
INTEGRASI SENSOR IOT DAN OPTIMASI ALGORITMA MACHINE LEARNING UNTUK DETEKSI REAL-TIME TINGKAT STRES MAHASISWA

Richi Andrianto¹, Mustopa Husein Lubis², Rina Irawan³, Yuda Irawan⁴,
Urfi Utami⁵

^{1,2,3}Institut Teknologi dan Sains Padang Lawas Utara, Sumatera Utara

⁴Universitas Hang Tuah Pekanbaru, Pekanbaru

⁵Universitas Pasir Pengaraian, Rokan Hulu

e-mail: ¹richiandrianto28@gmail.com, ²mustopahusein1302@gmail.com,
³rinairawan981@gmail.com, ⁴yudairawan89@gmail.com, ⁵urfiutami@upp.ac.id

Abstract: High levels of stress among university students are a critical issue that can affect mental health, well-being, and academic performance. This study aims to develop a real-time student stress detection system using physiological data integrated with IoT technology and machine learning algorithms. The data used includes body temperature, blood oxygen saturation (SpO₂), heart rate, and blood pressure, acquired via embedded sensors and automatically transmitted to the cloud. The classification model was built using a combination of Random Forest and XGBoost, with enhanced accuracy through SMOTE-based data balancing and hyperparameter optimization using Optuna. The system was tested on a dataset of 3,420 records, classified into four stress levels: anxious, calm, tense, and relaxed. Evaluation results showed that the Random Forest model achieved the highest accuracy of 91%, followed by RF + XGBoost and RF + XGBoost + Optuna with accuracies of 90% each. The final model was deployed in a user interface using Streamlit, allowing real-time stress classification from IoT sensor input and manual input testing. The system proved to be effective and responsive in detecting stress objectively and can support digital-based mental health monitoring and counseling services for students.

Keywords: Stress detection, IoT, Machine Learning, Random Forest, XGBoost

Abstrak: Tingkat stres yang tinggi di kalangan mahasiswa merupakan permasalahan serius yang dapat memengaruhi kesehatan mental, kesejahteraan, dan performa akademik. Penelitian ini bertujuan untuk mengembangkan sistem deteksi tingkat stres mahasiswa secara real-time menggunakan data fisiologis berbasis teknologi IoT dan algoritma machine learning. Data yang digunakan meliputi suhu tubuh, kadar oksigen dalam darah (SpO₂), detak jantung, dan tekanan darah yang diperoleh melalui sensor terintegrasi dan dikirim ke cloud secara otomatis. Model klasifikasi yang dikembangkan memanfaatkan kombinasi algoritma Random Forest dan XGBoost, dengan peningkatan akurasi melalui teknik balancing data menggunakan SMOTE dan optimasi hyperparameter otomatis menggunakan Optuna. Sistem diuji menggunakan dataset berjumlah 3.420 data dengan distribusi empat kelas stres: cemas, tenang, tegang, dan rileks. Hasil evaluasi menunjukkan bahwa model Random Forest menghasilkan akurasi tertinggi sebesar 91%, disusul oleh RF + XGBoost dan RF + XGBoost + Optuna dengan akurasi masing-masing sebesar 90%. Model akhir kemudian diintegrasikan ke dalam antarmuka pengguna berbasis Streamlit, yang memungkinkan klasifikasi stres secara real-time dari data sensor IoT dan juga melalui input manual. Sistem ini terbukti efektif dan responsif dalam mendeteksi stres secara objektif dan dapat digunakan untuk mendukung layanan konseling atau pemantauan kesehatan mental mahasiswa secara digital.

Kata kunci: Deteksi stres, IoT, Machine Learning, Random Forest, XGBoost

PENDAHULUAN

Stres merupakan salah satu masalah kesehatan mental yang umum dialami oleh mahasiswa di berbagai negara (Fadilla et al., 2024; Gustiadi et al., 2025). Tekanan akademik, tuntutan sosial, dan perubahan lingkungan turut berkontribusi terhadap tingginya tingkat stres di kalangan mahasiswa, yang berdampak negatif pada kesehatan fisik, mental, serta prestasi akademik mereka (Irwin Hidayat, 2019). Studi menyebutkan bahwa lebih dari 60% mahasiswa mengalami stres tinggi selama masa studi (Anggraini et al., 2025).

