

Classification Of Student Depression Using Support Vector Machine Modelling and Backward Elimination

M. Zaeni Rohmat Abidin^{*1}, Afril Efan Pajri², Jauhara Rana Budiani³

¹²³Teknik Informatika, Universitas Nahdlatul Ulama Sunan Giri

¹mzaenirohmatabidin@gmail.com, ²afiril@unugiri.ac.id, ³jauahararanaab@gmail.com

Article Info

Article history:

Received 2026-01-07

Revised 2026-01-26

Accepted 2026-01-30

Keyword:

*Backward Elimination,
Feature Selection,
Machine Learning,
Student Depression,
Support Vector Machine.*

ABSTRACT

Depression among university students has become a serious mental health concern that can negatively affect academic performance and overall well-being. Early detection of Depression is essential to provide timely support and preventive interventions. This study proposes a machine learning approach to classify student Depression using a Support Vector Machine (SVM) combined with Backward Elimination (BE) for feature selection. The dataset used in this research was obtained from a public repository and consists of 502 student records with multiple psychological and demographic attributes. Data preprocessing included categorical encoding and Min-Max normalization, followed by an 80:20 split for training and testing. Experimental results show that the baseline SVM model achieved an accuracy of 0.9208, while the application of Backward Elimination improved the performance to 0.9604. In addition, precision, recall, and F1-score also showed notable improvements, indicating a reduction in misclassification, particularly for non-depressed students. These findings demonstrate that integrating feature selection with SVM can enhance classification performance and provide a more efficient model for supporting early Depression detection among university students.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Kesehatan mental merupakan aspek fundamental yang menentukan kualitas hidup, produktivitas, serta kemampuan seseorang dalam menjalankan fungsi sosialnya. Depresi menjadi salah satu gangguan mental yang paling banyak dialami dan menunjukkan tren peningkatan dari tahun ke tahun. Laporan global terbaru menunjukkan bahwa lebih dari 280 juta orang di seluruh dunia hidup dengan depresi, menjadikannya penyebab utama disabilitas dan penurunan kualitas hidup [1]. Dampak depresi tidak hanya dirasakan pada level individu, tetapi juga menimbulkan beban ekonomi yang signifikan akibat berkurangnya produktivitas dan meningkatnya kebutuhan layanan kesehatan [2].

Dalam konteks nasional, Indonesia menghadapi tantangan serupa. Survei Kesehatan Mental Remaja Indonesia menunjukkan bahwa sekitar 5,5% remaja mengalami gangguan mental, dengan gejala depresi sebagai salah satu yang paling dominan [3]. Di sisi lain, data Badan Pusat Statistik mencatat bahwa jumlah mahasiswa aktif pada tahun

2023 mencapai lebih dari 8,9 juta orang, menjadikan kelompok ini sebagai populasi besar yang rentan terhadap tekanan psikologis [4]. Berbagai tuntutan akademik, sosial, hingga ekonomi menjadi pemicu munculnya stres dan depresi pada mahasiswa.

Sejumlah penelitian telah menunjukkan adanya hubungan yang kuat antara tekanan akademik dan gangguan kesehatan mental. Stres selama pembelajaran—terutama pada masa transisi pasca-pandemi—terbukti meningkatkan risiko gejala depresi pada mahasiswa [5]. Penelitian lain juga menemukan bahwa beban akademik yang tinggi dapat menurunkan motivasi belajar dan berdampak pada performa akademik secara keseluruhan [6]. Selain itu, gejala depresi pada mahasiswa sering kali diabaikan atau tidak terdeteksi karena minimnya literasi kesehatan mental dan stigma sosial [7].

Penerapan pendekatan berbasis Kecerdasan Buatan (AI) dan Pembelajaran Mesin (ML) telah menjadi strategi penting untuk memfasilitasi deteksi dini dan intervensi gangguan kesehatan mental, seiring dengan percepatan kemajuan teknologi. Studi komputasi kontemporer telah menunjukkan

kemampuan metode ini untuk mengidentifikasi pola perilaku kompleks yang berkorelasi dengan kondisi depresi dengan cara yang jauh lebih objektif [8]. Berdasarkan berbagai metode klasifikasi yang tersedia, Support Vector Machine (SVM) merupakan salah satu algoritma klasifikasi yang banyak digunakan dalam penelitian kesehatan mental karena kemampuannya menangani hubungan non-linear antar fitur secara efektif. Algoritma SVM dipilih dalam penelitian ini karena karakteristik data psikologis mahasiswa cenderung bersifat non-linear dan memiliki korelasi antar fitur, sehingga pendekatan berbasis margin seperti SVM lebih stabil dibandingkan metode linier [9], jenis data yang kebetulan sering ditemukan dalam studi terkait psikologi [10]. Cara kerja SVM sendiri berputar pada usaha menemukan garis pemisah yang paling pas antara satu kelompok data dan kelompok lainnya. Pendekatan ini berkaitan erat dengan prinsip *Structural Risk Minimization* (SRM) [11], yang juga dibahas dalam *Advances in Computational Mental Health Modeling* [12], karena prinsip tersebut membantu model tetap stabil saat diberikan data yang belum pernah ia lihat sebelumnya.

SVM bisa menjadi lebih fleksibel lagi ketika dilengkapi dengan kernel tertentu—misalnya saja kernel *Radial Basis Function* (RBF). Kernel seperti ini membuat SVM lebih mampu menangani situasi ketika distribusi datanya tidak seimbang, hal yang cukup sering terjadi di penelitian tentang kesehatan mental [12]. Dalam satu penelitian yang mencoba SVM untuk mengklasifikasikan tingkat depresi mahasiswa, hasilnya malah cukup tinggi: akurasi dilaporkan mencapai 94,22%. Temuan semacam ini menunjukkan bahwa metode tersebut punya potensi besar jika digunakan untuk membantu proses deteksi depresi berbasis data [10].

Namun, kinerja SVM sangat dipengaruhi oleh kualitas fitur yang digunakan. Kehadiran fitur yang tidak relevan dapat menurunkan akurasi dan meningkatkan risiko overfitting. Oleh karena itu, pemilihan fitur merupakan langkah penting dalam mengembangkan model prediktif. Beberapa studi telah menunjukkan bahwa metode pemilihan fitur dapat menyederhanakan model dan meningkatkan interpretasi, terutama pada data kesehatan mental yang mengandung banyak variabel [13]. *Backward Elimination* merupakan salah satu cara yang cukup sering dipilih untuk menyaring fitur. Teknik ini bekerja dengan membuang fitur yang pengaruhnya kecil terlebih dahulu, lalu terus mengurangnya sampai hanya tersisa fitur-fitur yang benar-benar penting saja [14].

