, Major Recommendation, Decision Support System*

ABSTRAK

Pemilihan jurusan di Sekolah Menengah Kejuruan (SMK) merupakan proses penting yang menentukan arah perkembangan kompetensi siswa dan kesiapan mereka memasuki dunia kerja. Namun, proses penjurusan yang masih dilakukan secara manual sering menimbulkan ketidaktepatan karena dipengaruhi subjektivitas guru dan keterbatasan analisis data. Penelitian ini

bertujuan mengembangkan model klasifikasi pemilihan jurusan yang lebih akurat dan objektif dengan mengintegrasikan metode Support Vector Machine (SVM) dan Particle Swarm Optimization (PSO). Data yang digunakan terdiri atas nilai akademik siswa (Matematika, Bahasa Indonesia, Bahasa Inggris, dan IPA) serta skor kuesioner minat dengan total 292 data. Pengujian awal menggunakan SVM menghasilkan akurasi sebesar 89,33%, yang menunjukkan perlunya optimasi parameter. PSO kemudian digunakan untuk mencari nilai optimal parameter C dan Gamma, sehingga performa model meningkat signifikan dengan akurasi 97,20%, precision 96,33%, recall 95,22%, dan F1-score 95,77%. Hasil tersebut membuktikan bahwa PSO mampu meningkatkan kemampuan SVM dalam mengenali pola data serta mengatasi ketidakseimbangan kelas, terutama pada jurusan dengan jumlah siswa sedikit. Secara keseluruhan, integrasi SVM-PSO terbukti efektif sebagai Sistem Pendukung Keputusan yang membantu sekolah dalam memberikan rekomendasi penjurusan yang lebih tepat, objektif, dan berbasis data.

Kata Kunci: Support Vector Machine. Particle Swarm Optimization, Sistem Pendukung Keputusan, Pemilihan Jurusan, Website

1. PENDAHULUAN

Pemilihan jurusan merupakan salah satu Keputusan akademik paling krusial bagi siswa Sekolah Menengah Kejuruan (SMK) karena berkaitan langsung dengan arah pengembangan kompetensi, motivasi belajar, serta kesiapan siswa memasuki dunia kerja. (Pendidikan & Teknologi Tahun, 2022.)), penentuan jurusan harus mempertimbangkan minat, bakat, dan potensi siswa agar proses pembelajaran dapat berlangsung secara optimal dan relevan dengan tujuan karir mereka. Ketika siswa memilih jurusan yang tidak sesuai, mereka cenderung mengalami penurunan motivasi, kesulitan memahami materi, serta rendahnya prestasi belajar, sebagaimana dijelaskan oleh (Schunk and Zimmerman, 2012) serta ditemukan kembali oleh (Ernawati *et al.*, 2021) yang menyatakan bahwa ketidaksesuaian jurusan berdampak langsung terhadap kinerja akademik siswa. Situasi ini juga menjadi salah satu faktor yang berkontribusi terhadap tingginya Tingkat pengangguran lulusan SMK yang mencapai 8,62% pada tahun 2024 (Badan Pusat Statistik, 2022). Data tersebut menggambarkan adanya ketidaksesuaian antara pilihan jurusan siswa dengan tuntutan kompetensi dunia industry, sehingga menegaskan pentingnya mekanisme pemilihan jurusan yang lebih objektif dan berbasis data.

Di lapangan, proses penjurusan masih banyak dilakukan secara manual, mengandalkan penilaian subjektif guru, keterbatasan waktu, serta jumlah siswa yang besar. Tidak sedikit siswa memilih jurusan hanya karena pengaruh teman dan faktor eksternal lainnya, sementara faktor kemampuan akademik dan minat pribadi kurang diperhatikan. Permasalahan seperti rendahnya motivasi belajar, ketidaksesuaian kemampuan siswa dengan jurusan yang dipilih, hingga meningkatnya risiko ketidakcocokan karir di masa depan telah teridentifikasi dalam berbagai situasi yang

ditemukan di sekolah. Kondisi tersebut menunjukkan kebutuhan mendesak terhadap sistem pendukung Keputusan yang mampu memberikan rekomendasi jurusan secara lebih objektif, akurat, dan terstruktur..

Penelitian dalam bidang Sistem Pendukung Keputusan (SPK) telah banyak dilakukan menggunakan berbagai metode. Beberapa studi menerapkan K-Nearest Neighbor (KNN) untuk menentukan jurusan berdasarkan nilai rapor dan minat siswa, namun metode ini sensitif terhadap jumlah data dan outlier (Zainuddin, 2018). Penelitian lain menggunakan Weighted Product (WP) untuk menghasilkan rekomendasi berbasis bobot kriteria, tetapi WP memiliki kelemahan karena sangat bergantung pada bobot subjektif yang ditentukan oleh pengambil keputusan. Di sisi lain, Analytical Hierarchy Process (AHP) membantu melakukan perbandingan prioritas, namun proses perhitungannya kompleks dan rentan terhadap inkonsistensi penilai (Maulanii, 2024). Sementara itu, Simple Additive Weighting (SAW) menawarkan proses perankingan yang sederhana namun belum mampu menangkap kompleksitas hubungan antar-variabel yang memengaruhi pemilihan jurusan. Meskipun metode-metode tersebut memberikan kontribusi terhadap pengembangan SPK, keterbatasan akurasi dan kemampuan generalisasi masih menjadi tantangan yang belum terjawab secara optimal (Rokhmah et al., 2021).

Sebagai alternatif yang lebih kuat, Support Vector Machine (SVM) yang diperkenalkan oleh Cortes dan Vapnik (1995) menjadi salah satu metode klasifikasi yang efektif dalam menangani data berdimensi tinggi dan hubungan non-linear. SVM bekerja dengan mencari hyperplane optimal yang memaksimalkan margin antar kelas sehingga mampu menghasilkan akurasi prediksi yang tinggi dalam berbagai konteks, termasuk pengolahan data akademik dan pemetaan minat siswa (Zhang et al., 2022). Namun demikian, performa SVM sangat bergantung pada pemilihan parameter C dan γ pada kernel Radial Basis Function (RBF). Parameter yang tidak optimal dapat menyebabkan *overfitting* atau penurunan akurasi, sehingga diperlukan mekanisme optimasi otomatis untuk memperoleh kinerja terbaik.

