

PENERAPAN ALGORITMA SUPPORT VECTOR MACHINE (SVM) UNTUK MENGUKUR TINGKAT STRES MAHASISWA SEMESTER AKHIR

Yennimar¹
Rohib Nabil Dauly²
Rahmad Rifky Alfaresh^{3*}
Tiara Dwi Tasya⁴
Venus Angela Bu'ulolo⁵

^{1,2,3,4,5}Teknik Informatika, Universitas Prima Indonesia, Indonesia
Jl. Sampul No.3, Sei Putih Barat., Kec. Medan Petisah, Kota Medan, Sumatera Utara 20118,
INDONESIA

Abstract

This study focuses on the development of an academic stress classification system for university students undergoing the thesis-writing process using the Support Vector Machine (SVM) algorithm and comparing its performance with Random Forest. The dataset consisted of responses from 150 final-year students collected through a Likert-scale questionnaire covering four dimensions of academic stress: physiological, cognitive, behavioral, and emotional aspects. Data preprocessing, validity testing, and reliability testing were conducted before the modeling stage. The research methodology applied SVM with the Radial Basis Function (RBF) kernel and Random Forest as a comparative algorithm. Hyperparameter optimization was performed using Grid Search, while model validation employed Stratified K-Fold Cross Validation ($k=10$). Model performance was evaluated using accuracy, precision, recall, F1-score, and ROC-AUC metrics. The results showed that SVM outperformed Random Forest, achieving an accuracy of 96.00%, precision of 96.31%, recall of 95.07%, F1-score of 94.56%, and ROC-AUC of 1.000, while Random Forest achieved an accuracy of 94.00%. The distribution of stress levels indicated that 66% of respondents experienced moderate stress. Furthermore, the emotional aspect was identified as the most influential factor contributing to academic stress intensity. These findings demonstrate that SVM is effective for academic stress classification and has potential to support the development of early stress detection systems in higher education institutions.

Keywords:

Academic Stress; Classification; Final-Year Students; Random Forest; Support Vector Machine

Abstrak

Pengembangan sistem klasifikasi stres akademik bagi mahasiswa yang sedang menempuh proses penyusunan skripsi menjadi fokus utama penelitian ini, dengan menempatkan algoritma *Support Vector Machine* (SVM) sebagai metode utama yang dikomparasikan dengan *Random Forest*. Basis data penelitian bersumber dari 150 mahasiswa akhir yang memberikan respons terhadap kuesioner berskala Likert, mencakup indikator-indikator dari empat domain, fisiologis, kognitif, perilaku dan emosional. Integritas data dijamin melalui prosedur pra-pemrosesan yang sistematis, diikuti verifikasi validitas dan reliabilitas instrumen sebelum tahap pemodelan dilakukan. Kerangka metodologis penelitian ini mengintegrasikan SVM dengan fungsi kernel *Radial Basis Function* (RBF) dan *Random Forest* sebagai algoritma pembandingan, didukung oleh teknik *Grid Search* untuk optimasi hiperparameter serta *Stratified K-Fold Cross Validation* ($k=10$) sebagai prosedur validasi model. Performa kedua algoritma dievaluasi secara komprehensif menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Temuan empiris mengindikasikan keunggulan SVM atas *Random Forest*, dengan capaian *accuracy* sebesar 96,00%, *precision* 96,31%, *recall* 95,07%, *F1-score* 94,56%, dan *ROC-AUC* bernilai sempurna 1,000, sementara *Random Forest* mencatatkan *accuracy* 94,00%. Distribusi tingkat stres responden memperlihatkan proporsi terbesar, yakni 66% pada kategori stres sedang. Analisis terhadap kontribusi dimensi mengungkapkan bahwa aspek emosional menjadi faktor paling determinan dalam membentuk intensitas stres akademik mahasiswa. Berdasarkan keseluruhan temuan tersebut, algoritma SVM terbukti efektif sebagai instrumen identifikasi stres akademik dan membuka peluang pengembangannya sebagai fondasi sistem deteksi dini stres di lingkungan perguruan tinggi.