Dalam sejumlah penelitian tentang kesehatan mental, metode ini sudah beberapa kali menunjukkan hasil yang cukup meyakinkan. Misalnya saja sebuah studi yang membandingkan model klasifikasi stres pada mahasiswa—di situ, akurasi SVM bisa naik sampai 91% setelah memakai *Backward Elimination* [15]. Penelitian lain di bidang klinis juga menemukan hal serupa; teknik ini membantu menemukan variabel yang betul-betul berperan dalam kondisi tertentu [16]. Bahkan riset yang menggunakan data dari media sosial pun memperlihatkan bahwa ketika SVM digabung

dengan seleksi fitur, kemampuan model dalam mengenali gejala depresi jadi jauh lebih baik [17].

Melihat berbagai temuan tersebut, penelitian ini mencoba mengembangkan model untuk memprediksi tingkat depresi mahasiswa dengan memakai SVM yang telah dioptimalkan melalui *Backward Elimination*. Harapannya sederhana: model yang dihasilkan bisa lebih ringan, lebih tepat dalam memprediksi, dan bisa membantu proses deteksi awal masalah kesehatan mental di lingkungan kampus.

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan algoritma supervised machine learning untuk memprediksi tingkat depresi mahasiswa berdasarkan data perilaku, psikologis, dan akademik. Pendekatan kuantitatif dipilih karena memungkinkan proses analisis yang terukur, objektif, serta mampu memberikan gambaran performa model secara komprehensif melalui evaluasi statistik [18].

Algoritma utama yang diterapkan adalah *Support Vector Machine* (SVM). SVM dikenal mampu bekerja dengan baik pada data non-linear dan menjadi salah satu algoritma yang paling stabil digunakan untuk kasus psikologis dan kesehatan mental. Dengan konsep maximum-margin hyperplane, SVM berusaha memisahkan dua kelas secara optimal sehingga pola yang kompleks dapat dikenali lebih akurat [9].

Untuk meningkatkan performa SVM, penelitian ini menggunakan teknik seleksi fitur *Backward Elimination* (BE). Teknik ini diadopsi karena kesederhanaannya, kemampuan menyaring fitur yang kurang relevan, serta efektivitasnya dalam meningkatkan akurasi pada model klasifikasi kesehatan [13]. Proses seleksi fitur menjadi penting karena model pembelajaran mesin hanya dapat bekerja optimal apabila informasi yang diberikan benar-benar relevan dan bebas dari noise.

Tahapan penelitian disusun secara sistematis dan divisualisasikan melalui diagram alur metode (Gambar 1). Selain memudahkan pemahaman, alur terstruktur ini mengikuti prinsip research reproducibility, yaitu memastikan penelitian dapat diulang oleh peneliti lain dengan hasil yang sebanding [19]. Secara keseluruhan, tahapan penelitian mencakup pengambilan dataset, *preprocessing* data, pembagian data latih dan uji, pembentukan model SVM awal, seleksi fitur BE, evaluasi performa, dan perbandingan hasil model.

A. Dataset

Dataset yang digunakan dalam penelitian ini diperoleh dari repositori data publik Kaggle, yaitu *Depression Student Dataset* www.kaggle.com/datasets/ikynahidwin/Depression-student-dataset. Dataset ini berisi data mahasiswa yang dikumpulkan melalui kuesioner berbasis laporan diri (*self-reported questionnaire*) yang mencakup aspek demografis, akademik, dan psikologis.

Secara keseluruhan, dataset terdiri dari 502 data mahasiswa dengan 10 atribut prediktor dan 1 atribut target berupa status depresi. Atribut prediktor mencakup beberapa faktor yang


berkaitan dengan kondisi mahasiswa, antara lain jenis kelamin, tekanan akademik, durasi tidur, kepuasan belajar, stres finansial, pikiran bunuh diri, serta riwayat gangguan mental dalam keluarga. Dataset ini bersifat sekunder dan tidak dikumpulkan secara langsung oleh penulis, sehingga karakteristik dan struktur data mengikuti definisi yang telah ditetapkan oleh penyusun dataset pada platform Kaggle.

Label depresi pada dataset ini telah ditentukan oleh penyusun dataset dan diklasifikasikan ke dalam dua kelas, yaitu *depressed* dan *not depressed*. Penelitian ini tidak melakukan proses pengukuran ulang maupun diagnosis klinis terhadap responden, melainkan menggunakan label yang telah tersedia pada dataset sebagai dasar dalam proses klasifikasi. Deskripsi dataset pada repositori Kaggle tidak secara eksplisit menyebutkan penggunaan instrumen depresi klinis standar, seperti PHQ-9, DASS-21, atau *Beck Depression Inventory* (BDI). Oleh karena itu, label depresi pada penelitian ini diperlakukan sebagai label indikatif untuk keperluan pemodelan prediktif dan evaluasi algoritma, bukan sebagai dasar diagnosis medis atau klinis.

Seluruh data yang digunakan bersifat anonim dan tersedia secara publik, sehingga penelitian ini tidak melibatkan akses terhadap identitas personal responden. Dengan demikian, model yang diusulkan ditujukan sebagai alat bantu skrining awal berbasis data dan tidak dimaksudkan untuk menggantikan asesmen profesional di bidang kesehatan mental.

B. Tahapan Penelitian

Tahapan penelitian disusun secara sistematis dan divisualisasikan melalui canva. Diagram ini memberikan gambaran menyeluruh mengenai langkah-langkah penelitian, mulai dari pengambilan dataset hingga tahap hasil akhir dan kesimpulan. Berikut adalah tahap alur metodologi penelitian.



Gambar 1. Tahap Penelitian

Setiap tahapan dalam alur tersebut saling berkaitan dan berfungsi menunjang akurasi hasil akhir. Proses dimulai dengan akuisisi dataset, yang berfungsi sebagai dasar untuk seluruh analisis. Tahap pra-pemrosesan memastikan kualitas data yang optimal dengan mengubah variabel kategorikal menjadi nilai numerik, menormalisasi skala fitur, dan mempertahankan distribusi kelas yang seimbang melalui pembagian data yang terkontrol. Hasil pra-pemrosesan berfungsi sebagai input untuk model SVM awal, yang berfungsi sebagai dasar untuk menilai kinerja model sebelum

optimasi. Teknik *Backward Elimination* kemudian diterapkan untuk mengurangi fitur yang tidak relevan, membuat model lebih efisien dan bebas noise. Tahap evaluasi dan perbandingan model digunakan untuk menilai sejauh mana proses penghapusan fitur meningkatkan kinerja klasifikasi. Proses sistematis ini memungkinkan penelitian untuk direplikasi oleh peneliti lain dan menghasilkan temuan yang konsisten.

C. Preprocessing Data

1) Encoding variabel kategorikal

Variabel kategorikal seperti gender dan jawaban Yes/No dikonversi menjadi nilai numerik menggunakan teknik Label Encoding, yang terbukti efisien untuk algoritma berbasis margin seperti SVM karena tidak menambah dimensi fitur [20][21].