Berbagai studi telah mencoba meningkatkan performa SVM melalui integrasi dengan algoritma optimasi seperti Genetic Algorithm (GA), Grey Wolf Optimizer (GWO), dan Ant Colony Optimization (ACO). Pada pendekatan SVM-GWO, peningkatan akurasi umumnya dicapai karena GWO memiliki kemampuan eksplorasi yang kuat dalam menemukan kombinasi parameter optimal, meskipun beberapa penelitian mencatat bahwa metode ini membutuhkan waktu komputasi lebih panjang dan dapat kurang stabil pada dataset berukuran kecil (Afifudin et al., 2024). Di sisi lain, SVM-ACO (Manakkadu & Dutta, 2024) juga menunjukkan performa lebih baik dibandingkan SVM murni berkat mekanisme pencarian adaptif yang dimilikinya, namun algoritma ini cenderung memiliki kompleksitas lebih tinggi serta proses konvergensi yang lebih lambat dibandingkan PSO. Kondisi tersebut menunjukkan bahwa meskipun hibrida seperti SVM-GWO dan SVM-ACO mampu meningkatkan performa SVM, efektivitasnya belum konsisten dan sangat dipengaruhi oleh konfigurasi parameter awal serta dinamika masing-masing algoritma optimasi.

Dalam konteks tersebut, Particle Swarm Optimization (PSO) menjadi salah satu algoritma optimasi yang lebih efisien karena mampu menyeimbangkan eksplorasi dan eksploitasi ruang pencarian secara sederhana namun efektif. PSO dapat menentukan parameter C dan γ secara otomatis dan lebih cepat dibandingkan sebagian hibrida lainnya, sehingga meningkatkan performa SVM secara signifikan. Integrasi SVM-PSO yang digunakan dalam penelitian ini merupakan pendekatan yang belum pernah diterapkan pada sistem pendukung keputusan pemilihan jurusan di SMK, sementara penelitian terdahulu masih didominasi oleh metode tradisional seperti KNN, WP, AHP, dan SAW.

Kebaruan penelitian ini terletak pada penerapan SVM-PSO untuk optimasi parameter SVM dalam konteks pemilihan jurusan, di mana model tidak hanya mempertimbangkan nilai akademik, tetapi juga minat siswa. Hasil eksperimen menunjukkan bahwa SVM-PSO mampu mencapai akurasi 97,20%, precision 96,33%, recall 95,22%, dan F1-score 95,77%, melampaui performa metode-metode sebelumnya maupun hibrida lain yang dilaporkan dalam literatur. Selain itu, penelitian ini menghadirkan implementasi berbasis web yang memungkinkan proses penjurusan dilakukan secara cepat, objektif, dan berbasis data, sehingga berkontribusi pada pengembangan teknologi pendidikan dan sistem pengambilan keputusan yang lebih modern.

2. METODE

2.1 Metode Penelitian dan DataSet

Penelitian ini menggunakan pendekatan kuantitatif dengan metode Machine Learning Eksperimental untuk mengembangkan dan mengevaluasi model klasifikasi berbasis Support Vector Machine (SVM) yang dioptimasi menggunakan Particle Swarm Optimization (PSO). Desain penelitian yang digunakan bersifat model development dan comparative experiment, di mana model SVM baseline dibandingkan dengan model SVM-PSO yang telah melalui proses optimasi hyperparameter. Pendekatan eksperimen ini sejalan dengan konsep metode eksperimen dalam penelitian komputasi yang bertujuan mengukur efektivitas algoritma melalui berbagai skenario pengujian ((A Man Kumar, 2018) serta relevan dengan studi sebelumnya yang menunjukkan bahwa eksperimen machine learning menghasilkan evaluasi model yang objektif dan terukur ((Zhang et al., 2022).

Penelitian ini dilaksanakan di SMK NU Hayim Asy'ari Tarub. penelitian dilakukan pada Maret sampai Mei 2025. Subjek penelitian melibatkan 292 siswa kelas X, yang menjadi populasi penug (total sampling) dalam proses klasifikasi jurusan. Data dikumpulkan menggunakan Teknik dokumentasi dan angket, yang mencakup nilai ijazah SLTP sebagai indikator kemampuan akademik dan angket minat siswa sebagai indikator preferensi jurusan. Kedua data tersebut diperoleh dari pihak sekolah dan siswa kelas X SMK NU Hayim Asy'ari Tarub, serta didukung dokumen seunder berupa kebijakan sekolah terkait proses penjurusan.

Dataset akhir terdiri dari empat fitur akademik (Matemika, Bahasa Indonesia, Bahasa Inggris, dan IPA) serta fitur non-akademi, yaitu minat siswa. Seluruh data diproses melalui tahapan preprocessing termasuk pembersihan data, normalisasi menggunakan min-max scaling serta pembagian data menjadi data latih dan data uji. Fokus penelitian ini diarahkan sepenuhnya pada analisis performa model SVM sebelum dan sesudah optimasi PSO, tanpa menyoroti aspek implementasi web. Pendekatan ini bertujuan menghasilkan analisis yang mendalam terkait efektivitas integrasi metode SVM-PSO dalam klasifikasi pemilihan jurusan berbasis data.

2.2 Data Preprocessing

Tahap data preprocessing dilakukan untuk menyiapkan data agar dapat diproses secara optimal oleh algoritma machine learning. Proses ini mencakup pembersihan data, normalisasi fitur menggunakan Min-Max Scaling, penyesuaian format data, serta pembagian dataset menjadi data latih dan data uji.

