

Implementasi dan Analisis Perbandingan *Support Vector Machine* dan *Random Forest* untuk Mengklasifikasikan Gaya Belajar Siswa (Studi Kasus: SMPN 1 Rancabungur)

Muhammad Ghiyats Akbar Darmawan¹, Dola Irwanto²

^{1,2}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, Tangerang Selatan, Indonesia
Email: ¹ghiyatsmhs12@gmail.com, ²dosen01115@unpam.ac.id

Abstrak

Pemetaan gaya belajar peserta didik berdasarkan model Visual, Auditorial, dan Kinestetik (VAK) merupakan instrumen krusial dalam mendukung pembelajaran terdiferensiasi di tingkat sekolah menengah pertama. Namun, proses identifikasi konvensional menggunakan kuesioner fisik dan perhitungan manual membutuhkan waktu yang relatif lama serta rentan terhadap inefisiensi administratif. Penelitian ini bertujuan untuk mengimplementasikan serta menganalisis perbandingan performa algoritma *Support Vector Machine* dan *Random Forest* dalam mengklasifikasikan gaya belajar siswa secara otomatis. Metodologi penelitian dirancang berbasis kerangka kerja *Cross-Industry Standard Process for Data Mining (CRISP-DM)* untuk pemodelan komputasi cerdas, didukung metode *Waterfall* dalam merancang sistem berbasis web terintegrasi menggunakan arsitektur *Flask API*. Dataset diperoleh dari respons 42 butir kuesioner model VAK yang diisi oleh siswa SMPN 1 Rancabungur, dilanjutkan dengan prapemrosesan data yang mencakup pemetaan skala Likert, penjumlahan skor kualitatif, serta pembagian dataset (80% data latih dan 20% data uji). Evaluasi performa model dilakukan melalui pengujian *Confusion Matrix* berbasis metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil pengujian menunjukkan bahwa kedua algoritma mampu mengenali pola preferensi belajar secara efektif. Algoritma *Support Vector Machine* unggul dengan tingkat kestabilan dan akurasi yang lebih tinggi dibandingkan *Random Forest* pada karakteristik dataset kuesioner yang bervariasi. Penelitian ini menyimpulkan bahwa pengintegrasian algoritma klasifikasi terbaik ke dalam sistem berbasis web terbukti mampu memangkas durasi rekapitulasi data secara signifikan, sekaligus memberikan rekomendasi prediktif yang presisi bagi tenaga pendidik untuk menyelaraskan strategi pembelajaran sesuai kebutuhan individual siswa.

Kata kunci: *CRISP-DM, Gaya Belajar VAK, Klasifikasi Machine Learning, Random Forest, Support Vector Machine.*

Abstract

Mapping student learning styles based on the Visual, Auditory, and Kinesthetic (VAK) model constitutes a crucial instrument for supporting differentiated instruction in junior high schools. However, conventional identification processes utilizing paper questionnaires and manual score calculation are time-consuming and prone to administrative inefficiencies. This study aims to implement and comparatively analyze the performance of *Support Vector Machine (SVM)* and *Random Forest* algorithms in automatically classifying student learning styles. The research methodology was structured upon the *Cross-Industry Standard Process for Data Mining (CRISP-DM)* framework for computational modeling, supported by the *Waterfall* model to build an integrated web-based system via *Flask API* architectures. The dataset was collected from 42 VAK questionnaire items answered by students at SMPN 1 Rancabungur, followed by data preprocessing steps including Likert scale mapping, qualitative score summation, and dataset splitting (80% training data and 20% testing data). Model performance was evaluated using a *Confusion Matrix* across *Accuracy*, *Precision*, *Recall*, and *F1-Score* metrics. The experimental results demonstrate that both algorithms effectively recognize learning preference patterns. The *Support Vector Machine* algorithm outperformed *Random Forest*, achieving higher accuracy and prediction stability on the multidimensional questionnaire dataset. This study concludes that integrating the optimal classification algorithm into a web platform significantly accelerates data processing time while delivering precise predictive insights to assist educators in tailoring instructional strategies to students' individual learning needs.

