NEXUS : Journal of Information & Computational Science
Vol. 1, No. 1, January (2026) 31 - 39
e-ISSN XXXX-XXXX
p-ISSN XXXX-XXXX
https://ejournal.unupasuruan.ac.id/index.php/NEXUS

Received : July 11, 2025
Accepted : October 08, 2025
Available Online : January 11, 2026

PREDIKSI TINGKAT STRES SISWA BERBASIS MACHINE LEARNING MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBORS (KNN)

Wisnu Cahyo Utomo[1], Sapto Hadi Riono[2], Wahyu Triono[3], Muhammad Syahrul Mukharrom[4]
[1,2,3,4] Program Studi lmu Komputer, Universitas PGRI Wiranegara
email: [1]saptoenator@gmail.com

Abstract: Student stress has become an increasingly important issue in the educational environment, as it can negatively affect academic performance, emotional well-being, and overall mental health. Early detection of student stress levels is therefore essential to enable timely intervention and support. This study aims to develop a student stress level prediction model based on machine learning using the K-Nearest Neighbors (KNN) algorithm. The research utilizes a dataset consisting of several psychological and academic attributes that represent students' stress conditions. Data preprocessing is conducted through data cleaning and normalization to improve model performance. The KNN algorithm is applied by calculating the distance between data points to classify students into different stress levels. Model performance is evaluated using accuracy, precision, recall, and F1-score metrics. The experimental results show that the KNN algorithm is capable of predicting student stress levels with satisfactory accuracy, indicating its effectiveness for stress classification tasks. The findings of this study demonstrate that machine learning, particularly the KNN method, can serve as a supportive tool for educators and institutions in monitoring student stress levels and implementing early preventive measures.

Keywords: Student Stress; Machine Learning; K-Nearest Neighbors; Stress Prediction; Classification.

Abstrak: Stres siswa telah menjadi masalah yang semakin penting dalam lingkungan pendidikan, karena dapat berdampak negatif pada prestasi akademik, kesejahteraan emosional, dan kesehatan mental secara keseluruhan. Deteksi dini tingkat stres siswa sangat penting untuk memungkinkan intervensi dan dukungan yang tepat waktu. Studi ini bertujuan untuk mengembangkan model prediksi tingkat stres siswa berdasarkan machine learning menggunakan algoritma K-Nearest Neighbors (KNN). Penelitian ini menggunakan dataset yang terdiri dari beberapa atribut psikologis dan akademik yang mewakili kondisi stres siswa. Prasunting data dilakukan melalui pembersihan dan normalisasi data untuk meningkatkan kinerja model. Algoritma KNN diterapkan dengan menghitung jarak antara titik data untuk mengklasifikasikan siswa ke dalam tingkat stres yang berbeda. Kinerja model dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil eksperimen menunjukkan bahwa algoritma KNN mampu memprediksi tingkat stres siswa dengan akurasi yang memuaskan, menunjukkan efektivitasnya dalam tugas klasifikasi stres. Temuan penelitian ini menunjukkan bahwa machine learning, khususnya metode KNN, dapat berfungsi sebagai alat pendukung bagi pendidik dan lembaga dalam memantau tingkat stres siswa dan menerapkan langkah-langkah pencegahan dini.

Kata kunci: Stres Siswa; Machine Learning; K-Nearest Neighbors; Prediksi Stres; Klasifikasi.

NEXUS : Journal of Information & Computational Science
Vol. 1, No. 1, January (2026) 31 - 39
e-ISSN XXXX-XXXX
p-ISSN XXXX-XXXX
https://ejournal.unupasuruan.ac.id/index.php/NEXUS

PENDAHULUAN

Stres pada siswa merupakan salah satu permasalahan penting dalam dunia pendidikan yang terus meningkat seiring dengan kompleksitas tuntutan akademik dan sosial. Tekanan akademik yang tinggi, beban tugas, persaingan prestasi, serta adaptasi terhadap lingkungan belajar yang dinamis dapat memicu stres yang berdampak negatif terhadap konsentrasi belajar, motivasi, kesehatan mental, dan kesejahteraan siswa secara keseluruhan. Apabila kondisi ini tidak teridentifikasi dan ditangani sejak dini, stres dapat berkembang menjadi gangguan psikologis yang lebih serius serta menurunkan kualitas hasil belajar [1].