2) Normalisasi fitur

Normalisasi dilakukan menggunakan *Min-Max Scaling*, karena fitur dalam dataset memiliki rentang nilai berbeda-beda. Normalisasi mencegah fitur dengan skala besar mendominasi proses pembentukan model [22]. Normalisasi wajib dilakukan menggunakan *Min-Max Scaling*. Ini karena fitur dalam dataset memiliki rentang nilai yang berbeda-beda. Normalisasi ini sangat krusial; ia mencegah fitur dengan skala besar mendominasi proses pembentukan model [21]. Pentingnya langkah *preprocessing* ini ditekankan dalam berbagai riset, bahkan dalam model deret waktu yang kompleks, di mana data yang ternormalisasi menjadi kunci keberhasilan *hyperparameter tuning* dan stabilitas model [23].

Rumus normalisasi *Min-Max*:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

X = nilai asli suatu fitur sebelum dinormalisasi

X' = nilai fitur setelah dinormalisasi

X_{\min} = nilai terkecil fitur pada dataset

X_{\max} = nilai terbesar fitur pada dataset

Dengan ini, seluruh fitur dipetakan ke rentang [0,1] untuk menjaga stabilitas SVM [24].

3) Pembagian data

Data dibagi menjadi 80% data latih dan 20% data uji menggunakan teknik stratifikasi. Pembagian ini bertujuan untuk memastikan proporsi kelas *depressed* dan *not depressed* tetap seimbang pada kedua subset data, sehingga model tidak bias terhadap salah satu kelas. Strategi ini sejalan dengan rekomendasi pada pipeline *machine learning* modern untuk data klasifikasi kesehatan mental [2][7]. Komposisi pembagian data yang tepat serta penerapan stratifikasi

terbukti memiliki pengaruh signifikan terhadap stabilitas dan akurasi klasifikasi akhir model *machine learning* [25].

Pada penelitian ini digunakan skema *hold-out validation* untuk mengevaluasi performa model sebelum dan sesudah penerapan Backward Elimination. Validasi silang (*cross-validation*) tidak diterapkan karena fokus penelitian diarahkan pada analisis perbandingan kinerja model dengan dan tanpa seleksi fitur pada dataset yang sama. Meskipun demikian, penerapan *cross-validation* direkomendasikan pada penelitian selanjutnya untuk menguji konsistensi performa model dan meminimalkan potensi *overfitting* pada dataset yang berbeda.

D. Pembentukan Model SVM Awal

Support Vector Machine (SVM) merupakan algoritma klasifikasi yang bekerja dengan mencari sebuah *hyperplane* optimal yang mampu memisahkan dua kelas data secara maksimal. Pemisahan optimal ini dicapai dengan memaksimalkan margin, yaitu jarak antara *hyperplane* dengan titik data terdekat dari masing-masing kelas yang dikenal sebagai *support vectors*. Margin yang besar berperan penting dalam meningkatkan kemampuan generalisasi model ketika dihadapkan pada data baru yang belum pernah dilihat sebelumnya [9]. Berbagai penelitian menunjukkan bahwa SVM memiliki performa yang unggul dalam klasifikasi data kesehatan, bahkan mampu mengungguli algoritma lain seperti Decision Tree pada beberapa kasus medis [26].

Secara matematis, formulasi dasar SVM dinyatakan melalui fungsi objektif berikut:

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

dengan kendala:

$$y_i(w^T x_i + b) \geq 1 \quad (3)$$

Keterangan:

- w : vektor bobot yang menentukan arah *hyperplane*
- b : bias atau pergeseran *hyperplane*
- $\|w\|^2$: norma kuadrat vektor bobot yang berbanding terbalik dengan besar margin
- x_i : vektor fitur sampel ke- i
- y_i : label kelas, dengan +1 untuk *depressed* dan -1 untuk *not depressed*

Tujuan dari fungsi objektif pada Persamaan (2) adalah meminimalkan nilai $\|w\|$, sehingga margin pemisah antar kelas menjadi semakin besar. Kendala pada Persamaan (3) memastikan bahwa setiap data berada pada sisi *hyperplane* yang benar dengan jarak minimal satu satuan margin.

Formulasi pada Persamaan (2)–(3) merepresentasikan konsep dasar SVM. Dalam implementasi praktis pada penelitian ini, digunakan pendekatan *soft-margin* SVM yang

dikombinasikan dengan fungsi kernel untuk mengakomodasi data yang tidak terpisahkan secara linear sempurna.

Untuk menangani karakteristik data psikologis mahasiswa yang bersifat non-linear, penelitian ini menggunakan kernel Radial Basis Function (RBF). Pemilihan kernel RBF didukung oleh penelitian sebelumnya yang menyatakan bahwa kernel ini sangat efektif dalam memodelkan hubungan non-linear pada data psikologis dan kesehatan mental [26][27]. Fungsi kernel RBF dirumuskan sebagai berikut:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (4)$$

Keterangan:

- x_i, x_j : dua titik data yang dibandingkan
- $\|x_i - x_j\|^2$: jarak kuadrat antara dua titik data
- γ : parameter kernel yang mengontrol tingkat sensitivitas terhadap jarak antar data

Nilai γ berperan dalam menentukan kompleksitas batas keputusan. Nilai γ yang besar menghasilkan batas keputusan yang lebih kompleks dan sensitif terhadap variasi data, sedangkan nilai γ yang kecil menghasilkan model yang lebih halus dan memiliki kemampuan generalisasi yang lebih baik. Dengan penggunaan kernel RBF, SVM mampu membentuk batas keputusan yang fleksibel dan melengkung, sehingga lebih sesuai untuk klasifikasi data depresi mahasiswa yang memiliki pola non-linear.

E. Seleksi Fitur Menggunakan Backward Elimination

Backward Elimination dilakukan untuk mengurangi fitur yang tidak relevan terhadap model. Proses BE dimulai dari seluruh fitur, kemudian satu fitur dihapus pada setiap iterasi, dan model dilatih ulang untuk melihat perubahan performa.

Prosedur BE [13]:

$$S_{\text{baru}} = S_{\text{lama}} - \{f_i \mid p(f_i) > \alpha\} \quad (5)$$

Keterangan:

- S_{lama} = kumpulan semua fitur awal
- S_{baru} = kumpulan fitur setelah penghapusan
- f_i = fitur ke- i yang sedang diuji
- $p(f_i)$ = tingkat signifikansi / kontribusi fitur
- α = batas ambang seleksi fitur

Fitur yang tidak memberikan peningkatan performa (memiliki nilai p lebih besar dari ambang) dihapus. Tujuannya agar model menjadi lebih ringan, lebih cepat, dan lebih akurat [28]. Fitur dengan kontribusi rendah dieliminasi sampai tidak ada peningkatan performa yang signifikan. Teknik ini membantu model menjadi lebih sederhana, lebih cepat, dan lebih akurat.