Keywords: *CRISP-DM, Machine Learning Classification, Random Forest, Support Vector Machine, VAK Learning Style.*

1. PENDAHULUAN

Seiring dengan perkembangan zaman, dimana teknologi bukan sekedar fasilitas mewah melainkan kebutuhan dasar. Perkembangan perangkat lunak dan internet telah memotong banyak batasan, membuat hal-hal yang dulunya rumit menjadi sangat praktis. Salah satu sektor yang merasakan dampak paling positif dari transformasi ini adalah dunia pendidikan. Peran teknologi di sekolah kini bukan sekedar menggantikan buku dengan layar, tapi sudah masuk ke tahap bagaimana sistem komputasi bisa membantu guru dan institusi untuk memahami siswa dengan lebih baik (Belva Saskia Permana dkk., 2024). Pemahaman terhadap gaya belajar peserta didik menjadi aspek vital dalam upaya personalisasi ini. Gaya belajar dapat didefinisikan sebagai metode khas seseorang dalam menerima, mengolah, dan menginterpretasi data. Model VAK (Visual, Auditorial, Kinestetik) adalah salah satu kategori gaya belajar yang paling umum digunakan. Peserta didik yang proses belajarnya disesuaikan dengan gaya belajar mereka cenderung meraih pemahaman, partisipasi, dan hasil akademik yang lebih optimal.

Namun, dalam konteks pendidikan di Indonesia, di tingkat sekolah menengah pertama, guru-guru kita saat ini menghadapi tantangan yang lumayan berat. Kurikulum Nasional menuntut mereka untuk menerapkan pembelajaran yang berpusat pada siswa, yang artinya guru harus tahu gaya belajar tiap-tiap anak apakah mereka Visual, Auditorial, atau Kinestetik. Masalahnya, menyebarkan kuesioner kertas dan menghitung skor puluhan hingga ratusan siswa secara manual itu sangat menyita waktu. Guru yang seharusnya fokus menyiapkan materi yang kreatif malah habis waktunya untuk urusan administratif (I Kadek Nicko Ananda dkk., 2024).

Perkembangan pesat di bidang kecerdasan buatan dan ilmu data menawarkan solusi potensial untuk tantangan ini. Teknologi *Machine Learning* terbukti bisa memangkas waktu analisis dari hitungan jam menjadi sekian detik saja. Ini menunjukkan bahwa pemodelan karakteristik belajar secara otomatis sekarang sudah jadi komponen wajib dalam sistem pendidikan berbasis teknologi. Dengan memasukkan data jawaban kuesioner ke dalam sistem, komputer bisa langsung memprediksi gaya belajar siswa secara akurat (Agung Wicakono dkk., 2026).

Dua kandidat terkuat untuk tugas ini adalah algoritma *Support Vector Machine* dan algoritma *Random Forest*. Di satu sisi, algoritma *Support Vector Machine* punya reputasi luar biasa dalam mencari batas klasifikasi yang paling jelas (Yustanti & Rochmawati, 2022). Meskipun kedua algoritma tersebut sama-sama kuat, keduanya memiliki karakteristik dan pendekatan matematis yang berbeda. Belum banyak penelitian yang secara spesifik membandingkan efektivitas kedua algoritma ini untuk kasus klasifikasi gaya belajar siswa di lingkungan pendidikan Indonesia. Oleh karena itu, penelitian ini penting untuk dilakukan guna mengetahui algoritma mana yang memberikan performa terbaik untuk dataset gaya belajar siswa pada studi kasus di SMPN 1 RANCABUNGUR.