Kata kunci:

Klasifikasi; Mahasiswa akhir; Random Forest; Stres Akademik; Support Vector Machine

***Corresponding author:**

Rahmad Rifky Alfaresh, Teknik Informatika, Universitas Prima Indonesia Jl. Sampul No.3, Sei Putih Barat., Kec. Medan Petisah, Kota Medan, Sumatera Utara 20118, INDONESIA

Email: alfareshrahmadrifky@gmail.com

1. PENDAHULUAN

Menurut laporan Psikososial Nasional Kementerian Kesehatan RI, pada Januari-April 2025 sebanyak 1.123 kasus bunuh diri di Indonesia, dengan 142 kasus (12,6%) melibatkan individu berusia 18–25 tahun yang sebagian besar merupakan mahasiswa. Penelitian WHO WMH-ICS periode 2014–2018 menunjukkan bahwa 93,7% mahasiswa mengalami stres, dengan 73,8% mengalami stres pada tiga area atau lebih secara bersamaan (Fatah & Hasanah, 2025). Kondisi tersebut menunjukkan bahwa stres akademik mahasiswa merupakan persoalan serius. Stres akademik muncul akibat tekanan akademik, kesulitan menyelesaikan tugas akhir, ketidakpastian masa depan, serta tuntutan lingkungan sosial. Gejala yang muncul meliputi emosi tidak terkontrol, gelisah, mudah lelah, sulit berkonsentrasi, hingga kecemasan berlebihan (Saifudin et al., 2023). Apabila tidak ditangani dengan baik, stres dapat berkembang menjadi depresi, menurunkan performa akademik, memperlambat penyelesaian studi, bahkan berpotensi menyebabkan tindakan bunuh diri (Putra et al., 2023).

Dalam kajian teoritis, *SVM* merupakan salah satu algoritma machine learning yang mampu menangani data berdimensi tinggi dan dataset berukuran terbatas. *SVM* bekerja dengan membentuk hyperplane optimal untuk memisahkan kelas data sehingga kesalahan generalisasi dapat diminimalkan (Aisah et al., 2023). Penggunaan fungsi kernel memungkinkan *SVM* menyelesaikan permasalahan non-linear secara efektif. Oleh karena itu, *SVM* banyak diterapkan dalam penelitian klasifikasi kesehatan mental, termasuk klasifikasi tingkat stres dan depresi mahasiswa (Fatah & Hasanah, 2025; Putri & Agung, 2023; Pratiwi et al., 2025). Idealnya, identifikasi tingkat stres mahasiswa seharusnya dapat dilakukan secara cepat, objektif, dan akurat sehingga institusi pendidikan dapat memberikan intervensi yang tepat. Namun pada praktiknya, identifikasi masih sering dilakukan secara manual dan penelitian terdahulu berfokus pada peningkatan performa model dibandingkan analisis faktor yang mempengaruhi tingkat stres mahasiswa (Mahing et al., 2024; Ramadani et al., 2024).

Penelitian terdahulu mengkaji klasifikasi tingkat stres mahasiswa menggunakan metode machine learning. Penelitian oleh (Fatah & Hasanah, 2025) menunjukkan hasil yang baik, namun belum disertai perbandingan algoritma lain maupun analisis kontribusi aspek stres. Mahing et al., (2024) membandingkan *SVM* dan *Random Forest* pada data teks berakurasi tertinggi 71,2%, sedangkan Anisa et al., (2024) menggunakan *KNN* dengan akurasi 91,58% namun memiliki keterbatasan sensitivitas data dan pemilihan nilai *K*. Penelitian-penelitian tersebut belum mengintegrasikan optimasi parameter menggunakan *Grid Search*, evaluasi *Stratified K-Fold Cross Validation*, serta analisis kontribusi aspek stres secara bersamaan dalam satu kerangka penelitian yang komprehensif.

Berdasarkan permasalahan tersebut, penelitian ini menerapkan algoritma *SVM* dengan optimasi *Grid Search* untuk mengklasifikasikan tingkat stres akademik mahasiswa, membandingkan performanya dengan *Random Forest*, serta menganalisis kontribusi aspek fisiologis, kognitif, perilaku, dan emosional terhadap tingkat stres mahasiswa akhir.

