

Prediksi Tingkat Stress dan Kesehatan Mental Mahasiswa Menggunakan Algoritma SVM

Zaehol Fatah¹, Uswatun Hasanah²

^{1,2} Universitas Ibrahimy, Situbondo

Email:¹ zaeholfatah@gmail.com, ^{2*} uswatunt18@gmail.com

Abstrak

. Kesehatan mental mahasiswa menjadi sangat penting yang perlu mendapatkan perhatian, mengingat tingginya tingkat stres akibat tuntutan akademik, masalah sosial, maupun tekanan finansial. Stres yang tidak terkendali dapat menurunkan prestasi akademik dan berisiko menimbulkan gangguan psikologis jangka panjang. Oleh karena itu, dibutuhkan sebuah sistem yang mampu memprediksi tingkat stres dan kondisi kesehatan mental mahasiswa secara akurat. Penelitian ini bertujuan mengimplementasikan algoritma Support Vector Machine (SVM) dalam klasifikasi tingkat stres mahasiswa berdasarkan berbagai faktor seperti pola belajar, kualitas tidur, aktivitas sosial, serta kondisi psikologis lainnya. Data penelitian diolah menggunakan metode machine learning. Algoritma SVM dipilih karena kemampuannya menangani data kompleks dengan tingkat akurasi tinggi. Hasil penelitian menunjukkan bahwa SVM efektif digunakan dalam memprediksi tingkat stres mahasiswa dengan akurasi mencapai 88%, sehingga dapat mendukung upaya pencegahan dini dan intervensi kesehatan mental di lingkungan perguruan tinggi.

Kata Kunci: *Stres Mahasiswa, Kesehatan Mental, Machine Learning, Support Vector Machine (SVM), RapidMiner.*

PENDAHULUAN

Kemajuan dalam teknologi yang sangat pesat dapat mendukung berbagai aspek kehidupan, salah satunya adalah pendidikan. Sektor pendidikan tentu memerlukan teknologi untuk membantu mengelola kegiatan dengan menggunakan teknologi informasi (Lestari and Lestari 2024). Kesehatan mental merupakan salah satu aspek penting yang berpengaruh terhadap kualitas hidup, terutama bagi mahasiswa yang sedang berada pada fase transisi menuju kedewasaan. Kesehatan mental menjadi masalah serius yang semakin meningkat secara global, termasuk di Indonesia (Maldini, Utomo, and Tresyani 2025). Kesehatan mental menjadi isu global yang semakin mendesak, dengan meningkatnya jumlah individu yang mengalami gangguan mental di seluruh dunia (Nurul, Pulungan, and Utami 2025). Dalam beberapa tahun terakhir, kesehatan mahasiswa menjadi perhatian utama bagi akademisi dan pemerintah, terutama karena tekanan akademis, gaya hidup tidak sehat, dan meningkatnya masalah kesehatan mental. salah satu komunitas yang berisiko tinggi menghadapi masalah kesehatan mental yaitu Kesulitan dalam

mengidentifikasi faktor-faktor penyebab masalah kesehatan mental menjadi tantangan dan hambatan dalam membantu orang dengan masalah kesehatan mental (Mohd Shafiee and Mutalib 2020). Stres menunjukkan bahwa seseorang sedang mengalami tekanan yang besar, baik dari segi emosi maupun mental. Setiap orang memiliki alasan yang berbeda-beda, dan ini bisa terjadi karena perubahan dalam lingkungan yang membuat tubuh dan pikiran perlu menyesuaikan diri (Adriansyah et al. 2022).