Tahap pertama Adalah data cleaning, yaitu memastikan bahwa seluruh data nilai akademik serta data minat siswa tidak mengandung missing values, duplikai, maupun nilai ekstrem. Berdasarkan hasil pengecekan, seluruh data berada dalam kondisi lengkap dan tidak ditemukan ketidakwajaran nilai sehingga keseluruhan data set dapat digunakan tanpa proses imputasi atau penghapusan data.

Tabel 1. Data Siswa

ID	IP A	B.IN D	B.IN G	MT K	Pemina tan
A1	82	70	76	59	63,64
A2	81	70	80	49	72,73
A3	81	83	72	62	68,18
A4	83	80	66	54	59,09
A5	81	81	54	68	77,27
A6	70	65	58	71	59,09
A7	87	85	73	68	56,82
A8	93	86	64	67	72,73
A9	86	84	64	69	68,18
A10	58	80	78	62	61,36
.....					
A291	68	81	90	56	43,18
A292	64	91	86	71	65,91

Tabel 2. Struktur Data

	Columns	Non-Null Count	Dtype
0	ID	292 non-null	Object
1	IPA	292 non-null	Int
2	MTK	292 non-null	Int
3	B.IND	292 non-null	Int
4	B.ING	292 non-null	Int
5	PEMINATAN	292 non-null	int

Selanjutnya, dilakukan proses normalisasi menggunakan teknik Min–Max Scaling untuk menyetarakan skala seluruh fitur ke dalam rentang [0,1]. Normalisasi diperlukan karena fitur-fitur akademik dan non-akademik memiliki rentang nilai yang berbeda, sementara algoritma SVM sensitif terhadap perbedaan skala fitur. Rumus normalisasi yang digunakan adalah:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

Dengan x adalah nilai asli, x_{min} nilai minimum fitur, x_{max} nilai maksimum fitur, dan x' adalah nilai hasil normalisasi. Nilai minimum dan maksimum tiap fitur ditampilkan pada tabel berikut, yang menjadi acuan proses *scaling*:

Tabel 3. Nilai Min Max

	MIN	MAX
IPA	48	94
MATEMATIKA	48	95
B.INDONESIA	48	94
B.INGGRIS	48	95
PEMINATAN	40.91	84.09

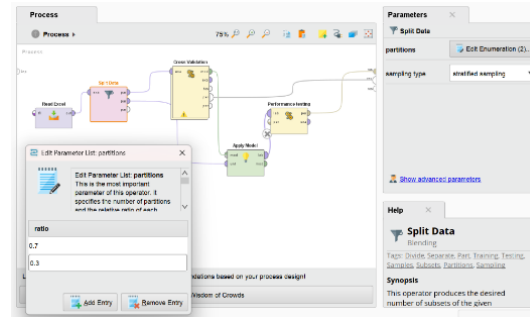
Transformasi ini diterapkan secara konsisten terhadap seluruh data yang berjumlah 292 sampel. Berikut hasil Min-Max Scaling :

Tabel 4. Hasil Normalisasi Min Max Scaling

ID	IPA	MTK	B.IND	B.ING	PEMINATAN
A1	0,73913	0,468085	0,608696	0,234043	0,526401
A2	0,717391	0,468085	0,695652	0,021277	0,736915
A3	0,717391	0,744681	0,521739	0,297872	0,631542
A4	0,76087	0,680851	0,391304	0,12766	0,421028
A5	0,717391	0,702128	0,130435	0,425532	0,842057
A6	0,478261	0,361702	0,217391	0,489362	0,421028
A7	0,847826	0,787234	0,543478	0,425532	0,368458
A8	0,978261	0,808511	0,347826	0,404255	0,736915
A9	0,826087	0,765957	0,347826	0,446809	0,631542
A10	0,217391	0,680851	0,652174	0,297872	0,473599
				
A291	0,434783	0,702128	0,913043	0,170213	0,052571
A292	0,347826	0,914894	0,826087	0,489362	0,578972

Support Vector Machine sebagai Sistem Pendukung Keputusan Pemilihan Jurusan Berbasis Website pada SMK NU Hasyim Asy'ari Tarub

Tahap terakhir adalah pembagian dataset menjadi data latih dan data uji menggunakan rasio 70:30. Teknik stratified sampling digunakan untuk menjaga proporsi tiap jurusan tetap seimbang pada kedua subset data. Dari total 292 siswa, diperoleh 204 data latih dan 88 data uji, sehingga model dapat belajar dari variasi data yang memadai sekaligus diuji menggunakan data yang belum pernah dilihat sebelumnya.



Gambar 1. Splitting Data

Gambar 1 menunjukkan proses pembagian data menggunakan operator *Split Data* pada RapidMiner. Dataset terdiri dari 292 siswa, yang meliputi 77 siswa jurusan TKR, 68 siswa jurusan TSM, 80 siswa jurusan TKJ, dan 67 siswa jurusan LP. Pembagian dilakukan dengan rasio 70% data latih dan 30% data uji untuk mempersiapkan proses pelatihan dan evaluasi model SVM. Agar distribusi masing-masing jurusan tetap seimbang antara data latih dan data uji, digunakan metode *stratified sampling*, sehingga representasi tiap kelas dalam kedua subset tetap konsisten dan tidak menyebabkan bias selama proses pelatihan maupun pengujian.

2.3 Support Vector Machine

Support Vector Machine (SVM) merupakan algoritma supervised learning yang dirancang untuk mencari hyperplane terbaik dalam memisahkan data berdasarkan kelasnya. (Handayanto *et al.*, 2019) Pada kasus klasifikasi pemilihan jurusan, SVM digunakan untuk memetakan hubungan antara nilai akademik dan minat siswa terhadap label jurusan, sehingga model mampu menghasilkan Keputusan klasifikasi yang optimal. SVM bekerja dengan mencari batas Keputusan (Decision Boundary) yang memiliki margin terbesar antara data dari kelas yang berbeda, sehingga model menjadi lebih tahan terhadap kesalahan dan mampu melakukan generalisasi dengan baik pada data baru.