Dalam konteks penelitian, pemanfaatan teknologi informasi dan machine learning telah berkembang pesat dan banyak diterapkan dalam bidang pendidikan dan kesehatan mental. Machine learning memungkinkan pengolahan data dalam jumlah besar secara sistematis dan objektif, sehingga mampu menghasilkan pola dan prediksi yang sulit diperoleh melalui pendekatan konvensional. Beberapa studi menunjukkan bahwa machine learning efektif digunakan untuk memprediksi kondisi psikologis seperti stres, kecemasan, dan kelelahan akademik berdasarkan data perilaku dan akademik siswa [2].

Urgensi permasalahan stres siswa mendorong perlunya pendekatan berbasis sistem prediksi yang dapat membantu pendidik dan institusi pendidikan dalam melakukan pemantauan secara dini. Metode konvensional yang bergantung pada observasi manual dan kuesioner sering kali membutuhkan waktu, tenaga ahli, serta berpotensi menghasilkan penilaian subjektif. Oleh karena itu, penerapan machine learning dinilai sebagai solusi yang lebih efisien dan konsisten dalam mendukung pengambilan keputusan berbasis data [3].

Hasil kajian pustaka menunjukkan bahwa berbagai algoritma klasifikasi telah digunakan dalam penelitian terkait prediksi stres siswa, seperti decision tree, support vector machine, dan naive bayes. Salah satu metode yang cukup populer adalah K Nearest Neighbors karena memiliki konsep yang sederhana, mudah diimplementasikan, serta mampu memberikan performa klasifikasi yang baik pada data multivariabel. Penelitian sebelumnya juga melaporkan bahwa K Nearest Neighbors menghasilkan tingkat akurasi yang kompetitif dalam tugas klasifikasi kondisi psikologis siswa [4].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun model prediksi tingkat stres siswa berbasis machine learning menggunakan metode K Nearest Neighbors serta menganalisis kinerja model dalam mengklasifikasikan tingkat stres siswa. Hasil penelitian diharapkan dapat menjadi landasan dalam pengembangan sistem pendukung yang membantu deteksi dini stres siswa dan mendukung upaya pencegahan di lingkungan pendidikan.

TINJAUAN PUSTAKA

K-Nearest Neighbors (KNN) merupakan salah satu algoritma *supervised learning* yang paling sederhana namun cukup efektif dalam bidang *machine learning*, khususnya untuk permasalahan klasifikasi dan regresi. Algoritma ini bersifat non-parametrik, artinya KNN tidak membentuk model matematis eksplisit selama proses pelatihan, melainkan

menyimpan seluruh data latih dan melakukan proses prediksi berdasarkan kedekatan data uji dengan data latih tersebut [5].

Prinsip dasar KNN adalah bahwa data yang memiliki karakteristik serupa cenderung berada pada kelas yang sama. Dalam proses klasifikasi, sebuah data baru akan dibandingkan dengan seluruh data latih menggunakan suatu metrik jarak, kemudian dipilih sejumlah K data terdekat (neighbors). Kelas yang paling banyak muncul di antara K tetangga tersebut akan ditetapkan sebagai hasil prediksi untuk data baru.

Secara umum, tahapan kerja algoritma KNN dapat dijelaskan sebagai berikut:

1. Menentukan nilai **K**, yaitu jumlah tetangga terdekat yang akan digunakan dalam proses klasifikasi.
2. Menghitung jarak antara data uji dan seluruh data latih menggunakan metode jarak tertentu.
3. Mengurutkan data latih berdasarkan jarak terdekat ke data uji.
4. Memilih K data latih dengan jarak terpendek.
5. Menentukan kelas data uji berdasarkan voting mayoritas dari K tetangga terdekat tersebut.

Metode perhitungan jarak yang paling sering digunakan adalah Euclidean Distance, terutama ketika data berbentuk numerik dan telah dinormalisasi. Selain itu, terdapat juga metrik jarak lain seperti Manhattan Distance dan Minkowski Distance yang dapat digunakan tergantung pada karakteristik data [6].