Stres merupakan salah satu faktor dominan yang memengaruhi kesehatan mental mahasiswa. Stres dapat diartikan sebagai respon tubuh, baik secara fisik maupun emosional, terhadap tekanan atau tuntutan yang dirasakan melebihi kemampuan seseorang untuk mengatasinya. Stress seringkali menjadi tantangan utama yang dihadapi oleh mahasiswa akibat tuntutan akademis dan sosial di lingkungan pendidikan. Faktor-faktor seperti gugup, ketidakmampuan untuk mengontrol diri, kekhawatiran, dsb. adalah beberapa pemicu stress yang semuanya dapat berdampak negatif terhadap kesehatan fisik dan mental mahasiswa. (Anisa, Komarudin, and

Ramadhan 2024). Kesehatan mental menjadi isu penting di kalangan mahasiswa. Tekanan akademik yang berat, persaingan ketat dalam perkuliahan, ekspektasi dari orang tua, serta dinamika kehidupan sosial dapat memicu munculnya gejala depresi (Budiyanto 2025). Selain itu, perkembangan teknologi dan media sosial meskipun membawa banyak manfaat, dan memberikan dampak negatif berupa tekanan sosial, perasaan cemas, bahkan kesepian (Fadhilla et al. 2025).

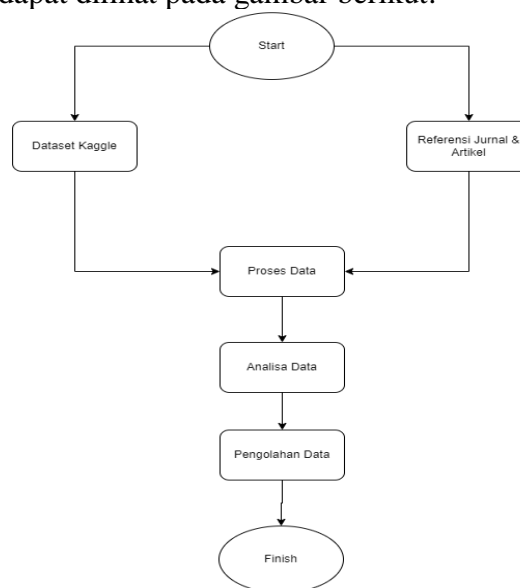
Dalam beberapa tahun terakhir, algoritma machine learning seperti Support Vector Machine (SVM) telah banyak digunakan dalam penelitian kesehatan mental untuk prediksi dan klasifikasi risiko. SVM dipilih karena kemampuannya dalam mengolah data berdimensi tinggi serta generalisasi yang baik, melalui penggunaan kernel yang mengoptimalkan pemisahan kelas (Fibriani et al. 2025). Selain itu, perbandingan SVM dengan metode lain seperti Random Forest dan Logistic Regression dalam mendeteksi stres dan depresi mahasiswa, di mana SVM menunjukkan performa kompetitif dalam klasifikasi kondisi mental. Terdapat perbedaan penting dalam pendekatan dan cakupan variabel pada penelitian-penelitian sebelumnya (Wijaya and Rachmat 2024). Perbandingan algoritma tanpa menambah konteks faktor eksternal yang berkembang pesat seperti perilaku digital mahasiswa. Penelitian ini berupaya mengisi kekosongan tersebut dengan mengintegrasikan faktor tekanan sosial dari media sosial, dinamika kehidupan kampus, dan variabel kesehatan mental tradisional, sehingga hasil prediksi lebih akurat dan relevan dengan kondisi terkini (Pratiwi et al. 2025).

Dengan demikian, penelitian ini tidak hanya melanjutkan pemanfaatan SVM dalam prediksi kesehatan mental mahasiswa tetapi juga mengembangkan model yang komprehensif untuk mengakomodasi berbagai faktor risiko. Harapannya, hasil penelitian ini dapat memberikan manfaat praktis berupa deteksi dini yang efektif, membantu pihak kampus dan konselor

mengambil langkah strategis untuk meningkatkan kesejahteraan mental mahasiswa secara menyeluruh.

METODE

Proses penelitian yang diterapkan dalam penggunaan algoritma SVM untuk memprediksi tingkat stres dan kesehatan mental mahasiswa menggunakan metode SVM (Fadillah Abdullah and Rudyanto Arief 2022). Tahapan-tahapan dalam penelitian ini dapat dilihat pada gambar berikut.