Secara matematis, tujuan SVM adalah memaksimalkan margin antara dua kelas dengan mencari hyperplane yang direpresentasikan oleh fungsi:

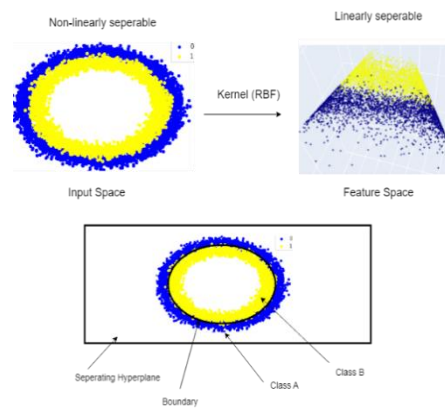
$$f(x) = w^T x + b$$

di mana w adalah vektor bobot dan b adalah bias. SVM berupaya menemukan nilai w dan b yang memaksimalkan margin sambil meminimalkan kesalahan prediksi. Proses optimasi dilakukan melalui pemecahan masalah *quadratic programming* sebagai berikut:

$$\min \frac{1}{2} \|w\|^2 \text{ dengan syarat } y_i(w^T x_i + b) \geq 1$$

Untuk data yang tidak sepenuhnya linear separable, SVM menggunakan fungsi kernel untuk memetakan data ke ruang berdimensi lebih tinggi sehingga pemisahan dapat dilakukan secara linear pada ruang tersebut. Teknik ini dikenal sebagai *kernel trick* dan menjadi salah satu kekuatan utama SVM dalam menangani data non-linear (Muis and Affandes, 2015). Fungsi kernel yang digunakan dalam penelitian ini adalah Radial Basis Function (RBF), karena mampu menjangkau pola non-linear yang kompleks dalam data nilai akademik siswa. Kernel RBF didefinisikan sebagai:

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



Gambar 2. Ilustrasi Kernel RBF

Parameter γ pada kernel ini berperan penting dalam menentukan seberapa jauh pengaruh satu titik data terhadap titik lainnya; nilai γ yang besar membuat model lebih sensitif terhadap perubahan data, sedangkan nilai yang terlalu kecil dapat menyebabkan model terlalu sederhana dan gagal menangkap pola penting. Selain parameter γ , SVM juga menggunakan parameter C sebagai pengontrol *trade-off* antara margin besar dan tingkat kesalahan klasifikasi. Kedua parameter ini sangat menentukan kinerja SVM sehingga memerlukan proses optimasi yang tepat (Sidharth, 2022).

Dalam konteks klasifikasi multikelas, seperti empat jurusan yang tersedia (TKR, TBM, TKJ, dan LP), SVM menerapkan strategi one-vs-one, yaitu membangun model klasifikasi untuk setiap pasangan kelas dan memilih hasil klasifikasi berdasarkan voting. Dengan pendekatan ini, SVM mampu menangani data dengan jumlah kelas lebih dari dua tanpa mengubah struktur dasar algoritmanya. Pemilihan SVM dalam penelitian ini didukung oleh literatur yang menunjukkan performanya yang baik dalam domain pendidikan dan klasifikasi akademik, melalui kemampuan generalisasi yang kuat serta ketahanannya terhadap overfitting pada dataset berskala menengah.

Integrasi SVM dengan proses optimasi hyperparameter menjadi bagian penting dalam penelitian ini, karena nilai parameter C dan γ sangat berpengaruh terhadap performa model. Oleh karena itu, tahap selanjutnya menggunakan algoritma Particle Swarm Optimization (PSO) untuk menemukan kombinasi parameter terbaik sehingga kinerja klasifikasi dapat ditingkatkan secara signifikan.

Parameter SVM (baseline). Parameter awal SVM yang digunakan sebelum proses optimasi ditunjukkan pada Gambar 4.9. Model SVM menggunakan kernel Radial Basis Function (RBF) dengan nilai parameter awal $C = 1.0$ dan $\gamma = 0.01$ (pengaturan default pada LibSVM di RapidMiner). Nilai ini berfungsi sebagai baseline dan selanjutnya dioptimasi menggunakan PSO untuk memperoleh kombinasi parameter yang memberikan performa terbaik.

2.4 Particle Swarm Optimization (PSO)

Particle Swarm Optimization (PSO) merupakan algoritma optimasi berbasis populasi yang dikembangkan oleh (Hasfi, 2016). Algoritma ini terinspirasi dari perilaku sosial kawanan burung dalam mencari sumber makanan, di mana setiap individu (partikel) bergerak mengikuti posisi terbaiknya sendiri serta posisi terbaik kelompok. Sifat inilah yang membuat PSO mampu melakukan eksplorasi ruang solusi secara efisien dan mencapai konvergensi yang cepat, sehingga sering digunakan untuk optimasi parameter model pembelajaran mesin, termasuk Support Vector Machine (SVM) (Batista et al., 2019).

Dalam PSO, setiap partikel memiliki posisi dan kecepatan yang mewakili kandidat solusi. Pada setiap iterasi, partikel mengoreksi pergerakannya berdasarkan pengalaman personal (*personal best* atau *pbest*) dan pengalaman global (*global best* atau *gbest*). Mekanisme pembaruan posisi dimulai dengan pembaruan kecepatan yang dirumuskan sebagai berikut (MADE AGUS, 2024):

$$v_i(t) = w \cdot v_i(t - 1) + c_1 \cdot r_1 \cdot (pbest_i - x_i(t - 1)) + c_2 \cdot r_2 \cdot (gbest - x_i(t - 1))$$

Kecepatan yang telah diperbarui selanjutnya digunakan untuk menghitung posisi partikel:


$$x_i(t) = x_i(t - 1) + v_i(t)$$

Pada persamaan tersebut, w adalah inertia weight yang mengontrol kontribusi kecepatan sebelumnya, sedangkan c_1 dan c_2 merupakan *cognitive* dan *social learning factor*. Parameter r_1 dan r_2 adalah bilangan acak dalam rentang 0–1 yang memberikan sifat stokastik pada pergerakan partikel. Proses iteratif ini berlanjut hingga kondisi berhenti terpenuhi, seperti iterasi maksimum tercapai atau nilai solusi tidak lagi mengalami peningkatan (Rahma Kurniawan, 2023).