Penelitian ini bertujuan untuk mengetahui tingkat stres akademik mahasiswa akhir berdasarkan aspek fisiologis, kognitif, perilaku, dan emosional, serta mengimplementasikan dan membandingkan performa algoritma *SVM* dan *Random Forest* dalam mengklasifikasikan tingkat stres akademik.

2. STUDI PUSTAKA

2.1. Support Vector Machine (SVM)

SVM merupakan algoritma *machine learning* yang unggul dalam menangani data berdimensi tinggi, performa optimal pada dataset berukuran terbatas, serta kapasitasnya dalam menyelesaikan permasalahan *non-linear* melalui mekanisme fungsi kernel. *SVM* bekerja dengan membangun *hyperplane* optimal sebagai

bidang pemisah antarkelas dengan memaksimalkan margin, sehingga menghasilkan kemampuan klasifikasi yang baik (Aisah et al., 2023; Yennimar et al., 2023).

2.2 Random Forest


Random Forest merupakan algoritma *ensemble learning* yang membangun banyak pohon keputusan menggunakan teknik *bootstrap sampling*. Prediksi dari setiap pohon digabungkan melalui *majority voting* sehingga menghasilkan model yang lebih akurat dan mampu mengurangi risiko *overfitting* (Larasati et al., 2024).

2.3 Stres Akademik

Stres akademik pada mahasiswa umumnya dipicu oleh beban akademik, ketidakpastian masa depan, serta ekspektasi dari lingkungan sosial. Kondisi ini dapat ditandai dengan emosi tidak terkontrol, lelah, mudah tersinggung, sulit konsentrasi, hingga kecemasan berlebihan (Fatah & Hasanah, 2025).

3. METODE PENELITIAN

3.1 Metode Yang Diusulkan



Gambar 1. Alur desain penelitian

Penelitian ini menggunakan pendekatan eksperimental. Dengan bantuan metode kuantitatif tingkat stres diukur secara objektif berdasarkan data kuesioner yang terukur, sedangkan kerangka eksperimental diterapkan guna menganalisis efektivitas dua metode *machine learning*, yaitu *SVM* dan *Random Forest*, dalam menetapkan tingkat stres akademik mahasiswa (Septini et al., 2025; Tugiman et al., 2022; Kuntoro & Fajrie, 2023).

3.2 Pengumpulan Data

Pengumpulan data dilakukan melalui penyebaran kuesioner secara daring menggunakan *Google Form* kepada mahasiswa tingkat akhir yang sedang menyusun skripsi pada periode 1–7 Januari 2026. Setiap responden hanya diperbolehkan mengisi kuesioner satu kali untuk menghindari duplikasi data. Seluruh respons kemudian diperiksa guna memastikan kelengkapan data dan menghapus respons yang tidak valid atau terduplikasi. Sebelum digunakan sebagai dataset penelitian, instrumen telah melalui uji validitas menggunakan Pearson *Product Moment* dan uji reliabilitas menggunakan Cronbach's Alpha. Data yang memenuhi kriteria berjumlah 150 responden dan disimpan dalam format CSV.

3.3 Penentuan Kelas Tingkat Stres

Instrumen penelitian terdiri atas 40 item pernyataan yang dikembangkan berdasarkan empat aspek stres akademik, yaitu fisiologis, kognitif, perilaku, dan emosional, dengan masing-masing aspek diwakili oleh 10 pernyataan. Seluruh item diukur menggunakan skala Likert 4 poin (1–4), sehingga skor total berada pada rentang 40–160. Selanjutnya, skor tersebut diklasifikasikan ke dalam tiga kategori tingkat stres akademik sebagai berikut:

Tabel 1. Rentang kategori

Rentang Skor	Kategori
40 – 80	Rendah
81 – 120	Sedang

3.4 Operasional Variabel

Variabel dalam penelitian ini didefinisikan beserta indikatornya seperti pada tabel berikut.