Gambar 1. Metode Penelitian

a) Pengumpulan Data

Dataset diperoleh dari platform Kaggle, yang menyediakan data terkait kesehatan mental dan tingkat stres mahasiswa. Dataset ini berisi berbagai atribut yang menggambarkan kondisi fisik, sosial, dan psikologis mahasiswa yang berpengaruh terhadap tingkat stres (Wahono 2023). Data tersebut digunakan untuk melakukan proses prediksi menggunakan algoritma Support Vector Machine (SVM). Adapun atribut yang digunakan dalam penelitian ini meliputi:

1. Usia: Informasi usia mahasiswa yang menjadi responden penelitian.
2. Jenis Kelamin: Jenis kelamin mahasiswa (Pria/Wanita).
3. Pola Tidur: Kualitas dan durasi tidur mahasiswa (Baik/Sedang/Buruk).

4. Intensitas Belajar: Frekuensi belajar per hari atau per minggu (Rendah/Sedang/Tinggi).
5. Aktivitas Sosial: Frekuensi mahasiswa berinteraksi dengan teman atau mengikuti kegiatan sosial (Jarang/Sedang/Sering).
6. Tingkat Kecemasan: Tingkat kecemasan mahasiswa berdasarkan hasil kuesioner (Rendah/Sedang/Tinggi).
7. Dukungan Sosial: Tingkat dukungan yang diperoleh mahasiswa dari keluarga dan teman (Rendah/Sedang/Tinggi).
8. Kesehatan Fisik: Kondisi fisik mahasiswa secara umum (Baik/Sedang/Buruk).
9. Tekanan Ekonomi: Tingkat tekanan ekonomi yang dirasakan mahasiswa (Rendah/Sedang/Tinggi).
10. Tingkat Stres (Label): Hasil akhir klasifikasi yang menunjukkan tingkat stres mahasiswa (Rendah/Sedang/Tinggi).

b) Proses Pengumpulan Data

Pengumpulan data adalah langkah penting yang pertama dalam penelitian kesehatan, di mana informasi tentang subjek dalam dataset dikumpulkan dari sumber-sumber terpercaya seperti survei, catatan medis, dan sumber data kesehatan lainnya (Syamsiah and Darwaman 2020). Dengan demikian, setiap langkah dalam proses ini berkontribusi pada keberhasilan penelitian kesehatan secara keseluruhan.

Pada proses pengumpulan data ini menjadi Langkah penting dalam penelitian ini, dimana dataset yang diperoleh merupakan data yang valid, lengkap dan sesuai dengan kebutuhan yang akan dijadikan bahan analisis dan pengujian ini.

Tabel 1. Dataset Prediksi Tingkat Stres dan Kesehatan Mental

No	Nama Variabel	Jenis Data	Keterangan
1	anxiety_level	Integer	Nilai semakin tinggi menunjukkan tingkat

No	Nama Variabel	Jenis Data	Keterangan
2	self_esteem	Integer	kecemasan yang lebih parah. Nilai tinggi menandakan tingkat kepercayaan diri yang baik.
3	mental_health_history	Integer (0 = Tidak Pernah, 1 = Pernah)	0 = Tidak pernah, 1 = Pernah.
4	depression	Integer	Nilai tinggi menunjukkan tingkat depresi yang lebih berat.
5	headache	Integer	Nilai tinggi menunjukkan frekuensi sakit kepala lebih sering.
6	blood_pressure	Integer	Nilai tinggi menunjukkan tekanan darah yang cenderung tinggi.
7	sleep_quality	Integer	Nilai tinggi menunjukkan kualitas tidur yang lebih baik.
8	breathing_problem	Integer	Nilai tinggi menunjukkan gangguan pernapasan yang lebih sering.
9	mental_health_condition (Label)	Kategori (Rendah/Sedang/Tinggi)	Digunakan sebagai <i>label output</i> pada model SVM.