Dalam dunia pendidikan tinggi, mahasiswa dituntut untuk menyelesaikan berbagai tugas, mengikuti ujian, dan beradaptasi dengan lingkungan baru dalam waktu yang terbatas. Tekanan tersebut dapat menyebabkan gangguan tidur, kelelahan, hingga kecemasan kronis apabila tidak dikelola dengan baik (Awaru et al., 2024). Oleh karena itu dibutuhkan metode yang efektif untuk mendeteksi dan memantau tingkat stres secara dini (Ridha et al., 2024).

Peneliti sebelumnya mengembangkan sistem deteksi stres berbasis IoT dengan fuzzy logic, dan memperoleh akurasi tertinggi 92%, namun belum mengoptimalkan proses adaptif model (Mentis et al., 2024). Selanjutnya menggabungkan data fisiologis dan kontekstual untuk memantau stres harian, tetapi sistemnya belum mendukung klasifikasi real-time berbasis IoT (Irmayanti et al., 2022). Peneliti lain berhasil meningkatkan performa klasifikasi stres menggunakan teknik SMOTE untuk mengatasi ketidakseimbangan data, namun belum diintegrasikan dalam sistem pemrosesan real-time (Oktaviani et al., 2024).

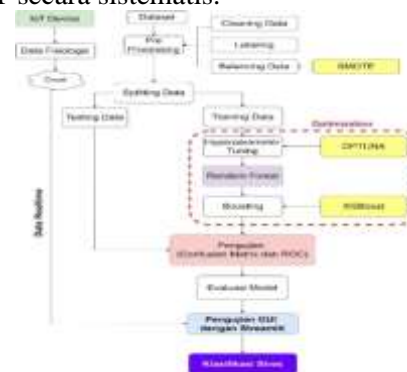
Studi lain merancang prototipe sistem wearable untuk lansia, namun hanya menggunakan satu algoritma ML dan belum dilengkapi dengan proses optimasi hyperparameter (Juliantino & Widasari, 2025). Pendekatan lain yang menggunakan sensor smartphone atau

pengukuran aktivitas mengetik menunjukkan potensi deteksi stres berbasis perilaku, namun tidak melibatkan sinyal fisiologis secara menyeluruh (Sza et al., 2023). Peneliti selanjutnya memvalidasi teknologi wearable dalam tiga tahap untuk pemantauan stres, namun masih terbatas pada pengukuran pasif tanpa sistem klasifikasi yang aktif dan adaptif (Lilyanti, 2025). Selain itu penelitian lain merancang sistem IoT untuk memantau stres menggunakan sensor wearable, namun belum mengintegrasikan algoritma machine learning canggih dan optimasi model (Pratama et al., 2024).

Sejumlah penelitian juga telah menerapkan algoritma seperti KNN, SVM, dan Decision Tree untuk klasifikasi stres, namun akurasi dan kestabilan model masih bergantung pada konfigurasi manual dan data yang tidak seimbang (Farhan & Setiaji, 2023; Manullang et al., 2024; Solihah et al., 2025). Di sisi lain beberapa pendekatan berbasis sinyal fisiologis seperti EEG dan EMG memiliki keterbatasan pada aspek portabilitas dan penerapan di luar laboratorium (Devianto et al., 2024) (Raden et al., 2024).

METODE

Gambar 1 menyajikan rincian tahapan dalam proses pengembangan model yang terintegrasi dengan teknologi IoT secara sistematis:




Gambar 1 Alur Pengembangan Model

Berikut penjelasan singkat dari ringkasan alur model:

$$\begin{matrix} X, y \\ \xrightarrow{\text{SMOTE}} X', y' \end{matrix} \xrightarrow{\text{Optuna}} \theta^* \xrightarrow{\text{Random Forest+XGBoost}} \hat{y}$$

Untuk kelas Calm, model juga mempertahankan akurasi tinggi dengan 346 prediksi benar. Meskipun masih terdapat beberapa misclassifications, terutama pada kelas Relaxed (2) dan Tense (3), kesalahan tersebar secara proporsional dan tidak terkonsentrasi pada satu kelas saja. Hal ini mengindikasikan bahwa teknik boosting melalui XGBoost berhasil memperkuat kemampuan model dalam membedakan pola antar kelas yang kompleks, sekaligus meningkatkan performa klasifikasi keseluruhan.