F. Evaluasi Model

Evaluasi dilakukan menggunakan metrik-metrik berikut:

1. Accuracy

Evaluasi performa model dalam penelitian ini dilakukan menggunakan empat metrik utama, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Menurut S. Aini dkk. (2023), penggunaan metrik yang komprehensif sangat ideal untuk data kesehatan mental karena mampu menggambarkan keseimbangan antara prediksi yang benar dan salah secara mendalam [16]. *Accuracy* digunakan sebagai parameter awal untuk mengukur sejauh mana model mampu memberikan prediksi yang benar secara keseluruhan. Metrik ini dihitung melalui Persamaan (6):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

Keterangan rumus ini menunjukkan *Accuracy* diperoleh dari hasil bagi antara seluruh prediksi benar, yang mencakup *True Positive* (TP) atau mahasiswa depresi yang diprediksi benar dan *True Negative* (TN) atau mahasiswa sehat yang diprediksi benar, terhadap total seluruh data uji yang juga melibatkan kesalahan prediksi berupa *False Positive* (FP) dan *False Negative* (FN). *Accuracy* mengukur berapa banyak prediksi model yang benar secara keseluruhan dibandingkan total data uji. Metrik ini menjumlahkan semua prediksi benar (baik memprediksi depresi maupun tidak depresi) lalu membaginya dengan jumlah seluruh prediksi. *Accuracy* baik digunakan sebagai gambaran awal performa model, tetapi tidak cukup untuk dataset kesehatan mental yang sering tidak seimbang [29]. Oleh karena itu, *precision*, *recall*, dan *F1-score* tetap diperlukan.

2. Precision

Meskipun memberikan gambaran umum, akurasi saja tidak cukup untuk menangani dataset kesehatan yang sering tidak seimbang. Oleh karena itu, diperlukan metrik *Precision* untuk mengukur tingkat ketepatan model ketika memberikan label "depresi" melalui Persamaan (7):

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

Keterangan dari rumus ini menunjukkan bahwa *Precision* berfokus pada perbandingan antara prediksi benar (TP) dengan seluruh mahasiswa yang didiagnosis depresi oleh sistem (termasuk FP). Fokus utama metrik ini adalah meminimalkan kesalahan diagnosis pada mahasiswa sehat agar tidak mendapatkan intervensi medis yang tidak diperlukan.

3. Recall

Recall atau sensitivitas menjadi metrik yang paling diprioritaskan dalam penelitian kesehatan mental. Sebagaimana dijelaskan oleh [30], *Recall* berfungsi untuk

memastikan seberapa mampu model menemukan seluruh mahasiswa yang benar-benar mengalami depresi melalui Persamaan (8):

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

Recall mengukur seberapa mampu model menemukan mahasiswa yang benar-benar depresi. Artinya, *recall* sangat penting pada penelitian kesehatan mental, karena FN (mahasiswa depresi yang tidak terdeteksi) jauh lebih berbahaya dibanding FP [30]. Dalam perhitungan ini, TP dibandingkan dengan jumlah mahasiswa yang seharusnya depresi (termasuk yang terlewat atau FN). Hal ini sangat krusial karena kondisi FN dianggap jauh lebih berbahaya daripada FP, sebab mahasiswa yang membutuhkan bantuan tidak teridentifikasi oleh sistem. *Recall* sangat penting pada penelitian kesehatan mental, karena FN (mahasiswa depresi yang tidak terdeteksi) jauh lebih berbahaya dibanding FP. Jika *recall* rendah, banyak mahasiswa depresi tidak teridentifikasi sehingga tidak mendapat dukungan.

4. F1-Score

Sebagai penyeimbang, digunakan *F1-Score* yang merupakan rata-rata harmonik antara *Precision* dan *Recall* untuk memberikan representasi performa yang paling objektif, dengan rumus pada Persamaan (9):

$$F1 = 2 \times \frac{Precision \cdot Recall}{Precision + Recall} \quad (9)$$

Keterangan rumus ini menunjukkan penggabungan antara aspek ketepatan (*precision*) dan kepekaan (*recall*) secara harmonis. Menurut [31], metrik ini paling efektif digunakan ketika dataset tidak seimbang karena tidak membiarkan salah satu metrik menjadi terlalu dominan dalam penilaian kualitas model [31]. *F1-Score* adalah harmonic mean antara *Precision* dan *Recall*. Nilai F1 menjadi representasi yang lebih seimbang, terutama jika salah satu dari *precision* atau *recall* jauh lebih rendah.

F1-score adalah metrik yang paling baik digunakan ketika dataset tidak seimbang, atau ketika kedua jenis kesalahan (FP dan FN) sama-sama harus dipertimbangkan secara seimbang [31]. Menurut Menurut [29], keempat metrik ini ideal digunakan pada data kesehatan mental karena mampu menggambarkan keseimbangan prediksi yang benar dan salah dengan lebih komprehensif.

G. Perbandingan Model

Pada tahap akhir, performa model SVM awal dibandingkan dengan model SVM + BE berdasarkan keempat metrik evaluasi yang telah dijelaskan. Perbandingan ini menjadi dasar untuk menilai sejauh mana seleksi fitur *Backward Elimination* mampu meningkatkan kemampuan model dalam mengklasifikasikan tingkat depresi mahasiswa. Hasil

perbandingan inilah yang kemudian dibahas lebih lanjut pada bagian Hasil dan Pembahasan untuk melihat implikasi praktisnya bagi deteksi dini depresi di lingkungan kampus.

III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan analisis komprehensif mengenai penerapan algoritma *Support Vector Machine* (SVM) yang diintegrasikan dengan teknik seleksi fitur *Backward Elimination* (BE) dalam konteks klasifikasi tingkat depresi mahasiswa. Pembahasan diawali dengan evaluasi mendalam terhadap performa model standar SVM untuk memahami kemampuan dasar algoritma dalam mengenali pola-pola psikologis pada dataset awal. Selanjutnya, diuraikan proses optimasi melalui tahapan *Backward Elimination*, yang berfokus pada signifikansi statistik tiap fitur serta bagaimana eliminasi variabel yang tidak relevan dapat menyederhanakan kompleksitas komputasi model. Selain itu, bagian ini juga mengulas dampak dari perubahan prosedural tersebut terhadap stabilitas prediksi dan kemampuan generalisasi model dalam membedakan kelas depresi secara lebih selektif. Sebagai penutup, dilakukan sintesis hasil melalui perbandingan performa antara model tunggal dengan model teroptimasi guna memberikan wawasan mengenai efektivitas reduksi fitur dalam meningkatkan akurasi klinis dan keandalan sistem deteksi dini di lingkungan universitas.

A. Hasil Preprocessing Data

Tahap *preprocessing* pada penelitian ini menghasilkan dataset yang telah bersih, terstruktur, dan siap digunakan untuk pemodelan. Dataset awal terdiri dari 502 sampel mahasiswa dengan 11 fitur. Berdasarkan pemeriksaan awal, seluruh fitur tidak memiliki missing value sehingga tidak diperlukan proses imputasi. Kondisi ini memberikan keuntungan karena menjaga pola data tetap alami tanpa modifikasi statistik tambahan.