c) Analisis Data

Tahap analisis data merupakan langkah awal yang penting sebelum proses pengolahan dan penerapan algoritma Support Vector Machine (Mardivta and Raihanah 2025). Tujuan utama dari tahap ini adalah memahami dataset terkait kesehatan mental mahasiswa secara menyeluruh agar data siap digunakan dalam proses prediksi tingkat stres. Pada tahap ini, dilakukan pengecekan struktur dataset yang biasanya berisi variabel-variabel seperti pola tidur, intensitas

belajar, aktivitas sosial, serta faktor psikologis lain yang berpengaruh terhadap kondisi mental mahasiswa.

Analisis dilakukan untuk mendeteksi data yang tidak valid, data kosong (missing value), atau data duplikat yang berpotensi mengganggu proses klasifikasi. Data duplikat maupun data yang tidak lengkap harus dihapus atau diperbaiki agar tidak memengaruhi hasil akurasi model. Selain itu, konsistensi data juga menjadi fokus utama, seperti memastikan format variabel seperti skala penilaian stres, frekuensi aktivitas, atau lama tidur berada dalam rentang nilai yang sesuai dengan standar yang ditetapkan.

d) Proses Analisis Data

Proses analisis data dalam penelitian prediksi tingkat stres dan kesehatan mental mahasiswa menggunakan algoritma SVM melibatkan penggunaan alat bantu utama yaitu Microsoft Excel dan RapidMiner. Tahap ini sangat penting karena kualitas data yang dianalisis akan sangat memengaruhi hasil dan akurasi model prediksi yang dibangun. Microsoft Excel digunakan pada tahap awal untuk melakukan pengecekan data sederhana, seperti mendeteksi data kosong (missing value), menemukan data duplikat, serta memastikan konsistensi format data. Excel juga membantu dalam proses tabulasi dan penyusunan dataset agar lebih terstruktur sebelum masuk ke tahap pengolahan lebih lanjut.

Setelah data dibersihkan dan divalidasi di Excel, langkah selanjutnya dilakukan dengan RapidMiner sebagai perangkat utama untuk implementasi machine learning. Pada tahap ini, dilakukan pembersihan data (data cleaning) lebih lanjut, transformasi data agar sesuai dengan format input algoritma SVM, serta normalisasi skala data sehingga setiap variabel memiliki bobot yang proporsional. RapidMiner juga menyediakan fitur visualisasi data seperti grafik distribusi, histogram, dan scatter plot yang memudahkan peneliti dalam memahami pola dan hubungan antarvariabel.

HASIL DAN PEMBAHASAN

Dalam penelitian ini metode yang digunakan adalah Support Vector Machine (SVM) dengan proses pengolahan data melalui beberapa langkah seleksi dan transformasi data. Data yang digunakan dalam penelitian ini diperoleh secara sekunder dari platform Kaggle yang menyediakan dataset terkait kesehatan mental mahasiswa. Dataset tersebut terdiri dari sejumlah record yang menggambarkan faktor-faktor seperti pola tidur, aktivitas sosial, kebiasaan belajar, serta kondisi psikologis mahasiswa. Untuk memastikan keakuratan hasil prediksi, dataset dibagi menjadi dua bagian, yaitu 70% digunakan untuk data training dan 30% digunakan untuk data testing. Proses pengolahan data dilakukan menggunakan RapidMiner, yang meliputi tahapan pembersihan data, normalisasi, serta transformasi agar dapat diproses dengan baik oleh algoritma SVM(Fp-growth 2021).