2. METODE PENELITIAN

Metode penelitian ini mencakup tahapan pengumpulan data kuesioner gaya belajar siswa, pengolahan dan persiapan data, penerapan algoritma *Support Vector Machine* dan *Random Forest*, serta pengujian untuk membandingkan kinerja kedua algoritma. Hasil pengolahan tersebut kemudian diterapkan pada sistem berbasis website untuk menghasilkan klasifikasi gaya belajar siswa dan menentukan algoritma dengan performa terbaik.

2.1. Teknik Pengumpulan Data

1. Studi Literatur

Tahap awal ini melibatkan pengumpulan informasi dan tinjauan pustaka dari berbagai sumber ilmiah seperti jurnal, prosiding konferensi, dan buku teks. Fokus studi literatur adalah pada konsep gaya belajar (khususnya model VAK), teori dasar algoritma *Support Vector Machine* dan *Random Forest*, serta penelitian-penelitian sebelumnya yang relevan.

2. Kuesioner

Menjadi sumber data utama penelitian. Kuesioner ini disebarakan kepada siswa di SMPN 1 Rancabungur untuk merekam respons kebiasaan belajar mereka, yang nantinya akan dijadikan dataset untuk melatih algoritma *Machine Learning*.

3. Wawancara dan Observasi

Melakukan diskusi dengan pihak guru atau wali kelas di SMPN 1 Rancabungur, sekaligus mengamati langsung bagaimana proses pendataan profil siswa berjalan saat ini untuk menggali kebutuhan sistem.

2.2. Kerangka Kerja Penelitian

Studi ini menggunakan metode CRISP-DM karena fokusnya adalah membandingkan dua algoritma klasifikasi yang cukup kompleks. Random Forest dan Support Vector Machine. Data kuesioner skala Likert sering mengalami masalah, seperti data tidak lengkap atau distribusi kelas yang tidak seimbang. Sebelum masuk ke tahap pemodelan, CRISP-DM memberikan petunjuk langkah demi langkah yang jelas untuk melakukan proses prapemrosesan data menggunakan Python. Kerangka ini memungkinkan proses perbandingan Random Forest dan SVM yang lebih objektif (Givari dkk., 2022).

Metode CRISP-DM (Cross-Industry Standard Process for Data Mining) adalah kerangka kerja data mining yang digunakan untuk mengelola proses analisis data secara terstruktur melalui tahapan yang saling terkait, mulai dari pemahaman tentang tujuan bisnis hingga penerapan hasil analisis (Shedriko & Firdaus, 2026).

Dalam penelitian Indonesia, CRISP-DM dijelaskan sebagai model yang membagi siklus proyek menjadi enam tahap utama: pemahaman bisnis, pemahaman data, persiapan data, modeling, evaluasi, dan penyebaran. Fase-fase ini berulang sehingga memungkinkan perubahan pada setiap tahap sesuai dengan kebutuhan analisis dan konteks masalah. Metode ini memastikan bahwa proses pengolahan data tidak hanya berfokus pada teknik tetapi juga pada tujuan bisnis atau penelitian (Saputra dkk., 2024). Alasan menggunakan metode ini karena memberikan alur kerja yang jelas dan sistematis untuk mengolah data, terutama untuk menangani data kuesioner yang seringkali tidak lengkap atau tidak seimbang (Putri Cahyani & Lufty Abdillah, 2024).

Penelitian ini menggunakan metode Cross-Industry Standard Process for Data Mining (CRISP-DM) untuk merancang, memproses, dan memodelkan data kuesioner yang telah dikumpulkan. Metode ini dipilih karena memberikan kerangka kerja yang sangat terstruktur, iteratif, dan terstandarisasi untuk proyek berbasis Data Science dan Machine Learning, yang memastikan perbandingan performa algoritma dilakukan secara objektif. Penelitian yang didasarkan pada CRISP-DM mencakup enam proses utama:

1. Pemahaman Bisnis (Business Understanding)

Menganalisis kebutuhan di Sekolah terkait urgensi pemetaan gaya belajar siswa (Visual, Auditori, Kinestetik) untuk membantu guru menyesuaikan metode pengajaran.