Setelah dilakukan proses optimasi hyperparameter menggunakan Optuna, model gabungan RF + XGBoost mengalami peningkatan performa yang lebih stabil dan akurat. Hasil evaluasi akhir model setelah tuning ditunjukkan pada Gambar 8:




Gambar 8 Confusion Matrix untuk Model RF + XGBoost dengan Optimasi Optuna

Kelas Calm (1), Relaxed (2), dan Tense (3) masing-masing menunjukkan 343, 335, dan 331 prediksi benar. Total kesalahan klasifikasi tersebar merata dan lebih rendah dibanding model sebelumnya. Hal ini menunjukkan bahwa penggunaan Optuna berhasil menyempurnakan konfigurasi hyperparameter, sehingga meningkatkan efisiensi pembelajaran model serta memperbaiki kemampuan generalisasi terhadap data yang belum pernah dilihat. Secara keseluruhan, model ini menjadi versi terbaik dari seluruh kombinasi yang diuji.

Analisis ROC Curve

Untuk mengevaluasi performa model dalam membedakan antar kelas secara keseluruhan, digunakan kurva

Receiver Operating Characteristic (ROC) yang menggambarkan hubungan antara True Positive Rate dan False Positive Rate. Adapun hasil ROC Curve dari model RF, RF + XGBoost, dan RF + XGBoost + Optuna dapat dilihat pada Gambar 9:



Gambar 9 Kurva ROC untuk Model RF, RF + XGBoost, dan RF + XGBoost + Optuna

Uji Perangkat IoT dan Pengujian Model

Sebelum model diintegrasikan ke dalam sistem real-time, dilakukan pengujian fungsional terhadap perangkat IoT untuk memastikan stabilitas akuisisi data fisiologis dan kompatibilitas dengan platform klasifikasi. Adapun tampilan fisik dan operasional dari perangkat IoT yang telah dikembangkan dapat dilihat pada Gambar 10:



Gambar 10 Tampilan Fisik dan Operasional Perangkat IoT untuk Deteksi Stres

Perangkat ini juga terhubung dengan mikrokontroler dan sistem pengukuran tekanan darah untuk mendukung akurasi data. Seluruh sensor bekerja secara simultan dan mengirimkan data ke cloud untuk kemudian diproses oleh model machine learning. Pengujian perangkat menunjukkan bahwa transmisi data berjalan stabil dengan interval pengiriman <3 detik, serta kompatibel secara penuh dengan antarmuka Streamlit yang digunakan untuk klasifikasi stres secara real-time.



Gambar 11 Uji Coba Langsung Perangkat IoT oleh Responden

Hasil pengukuran ditampilkan secara real-time pada layar perangkat dan dikirim ke model klasifikasi untuk menentukan tingkat stres pengguna. Uji coba ini menunjukkan bahwa sistem dapat digunakan secara praktis oleh pengguna non-teknis, dengan hasil klasifikasi yang ditampilkan secara cepat dan akurat. Hal ini mengindikasikan bahwa sistem telah siap untuk digunakan dalam lingkungan nyata seperti layanan konseling kampus atau monitoring kesehatan preventif.

Sebagai bagian dari sistem pemantauan real-time, data yang dikirim oleh perangkat IoT disimpan secara otomatis ke cloud menggunakan Google Sheets sebagai media integrasi antarmuka. Adapun tampilan data yang terekam secara real-time pada cloud server dapat dilihat pada Gambar 12:

Timestamp	HR (b/m)	HRV (ms)	SpO2 (%)	Temperature (°C)
8/10/2025 08:34:36	34,2	58	98	36,8
8/10/2025 08:34:38	32,7	60	98	36,8
8/10/2025 08:34:40	30,8	60	98	36,8
8/10/2025 08:34:42	41,2	58	98	36,8
8/10/2025 08:34:44	33,9	62	98	36,8
8/10/2025 08:34:46	34,9	65	98	36,8
8/10/2025 08:34:48	36	70	97	36,8
8/10/2025 08:34:50	35,5	70	98	36,8

Gambar 12 Tampilan Dataset Fisiologis Real-Time dari Perangkat IoT di Google Sheets

Sebagai bagian dari integrasi sistem deteksi stres berbasis AI-IoT, data hasil klasifikasi ditampilkan melalui dashboard antarmuka pengguna yang dirancang menggunakan Streamlit. Adapun tampilan sistem pada saat melakukan deteksi real-time dapat dilihat pada Gambar 13:



Gambar 13 Tampilan Antarmuka Streamlit Sistem Deteksi Stres Mahasiswa Secara Real-Time

Antarmuka dirancang sederhana, informatif, dan mudah diakses melalui perangkat laptop maupun mobile. Sistem ini bekerja dengan memanfaatkan model machine learning hasil training menggunakan kombinasi algoritma Random Forest, XGBoost, dan optimasi hyperparameter dengan Optuna.