Tabel 2. Definisi operasional variabel

Variabel	Definisi	Indikator
Fisiologis	Respon fisik akibat stres akademik	Mudah lelah, sakit kepala, gangguan tidur
Kognitif	Gangguan proses berpikir	Sulit konsentrasi, mudah lupa
Perilaku	Perubahan prilaku akibat stres	Menunda pekerjaan, menarik diri
Emosional	Perubahan kondisi emosi	Cemas, sedih, mudah marah

3.5 Validasi Model

Sebelum tahap klasifikasi, dataset diproses menggunakan *Stratified K-Fold Cross Validation* dengan nilai $k=10$. Tahapan ini membagi data ke dalam 10 fold dengan memastikan komposisi kelas yang proporsional pada setiap partisi. Setiap fold secara bergantian difungsikan sebagai data uji, sehingga keseluruhan data tervalidasi secara menyeluruh dan hasil evaluasi tidak bergantung pada satu skema pembagian data tertentu (Septini et al., 2025).

3.6 Hyperparameter Tuning

Hyperparameter tuning dilakukan untuk memperoleh kombinasi parameter terbaik yang meningkatkan performa model klasifikasi. Pada algoritma *SVM*, tuning dilakukan pada parameter C dan γ menggunakan metode *Grid Search*. Sedangkan pada algoritma Random Forest, tuning dilakukan pada parameter $n_estimators$, max_depth , $min_samples_split$, dan $min_samples_leaf$. Kombinasi parameter terbaik dipilih berdasarkan hasil evaluasi performa model.

Tabel 2. Nilai parameter uji

Model	Parameter	Nilai
Support Vector Machine	C	0.1, 1, 10, 100 (4 nilai)
	γ	0.001, 0.01, 0.1, 1 (4 nilai)
	kernel	Rbf (1 nilai)
Random Forest	$n_estimators$	300 (1 nilai)
	max_depth	10 (1 nilai)
	$min_samples_split$	5 (1 nilai)
	$min_samples_leaf$	2 (1 nilai)
	$class_weight$	Balanced (1 nilai)

3.7 Evaluasi Model

Untuk memastikan kemampuan generalisasi yang baik, kinerja model dievaluasi pada setiap fold. Evaluasi model dilakukan berdasarkan *Accuracy*, *Precision*, *Recall*, *F1-Score*, ROC-AUC, dan Standar Deviasi

antar fold. Setiap metrik dihitung secara rata-rata dari 10 fold untuk menghasilkan perkiraan kinerja yang stabil dan tidak bias.

3.8 Analisis Kontribusi Aspek

Analisis kontribusi aspek menggunakan metode Korelasi Pearson dilakukan untuk mengukur tingkat hubungan antara aspek fisiologis, kognitif, perilaku, dan emosional terhadap tingkat stres mahasiswa. Pengukuran dilakukan menggunakan rumus Pearson *Product Moment Correlation* untuk mengetahui hubungan antara skor masing-masing aspek dengan total skor stres mahasiswa.

$$r_{xy} = \frac{n \sum x_i y_i - (\sum x_i)(\sum y_i)}{\sqrt{[n \sum x_i^2 - (\sum x_i)^2][n \sum y_i^2 - (\sum y_i)^2]}}$$

Nilai koefisien korelasi yang diperoleh, diinterpretasikan berdasarkan tingkat hubungan, mulai dari sangat rendah hingga sangat kuat, serta dikonversi ke dalam bentuk persentase untuk mengidentifikasi aspek paling dominan dalam memengaruhi stres akademik mahasiswa akhir (Tugiman et al., 2022). Berikut interpretasi nilai Korelasi Pearson yang umum digunakan sebagai acuan dalam penelitian:

Tabel 3. Koefisien relasi

Interval koefisien	Tingkat Hubungan
0,00 – 0,199	Sangat Rendah
0,20 – 0,399	Rendah
0,40 – 0,599	Cukup
0,60 – 0,799	Kuat
0,80 – 1,000	Sangat Kuat

4. HASIL DAN PEMBAHASAN

4.1 Deskripsi Data

Data penelitian diperoleh dari 150 mahasiswa akhir Universitas Prima Indonesia yang sedang menyusun skripsi. Berdasarkan rentang skor yang telah ditetapkan, sebanyak 30 mahasiswa (20%) berada pada kategori stres rendah, 99 mahasiswa (66%) berada pada kategori stres sedang, dan 21 mahasiswa (14%) berada pada kategori stres tinggi. Distribusi ini menunjukkan bahwa mayoritas mahasiswa akhir mengalami stres pada level sedang, yang mengindikasikan bahwa proses penyusunan skripsi memberikan tekanan psikologis, namun masih dalam ambang batas yang dapat ditangani secara adaptif.