Dalam Metode ini Pemilihan nilai K memiliki pengaruh besar terhadap performa algoritma KNN. Nilai K yang terlalu kecil dapat menyebabkan model menjadi sensitif terhadap noise dan outlier, sedangkan nilai K yang terlalu besar dapat mengakibatkan model menjadi kurang responsif terhadap pola lokal dalam data. Oleh karena itu, penentuan nilai K umumnya dilakukan menggunakan teknik validasi seperti cross-validation untuk memperoleh nilai K yang menghasilkan akurasi terbaik [7].

Dalam konteks prediksi tingkat stres siswa, KNN digunakan untuk mengklasifikasikan siswa ke dalam kategori tingkat stres tertentu (misalnya stres rendah, sedang, dan tinggi) berdasarkan atribut atau fitur yang diperoleh dari kuesioner. Fitur-fitur tersebut dapat meliputi faktor akademik, kondisi kesehatan, hubungan sosial, tekanan lingkungan, dan aspek psikologis lainnya [8].

Ketika sebuah data siswa baru dimasukkan ke dalam sistem, algoritma KNN akan membandingkan data tersebut dengan data mahasiswa lain yang telah diketahui tingkat stresnya. Berdasarkan kemiripan karakteristik, sistem akan memprediksi tingkat stres mahasiswa tersebut sesuai dengan mayoritas tetangga terdekatnya [9].

KNN Memprediksi Tingkat Stres Siswa

Dalam penelitian prediksi tingkat stres siswa, KNN berfungsi sebagai *classifier* (atau *regressor*) yang menentukan level stres seorang mahasiswa dengan membandingkan profilnya terhadap mahasiswa lain pada data latih yang sudah memiliki label

tingkat stres. Secara praktis, setiap respon mahasiswa (misalnya dari kuesioner: beban belajar, kualitas tidur, keluhan fisik seperti sakit kepala, tekanan akademik, kondisi psikologis, dan faktor sosial) diubah menjadi vektor fitur numerik. Ketika ada data mahasiswa baru, KNN menghitung kedekatan data baru tersebut terhadap seluruh data latih, lalu mengambil K data terdekat sebagai "tetangga pembanding" untuk menentukan hasil prediksi. Prinsip kemiripan ini banyak dipakai pada studi prediksi stres berbasis survei/kuesioner di lingkungan pendidikan [10].

Fungsi penting KNN pada proyek ini adalah membantu sistem mengenali pola stres berdasarkan kemiripan multi-faktor. Karena stres mahasiswa biasanya tidak dipengaruhi satu variabel saja, KNN dapat bekerja dengan baik sebagai pendekatan non-linear yang menangkap pola lokal: misalnya dua mahasiswa bisa sama-sama berisiko stres tinggi bukan karena nilai akademik semata, tetapi kombinasi *study load* tinggi + tidur buruk + keluhan fisik. Studi komparatif (2025) menunjukkan model non-linear termasuk KNN mampu memberikan peningkatan kinerja prediksi dibanding model linear ketika stres dimodelkan dari beberapa variabel kunci seperti kualitas tidur, frekuensi sakit kepala, performa akademik, beban belajar, dan aktivitas ekstrakurikuler [11].

Selain itu, KNN berfungsi sebagai model yang relatif mudah dijadikan baseline dan pembanding terhadap algoritma lain (misalnya SVM, Random Forest, XGBoost). Dalam banyak penelitian kesehatan mental berbasis ML, KNN sering dimasukkan sebagai kandidat karena sederhana, interpretasinya mudah (berbasis tetangga terdekat), dan dapat menjadi acuan awal sebelum memilih model yang lebih kompleks. Hal ini sejalan dengan temuan tinjauan sistematis (2023) yang menekankan praktik umum pada studi prediksi stres/kecemasan mahasiswa: melakukan perbandingan beberapa algoritma ML, menilai metrik (akurasi, precision, recall, F1), serta memperhatikan pemilihan fitur dan prosedur evaluasi [12].