Konfigurasi PSO. Optimasi parameter SVM dilakukan menggunakan Particle Swarm Optimization (PSO) dengan konfigurasi sebagai berikut: jumlah iterasi $t = 30$, koefisien kognitif $c_1 = 1.0$, koefisien sosial $c_2 = 1.0$, nilai inersia adaptif pada rentang $w \in [0.4, 0.9]$, serta ukuran populasi sebanyak 20 partikel. Parameter-parameter ini digunakan untuk mengendalikan perilaku eksplorasi dan eksploitasi PSO selama pencarian kombinasi optimal nilai C dan γ .

Ruang pencarian (search space). Ruang pencarian untuk parameter SVM yang dieksplorasi PSO ditetapkan sebagai $C \in [0.1, 100]$ dan $\gamma \in [0.001, 1]$. Rentang ini dipilih agar mencakup nilai-nilai praktik umum pada kernel RBF sehingga PSO memiliki fleksibilitas yang cukup untuk menemukan kombinasi parameter optimal.

Dalam penelitian ini, PSO diterapkan untuk mengoptimasi parameter utama pada SVM kernel Radial Basis Function (RBF), yaitu parameter regulasi C dan parameter kernel γ . Menurut (Saprudin, 2017) kinerja SVM sangat dipengaruhi oleh pemilihan C dan γ . Oleh karena itu, PSO digunakan untuk mencari kombinasi nilai terbaik berdasarkan nilai *fitness* berupa akurasi validasi silang. Setiap partikel direpresentasikan sebagai pasangan (C, γ) , lalu dievaluasi menggunakan model SVM yang dilatih pada data pelatihan. Nilai terbaik partikel disimpan sebagai *pbest*, dan nilai terbaik seluruh partikel sebagai *gbest*. Dengan cara ini, PSO menghindari proses pencarian manual seperti grid search yang lebih lambat dan memungkinkan pencarian solusi optimal secara adaptif dan efisien.



Gambar 3. Ilustrasi Cara kerja Optimasi PSO dalam SVM
Sumber : (Batista *et al.*, 2019)

Melalui mekanisme optimasi ini, model SVM dapat bekerja lebih optimal dengan parameter yang sesuai sehingga menghasilkan performa klasifikasi yang lebih tinggi dan stabil (Batista *et al.*, 2019; Hasfi, 2016).

2.5 Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja sistem klasifikasi dalam menghasilkan prediksi yang sesuai dengan nilai sebenarnya. Penelitian ini menggunakan empat metrik evaluasi, yaitu akurasi, precision, recall, dan F1-score, sebagaimana digunakan pada penelitian terdahulu (Jainvidip, 2024)) Akurasi digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data uji, dengan rumus:

$$Akurasi = \frac{Jumlah\ Prediksi\ Benar}{Total\ Data\ Uji}$$

Precision merupakan tingkat ketepatan model dalam memprediksi kelas tertentu dan dirumuskan sebagai:

$$Precision = \frac{TP}{TP + FP}$$

Recall mengukur kemampuan model dalam mendeteksi seluruh data positif yang sebenarnya, dengan rumus:

$$Recall = \frac{TP}{TP + FN}$$

F1-score adalah rata-rata harmonik antara precision dan recall sehingga memberikan evaluasi yang lebih seimbang, terutama pada data yang tidak seimbang:

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Keempat metrik ini digunakan untuk menilai performa model sebelum dan sesudah dilakukan optimasi parameter, sehingga perubahan performa dapat diamati secara objektif.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian Awal

Evaluasi model dilakukan untuk menilai performa algoritma SVM dalam mengklasifikasikan data siswa ke dalam jurusan yang sesuai. Pada tahap ini digunakan metrik evaluasi berupa akurasi, precision, recall, dan F-1 score, yang diperoleh dari confusion matrix hasil pengujian. Metrik-metrik ini sangat penting karena memberikan gambaran menyeluruh terhadap kemampuan model dalam mengenali dan membedakan tiap kelas target.

Tabel 5. Confusion Matrix Support Vector Machine (SVM)

Kelas	TP	FP	FN	Pesisi (%)	Recall (%)	F1-Score
TKR	20	2	3	90.91	86.96	0.889
TSM	19	3	1	86.36	95.00	0.904
TKJ	23	2	2	92.00	95.83	0.938
LP	5	3	1	62.50	83.33	0.714

Akurasi menunjukkan proporsi data yang diklasifikasikan dengan benar dari total keseluruhan data pengujian. Menghasilkan nilai akurasi sebagai berikut :

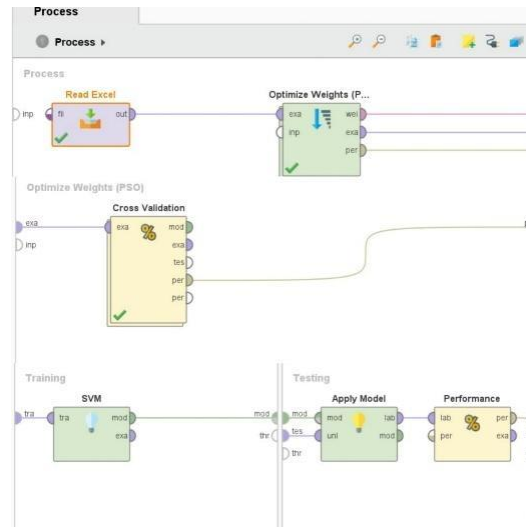
$$Akurasi = \frac{20 + 19 + 23 + 5}{84} \times 100\% = 79,76\%$$

Dari hasil evaluasi yang ditunjukkan pada table 5, dengan presisi dan recall tinggi pada kelas TRK, TSM, dan TKJ, namun performa untuk kelas minoritas LP masih rendah. Kondisi ini menunjukkan bahwa SVM belum mampu mengenali kelas LP dengan baik karena distribusi datanya tidak seimbang. Oleh sebab itu, perlu dilakukan proses optimasi parameter menggunakan Particle Swarm Optimization (PSO).