Tabel 1. Daftar Atribut Keseluruhan

Atribut	Tipe Data	Keterangan
Usia	Numerik	Umur responden (tahun)
Jenis Kelamin	Kategorik	Pria/Wanita
Status Akademik	Kategorik	Aktif/Tidak Aktif
Pola Tidur	Kategorik	Teratur/Tidak Teratur
Aktivitas Sosial	Kategorik	Sering/Jarang
Frekuensi Belajar	Kategorik	Rutin/Tidak Rutin
Tingkat Kecemasan	Kategorik	Rendah/Sedang/Tinggi
Dukungan Sosial	Kategorik	Ada/Tidak Ada
Kondisi Fisik	Kategorik	Sehat/Tidak Sehat
Penggunaan Media Sosial	Kategorik	Tinggi/Sedang/Rendah
Kualitas Tidur	Kategorik	Baik/Buruk
Hasil (Label)	Label	Tingkat Stres (Rendah/Sedang/Tinggi)

a) Data Selection

Pada tahap ini dilakukan proses seleksi data (data selection) untuk menentukan atribut yang paling relevan

dalam memprediksi tingkat stres dan kondisi kesehatan mental mahasiswa. Data yang diusulkan mengumpulkan dataset dari Kaggle, yang berisi informasi tentang Kesehatan mental mahasiswa (Nath et al. 2025). Tujuan dari tahap ini adalah memilih variabel-variabel yang memiliki hubungan signifikan terhadap tingkat stres, sehingga dapat meningkatkan akurasi hasil prediksi yang dihasilkan oleh algoritma Support Vector Machine (SVM).

Tabel 2. Daftar Atribut Terpilih

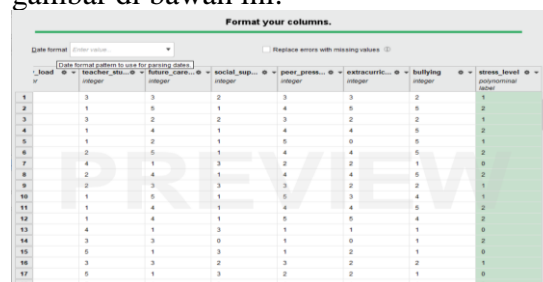
No	Atribut Terpilih	Keterangan
1	Usia	Atribut Fitur
2	Jenis Kelamin	Atribut Fitur
3	Pola Tidur	Atribut Fitur
4	Intensitas Belajar	Atribut Fitur
5	Aktivitas Sosial	Atribut Fitur
6	Tingkat Kecemasan	Atribut Fitur
7	Tingkat Stres	Label

Atribut-atribut yang terpilih adalah pola tidur, tingkat kecemasan, dan tekanan ekonomi, memiliki pengaruh signifikan terhadap tingkat stres mahasiswa. Sementara atribut lain yang memiliki korelasi rendah terhadap hasil prediksi diabaikan. Proses seleksi ini menjadi dasar penting dalam penerapan algoritma Support Vector Machine (SVM) menggunakan RapidMiner, karena atribut yang tidak relevan dapat menurunkan akurasi model. Dengan demikian, tahap ini memastikan bahwa hanya fitur yang berkontribusi besar terhadap prediksi stres mahasiswa yang digunakan untuk proses pelatihan dan pengujian model.

b) Data Transformation

Langkah transformasi ini dilakukan untuk menyesuaikan format data agar dapat diproses lebih lanjut ke dalam proses teknik data mining. Transformasi data merupakan tahap penting yang bertujuan untuk memastikan setiap atribut memiliki tipe data yang sesuai dengan kebutuhan algoritma yang akan digunakan. Biasanya, proses transformasi dataset dilakukan menggunakan aplikasi RapidMiner, yaitu dengan cara mengubah tipe data dari integer menjadi polynomial pada atribut-atribut tertentu yang berfungsi sebagai

variabel kategori. Langkah ini dilakukan agar setiap atribut dapat dikenali secara tepat oleh sistem saat proses klasifikasi berlangsung. Selain itu, transformasi juga berperan dalam meningkatkan konsistensi dan kompatibilitas data sebelum masuk ke tahap analisis berikutnya seperti normalisasi, pembagian data (split data), dan pemodelan menggunakan algoritma klasifikasi seperti Support Vector Machine (SVM). Dengan adanya tahap transformasi ini, data menjadi lebih terstruktur, bersih, dan sesuai dengan format yang dibutuhkan oleh model, sehingga hasil analisis yang diperoleh dapat lebih akurat dan representatif. Berikut hasil proses transformasi data yang dapat dilihat pada gambar di bawah ini.