Terakhir, dalam implementasi prediksi stres mahasiswa, KNN juga berperan mendorong desain pipeline yang "rapi" karena menuntut preprocessing yang benar: normalisasi/standardisasi fitur (karena KNN berbasis jarak), penentuan nilai K (melalui *cross-validation*), serta strategi penanganan ketidakseimbangan kelas bila distribusi level stres tidak merata. Studi berbasis kuesioner pada mahasiswa (2024) juga menjelaskan penggunaan KNN dengan mekanisme *majority voting* dari tetangga terdekat untuk klasifikasi stres dan non-stres, memperlihatkan bahwa KNN dapat digunakan langsung pada data survei yang disusun menjadi fitur numerik [13].

K-Nearest Neighbors (KNN)

Algoritma K-Nearest Neighbors (KNN) bekerja berdasarkan konsep kedekatan jarak antara data uji dan data latih. Dalam proses klasifikasi, KNN tidak membentuk model matematis selama tahap pelatihan, melainkan melakukan perhitungan jarak pada saat prediksi untuk menentukan kelas suatu data baru. Oleh karena itu, komponen utama dalam KNN adalah perhitungan jarak (distance metric) dan mekanisme penentuan kelas berdasarkan K tetangga terdekat.

Metrik jarak yang paling umum digunakan dalam KNN adalah Euclidean Distance, terutama pada data numerik

yang telah dinormalisasi. Rumus Euclidean Distance antara data uji xxx dan data latih yyy dengan nnn atribut adalah sebagai berikut:

$$d(x,y) = \sqrt{\sum_{i=1}^{n}(X_i - y_i)^2} \quad (1)$$

di mana:

- x_i adalah nilai atribut ke-i dari data uji,
- y_i adalah nilai atribut ke-i dari data latih,
- n adalah jumlah atribut atau fitur,
- $d(x,y)$ adalah jarak antara dua data.

Jarak yang lebih kecil menunjukkan tingkat kemiripan yang lebih tinggi antara data uji dan data latih. Dalam prediksi tingkat stres siswa, atribut xix_ixi dapat berupa skor beban belajar, kualitas tidur, tekanan akademik, atau indikator psikologis lainnya [14].

Setelah jarak antara data uji dan seluruh data latih dihitung, nilai jarak tersebut diurutkan dari yang terkecil. Selanjutnya dipilih K data dengan jarak terpendek sebagai tetangga terdekat. Kelas dari data uji ditentukan menggunakan voting mayoritas, yaitu kelas yang paling sering muncul di antara K tetangga terdekat. Secara matematis, kelas prediksi C(x)C(x)C(x) dapat dinyatakan sebagai:

$$C(x) = \arg\max_{c \in C} \sum_{i=1}^{K} \delta(c_i = c) \quad (2)$$

di mana:

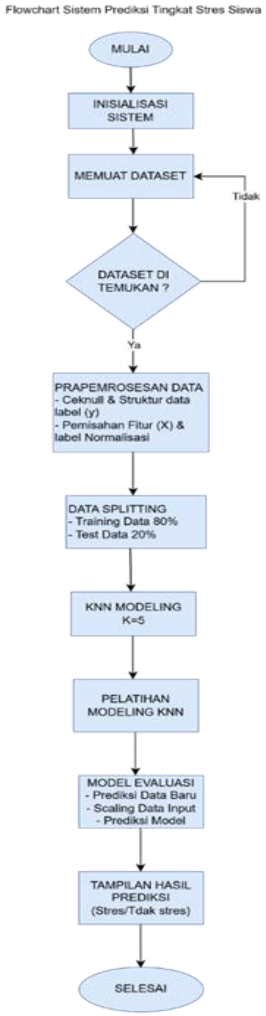
- $C(x)$ adalah kelas hasil prediksi,
- C_i adalah kelas dari tetangga ke-iii,
- σ bernilai 1 jika kondisi benar dan 0 jika salah.

Pada kasus prediksi stres siswa, kelas CCC dapat berupa stres rendah, sedang, atau tinggi, dan hasil prediksi diperoleh dari kategori yang paling dominan di antara K tetangga terdekat [15].

Karena KNN berbasis jarak, perbedaan skala antar fitur dapat memengaruhi hasil perhitungan jarak. Oleh sebab itu, normalisasi data seperti *Min–Max Normalization* atau *Standardization* sering diterapkan sebelum perhitungan jarak, agar setiap atribut memiliki kontribusi yang seimbang dalam proses klasifikasi.