Fitur kategorikal diubah ke bentuk numerik menggunakan Label Encoding. Konversi ini bertujuan menghindari peningkatan dimensi seperti pada One-Hot Encoding dan menjaga agar model SVM tetap efisien dalam proses perhitungan margin. Selanjutnya, seluruh fitur numerik dinormalisasi menggunakan *Min-Max Scaling* untuk memastikan setiap variabel berada dalam rentang yang seragam antara 0 dan 1. Normalisasi sangat penting karena SVM sensitif terhadap perbedaan skala fitur, dan tanpa normalisasi SVM dapat membentuk hyperplane yang bias.

TABEL I.

DESKRIPSI FITUR DATASET SETELAH *PREPROCESSING*


No	Nama Fitur	Tipe Data	Rentang / Kategori	Status dalam Model
1	Gender	Kategorikal (Encoded)	0–1	Dieliminasi
2	Age	Numerik	17–28	Dipakai
3	Academic Pressure	Numerik (Scaled)	0–1	Dipakai

4	Study Satisfaction	Numerik (Scaled)	0–1	Dipakai
5	Sleep Duration	Numerik (Scaled)	0–1	Dieliminasi
6	Dietary Habits	Kategorikal (Encoded)	0–1	Dipakai
7	Suicidal Thoughts	Kategorikal (Encoded)	0–1	Dipakai
8	Study Hours	Numerik (Scaled)	0–1	Dipakai
9	Financial Stress	Numerik (Scaled)	0–1	Dipakai
10	Family History of Mental Illness	Kategorikal (Encoded)	0–1	Dipakai
11	Depression (Label)	Kategorikal	0 / 1	Target

Tabel ini menunjukkan bagaimana seluruh fitur telah dipersiapkan untuk tahap modelling. Status fitur yang dieliminasi (Gender dan Sleep Duration) merupakan hasil analisis *Backward Elimination* berdasarkan nilai p-value, yang akan dibahas pada subbab berikutnya. Informasi ini penting karena memberikan gambaran awal fitur mana saja yang akhirnya menjadi kontributor signifikan terhadap prediksi depresi.

B. Hasil Model SVM Tanpa Backward Elimination

Model baseline SVM dibangun menggunakan seluruh 10 fitur prediktor. Confusion Matrix untuk model baseline ditampilkan pada Gambar 2. Berdasarkan data dari matriks tersebut, diperoleh nilai evaluasi statistik yang dirangkum dalam Tabel II.



Gambar 2. Confusion Matrix Model SVM Tanpa Backward Elimination

Model baseline SVM dibangun menggunakan seluruh 10 fitur prediktor. Confusion matrix untuk model baseline ditampilkan pada Gambar 2. Confusion matrix pada Gambar 2 dihasilkan melalui proses evaluasi model SVM yang diimplementasikan menggunakan bahasa pemrograman

Python pada lingkungan Google Colaboratory dengan memanfaatkan pustaka *scikit-learn* untuk perhitungan metrik evaluasi dan visualisasi hasil klasifikasi. Hasil evaluasi statistik dari model baseline SVM dirangkum dalam Tabel II.

Gambar 2 menunjukkan bahwa model SVM tanpa Backward Elimination memiliki tingkat *recall* sempurna sebesar 1,0000, yang berarti seluruh mahasiswa yang benar-benar mengalami depresi berhasil terdeteksi tanpa adanya kasus *False Negative* (FN = 0). Dari perspektif kesehatan mental, kondisi ini sangat krusial karena meminimalkan risiko individu berisiko tidak teridentifikasi oleh sistem. Namun, tingginya nilai *recall* ini diikuti oleh nilai *precision* yang relatif lebih rendah, yang mengindikasikan bahwa model cenderung terlalu sensitif dalam memberikan prediksi depresi.

TABEL II
HASIL EVALUASI MODEL SVM TANPA BACKWARD ELIMINATION

NO	Matrik Evaluasi	Hasil Evaluasi
1	<i>Akurasi</i>	0,9208
2	<i>Precision</i>	0,8644
3	<i>Recall</i>	1,000
4	<i>F1-Score</i>	0,9273

Meskipun nilai *recall* sangat tinggi, nilai *precision* hanya mencapai 0,8644. Hal ini disebabkan oleh adanya 8 kasus *False Positive* (FP), yaitu mahasiswa sehat yang salah diprediksi mengalami depresi. Fenomena ini sering muncul pada SVM ketika terdapat fitur yang tidak relevan yang menyebabkan *noise*, sehingga margin *hyperplane* menjadi kurang optimal. Oleh karena itu, komposisi fitur yang belum ideal menjadi landasan kuat bagi penelitian ini untuk melakukan optimasi model melalui seleksi fitur menggunakan Backward Elimination.

C. Seleksi Fitur Menggunakan Backward Elimination

Backward Elimination dilakukan secara iteratif dengan menghapus fitur yang memiliki kontribusi paling kecil berdasarkan p-value. Hasil proses BE ditampilkan pada Tabel III.

TABEL III.
RINGKASAN PROSES BACKWARD ELIMINATION


NO	Fitur yang Dihapus	p-value	Alasan
1	<i>Gender</i>	0.7067	Tidak signifikan dalam mempengaruhi kelas
2	<i>Sleep Duration</i>	0.0628	Marginal dan tidak konsisten secara statistik
3	–	≤ 0.05	Semua fitur tersisa signifikan

Fitur Gender dieliminasi karena memiliki nilai p-value sebesar 0,7067, yang menunjukkan bahwa kontribusinya terhadap variabel target tidak signifikan secara statistik. Temuan ini konsisten dengan beberapa penelitian sebelumnya yang melaporkan bahwa perbedaan tingkat depresi pada populasi dewasa muda tidak selalu menunjukkan signifikansi

statistik yang kuat. Fitur *Sleep Duration* dieliminasi karena memiliki nilai p-value sebesar 0,0628, yang berada di atas ambang signifikansi. Hal ini menunjukkan bahwa durasi tidur tidak memberikan kontribusi yang konsisten terhadap prediksi depresi pada dataset penelitian ini. Fitur penting yang tersisa setelah BE justru terkait langsung dengan faktor psikologis seperti Suicidal Thoughts, Financial Stress, dan Study Satisfaction, yang memang banyak dilaporkan dalam literatur psikologi sebagai faktor yang memiliki hubungan kuat dengan gejala depresi.

D. Hasil Model SVM Setelah Backward Elimination

Setelah metode Backward Elimination (BE) diterapkan untuk mengeliminasi fitur-fitur yang tidak signifikan pada model sebelumnya, model SVM dibangun ulang menggunakan fitur-fitur yang paling optimal. Perubahan performa model setelah proses optimasi ini dapat diamati melalui Confusion Matrix yang disajikan pada Gambar 3.