3.2 Hasil Optimasi PSO

Optimasi parameter Support Vector Machine (SVM) dilakukan menggunakan algoritma Particle Swarm Optimization (PSO) untuk memperoleh nilai parameter terbaik dari kernel RBF, yaitu C (cost) dan Gamma (γ), agar model mencapai akurasi tertinggi.

Support Vector Machine sebagai Sistem Pendukung Keputusan Pemilihan Jurusan Berbasis Website pada SMK NU Hasyim Asy'ari Tarub



Gambar 4. Penerapan Particle Swarm Optimization (PSO) pada algoritma Support Vector Machine SVM)

Gambar diatas menunjukkan proses integrasi algoritma PSO dalam optimasi parameter SVM pada RapidMiner. PSO digunakan melalui operator optimize weight (PSO) yang mengatur proses optimasi terhadap parameter input, dengan validasi model dilakukan melalui Cross Validation. Model SVM dilatih dan diuji pada bagian training dan testing didalam Cross Validation.

Pada tahap awal, seluruh partikel diinisialisasi terlebih dahulu, di mana setiap partikel merepresentasikan kandidat pasangan parameter (C , γ). Parameter konfigurasi PSO yang digunakan dalam penelitian ini meliputi: jumlah iterasi sebesar 30, nilai konstanta kognitif $c_1 = 1.0$, konstanta sosial $c_2 = 1.0$, serta nilai inersia w yang bersifat adaptif dengan rentang 0,4 hingga 0,9. Ukuran populasi ditetapkan sebanyak 20 partikel. Parameter-parameter ini mengatur arah, laju, serta stabilitas pergerakan partikel selama proses pencarian solusi optimal.

Selain itu, ruang pencarian (search space) untuk parameter SVM ditetapkan sebagai $C \in [0.1, 100]$ dan $\gamma \in [0.001, 1]$. Rentang ini dipilih untuk memberikan fleksibilitas yang memadai bagi PSO dalam mengeksplorasi kombinasi parameter kernel RBF yang umum digunakan.

Setelah inisialisasi selesai, PSO mulai melakukan pembaruan kecepatan dan posisi seluruh partikel. Mekanisme pergerakan partikel mengikuti rumus umum PSO, yaitu:

$$V_{new} = w \cdot V_{old} + c_1 r_1 (pBest - x) + c_2 r_2 (gBest - x) \quad X_{new} = X_{old} + V_{new}$$

Rumus tersebut memungkinkan partikel untuk menyesuaikan pergerakannya berdasarkan pengalaman terbaiknya sendiri (pBest) dan pengalaman terbaik dari keseluruhan partikel (gBest), sehingga proses konvergensi dapat berlangsung lebih cepat dan terarah. Pada contoh perhitungan yang ditampilkan dalam tabel, posisi partikel dihitung menggunakan nilai awal seperti

$$V_{old} = [0.1, 0.2, -0.1, 0.3, 0.05],$$

$$x = [82, 70, 76, 59, 63.64],$$

$$pBest = x,$$

$$gBest = [94, 95, 94, 95, 84.09].$$

Karena pBest sama dengan posisi awal, maka pengaruh terbesar pada pembaruan kecepatan berasal dari komponen $gBest - x$.

Setiap kali posisi partikel diperbarui, nilai baru tersebut langsung digunakan sebagai parameter untuk melatih SVM pada iterasi tersebut. Model kemudian dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score untuk menentukan nilai fitness. Nilai fitness terbaik akan disimpan sebagai gBest, dan seluruh proses pembaruan berlangsung secara berulang hingga seluruh iterasi selesai. Proses iteratif inilah yang memungkinkan PSO mengeksplorasi ruang solusi secara efektif dan menemukan kombinasi parameter SVM paling optimal (Bumbungan, 2023).

Hasil akhir dari proses optimasi menunjukkan peningkatan performa yang sangat signifikan. Model SVM yang telah dioptimasi mampu mencapai akurasi sebesar 97,20%, dengan perhitungan sebagai berikut:

$$Akurasi = \frac{74 + 66 + 80 + 24}{251} \times 100\% = 97,20\%$$

Tabel 6. Confusion Matrix Support Vector Machine (SVM) berbasis Particle Swarm Optimization (PSO)

	True TKR	True TSM	True TKJ	True LP	Class Precision
Pred. TKR	74	2	0	0	97.37%
Pred. TSM	2	66	0	1	94.29%
Pred. TKJ	0	0	80	0	100%
Pred. LP	1	0	0	24	96%
Class Recall	96.10%	97.06%	100%	92.31%	

Selain peningkatan akurasi, hasil evaluasi setelah optimasi juga memperlihatkan peningkatan presisi, recall, dan F1-score pada seluruh kelas, termasuk kelas minoritas LP yang sebelumnya sulit dikenali. Misalnya, kelas TKR mencapai F1-score 96,73%, kelas TSM 95,65%, kelas TKJ 100%, dan kelas LP 94,16%, yang menunjukkan performa klasifikasi yang jauh lebih stabil dan merata.

Secara keseluruhan, proses optimasi menggunakan PSO berhasil meningkatkan kualitas model SVM secara signifikan melalui pencarian parameter terbaik secara iteratif dan terarah, sehingga menghasilkan model klasifikasi yang lebih akurat, konsisten, dan mampu mengenali seluruh kelas baik mayoritas maupun minoritas secara lebih adil.