METODOLOGI

Metode Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen berbasis machine learning untuk memprediksi tingkat stres siswa. Metodologi penelitian dirancang melalui beberapa tahapan utama, yaitu pengumpulan data, pra-pemrosesan data, pembagian data, pemodelan menggunakan algoritma K Nearest Neighbors, serta evaluasi kinerja model.



Gambar 1. Flowchart Penelitian

Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan data primer yang diperoleh secara langsung dari Sekolah Dasar Negeri (SDN) Sungikulon melalui kerja sama resmi dengan pihak sekolah. Pengumpulan data dilakukan dengan izin dan pendampingan dari sekolah, sehingga data yang diperoleh mencerminkan kondisi nyata siswa di lingkungan pendidikan tersebut. Data dikumpulkan berdasarkan hasil pengisian instrumen/kuesioner yang dirancang untuk mengukur tingkat stres siswa, mencakup aspek akademik, psikologis, dan perilaku.

Dataset yang diperoleh berisi sejumlah atribut yang merepresentasikan kondisi siswa, seperti beban belajar, tekanan akademik, kondisi emosional, serta indikator perilaku yang berkaitan dengan tingkat stres. Setiap data siswa diberi label tingkat stres yang digunakan sebagai variabel target dalam proses klasifikasi. Pemilihan data dari SDN Sungikulon dilakukan karena relevan dengan tujuan penelitian, yaitu memprediksi tingkat stres siswa secara objektif berbasis data pada lingkungan sekolah dasar, serta memungkinkan peneliti memperoleh data yang valid dan kontekstual.

Tabel 1. Data Siswa

DATA SELURUH SISWA
TAHUN AJARAN 2025-2026
SDN SUNGIKULON KEC POHJENTREK

NO	Nama	Nilai Kualitas Tidur	Berapa kali seminggu mengalami sakit kepala	Nilai prestasi akademik	Nilai Beban Studi	Berapa kali seminggu kegiatan ekstrakurikuler?	Nilai Tingkat Stres
1	Maya	3	1	3	4	2	3
2	Maya	4	1	2	3	3	2
3	Tono	2	1	2	1	4	4
4	Rizki	3	2	3	2	3	3
5	Lestari	2	3	1	5	5	3
6	Tono	3	1	3	2	1	1
7	Intan	3	5	1	4	3	5
8	Eka	4	3	1	4	1	1
9	Wulan	2	1	4	4	5	1
10	Dewi	1	2	3	2	5	2

Tabel diatas menampilkan struktur awal data siswa dalam bentuk file Microsoft Excel yang berisi baris data responden dan kolom atribut penelitian. Penyajian ini bertujuan untuk memberikan gambaran visual mengenai bentuk dan struktur data sebelum dilakukan pengolahan lebih lanjut.

Pra-pemrosesan Data

Tahap pra-pemrosesan data merupakan salah satu tahapan paling penting dalam penelitian berbasis machine learning karena kualitas data sangat berpengaruh terhadap kinerja

model prediksi yang dihasilkan. Data mentah yang diperoleh dari dataset analisis stres siswa belum tentu sepenuhnya siap digunakan untuk proses pemodelan, karena kemungkinan masih mengandung nilai kosong, perbedaan skala antar atribut, serta struktur data yang tidak seragam. Oleh karena itu, pra-pemrosesan data dilakukan untuk memastikan bahwa data yang digunakan memiliki kualitas yang baik, konsisten, dan sesuai dengan kebutuhan algoritma K Nearest Neighbors.

Pembagian Data

Tahap pembagian data merupakan bagian penting dalam metodologi penelitian berbasis machine learning karena berfungsi untuk mengevaluasi kemampuan model dalam melakukan generalisasi terhadap data yang belum pernah dilihat sebelumnya. Setelah data melalui tahap pra-pemrosesan, langkah selanjutnya adalah membagi dataset menjadi dua bagian utama, yaitu data latih dan data uji. Data latih digunakan untuk membangun dan melatih model klasifikasi, sedangkan data uji digunakan untuk mengukur kinerja model dalam memprediksi data baru.