4.2 Hasil Evaluasi Model

4.2.1 Evaluasi Model Dengan Stratified K-Fold Cross Validation

Hasil evaluasi menggunakan *Stratified K-Fold Cross Validation* (k=10) menunjukkan bahwa *SVM* dengan kernel RBF memiliki performa lebih baik dibandingkan *Random Forest* pada seluruh metrik evaluasi. Nilai ROC-AUC kedua model mendekati sempurna disebabkan oleh pemisahan kelas yang sangat jelas pada dataset, sehingga keempat aspek mampu memisahkan kelas dengan sangat baik. Hasil evaluasi lengkap disajikan pada Tabel 4.

Tabel 4. Hasil evaluasi model klasifikasi

Metrik	SVM	Random Forest	Selisih	Keterangan
Accuracy	96,00%	94,00%	+2,00%	SVM Unggul

Precision	96,31%	95,20%	+1,11%	SVM Unggul
Recall	95,07%	91,74%	+3,33%	SVM Unggul
F1-Score	94,56%	91,81%	+2,75%	SVM Unggul
ROC-AUC	1,000	0,9972	+0,0028	SVM Unggul

Nilai ROC-AUC yang mendekati sempurna pada kedua model menunjukkan bahwa pemisahan kelas dataset berlangsung dengan sangat baik. Hal tersebut disebabkan rentang skor antar kategori stres yang tidak mengalami overlap sehingga aspek fisiologis, kognitif, perilaku, dan emosional mampu membedakan kelas secara jelas. Namun demikian, *SVM* menunjukkan tingkat stabilitas yang lebih baik dibandingkan *Random Forest* yang ditunjukkan oleh standar deviasi yang lebih rendah.

4.3 Hasil Analisis Kontribusi Aspek

Analisis kontribusi menggunakan Korelasi Pearson menghasilkan nilai seperti pada Tabel 5. Seluruh aspek memiliki kontribusi yang relatif seimbang, dengan aspek emosional sebagai yang paling dominan.

Tabel 5. Nilai korelasi dan kontribusi

Aspek	Korelasi Pearson	Kontribusi (%)
Emosional	0,847	26,3 %
Kognitif	0,813	25,2 %
Fisiologis	0,783	24,3 %
Perilaku	0,778	24,1 %

4.4 Hasil Pemodelan Klasifikasi

Model *SVM* berhasil mengklasifikasikan 150 data ke dalam tiga kategori tingkat stres dengan akurasi rata-rata 96,00% melalui *10-fold cross validation*. Pada setiap fold, model mampu mengidentifikasi pola dari keempat aspek kuesioner secara konsisten, dengan parameter optimal $C = 10$ dan $\text{Gamma} = 0,1$ yang diperoleh melalui *Grid Search*. Penggunaan *Pipeline* dengan *StandardScaler* memastikan tidak terjadi data *leakage* antar *fold* sehingga hasil evaluasi mencerminkan performa model pada data baru. Selain itu, ketidakseimbangan distribusi kelas ditangani menggunakan parameter *class_weight='balanced'*, sehingga model tetap memperhatikan kelas minoritas selama proses pelatihan.