Peningkatan performa model setelah proses optimasi menggunakan PSO terjadi karena penyesuaian parameter SVM yang menjadi jauh lebih sesuai dengan pola distribusi data. Nilai parameter C dan Gamma hasil optimasi mampu menghasilkan margin keputusan yang lebih seimbang antara kemampuan generalisasi dan ketepatan pemisahan antar kelas. Sebelum optimasi, model SVM cenderung lebih sensitif terhadap kelas mayoritas sehingga kelas minoritas, seperti LP, sering salah terklasifikasi. Setelah PSO menemukan kombinasi parameter optimal, model dapat membentuk batas keputusan yang lebih adaptif sehingga pola data pada keempat jurusan dapat dipetakan secara lebih jelas.

Analisis bobot fitur (feature importance) juga menunjukkan perubahan signifikan setelah optimasi parameter menggunakan PSO. Evaluasi dilakukan menggunakan metode *permutation importance*, di mana setiap fitur diacak secara terpisah untuk mengukur seberapa besar penurunan akurasi yang terjadi. Semakin besar penurunan akurasi, semakin penting peran fitur tersebut dalam proses klasifikasi. Hasil analisis bobot fitur setelah optimasi ditunjukkan pada Tabel berikut:

Tabel 6. Bobot Fitur (Permutation Importance) Setelah Optimasi PSO.

Atribut	weight
IPA	0,9
MTK	0,4
B.IND	0,681
B.ING	0,632
Peminatan	0,4

Hasil ini memperlihatkan bahwa atribut IPA memiliki kontribusi paling dominan (weight = 0,90), diikuti oleh Bahasa Indonesia dan Bahasa Inggris. Peminatan juga menunjukkan bobot yang cukup penting. Pola ini menunjukkan bahwa PSO berhasil mengatur atribusi fitur secara lebih proporsional, sehingga fitur-fitur yang benar-benar relevan terhadap pemilihan jurusan memperoleh pengaruh lebih besar dalam penentuan hyperplane SVM.

Sebelum optimasi, model cenderung terlalu bergantung pada nilai MTK dan kurang sensitif terhadap kelas minoritas seperti LP. Namun setelah PSO menemukan parameter optimal C dan γ , bobot fitur menjadi lebih stabil dan lebih selaras dengan struktur data yang sebenarnya. Hal ini terbukti meningkatkan kemampuan model dalam mengenali pola pada keempat jurusan, termasuk kelas LP yang sebelumnya sering salah klasifikasi.

Peningkatan performa model setelah optimasi memiliki implikasi langsung terhadap efektivitas sistem rekomendasi penjurusan di SMK. Dengan akurasi yang lebih tinggi serta metrik evaluasi yang lebih stabil pada seluruh kelas, model SVM-PSO memberikan prediksi yang lebih reliabel dalam menentukan jurusan yang sesuai bagi siswa. Hal ini penting karena proses penjurusan di SMK tidak hanya menuntut kesesuaian

nilai akademik, tetapi juga mempertimbangkan kecocokan minat siswa dengan bidang keahlian tertentu. Setelah optimasi, model menunjukkan kemampuan yang lebih baik dalam menangkap pola hubungan antara nilai mata pelajaran dan skor minat, sehingga rekomendasi yang dihasilkan menjadi lebih akurat dan tepat sasaran.

Dalam konteks sekolah, interpretasi ini berarti bahwa sistem dapat membantu guru BK dan pihak sekolah dalam membuat keputusan penjurusan yang lebih objektif, mengurangi potensi bias maupun kesalahan penentuan jurusan. Terlebih lagi, peningkatan performa pada kelas minoritas seperti jurusan LP menunjukkan bahwa model tidak hanya bekerja baik pada jurusan populer, tetapi juga adil dalam memberikan prediksi untuk seluruh siswa. Dengan demikian, sistem rekomendasi yang dibangun bukan hanya sekadar alat bantu teknis, tetapi dapat menjadi komponen penting dalam mendukung perencanaan pendidikan yang lebih terstruktur dan sesuai dengan karakteristik masing-masing siswa.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa integrasi Support Vector Machine (SVM) dengan Particle Swarm Optimization (PSO) mampu meningkatkan akurasi klasifikasi pemilihan jurusan siswa SMK secara signifikan. Model SVM awal menghasilkan akurasi 79,76%, sedangkan model SVM-PSO meningkat menjadi 97,20%. Peningkatan ini mengindikasikan bahwa proses optimasi parameter C dan Gamma melalui PSO efektif dalam memperbaiki margin pemisahan dan mengatasi ketidakseimbangan kelas. Selain itu, nilai precision, recall, dan F1-score mengalami peningkatan konsisten pada seluruh jurusan, termasuk jurusan dengan jumlah data minoritas.

Secara keseluruhan, hasil penelitian menegaskan bahwa SVM-PSO merupakan pendekatan yang akurat, stabil, dan dapat diandalkan sebagai Sistem Pendukung Keputusan dalam proses penjurusan siswa. Model ini mampu memberikan rekomendasi berbasis data yang lebih objektif dan sesuai dengan karakteristik siswa, sehingga dapat mendukung sekolah dalam pengambilan keputusan penempatan jurusan yang lebih tepat dan efektif.