Pembagian data dilakukan untuk menghindari terjadinya overfitting, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data latih sehingga tidak mampu memberikan prediksi yang baik pada data yang belum pernah dilatih. Dengan adanya data uji yang terpisah, kinerja model dapat dievaluasi secara objektif dan hasil evaluasi tersebut dapat mencerminkan kemampuan model dalam penerapan nyata. Oleh karena itu, tahap pembagian data menjadi landasan penting dalam penelitian eksperimen machine learning [16].

Evaluasi Model

Evaluasi model dilakukan untuk mengetahui sejauh mana algoritma K-Nearest Neighbors mampu memprediksi tingkat stres siswa secara akurat berdasarkan data uji. Pada tahap ini, hasil prediksi yang dihasilkan oleh model dibandingkan dengan label sebenarnya untuk mengukur kinerja klasifikasi. Evaluasi menjadi tahap penting karena memberikan gambaran objektif mengenai tingkat keandalan dan efektivitas model yang telah dibangun dalam mencapai tujuan penelitian.

HASIL DAN PEMBAHASAN

Hasil penelitian diperoleh dari proses pengujian model K-Nearest Neighbors terhadap data uji yang telah dipisahkan dari dataset utama. Dataset analisis stres siswa yang digunakan berjumlah 520 data dan terdiri dari lima atribut sebagai fitur, yaitu kualitas tidur, frekuensi sakit kepala, performa akademik, beban belajar, dan aktivitas ekstrakurikuler. Label tingkat stres telah dikonversi menjadi dua kelas, yaitu stres dan tidak stres, sehingga penelitian ini menggunakan pendekatan klasifikasi biner.

```
Akurasi: 0.8942307692307693
              precision    recall  f1-score   support

       Stres       0.90      0.91      0.91        58
 Tidak Stres       0.89      0.87      0.88        46

    accuracy                           0.89       104
   macro avg       0.89      0.89      0.89       104
weighted avg       0.89      0.89      0.89       104

array([[53,  5],
       [ 6, 40]])
```

Gambar 2. Evaluasi Model

KESIMPULAN

Berdasarkan hasil pemodelan dan evaluasi yang telah dilakukan, penelitian ini menunjukkan bahwa algoritma K-Nearest Neighbors (KNN) mampu digunakan secara efektif untuk memprediksi tingkat stres siswa dalam skema klasifikasi biner (stres dan tidak stres). Dengan dataset berjumlah 520 data dan lima atribut utama kualitas tidur, frekuensi sakit kepala, performa akademik, beban belajar, dan aktivitas ekstrakurikuler model KNN yang dibangun setelah melalui tahap pra-pemrosesan (pembersihan serta normalisasi/standarisasi fitur) menghasilkan performa yang baik. Pembagian data latih dan data uji dengan rasio 80:20 serta penggunaan parameter K = 5 memberikan hasil akurasi 89,42%, disertai nilai precision, recall, dan F1-score yang relatif seimbang (sekitar 0,89), sehingga mengindikasikan bahwa model tidak hanya akurat secara umum tetapi juga cukup konsisten dalam mengenali kedua kelas.

Selain itu, hasil confusion matrix memperlihatkan bahwa mayoritas data berhasil diklasifikasikan dengan benar, meskipun masih terdapat sejumlah kecil kesalahan prediksi. Kesalahan ini menandakan adanya karakteristik siswa yang saling beririsan antar kelas (overlap), terutama pada kondisi peralihan (borderline) antara stres dan tidak stres, sehingga model berbasis jarak seperti KNN dapat mengalami ambiguitas ketika nilai fitur antar kelas memiliki kedekatan yang tinggi. Dengan demikian, penelitian ini menegaskan bahwa KNN layak dijadikan pendekatan awal dalam sistem prediksi stres siswa, namun peningkatan performa masih terbuka melalui optimasi nilai K, pengayaan fitur yang lebih representatif terhadap kondisi psikologis, serta pembandingan dengan algoritma klasifikasi lain sebagai baseline.

REFERENCES

[1] Hasan, M. A., Nasser, M., Ahmad, S., & Molla, K. I. (2012). Feature Selection for Classification of Diabetes Mellitus Using Machine Learning Techniques. *International Journal of Computer Applications*, 1–5.

[2] KH aur, G., & Chhabra, A. (2014). Improved J48 Classification Algorithm for the Prediction of Diabetes. *International Journal of Computer Applications*, 13–17.