Gambar 3. Confusion Matrix Model SVM dengan Backward Elimination

Confusion matrix pada Gambar 3 dihasilkan melalui proses evaluasi model SVM yang diimplementasikan menggunakan bahasa pemrograman Python pada lingkungan Google Colaboratory dengan memanfaatkan pustaka *scikit-learn*. Hasil evaluasi metrik setelah penerapan BE menunjukkan peningkatan performa yang cukup berarti di hampir seluruh parameter. Data lengkap mengenai perbandingan metrik evaluasi pasca-optimasi dirangkum dalam Tabel IV.

TABEL IV
HASIL EVALUASI MODEL SVM DENGAN BACKWARD ELIMINATION

NO	Metrik Evaluasi	Hasil Perhitungan
1	<i>Accuracy</i>	0,9604
2	<i>Precision</i>	0,9434
3	<i>Recall</i>	0,9804
4	<i>F1-Score</i>	0,9615

Model setelah BE menunjukkan penurunan *False Positive* (FP) yang sangat signifikan, yaitu dari 8 kasus menjadi 3 kasus. Penurunan jumlah False Positive setelah penerapan Backward Elimination menunjukkan bahwa penghapusan fitur yang tidak relevan membantu SVM membentuk

hyperplane pemisah yang lebih optimal, sehingga mengurangi kesalahan klasifikasi pada mahasiswa yang tidak mengalami depresi. Penurunan angka FP ini sangat penting dalam konteks klinis untuk mencegah mahasiswa sehat diklasifikasikan secara salah sebagai penderita depresi, yang dapat memicu kecemasan yang tidak perlu.

Meskipun terdapat sedikit peningkatan pada *False Negative* (FN) dari 0 menjadi 1 kasus, namun tingkat *recall* tetap terjaga pada angka yang sangat tinggi, yaitu 0,9804. Hal ini membuktikan bahwa model masih memiliki sensitivitas yang sangat baik dalam mendeteksi kasus depresi. Selain itu, peningkatan *F1-Score* menjadi 0,9615 menunjukkan adanya keseimbangan yang lebih baik antara *precision* dan *recall*. Secara keseluruhan, hasil ini membuktikan bahwa eliminasi fitur melalui metode BE tidak hanya menyederhanakan arsitektur model, tetapi juga meningkatkan stabilitas dan akurasi prediksi secara signifikan.

E. Perbandingan Performa SVM vs SVM+BE

Perbandingan performa antara model SVM tanpa seleksi fitur dan SVM yang dioptimalkan menggunakan *Backward Elimination* (BE) disajikan pada Tabel V. Tabel ini memberikan gambaran menyeluruh mengenai perubahan performa model setelah dilakukan proses seleksi fitur, baik dari sisi akurasi maupun stabilitas prediksi. Perbandingan performa kedua model ditampilkan dalam Tabel berikut.

TABEL V
PERBANDINGAN PERFORMA MODEL

No	Kriteria	SVM Tanpa BE	SVM + BE
0	Akurasi	0.920800	0.960400
1	Precision	0.864400	0.943400
2	Recall	1.000000	0.980400
3	F1-score	0.927300	0.961500
4	False Positif	8.000000	3.000000
5	False Negative	0.000000	1.000000


Tabel V menunjukkan bahwa penerapan *Backward Elimination* memberikan dampak positif terhadap performa model. Peningkatan akurasi dari 0.9208 menjadi 0.9604 menunjukkan bahwa model mampu membuat prediksi lebih tepat setelah fitur tidak relevan dihilangkan. Proses reduksi fitur juga berdampak pada peningkatan precision secara signifikan, dari 0.8644 menjadi 0.9434. Peningkatan precision ini menunjukkan bahwa model lebih mampu membedakan mahasiswa yang benar-benar depresi, sehingga mengurangi kesalahan false positive secara drastis dari 8 menjadi 3 kasus.

Pada sisi recall, nilai model awal mencapai 1.0000, sedangkan model dengan BE menunjukkan sedikit penurunan menjadi 0.9804. Meskipun nilai recall mengalami penurunan kecil dari 1.0000 menjadi 0.9804, tingkat sensitivitas model tetap tinggi. Dalam konteks sistem skrining awal, penurunan ini dapat diterima karena disertai dengan penurunan False Positive yang signifikan, sehingga menghasilkan keseimbangan yang lebih baik antara ketepatan dan

sensitivitas prediksi, sehingga model tetap sensitif dalam mengenali mahasiswa yang mengalami depresi. F1-score juga meningkat cukup besar dari 0.9273 menjadi 0.9615, yang menandakan adanya keseimbangan performa yang lebih baik antara precision dan recall.

Secara keseluruhan, BE terbukti efektif dalam meningkatkan kualitas prediksi model dengan cara mengurangi fitur-fitur yang tidak memberikan kontribusi signifikan terhadap klasifikasi. Hal ini mendukung temuan penelitian sebelumnya mengenai efektivitas seleksi fitur dalam meningkatkan performa SVM.

Untuk mengevaluasi efektivitas integrasi metode *Backward Elimination* (BE) pada algoritma *Support Vector Machine* (SVM), dilakukan analisis komparatif terhadap empat metrik evaluasi utama. Visualisasi performa ini bertujuan untuk memotret secara jelas bagaimana penyederhanaan fitur memengaruhi kualitas prediksi model, sebagaimana dirangkum dalam analisis berikut:



Gambar 4. Perbandingan Performa SVM vs SVM+BE

Gambar 4 menyoroti peningkatan precision yang cukup tajam setelah penerapan BE. Artinya, model menjadi jauh lebih akurat dalam mengidentifikasi mahasiswa yang benar-benar depresi, serta mengurangi kesalahan prediksi yang dapat menimbulkan kecemasan yang tidak perlu bagi mahasiswa yang sebenarnya tidak mengalami depresi. Secara keseluruhan, kombinasi SVM + BE memberikan performa yang lebih stabil, efisien, dan dapat diandalkan untuk keperluan deteksi depresi dini.

1. Akurasi (*Accuracy*) Akurasi merupakan metrik utama yang menunjukkan sejauh mana model mampu mengklasifikasikan data secara tepat. Berdasarkan hasil eksperimen, model SVM standar memberikan akurasi awal sebesar 92,08%. Namun, setelah dilakukan optimasi melalui *Backward Elimination*, akurasi meningkat menjadi 96,04%. Peningkatan sebesar 3,96% ini membuktikan bahwa penghapusan fitur yang tidak signifikan (seperti *gender* dan *durasi tidur*) justru mempertajam kemampuan algoritma dalam mengenali pola depresi yang sebenarnya tanpa terganggu oleh "kebisingan" data yang tidak relevan.
2. Presisi (*Precision*) Peningkatan paling signifikan terlihat pada nilai presisi, yang melonjak dari 84,62% menjadi 93,48%. Dalam konteks kesehatan mental, presisi

mencerminkan kemampuan model untuk meminimalkan *False Positive* (mahasiswa sehat yang salah didiagnosis depresi). Lonjakan sebesar 8,86% ini sangat krusial karena menunjukkan model menjadi jauh lebih selektif dan akurat, sehingga mengurangi risiko kesalahan diagnosis yang berpotensi memicu kecemasan yang tidak perlu bagi mahasiswa.