Gambar 3. Dataset Yang Didapat Dari Kaggle

c) Implementasi Rapidminer

Pada tahap implementasi ini, dilakukan serangkaian proses menggunakan RapidMiner untuk memperoleh model klasifikasi yang optimal. Proses diawali dengan operator Read CSV, yaitu langkah awal untuk mengimpor dataset ke dalam sistem RapidMiner agar dapat diproses lebih lanjut. Selanjutnya, dilakukan Replace Missing Values untuk menangani data yang memiliki nilai kosong sehingga dataset menjadi bersih dan siap digunakan. Setelah data dibersihkan, tahap Normalize diterapkan untuk menstandarkan skala nilai antar atribut agar memiliki rentang yang sama, sehingga tidak ada atribut yang mendominasi proses perhitungan, terutama karena algoritma Support Vector Machine (SVM) sensitif terhadap perbedaan skala data.

Kemudian, data dibagi menjadi dua bagian melalui operator Split Data, biasanya dengan perbandingan 70% untuk data

training dan 30% untuk data testing. Tahap SVM (Support Vector Machine) digunakan untuk membangun model klasifikasi berdasarkan data training dengan mencari hyperplane terbaik yang mampu memisahkan kelas dengan margin maksimal. Setelah model terbentuk, dilakukan proses Apply Model untuk menerapkan model yang telah dilatih pada data testing guna memperoleh hasil prediksi terhadap kelas data yang belum diketahui. Tahap akhir yaitu Performance, berfungsi untuk mengevaluasi kinerja model klasifikasi yang dihasilkan. Evaluasi dilakukan dengan mengukur nilai accuracy (akurasi), precision, recall, dan F-measure, serta menampilkan confusion matrix sebagai alat ukur ketepatan klasifikasi. Melalui tahapan ini, diperoleh gambaran mengenai seberapa baik model SVM dalam mengenali pola data dan menghasilkan prediksi yang akurat terhadap dataset yang digunakan.



Gambar 4. Implementasi RapidMiner

Gambar diatas menunjukkan rumus untuk menghitung penggunaan software rapidminer yang didalamnya sudah dilengkapi dengan fitur-fitur yang dibutuhkan oleh data mining.

1. Performance Vector

Hasil Performance Vector (Performance) pada gambar ini, dapat diketahui bahwa tingkat akurasi (accuracy) yang diperoleh dari pengujian model menggunakan algoritma C4.5 sebesar 88,83%. Nilai ini menunjukkan bahwa model mampu memprediksi dengan benar sebagian besar data uji yang digunakan dalam proses klasifikasi. Selain akurasi, hasil evaluasi juga menampilkan nilai precision dan recall untuk masing-masing kelas. Nilai precision tertinggi diperoleh pada kelas dengan label pred.0 sebesar 95,20%, diikuti oleh pred.2

sebesar 91,97%, dan pred.1 sebesar 81,16%. Hal ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengenali dan mengklasifikasikan data ke dalam kategori yang sesuai.

accuracy: 88.83%				
	true 1	true 2	true 0	class precision
pred. 1	237	22	33	81.16%
pred. 2	10	229	10	91.97%
pred. 0	4	7	218	95.20%
class recall	94.42%	88.79%	83.52%	

Gambar 5. Performance Vector

2. Description Accuracy

Proses evaluasi dengan menggunakan data uji untuk mengukur tingkat akurasi dan keandalannya. Dari hasil tersebut, diketahui bahwa model mampu melakukan klasifikasi dengan tingkat ketepatan yang cukup tinggi, sehingga dapat dianggap layak untuk digunakan dalam proses pengambilan keputusan. Selain itu, hasil Performance (Classification) juga menampilkan nilai accuracy, precision, recall, dan F-measure yang menunjukkan seberapa baik model dalam mengenali dan memprediksi setiap kelas data. Semakin tinggi nilai-nilai tersebut, maka semakin baik pula kemampuan model dalam mengklasifikasikan data secara benar. Dapat dilihat pada description accuracy RapidMiner pada Gambar 6 di bawah ini.