2. Pemahaman Data (Data Understanding)

Mengumpulkan data mentah kuesioner gaya belajar siswa Sekolah, kemudian mengenali karakteristik sebaran jawaban untuk mendeteksi adanya anomali data.

3. Persiapan Data (Data Preparation)

Melakukan pembersihan data, penanganan nilai yang hilang, serta pembagian dataset menjadi data latih dan data uji menggunakan *library Scikit-Learn* pada bahasa pemrograman Python.

4. Pemodelan (Modeling)

Prapemrosesan dasar komputasi cerdas, di mana penulis mulai menggunakan dan melatih dua algoritma klasifikasi, *Support Vector Machine* dan *Random Forest*, dengan data pelatihan yang telah disiapkan sebelumnya.

5. Evaluasi (Evaluation)

Menguji kedua model menggunakan Confusion Matrix untuk membandingkan nilai akurasi, presisi, dan recall guna menentukan algoritma mana yang paling tepat untuk mengklasifikasikan gaya belajar siswa.

6. Penerapan (Deployment)

Menyiapkan model Machine Learning terbaik dalam format yang siap diintegrasikan dengan sistem antarmuka berbasis web.

2.3. Model Pengembangan Sistem

Metode Waterfall, juga dikenal sebagai model air terjun, adalah model pengembangan perangkat lunak yang menggunakan pendekatan sekuensial linear dan sistematis. Metode ini disebut model siklus hidup klasik, dan implementasinya direncanakan secara bertahap. Metode yang terstruktur ini mewajibkan pengembang untuk menyelesaikan kemajuan sistem pada satu tingkat sebelum melanjutkan ke tahapan pembuatan program. Salah satu keunggulan utama penggunaan metode Waterfall dalam pengembangan sistem informasi adalah bahwa sistem atau perangkat lunak yang dihasilkan akan memiliki kualitas yang sangat baik karena seluruh implementasi dilakukan dan dipersiapkan secara bertahap (Apriyani dkk., 2025).

Pada metode Waterfall, proses pengembangan dilakukan secara berurutan. Ini biasanya dimulai dengan perencanaan atau analisis, diikuti dengan desain, pemrograman (implementasi), pengujian, dan akhirnya tahap akhir, yang mencakup pengoperasian dan pemeliharaan. Pada tahap analisis, pengembang mencari informasi tentang sistem dengan berbagai teknik pengumpulan data. Ini dilakukan agar kebutuhan program dapat dijelaskan dengan jelas. Setelah spesifikasi diputuskan, proses berlanjut ke tahap perancangan atau desain dengan menggunakan alat pemodelan sistem. Sebelum sistem diuji secara keseluruhan, rangkaian proses linier ini dirancang sedemikian rupa agar setiap fase penting selesai dan terkunci dengan baik (Achlisson dkk., 2025).

Untuk merancang dan membangun purwarupa antarmuka website, penelitian ini menggunakan model *Waterfall*, dengan tahapan sebagai berikut:

1. Analisis Kebutuhan
Menentukan spesifikasi sistem, perangkat keras, dan perangkat lunak yang dibutuhkan (seperti XAMPP, Python, dan Composer).
2. Desain Sistem
Merancang alur logika aplikasi agar system dan berfungsi secara optimal.
3. Implementasi
Menuliskan baris kode (coding) antarmuka sistem menggunakan kerangka kerja PHP dan menjembatani *Machine Learning* melalui API Flask.
4. Pengujian
Melakukan pengujian fungsionalitas sistem menggunakan metode *Black Box Testing* untuk memastikan seluruh fitur berjalan tanpa kesalahan atau bug.