3. Recall (*Sensitivitas*) Nilai *recall* pada model awal mencapai angka sempurna yaitu 100%, yang kemudian terkoreksi menjadi 97,73% setelah optimasi. Meskipun secara numerik terjadi penurunan kecil sebesar 2,27%, nilai ini tetap berada pada kategori yang sangat tinggi. Hal ini menjamin bahwa model tetap memiliki sensitivitas yang kuat dalam mendeteksi hampir seluruh kasus mahasiswa yang benar-benar mengalami depresi, sehingga meminimalisir risiko adanya kasus depresi yang terabaikan (*False Negative*).
4. *F1-Score* Sebagai nilai rata-rata harmonis yang menyeimbangkan presisi dan *recall*, *F1-Score* mengalami peningkatan dari 91,67% menjadi 95,56%. Kenaikan ini menegaskan bahwa model SVM + BE tidak hanya unggul pada satu sisi metrik saja, melainkan memiliki stabilitas performa yang merata. *F1-Score* yang tinggi memberikan keyakinan bahwa model ini andal digunakan sebagai instrumen deteksi dini yang seimbang antara ketajaman diagnosa dan ketepatan prediksi.

Secara visual dan numerik, penggabungan SVM dengan *Backward Elimination* berhasil menciptakan model yang lebih ramping namun lebih bertenaga. Transformasi ini membuktikan bahwa dalam pengembangan sistem pakar kesehatan mental, kualitas fitur jauh lebih menentukan dibandingkan kuantitas fitur.

F. Pembahasan Umum

Hasil penelitian ini secara empiris membuktikan bahwa integrasi *Backward Elimination* (BE) pada algoritma *Support Vector Machine* (SVM) mampu mentransformasi model prediksi menjadi instrumen yang jauh lebih akurat dalam mendeteksi potensi depresi mahasiswa. Signifikansi penelitian ini tidak hanya terletak pada angka akhir, tetapi pada konsistensi performa yang dihasilkan melalui penyederhanaan variabel-variabel kunci seperti tekanan akademik, kepuasan belajar, stres finansial, dan riwayat keluarga.

Dalam konteks literatur riset, keunggulan metode ini terlihat jelas saat dibandingkan dengan penelitian-penelitian sebelumnya. Sebagai contoh, penelitian oleh [10], yang menerapkan SVM tanpa optimasi fitur melaporkan akurasi sebesar 94,22%. Dengan pencapaian akurasi sebesar 96,04% pada studi ini, terdapat selisih keunggulan sebesar 1,82% yang menegaskan bahwa eliminasi fitur yang tidak relevan (seperti gender dan durasi tidur) secara drastis mengurangi *noise* yang menghambat ketajaman algoritma SVM.

Lebih lanjut, jika disandingkan dengan tren penelitian *machine learning* pada domain kesehatan mental, penggunaan seleksi fitur berbasis eliminasi mundur (*backward*) sering kali menunjukkan performa yang lebih stabil dibandingkan metode seleksi fitur tunggal lainnya. Hal ini sejalan dengan temuan [28], yang menekankan bahwa pengurangan fitur secara sistematis pada SVM dapat meningkatkan konvergensi model pada *hyperplane* yang lebih optimal. Begitu pula dengan studi [32] yang menyatakan bahwa meskipun SVM adalah algoritma yang kuat untuk data non-linear, efektivitasnya sangat bergantung pada kualitas input data. Dengan demikian, keberhasilan studi ini dalam melampaui tolok ukur (*benchmarking*) penelitian terdahulu mengukuhkan bahwa SVM-BE merupakan salah satu metode terbaik untuk menangani dataset psikologis yang memiliki keterkaitan fitur yang kompleks.

Secara psikologis dan klinis, temuan ini memberikan validasi kuantitatif terhadap literatur kesehatan mental. Depresi mahasiswa yang bersifat multifaktorial—melibatkan aspek emosional, akademik, dan sosial—tercermin secara akurat melalui fitur-fitur yang dipertahankan oleh model BE. Hal ini menunjukkan bahwa integrasi *machine learning* dengan metode seleksi fitur yang tepat tidak hanya menghasilkan angka akurasi yang tinggi, tetapi juga memberikan wawasan yang selaras dengan diagnosis psikologis konvensional, sehingga sangat layak diaplikasikan sebagai sistem pendukung keputusan (*decision support system*) di lingkungan universitas.

IV. KESIMPULAN

Penelitian ini menyimpulkan bahwa integrasi algoritma *Support Vector Machine* (SVM) dengan seleksi fitur *Backward Elimination* (BE) menunjukkan kinerja yang kompetitif dan efektif untuk klasifikasi depresi mahasiswa. Penerapan *Backward Elimination* mampu meningkatkan efektivitas model secara signifikan melalui eliminasi variabel yang tidak relevan, sehingga akurasi meningkat dari 92,08% menjadi 96,04%. Penggunaan BE terbukti krusial dalam mempertajam ketepatan prediksi dan stabilitas model dengan memfokuskan pada fitur-fitur yang memiliki pengaruh signifikan secara klinis, serta berhasil melampaui hasil penelitian sebelumnya yang hanya mencapai akurasi 94,22% tanpa optimasi fitur. Keunggulan performa ini, terutama pada peningkatan nilai presisi dan *F1-score*, menjadikan model yang diusulkan sebagai instrumen deteksi dini yang andal dan efisien untuk digunakan di lingkungan akademik. Sebagai rekomendasi pengembangan di masa depan, penelitian selanjutnya dapat difokuskan pada optimasi hyperparameter menggunakan *Bayesian Optimization* atau eksplorasi algoritma ensemble seperti *XGBoost* untuk menguji konsistensi performa model pada arsitektur yang lebih kompleks.

Meskipun model yang diusulkan menunjukkan performa klasifikasi yang tinggi, hasil prediksi yang dihasilkan tidak dimaksudkan sebagai diagnosis klinis, melainkan sebagai alat bantu skrining awal depresi mahasiswa. Kesalahan

klasifikasi, baik *false positive* maupun *false negative*, tetap memiliki implikasi yang perlu dipertimbangkan dalam konteks kesehatan mental. Oleh karena itu, penerapan model ini harus disertai dengan pendampingan profesional di bidang psikologi atau konseling agar hasil prediksi dapat ditindaklanjuti secara tepat. Selain itu, aspek etika, privasi data, dan kerahasiaan informasi mahasiswa harus menjadi perhatian utama dalam implementasi model di lingkungan kampus.