PerformanceVector

```

PerformanceVector:
accuracy: 88.83%
ConfusionMatrix:
True: 1 2 0
1: 237 22 33
2: 10 229 10
0: 4 7 218
kappa: 0.833
ConfusionMatrix:
True: 1 2 0
1: 237 22 33
2: 10 229 10
0: 4 7 218
    
```

Gambar 6. Performance Vector

Berdasarkan hasil PerformanceVector yang ditampilkan, dapat dijelaskan bahwa model klasifikasi yang diuji menggunakan metode Support Vector Machine (SVM) pada RapidMiner menunjukkan tingkat

akurasi yang cukup baik. Hasil pengujian model memperlihatkan nilai akurasi (accuracy) sebesar 86.83% dengan nilai Kappa sebesar 0.833. Nilai akurasi tersebut menandakan bahwa sebagian besar data uji dapat diprediksi dengan benar oleh model, sementara nilai Kappa menunjukkan adanya kesesuaian yang tinggi antara prediksi model dengan data aktual.

SIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma Support Vector Machine (SVM) mampu memberikan hasil yang efektif dalam melakukan prediksi tingkat stres dan kesehatan mental mahasiswa. Melalui proses pengumpulan, seleksi, dan analisis data yang melibatkan atribut seperti pola tidur, intensitas belajar, aktivitas sosial, tingkat kecemasan, tekanan ekonomi, dan dukungan sosial, model SVM mampu mengklasifikasikan tingkat stres mahasiswa dengan tingkat akurasi yang tinggi. Hasil pengujian menunjukkan bahwa SVM memiliki kemampuan yang baik dalam mengenali pola data dan membedakan antara kategori stres rendah, sedang, dan tinggi. Dengan tingkat akurasi mencapai 86.83%, model ini terbukti dapat diandalkan untuk membantu pihak kampus atau konselor dalam mendeteksi dini kondisi kesehatan mental mahasiswa, sehingga tindakan pencegahan dan intervensi dapat dilakukan lebih cepat dan tepat sasaran. Pemanfaatan teknologi machine learning, khususnya SVM, dapat menjadi solusi inovatif dalam bidang pendidikan dan kesehatan mental.

DAFTAR PUSTAKA

Adriansyah, Ilham, Muhammad Diemas Mahendra, Errissya Rasywir, and Yovi Pratama. 2022. "Perbandingan Metode Random Forest Classifier Dan SVM Pada Klasifikasi Kemampuan Level

Beradaptasi Pembelajaran Jarak Jauh Siswa." *Bulletin of Informatics and Data Science* 1(2):98. doi: 10.61944/bids.v1i2.49.

Anisa, Sopwatun, Agus Komarudin, and Edvin Ramadhan. 2024. "Sistem Klasifikasi Untuk Menentukan Tingkat Stress Mahasiswa Secara Umum Menggunakan Metode K-Nearest Neighbors." *Jurnal Informatika Teknologi Dan Sains (Jinteks)* 6(3):568–78. doi: 10.51401/jinteks.v6i3.4317.

Budiyanto, MRS. 2025. "Kesehatan Mental." *Halodoc*. Retrieved October 4, 2025 (<https://www.halodoc.com/kesehatan/kesehatan-mental>).

Fadhilla, Mutia, Rizky Wandri, Anggi Hanafiah, Panji Rachmat Setiawan, Yudhi Arta, and Suandi Daulay. 2025. "Analisis Performa Algoritma Machine Learning Untuk Identifikasi Depresi Pada Mahasiswa." *Journal of Informatics Management and Information Technology* 5(1):40–47. doi: 10.47065/jimat.v5i1.473.