2.4. Evaluasi Performa Model

Performa klasifikasi dievaluasi menggunakan *Confusion Matrix* yang menghitung nilai *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Metrik pengujian yang digunakan meliputi:


1. Accuracy
$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$
2. Precision
$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$
3. Recall
$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$
4. F1-Score
$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Hasil pengujian model klasifikasi menggunakan algoritma Support Vector Machine dan Random Forest terhadap kumpulan data hasil kuesioner gaya belajar siswa dijelaskan dalam bab ini. Pengujian dilakukan dengan menjalankan kedua algoritma secara bersamaan setelah kumpulan data diunggah ke

dalam sistem. Setelah itu, dilakukan analisis perbandingan performa berdasarkan beberapa metrik evaluasi.

3.1. Perbandingan Nilai Akurasi dan F1-Score



Gambar 1. Nilai Akurasi Perbandingan

Gambar ini menampilkan perbandingan performa kedua algoritma berdasarkan nilai akurasi dan F1-score macro setelah proses klasifikasi dilakukan. Dari hasil pengujian, algoritma *Support Vector Machine* memperoleh nilai akurasi sebesar 96,15%, sedangkan *Random Forest* memperoleh 91,61%. Pada pengukuran F1-score macro, *Support Vector Machine* menghasilkan nilai 95,96%, sementara *Random Forest* memperoleh 91,16%. Berdasarkan hasil tersebut, dapat dilihat bahwa algoritma *Support Vector Machine* memberikan hasil yang lebih baik dibandingkan *Random Forest* dalam klasifikasi gaya belajar siswa pada dataset yang digunakan dalam penelitian ini.


3.2. Classification Report

CLASSIFICATION REPORT COMPARISON									
SUPPORT VECTOR MACHINE (SVM)					RANDOM FOREST (RF)				
KELAS	PRECISION	RECALL	F1-SCORE	SUPPORT	KELAS	PRECISION	RECALL	F1-SCORE	SUPPORT
Visual	94.08%	98.62%	96.30%	145	Visual	91.84%	93.10%	92.47%	145
Auditory	97.87%	94.85%	96.34%	97	Auditory	88.35%	93.81%	91.00%	97
Kinesthetic	100.00%	90.91%	95.24%	44	Kinesthetic	100.00%	81.82%	90.00%	44
Accuracy	Global Accuracy Score			96.15%	Accuracy	Global Accuracy Score			91.61%

Gambar 2. Classification Report

Gambar ini menampilkan hasil *classification report* dari kedua algoritma yang digunakan pada tahap pengujian. Pada algoritma *Support Vector Machine*, kelas *Visual* memperoleh nilai *F1-score* sebesar 96,30%, kelas *Auditory* sebesar 96,34%, dan kelas *Kinesthetic* sebesar 95,24%. Sementara itu, pada algoritma *Random Forest*, kelas *Visual* memperoleh *F1-score* sebesar 92,47%, kelas *Auditory* sebesar 91,00%, dan kelas *Kinesthetic* sebesar 90,00%. Secara keseluruhan, nilai *precision*, *recall*, dan *F1-score* pada algoritma *Support Vector Machine* lebih tinggi dibandingkan *Random Forest*, sehingga dapat menunjukkan bahwa *Support Vector Machine* mampu memberikan hasil klasifikasi yang lebih baik pada setiap kategori gaya belajar siswa dalam penelitian ini.

3.3. Confusion Matrix



Gambar 3. Confusion Matrix

Gambar ini menampilkan confusion matrix yang digunakan untuk melihat jumlah prediksi benar dan kesalahan prediksi dari masing-masing algoritma pada setiap kelas. Pada algoritma *Support Vector Machine*, sebanyak 143 data Visual, 92 data Auditory, dan 40 data Kinesthetic berhasil diklasifikasikan dengan benar. Sementara itu, pada algoritma *Random Forest*, jumlah data yang berhasil diprediksi dengan benar yaitu 135 data Visual, 91 data Auditory, dan 36 data Kinesthetic. Berdasarkan hasil tersebut, terlihat bahwa algoritma *Support Vector Machine* menghasilkan jumlah prediksi yang lebih akurat dengan tingkat kesalahan klasifikasi yang lebih rendah dibandingkan *Random Forest*.