Sementara itu, model *Random Forest* juga berhasil mengklasifikasikan data dengan akurasi rata-rata 94,00% menggunakan parameter optimal *n_estimators=300* dan *max_depth* yang teroptimasi, di mana pohon keputusan dibangun menggunakan *bootstrap sampling* dengan *class_weight='balanced'* untuk menangani ketidakseimbangan distribusi kelas antara kategori rendah (20%), sedang (66%), dan tinggi (14%). Meskipun *Random Forest* menunjukkan performa yang baik, standar deviasi antar fold yang lebih tinggi (0,066) dibandingkan *SVM* (0,032) mengindikasikan bahwa *Random Forest* kurang stabil dalam menangani variasi data pada dataset berukuran kecil, sejalan dengan karakteristik *Random Forest* yang umumnya membutuhkan jumlah sampel lebih besar untuk membangun pohon-pohon keputusan yang beragam dan representatif.

4.5 Pembahasan

Keunggulan *SVM* dibandingkan *Random Forest* dipengaruhi oleh tiga faktor utama. Pertama, ukuran dataset relatif kecil sehingga lebih sesuai untuk *SVM*. Kedua, kernel RBF memungkinkan *SVM* menangkap hubungan *non-linear* yang kompleks dengan lebih baik. Ketiga, standar deviasi *SVM* lebih rendah (0,032 vs 0,066) menunjukkan performa model lebih stabil antar fold.

Jika dibandingkan penelitian terdahulu, hasil akurasi 91,58% menunjukkan peningkatan yang signifikan menggunakan KNN (Anisa et al., 2024), sedangkan Mahing et al., (2024) melaporkan akurasi *Random Forest* 71,2% pada data teks, Mujaky et al., (2026) melaporkan akurasi *Decision Tree* 55% menggunakan

variabel non-psikologis, jauh di bawah hasil penelitian ini. Peningkatan performa dalam penelitian ini dikaitkan dengan kombinasi *Grid Search* untuk optimasi parameter dan *Stratified K-Fold* untuk validasi yang lebih robust, serta penggunaan data kuesioner terstruktur berbasis empat aspek psikologis yang relevan.

Dominansi aspek emosional (26,3%) sejalan dengan karakteristik proses penyusunan skripsi yang sarat ketidakpastian, tekanan deadline, dan evaluasi berulang dari dosen pembimbing yang memicu kecemasan dan frustrasi berkepanjangan. Tingginya kontribusi aspek kognitif (25,2%) menunjukkan gangguan berpikir seperti sulit berkonsentrasi juga merupakan manifestasi signifikan. Temuan ini menggarisbawahi pentingnya program dukungan emosional berbasis *cognitive-behavioral approach* bagi mahasiswa akhir, serta layanan konseling akademik yang mudah diakses di lingkungan kampus.

5. SIMPULAN

Penelitian ini berhasil mengklasifikasikan tingkat stres akademik 150 mahasiswa akhir Universitas Prima Indonesia menggunakan *SVM* dan *Random Forest* berdasarkan data kuesioner empat aspek stres. *SVM* dengan kernel RBF yang dioptimasi melalui *Grid Search* dan divalidasi dengan *Stratified K-Fold* ($k=10$) terbukti unggul dengan akurasi 96,00% dan ROC-AUC sempurna 1,000, melampaui *Random Forest* (akurasi 94,00%). Mayoritas mahasiswa (66%) berada pada kategori stres sedang, mengindikasikan tekanan psikologis yang bermakna selama penyusunan skripsi. Aspek emosional menjadi faktor paling dominan (26,3%), sehingga intervensi yang berfokus pada pengelolaan emosi dan dukungan psikologis terstruktur perlu diprioritaskan. Penelitian selanjutnya disarankan memperluas sampel, menambahkan variabel faktor eksternal, menerapkan teknik *oversampling* seperti SMOTE untuk menangani data tidak seimbang, serta mengeksplorasi pendekatan *deep learning* untuk meningkatkan performa klasifikasi.