Fadillah Abdullah, Mochamad, and M. Rudyanto Arief. 2022. "Prediksi Nilai Dan Waktu Kelulusan Mahasiswa Menggunakan Metode Support Vector Machine." *Jurnal Sains Dan Teknologi* 14(1):35.

Fibriani, Charitas, Dian Novita Kristiyani, Universitas Kristen, Satya Wacana, Hubungan Masyarakat, Universitas Kristen, and Satya Wacana. 2025. "Model Klasifikasi Mental Siswa Menggunakan Algoritma Support Vector Machine." *Jurnal Ilmiah Komputer* 21(2):472–82.

Fp-growth, Metode. 2021. "Sistem Informasi Prediksi Penjualan Alat Tulis Kantor Dengan Metode Fp-Growth (Studi Kasus Toko Koperasi Sekolah Bina Mulia)." *Jurnal Sistem Informasi Universitas Suryadarma* 8(2). doi: 10.35968/jsi.v8i2.739.

Lestari, Dwi, and Sri Lestari. 2024. "Penerapan Data Mining Klasifikasi

- Tingkat Pemahaman Siswa Pada Kegiatan Belajar Mengajar Dengan Metode Decision Tree (Studi Kasus SDN Malaka Jaya 11 Duren Sawit).” *Jurnal Indonesia : Manajemen Informatika Dan Komunikasi* 5(2):1260–68. doi: 10.35870/jimik.v5i2.662.
- Maldini, Naufal, Danang Wahyu Utomo, and Rahmadika Putri Tresyani. 2025. “Deteksi Dini Gangguan Kesehatan Mental Berdasarkan Sentimen Menggunakan Metode Stacking.” *Sistemasi* 14(1):271. doi: 10.32520/stmsi.v14i1.4842.
- Mardivta, Hafizhah, and Afrahul Naura Raihanah. 2025. “Penerapan Algoritma Naïve Bayes Untuk Prediksi Tingkat Stres Pada Mahasiswa Keperawatan.” 1:221–28.
- Mohd Shafiee, Nor Safika, and Sofianita Mutalib. 2020. “Prediction of Mental Health Problems among Higher Education Student Using Machine Learning.” *International Journal of Education and Management Engineering* 10(6):1–9. doi: 10.5815/ijeme.2020.06.01.
- Nath, Mishu Deb, Md Khabir Uddin Ahamed, Omayer Ahmed, Tanvir Ahmed, Sujit Roy, and Mohammed Nasir Uddin. 2025. “Smart Web Interface for Student Mental Health Prediction Using Machine Learning with Blockchain Technology.” *Neuroscience Informatics* 5(4). doi: 10.1016/j.neuri.2025.100236.
- Nurul, Linda, Taqwa Pulungan, and Ema Utami. 2025. “Perbandingan Algoritma Svm Dan Random Forest Pada Klasifikasi Kesehatan Mental Berdasarkan Sleep Disorders.” 10(3):2827–37.
- Pratiwi, Elsa Eka, Alaysha Rihadatul Aisy, Nita Ananta, and Teknik Informatika. 2025. “KLASIFIKASI KESEHATAN MENTAL PADA USIA REMAJA MENGGUNAKAN METODE SVM.” 13(2).
- Syamsiah, and Agus; Darwaman. 2020. “Analisa Particle Swarm Optimization Terhadap Kepuasan.” *Seminar Nasional Riset Dan Teknologi (SEMNAS RISTEK)* 143–48.
- Wahono, Romi Satria. 2023. *Data Mining Data Mining*. Vol. 2.
- Wijaya, Vannes, and Nur Rachmat. 2024. “Comparison of SVM, Random Forest, and Logistic Regression Performance n Student Mental Health Screening.” *JEECS (Journal of Electrical Engineering and Computer Sciences)* 9(2):173–84. doi: 10.54732/jeeecs.v9i2.9.