DAFTAR PUSTAKA

- A Man Kumar (2018) *C dan Gamma dalam SVM*. A / oleh A Man Kumar / Medium. Available at: <https://medium.com/@myselfaman12345/c-and-gamma-in-svm-e6cee48626be> (Accessed: June 2, 2025).
- Afifudin, M., Junaedi, A., Nugroho, A., Fithriyah, I., Pembangunan Nasional Veteran Jawa Timur, U., Rungkut Madya No, J., Anyar, G., & Kesehatan Jiwa RSUD Soetomo, I. (2024). GWO-SVM: AN APPROACH TO IMPROVING SVM PERFORMANCE USING GREY WOLF OPTIMIZER IN INTELLECTUAL DISABILITY CLASSIFICATION. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3S1), 2830–7062. <https://doi.org/10.23960/JITET.V12I3S1.5359>

- Badan Pusat Statistik (2024) *Pengangguran Terbuka Menurut Pendidikan Tertinggi yang Ditamatkan 1986 - 2024 - Tabel Statistik - Badan Pusat Statistik Indonesia*. Available at: <https://www.bps.go.id/id/statistics-table/1/OTcyIzE=/pengangguran-terbuka-menurut-pendidikan-tertinggi-yang-ditamatkan-1986---2024.html> (Accessed: January 7, 2025).
- Batista, G. *et al.* (2019) "Illustration of how PSO-SVM hybrid training works | Download Scientific Diagram," *Multimedia Tools and Applications*, 78. Available at: https://www.researchgate.net/figure/Illustration-of-how-PSO-SVM-hybrid-training-works_fig4_334664872 (Accessed: November 16, 2025).
- Bumbungan, S. (2023) "Penerapan Particle Swarm Optimization (PSO) dalam Pemilihan Parameter Secara Otomatis pada Support Vector Machine (SVM) untuk Prediksi Kelulusan Mahasiswa Politeknik Amamapare Timika," *Jurnal Teknik AMATA*, 04(1).
- Ernawati, S. *et al.* (2021) "Comparative analysis of naïve bayes and knn on prediction of forex price movements for gbp/usd currency at time frame daily," *Journal of Physics: Conference Series*, 1810(1), p. 012012. Available at: <https://doi.org/10.1088/1742-6596/1810/1/012012>.
- Handayanto, A. *et al.* (2019) *Analisis dan Penerapan Algoritma Support Vector Machine (SVM) dalam Data Mining untuk Menunjang Strategi Promosi (Analysis and Application of Algorithm Support Vector Machine (SVM) in Data Mining to Support Promotional Strategies)*.
- Hasfi, A. (2016) "Klasifikasi Kinerja Akademik Mahasiswa Menggunakan Metode Pso-Svm."
- Jainvidip (2024) *Understanding Support Vector Machines (SVMs) | by Jainvidip | Medium, Medium*. Available at: <https://medium.com/@jainvidip/understanding-support-vector-machines-svms-1f7c78bad934> (Accessed: January 19, 2025).
- MADE AGUS, D. (2024) "PERANCANGAN MESIN KLASIFIKASI MENGGUNAKAN PARTICLE SWARM OPTIMIZATION."
- Manakkadu, S., & Dutta, S. (2024). Ant Colony Optimization based Support Vector Machine for Improved Classification of Unbalanced Datasets. *Procedia Computer Science*, 237, 586–593. <https://doi.org/10.1016/J.PROCS.2024.05.143>
- Maulanii, A.P. (2024) *SISTEM PENDUKUNG KEPUTUSAN PEMILIHAN JURUSAN SEKOLAH MENENGAH KEJURUAN MENGGUNAKAN METODE SIMPLE ADDITIVE WEIGHTING (SAW) DI SMKS BHAKTI PRAJA TALANG*.
- Muis, I.A. and Affandes, M. (2015) "Penerapan Metode Support Vector Machine (SVM) Menggunakan Kernel Radial Basis Function (RBF) Pada Klasifikasi Tweet," *Jurnal Sains, Teknologi dan Industri*, 12(2), pp. 189–197. Available at: <http://ejournal.uin-suska.ac.id/index.php/sitekin>.

- Pendidikan, K. and Teknologi Tahun, dan (no date) "Panduan Pemilihan Mata Pelajaran Pilihan di SMA/MA/Bentuk Lain yang Sederajat."
- Rahma Kurniawan (2023) *SISTEM PENDUKUNG KEPUTUSAN (Desicion Support System)*, Universitas Riau. Available at: <https://rahmadkurniawan.staff.unri.ac.id/files/2023/09/PERTEMUAN-2.pdf> (Accessed: January 25, 2025).
- Rokhmah, Z. *et al.* (2021) *Sistem Pendukung Keputusan Penentuan Jurusan Dengan Menggunakan Metode SAW Di SMK Negeri 1 Merangin.*
- Saprudin, S. (Saprudin) (2017) "Penerapan Particle Swarm Optimization (PSO) untuk Klasifikasi dan Analisis Kredit dengan Menggunakan Algoritma C4.5," *Jurnal Informatika Universitas Pamulang*, 2(4), pp. 214–219. Available at: <https://doi.org/10.32493/INFORMATIKA.V2I4.1488>.
- Schunk, D.H. and Zimmerman, B.J. (2012) "Motivation and self-regulated learning: Theory, research, and applications," *Motivation and Self-Regulated Learning: Theory, Research, and Applications*, pp. 1–417. Available at: <https://doi.org/10.4324/9780203831076>.
- Sidharth (2022) *Kernel RBF dalam SVM: Panduan Lengkap - PyCodeMates*, PyCodeMates. Available at: <https://www.pycodemates.com/2022/10/the-rbf-kernel-in-svm-complete-guide.html> (Accessed: January 19, 2025).
- Zainuddin, Moh. (2018) "METODE KLASIFIKASI BERBASIS PARTICLE SWARM OPTIMIZATION (PSO) UNTUK PREDIKSI KELULUSAN TEPAT WAKTU MAHASISWA," *Jurnal Ilmiah Teknologi Informasi Asia*, 13(1), p. 1. Available at: <https://doi.org/10.32815/JITIKA.V13I1.247>.
- Zhang, S. *et al.* (2022) "Identification of Diagnostic Markers for Breast Cancer Based on Differential Gene Expression and Pathway Network," *Frontiers in Cell and Developmental Biology*, 9, p. 811585. Available at: <https://doi.org/10.3389/FCELL.2021.811585/BIBTEX>.