[3] Singh, D., & Varshney, A. K. (2025). StressAlert: Early Detection of Student Stress. *International Journal of Computer Techniques*, 2-5.

[4] Sneha, N., & Mahalakshmi, V. (2018). Stress Detection and Analysis Using Machine Learning Techniques. *International Journal of Engineering Research & Technology (IJERT)*, 4-7.

[5] Wafiqi, A. U., Tundo, B. A., & Ramadhan, A. H. (2025). Prediksi Tingkat Stres Pada Mahasiswa UNUGHA Cilacap Menggunakan K-Nearest Neighbor. *Jurnal Tekno Kompak*, 90–100.

[6] Yeler, K., & Sürücü, S. (2025). Classification of Student Stress Levels Using Machine Learning Methods. *International Journal of Advanced Natural Sciences and Engineering Researches*, 210–214.

[7] S. Anisa, A. Komarudin, and E. Ramadhan, "SISTEM KLASIFIKASI UNTUK MENENTUKAN TINGKAT STRESS MAHASISWA SECARA UMUM MENGGUNAKAN METODE K-NEAREST NEIGHBORS", JINTEKS, vol. 6, no. 3, pp. 568–578, Aug. 2024.

[8] R. Arifudin, S. Subhan, and Y. N. Ifriza, "Student Adaptability Level Optimization using GridsearchCV with Gaussian Naive Bayes and K-Nearest Neighbor Methods as an

Effort to Improve Online Education Predictions", j. nas. pendidik. teknik. inform., vol. 14, no. 2, pp. 287–295, Jul. 2025.
[9] N. A. Widya Pertiwi and I. S. Wibisono, "Comparison of K-Nearest Neighbor, Naïve Bayes, and C4.5 Algorithms for Predicting Academic Stress Risk in Students Based on Psychological Survey Data", JAIC, vol. 10, no. 1, pp. 698–706, Feb. 2026.
[10] A. R. Sinadia, "Sumikolah: Jurnal Ilmu Pendidikan Aplikasi dan Praktik Konstruksi Skala Psikologi sebagai Instrumen Pengukuran dalam Penelitian Pendidikan," vol. 2, no. 1, 2024.
[11] Condroningtyas, S. A., & Marsofiyati, M. (2024). Pengaruh Tekanan Atau Stres Akademik Terhadap Prestasi Belajar Mahasiswa. Cendikia: Jurnal Pendidikan Dan Pengajaran, 2(6), 205–212. Retrieved from https://jurnal.kolibi.org/index.php/cendikia/article/view/1697
[12] F. A. Fitrony and S. M. Zulkif, "Forest Fire Detection Using the FireNet-Convolutional Neural Network Model with Image Augmentation", pectc, vol. 2, no. 1, pp. 105–115, Oct. 2025.
[13] D. Kurniadi, E. Abdurachman, H. L. H. S. Warnars, and W. Suparta, "The prediction of scholarship recipients in higher education using K-Nearest neighbor algorithm," IOP Conf. Ser. Mater. Sci. Eng., vol. 434, no. 1, p. 012039, 2018, DOI: 10.1088/1757-899X/434/1/012039.
[14] D. Yonitasari and R. Setiyani, Pengaruh Cara Belajar, Lingkungan Keluarga, dan Fasilitas Belajar Terhadap Prestasi Belajar Ekonomi Akuntansi Siswa Kelas XI IPS SMA Negeri 4 Magelang Tahun Ajaran 2013/2014,â€ Econ. Educ. Anal. J., vol. 3, no. 2, pp. 241â€“248, 2014.
[15] M. Mustakim and G. Oktaviani, Algoritma K-Nearest Neighbor Classification Sebagai Sistem Prediksi Predikat Prestasi Mahasiswa,â€ J. Sains dan Teknol. Ind., vol. 13, no. 2, pp. 195â€“202, 2016.
[16] H. Susanto and S. Sudiyatno, Data mining untuk memprediksi prestasi siswa berdasarkan sosial ekonomi, motivasi, kedisiplinan dan prestasi masa lalu,â€ J. Pendidik. Vokasi, vol. 4, no. 2, pp. 222â€“231, 2014, doi: 10.21831/jpv.v4i2.2547.