3.4. Perhitungan Evaluasi Model

Setelah pengujian, proses perhitungan manual digunakan untuk memastikan hasil evaluasi model yang dihasilkan sistem. Karena penelitian ini menggunakan klasifikasi multikelas, contoh perhitungan dilakukan pada kelas Visual, Auditori dan Kinestetik baik pada algoritma *Support Vector Machine* maupun *Random Forest*.

1. Perhitungan *Support Vector Machine*

a. Kelas Visual:

- Accuracy

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Accuracy = \frac{143 + 132}{143 + 132 + 9 + 2}$$

$$Accuracy = \frac{275}{286} = 0.9615$$

$$Accuracy = 96.15\%$$

- Precision:

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

$$Precision = \frac{143}{143 + 9}$$

$$Precision = \frac{143}{152} = 0.9408$$

$$Precision = 94.08\%$$

- Recall:

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

$$Recall = \frac{143}{143 + 2}$$

$$Recall = \frac{143}{145} = 0.9862$$

$$Recall = 98.62\%$$

- F1-Score:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

$$F1 = 2 \times \frac{0.9408 \times 0.9862}{0.9408 + 0.9862}$$

$$F1 = 0.9630$$

$$F1 = 96.30\%$$

- b. Kelas Auditori:

- Precision:

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

$$Precision = \frac{92}{92 + 2}$$

$$Precision = \frac{92}{94} = 0.9787$$

$$Precision = 97.87\%$$

- Recall:

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

$$Recall = \frac{92}{92 + 5}$$

$$Recall = \frac{92}{97} = 0.9485$$

$$Recall = 94.85\%$$

- F1-Score:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

$$F1 = 2 \times \frac{0.9787 \times 0.9485}{0.9787 + 0.9485}$$

$$F1 = 0.9634$$

$$F1 = 96.34\%$$

- c. Kelas Kinestetik

- Precision:

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

$$Precision = \frac{40}{40 + 0}$$

$$Precision = \frac{40}{40} = 1.0000$$

$$Precision = 100\%$$

- Recall:

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

$$Recall = \frac{40}{40 + 4}$$

$$Recall = \frac{40}{44} = 0.9091$$

$$Recall = 90.91\%$$

- F1-Score:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

$$F1 = 2 \times \frac{1.0000 \times 0.9091}{1.0000 + 0.9091}$$

$$F1 = 0.9524$$

$$F1 = 95.24\%$$

2. Perhitungan *Random Forest*

a. Kelas Visual:

- Precision:

$$Precision = \frac{135}{135 + 12}$$

$$Precision = \frac{135}{147} = 0.9184$$

$$Precision = 91.84\%$$

- Recall:

$$Recall = \frac{135}{135 + 10}$$

$$Recall = \frac{135}{145} = 0.9310$$

$$Recall = 93.10\%$$

- F1-Score:

$$F1 = 2 \times \frac{0.9184 \times 0.9310}{0.9184 + 0.9310}$$

$$F1 = 0.9247$$

$$F1 = 92.47\%$$

b. Kelau Auditori

- Precision:

$$Precision = \frac{91}{91 + 12}$$

$$Precision = \frac{91}{103} = 0.8835$$

$$Precision = 88.35\%$$

- Recall:

$$Recall = \frac{91}{91 + 6}$$

$$Recall = \frac{91}{97} = 0.9381$$

$$Recall = 93.81\%$$

- F1-Score:

$$F1 = 2 \times \frac{0.8835 \times 0.9381}{0.8835 + 0.9381}$$

$$F1 = 0.9100$$

$$F1 = 91.00\%$$

c. Kelas Kinestetik:

- Precision:

$$Precision = \frac{36}{36 + 0}$$

$$Precision = \frac{36}{36} = 1.0000$$

$$Precision = 100\%$$

- Recall:

$$Recall = \frac{36}{36 + 8}$$

$$\text{Recall} = \frac{36}{44} = 0.8182$$
$$\text{Recall} = 81.82\%$$

- F1-Score

$$F1 = 2 \times \frac{1.0000 \times 0.8182}{1.0000 + 0.8182}$$
$$F1 = 0.9000$$
$$F1 = 90.00\%$$

4. KESIMPULAN

Penelitian ini berhasil mengimplementasikan algoritma Support Vector Machine dan Random Forest ke dalam sistem berbasis website yang digunakan untuk melakukan klasifikasi gaya belajar siswa berdasarkan data hasil kuesioner yang terdiri dari 42 pertanyaan dengan kategori gaya belajar Visual, Auditory, dan Kinesthetic. Sistem yang dibangun dapat memproses dataset berformat CSV, menjalankan proses klasifikasi secara otomatis, serta menampilkan hasil klasifikasi secara langsung melalui antarmuka website.

Berdasarkan hasil pengujian model menggunakan metrik evaluasi Confusion Matrix yang meliputi Accuracy, Precision, Recall, dan F1-Score, kedua algoritma mampu melakukan proses klasifikasi dengan hasil yang baik. Hasil pengujian menunjukkan bahwa algoritma Support Vector Machine memperoleh nilai akurasi sebesar 96,15% dengan nilai Macro F1-Score sebesar 95,96%, sedangkan algoritma Random Forest memperoleh nilai akurasi sebesar 91,61% dengan Macro F1-Score sebesar 91,16%. Hasil tersebut menunjukkan bahwa terdapat perbedaan performa antara kedua algoritma dalam melakukan klasifikasi pada dataset yang digunakan dalam penelitian ini.

Berdasarkan hasil pengujian komparatif yang telah dilakukan, algoritma Support Vector Machine terbukti memiliki performa yang lebih baik dibandingkan Random Forest dalam proses klasifikasi gaya belajar siswa. Hal ini menunjukkan bahwa Support Vector Machine merupakan algoritma yang paling optimal pada penelitian ini dan dapat direkomendasikan untuk digunakan dalam proses klasifikasi gaya belajar siswa pada sistem yang dikembangkan.

DAFTAR PUSTAKA

- Ahlison, U., Santoso, J. T., Rozikin, K., & Diapoldo, F. (2025). *Analisis Model Implementasi Tracking Pengiriman Barang Menggunakan Waterfall dan Rapid Application Development*.
- Agung Wicakono, Zein Hani Pradana, Prasetyo Yuliantoro, & Hasri Wulan Nugraheni. (2026). Optimasi Artificial Neural Network Untuk Klasifikasi Gaya Belajar Mahasiswa Menggunakan Model Visual, Auditori, dan Kinestetik (VAK). *Jurnal Publikasi Teknik Informatika*, 5(1), 87–100. <https://doi.org/10.55606/jupti.v5i1.6311>.
- Apriyani, L., Sirait, H., & Situmorang, I. (2025). Sistem Informasi Manajemen Apotek Berbasis Web Menggunakan Metode Waterfall (Studi Kasus Apotek Mitha Pharma Pematangsiantar). 9(1).
- Belva Saskia Permana, Lutvia Ainun Hazizah, & Yusuf Tri Herlambang. (2024). Teknologi Pendidikan: Efektivitas Penggunaan Media Pembelajaran Berbasis Teknologi Di Era Digitalisasi. *Khatulistiwa: Jurnal Pendidikan dan Sosial Humaniora*, 4(1), 19–28. <https://doi.org/10.55606/khatulistiwa.v4i1.2702>
- Farida, L. N., & Bahri, S. (2024). Klasifikasi Gagal Jantung menggunakan Metode SVM (Support Vector Machine). *Komputika: Jurnal Sistem Komputer*, 13(2), 149–156. <https://doi.org/10.34010/komputika.v13i2.11330>
- Givari, M. R., Sulaeman, M. R., & Umaidah, Y. (2022). Perbandingan Algoritma SVM, Random Forest Dan XGBoost Untuk Penentuan Persetujuan Pengajuan Kredit. *NUANSA INFORMATIKA*, 16(1), 141–149. <https://doi.org/10.25134/nuansa.v16i1.5406>
- Hidayah, R. B., Latifah, K., & Herlambang, B. A. (2025). PREDIKSI GAYA BELAJAR MENGGUNAKAN ALGORITMA RANDOM FOREST DENGAN OPTIMASI