DAFTAR PUSTAKA

- [1] W. H. Organization, "World Mental Health Report 2023," WHO Press, 2023.
- [2] X. Li, Y. Chen, and L. Wang, "Depression Prediction in University Students Using Machine Learning Approaches," *J. Ment. Heal. Informatics*, vol. 12, no. 2, pp. 45–58, 2023.
- [3] A. Wahdi, S. Wilopo, and H. Erskine, "Indonesia National Adolescent Mental Health Survey 2023," *Indones. J. Ment. Heal.*, 2023.
- [4] B. P. Statistik, "Statistik Pendidikan Tinggi 2023," BPS, 2023.
- [5] R. Wardani and M. Rahman, "Pengaruh Stres Akademik terhadap Depresi Mahasiswa," *J. Psikol.*, 2023.
- [6] R. Alamsyah and D. Putra, "Beban Akademik dan Dampaknya terhadap Kesehatan Mental Mahasiswa," *J. Pendidik.*, 2022.
- [7] F. Anwar, R. Sari, and D. Nugraha, "Hubungan Tekanan Akademik dengan Tingkat Depresi pada Mahasiswa," *J. Psikol. Pendidik.*, 2022.
- [8] T. Hermawan, "Machine Learning Approach for Early Mental Health Detection," *J. Teknol. Inf.*, 2025.
- [9] M. Khan, F. Abdullah, and S. Rahman, "Support Vector Machine Performance in Nonlinear Psychological Data Classification," *Int. J. Behav. Comput.*, vol. 7, no. 1, pp. 21–34, 2022.
- [10] M. Risqi, W. Prastya, and J. Vikri, "Depression Classification Using SVM: A Study on Student Dataset," *J. Inform.*, 2025.
- [11] S. Putri, "Structural Risk Minimization in Modern Machine Learning," *Mach. Learn. Rev.*, 2023.
- [12] L. Guido, "Advances in Computational Mental Health Modeling," *Comput. Psychol. J.*, 2024.
- [13] N. Rakhmawati, A. Taufiq, and F. Maulana, "Backward Elimination for Feature Optimization on Health Data," *J. Ilmu Komput. dan Inf.*, 2023.
- [14] R. Safira and I. Sari, "Improving Health Prediction Accuracy Using Feature Selection," *J. Kesehat. Digit.*, 2025.
- [15] E. P. Efendi, M. A. Barata, and A. D. Ardianti, "Komparasi Metode Svm Dan C4.5 Dengan Backward Elimination Untuk Klasifikasi Stres," *JIKO (Jurnal Inform. dan Komputer)*, vol. 9, no. 3, p. (Halaman tidak tersedia, mohon periksa PDF)-(Halam, Mar. 2025, [Online]. Available: <https://ejournal.akakom.ac.id/index.php/jiko/article/view/2130>
- [16] A. Susanto, E. Wijaya, and I. Setiawan, "Predictive Analytics for Medical Classification Using SVM," *Bioinforma. Heal. Anal.*, 2024.
- [17] X. Zhang, Y. Liu, and H. Chen, "Social Media-Based Depression Detection Using SVM and Feature Reduction," *ACM Soc. Comput.*, 2023.
- [18] R. Juwita, A. Santoso, and M. Lestari, "Quantitative Approach for Machine Learning Evaluation in Mental Health Research," *J. Data Sci. Appl.*, vol. 5, no. 2, pp. 112–125, 2023.
- [19] T. Nguyen, P. Do, and L. Tran, "Reproducible Machine Learning Pipelines for Healthcare Data," *Healthc. Anal. Rev.*, vol. 9, no. 4, pp. 201–219, 2022.
- [20] A. Aliyev and S. A. Ozel, "Effective Methods of Categorical Data Encoding for Artificial Intelligence Algorithms," *Appl. Sci.*, vol. 13, no. 16, pp. 1–20, 2023.
- [21] D. Putra, R. Wibowo, and L. Sasmita, "The Efficiency of Label Encoding for Margin-Based Models in Machine Learning," *Indones. J. Inf. Syst.*, vol. 6, no. 1, pp. 33–47, 2024.
- [22] T. Handayani, R. Saputra, and S. Miranti, "Effect of Data Scaling Methods on Machine Learning Algorithms and Model Performance," *Appl. Data Eng. J.*, vol. 4, no. 3, pp. 55–66, 2023.
- [23] A. Faqih, M. J. Vikri, and I. A. Sa'ida, "Optimizing Gated Recurrent Unit (GRU) for Gold Price Prediction: Hyperparameter Tuning and Model Evaluation on Historical XAU/USD Data," *J. Sisfokom (Sistem Inf. dan Komputer)*, 2025, [Online]. Available: <https://api.semanticscholar.org/CorpusID:278868230>
- [24] N. Fadlullah, "Normalization Strategies for Machine Learning Stability," *J. Comput. Optim.*, vol. 9, no. 1, pp. 14–26, 2024.
- [25] F. R. A. Harianto, Z. Alawi, and I. A. Sa'ida, "Pengaruh Komposisi Split Data Pada Akurasi Klasifikasi Penderita Diabetes Menggunakan Algoritma Machine Learning," *J. Sist. Inf. dan Inform.*, 2025, [Online]. Available: <https://api.semanticscholar.org/CorpusID:276281557>
- [26] B. Haryanto, "Kernel RBF Performance on Nonlinear Psychological Pattern Classification," *Comput. Psychol. J.*, vol. 14, no. 1, pp. 12–25, 2024.
- [27] M. Riahi and A. Khelifa, "Hyperparameter Effects on Support Vector Machine Optimization," *Int. J. Mach. Learn. Optim.*, vol. 11, no. 3, pp. 188–204, 2023.
- [28] J. Pardede, R. Silalahi, and M. Naibaho, "Performance Enhancement of SVM Classification Using Backward Elimination," *J. Data Sci. Heal. Anal.*, vol. 9, no. 2, pp. 77–89, 2021.
- [29] S. Aini, H. Darmawan, and P. Yuliana, "Why Accuracy is Not Enough: Evaluation Metrics for Health Classification," *J. Appl. Data Sci.*, vol. 4, no. 2, pp. 99–115, 2023.
- [30] P. R. Group, "Recall as a Clinical Priority Metric for Early Disease Detection," *Polibatam J. Informatics*, vol. 3, no. 1, pp. 22–33, 2022.
- [31] L. Rochmah, R. Pratama, and S. Fauziah, "F1-Score as the Most Reliable Metric for Imbalanced Biomedical Classification," *Biomed. Comput. Rev.*, vol. 7, no. 2, pp. 44–59, 2023.
- [32] E. F. Laili, Z. Alawi, R. Rohmah, and M. A. Barata, "Komparasi Algoritma Decision Tree Dan Support Vector Machine (Svm) Dalam Klasifikasi Serangan Jantung," *J. Sist. Inf. dan Inform.*, 2025, [Online]. Available: <https://api.semanticscholar.org/CorpusID:276263579>