6. DAFTAR PUSTAKA

- Aisah, I. S., Irawan, B., & Suprapti, T. (2023). Algoritma support vector machine (SVM) untuk analisis sentimen ulasan aplikasi Al-Qur'an digital. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3759–3765. <https://doi.org/10.36040/jati.v7i6.8263>
- Anisa, S., Komarudin, A., & Ramadhan, E. (2024). Sistem klasifikasi untuk menentukan tingkat stres mahasiswa secara umum menggunakan metode k-nearest neighbors. *Jurnal Informatika Teknologi dan Sains (JINTEKS)*, 6(3), 568–578. <https://doi.org/10.51401/jinteks.v6i3.4317>
- Putra, D. E., Nelwati, N., & Fernandes, F. (2023). Hubungan depresi, stres akademik, dan regulasi emosi terhadap ide bunuh diri pada remaja. *Jurnal Keperawatan Jiwa (JKJ): Persatuan Perawat Nasional Indonesia*, 11, 689–702.
- Fatah, Z., & Hasanah, U. (2025). Prediksi tingkat stres dan kesehatan mental mahasiswa menggunakan algoritma SVM. *Jurnal Mahasiswa Teknik Informatika*, 4(2). <https://doi.org/10.35473/jamastika.v4i2.4542>
- Kuntoro, B. T., & Fajrie, N. (2023). Strategi membangun empati dalam pembelajaran. *Jurnal Tunas Bangsa*, 10(1), 1–10.
- Larasati, S. S. A., Dewi, E. N. K., Farhansyah, B. H., Bachtiar, F. A., & Pradana, F. (2024). Penerapan decision tree dan random forest dalam deteksi tingkat stres manusia berdasarkan kondisi tidur. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(5), 1043–1050. <https://doi.org/10.25126/jtiik.2024117993>
- Mahing, N. F., Gunawan, A. L., Foresta, A., & Zen, A. (2024). Klasifikasi tingkat stres dari data berbentuk teks menggunakan algoritma support vector machine (SVM) dan random forest. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(5). <https://doi.org/10.25126/jtiik2024118010>
- Mujaky, A. M., Telaumbanua, B., Safitri, D., Ardiansyah, F. A., Hafiz, M. I., Informasi, T., Teknik, F., Bina, U., & Informatika, S. (2026). Prediksi tingkat stres mahasiswa menggunakan algoritma decision tree predicting student stress levels through decision tree algorithm : a machine learning. 4(1), 188–194. <https://doi.org/10.26905/jisad.v4i1.16616>
- Ramadani, N. C., Tahyudin, I., & Barkah, A. S. (2024). Perbandingan algoritma support vector machine, decision tree, dan logistic regression pada analisis sentimen ulasan aplikasi Netflix. 2, 110–117.
- Pratiwi, E. E., Aisy, A. R., Rahmadden, & Ananta, N. (2025). Klasifikasi kesehatan mental pada usia remaja menggunakan metode SVM. *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, 13(2). <https://doi.org/10.23960/jitet.v13i2.6232>
- Putri, K., & Agung, M. (2023). Implementasi algoritma support vector machine dalam klasifikasi deteksi depresi dari postingan pada media sosial. 2, 193–202.

- Saifudin, M., Adawiyah, S. R., & Mukhaira, I. (2023). Faktor-faktor yang memengaruhi tingkat stres akademik pada mahasiswa program studi S1 keperawatan nonreguler. *Jurnal Kesehatan*, 12(2), 199–207. <https://doi.org/10.37048/kesehatan.v12i2.267>
- Septini, A., Susanto, & Elmayati. (2025). Analisis sentimen masyarakat di Twitter mengenai OpenAI ChatGPT menggunakan metode support vector machine (SVM). *Bulletin of Computer Science Research*, 5(2), 138–149. <https://doi.org/10.47065/bulletincsr.v5i2.475>
- Tugiman, T., Herman, H., & Yudhana, A. (2022). Uji validitas dan reliabilitas kuesioner model UTAUT untuk evaluasi sistem pendaftaran online rumah sakit. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 9(2), 1621–1630. <https://doi.org/10.35957/jatisi.v9i2.2227>
- Yennimar, Y., Rasid, A., & Kenedy, S. (2023). Implementation of support vector machine algorithm with hyperparameter tuning using randomized search for stroke prediction. *Jurnal Sistem Informasi dan Ilmu Komputer Prima (JUSIKOM PRIMA)*, 6(2), 61–65. <https://doi.org/10.34012/jurnalsisteminformasidanilmukomputer.v6i2.3479>