- HYPERPARAMETER TUNING BERBASIS WEB. *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, 10(2), 864–873. <https://doi.org/10.36341/rabit.v10i2.6393>
- I Kadek Nicko Ananda, Ni Putu Novita Puspa Dewi, Ni Wayan Marti, & Luh Joni Erawati Dewi. (2024). Klasifikasi Multilabel Pada Gaya Belajar Siswa Sekolah Dasar Menggunakan Algoritma Machine Learning. *Journal of Applied Computer Science and Technology*, 5(2), 144–154. <https://doi.org/10.52158/jacost.v5i2.940>
- Oktavia, T., Ula, M., & Razi, A. (2025). ANALISIS DATA MINING PERBANDINGAN ALGORITMA SUPPORT VEKTOR MACHINE DAN RANDOM FOREST PADA KLASIFIKASI SUBTIPE ANEMIA: Data Mining Analysis A Comparative Study of Support Vector Machine and Random Forest Algorithms in Anemia Subtype Classification. *Rabit : Jurnal Teknologi dan Sistem Informasi Univrab*, 10(2), 1405–1414. <https://doi.org/10.36341/rabit.v10i2.6565>
- Pranata, B. D., Mahdiyah, U., & Kasih, P. (2023). Pemodelan Gaya Belajar Siswa dengan Menggunakan Support Vector Machine. *Nusantara of Engineering (NOE)*, 6(2), 144–150. <https://doi.org/10.29407/noe.v6i2.20884>
- Putri Cahyani & Lufty Abdillah. (2024). Perbandingan Performa Algoritma Naïve Bayes, SVM dan Random Forest Studi Kasus Analisis Sentimen Pengguna Sosial Media X. *KALBISCIENTIA Jurnal Sains dan Teknologi*, 11(02), 12–21. <https://doi.org/10.53008/kalbiscientia.v11i02.3624>
- Saputra, D. B., Atina, V., & Nastiti, F. E. (2024). PENERAPAN MODEL CRISP-DM PADA PREDIKSI NASABAH KREDIT MENGGUNAKAN ALGORITMA RANDOM FOREST. *IDEALIS : InDonEsiA journal Information System*, 7(2), 240–247. <https://doi.org/10.36080/idealism.v7i2.3244>
- Shedriko, S., & Firdaus, M. (2026). Perbandingan Klasifikasi DT, RF, GB dan SVM Dalam Implementasi CRISP-DM Terhadap Kelulusan Mata Kuliah. *remik*, 10(1), 20–27. <https://doi.org/10.33395/remik.v10i1.15537>
- Suciati Rahayu Widyastuti. (2022). PENGEMBANGAN SKALA LIKERT UNTUK MENGUKUR SIKAP TERHADAP PENERAPAN PENILAIAN AUTENTIK SISWA SEKOLAH MENENGAH PERTAMA. *Jendela ASWAJA*, 3(02), 57–75. <https://doi.org/10.52188/ja.v3i02.393>
- Yustanti, W., & Rochmawati, N. (2022). Analisis Algoritma Klasifikasi untuk Memprediksi Karakteristik Mahasiswa pada Pembelajaran Daring. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 8(1), 57. <https://doi.org/10.26418/jp.v8i1.50452>