Model tersebut telah diuji dan divalidasi pada dataset terstruktur dan data sensor nyata, sehingga mampu memberikan hasil klasifikasi yang akurat dan adaptif saat digunakan dalam kondisi real-time. Dengan pendekatan ini, sistem tidak hanya menyediakan klasifikasi stres yang presisi, tetapi juga memudahkan pengguna maupun tenaga konselor untuk melakukan monitoring secara cepat dan responsif.


Selain pengujian data real-time dari perangkat IoT, sistem juga menyediakan fitur input manual yang memungkinkan pengguna menguji model dengan memasukkan nilai parameter fisiologis secara langsung. Adapun tampilan fitur deteksi manual tersebut dapat dilihat pada Gambar 14:



Gambar 14 Tampilan Fitur Uji Manual Data Fisiologis pada Sistem Klasifikasi Stres

Diskusi Hasil

Untuk mengetahui efektivitas masing-masing pendekatan dalam klasifikasi tingkat stres mahasiswa, dilakukan perbandingan akurasi model pada tiga skenario: Random Forest (RF), kombinasi RF dengan XGBoost (RF+XGB), dan RF+XGB yang telah dioptimasi menggunakan Optuna. Adapun hasil perbandingan akurasi dari ketiga model tersebut dapat dilihat pada Gambar 15:



Gambar 15 Perbandingan Akurasi Model RF, RF + XGBoost, dan RF + XGBoost + Optuna

Namun demikian, penting dicatat bahwa peningkatan performa model tidak hanya diukur dari akurasi saja. Model RF + XGB + Optuna menunjukkan peningkatan dalam aspek stabilitas prediksi, persebaran kesalahan yang lebih proporsional (berdasarkan confusion matrix), dan kurva ROC yang lebih halus. Hal ini menandakan bahwa model gabungan yang dioptimasi dapat memberikan kinerja yang lebih seimbang pada kondisi data real-time, terutama dalam konteks sistem deteksi stres berbasis IoT yang dinamis. Oleh karena itu, meskipun akurasinya setara, model RF + XGB + Optuna tetap dipilih sebagai model akhir karena menawarkan trade-off terbaik antara performa, generalisasi, dan stabilitas klasifikasi.

SIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi tingkat stres mahasiswa secara real-time berbasis data fisiologis menggunakan teknologi IoT dan model machine learning. Parameter fisiologis seperti suhu tubuh, kadar oksigen dalam darah (SpO_2), dan detak jantung diperoleh dari perangkat IoT berbasis ESP32 yang terhubung dengan sensor industri, lalu dikirim secara otomatis ke cloud untuk diproses oleh model klasifikasi. Tiga pendekatan model diuji, yaitu Random Forest, kombinasi Random Forest dan XGBoost, serta versi yang dioptimasi menggunakan Optuna.

Hasil evaluasi menunjukkan bahwa

model Random Forest mencatatkan akurasi tertinggi sebesar 91%, meskipun model RF + XGBoost + Optuna menunjukkan kinerja yang lebih stabil dengan distribusi kesalahan yang proporsional serta kurva ROC yang lebih baik. Sistem mampu mengklasifikasikan tingkat stres ke dalam empat kelas: cemas (Anxious), tenang (Calm), tegang (Tense), dan rileks (Relaxed), serta menampilkannya secara langsung melalui antarmuka visual berbasis Streamlit. Sistem ini terbukti akurat, efisien, dan aplikatif dalam mendukung upaya deteksi dini stres mahasiswa secara objektif dan berkelanjutan.

Untuk pengembangan selanjutnya, penelitian ini dapat ditingkatkan dengan menambahkan sensor tekanan darah (sistolik dan diastolik) sebagai variabel fisiologis tambahan yang relevan dalam konteks stres. Selain itu, integrasi sensor seperti Galvanic Skin Response (GSR) dan EEG ringan juga dapat digunakan untuk memperkaya dimensi data. Penelitian lanjutan juga disarankan untuk memperluas cakupan uji coba pada populasi yang lebih beragam, mengembangkan model adaptif berbasis pembelajaran online, serta menambahkan fitur intervensi atau rekomendasi tindakan berdasarkan tingkat stres yang terdeteksi.

DAFTAR PUSTAKA

- Anggraini, D. R., Dassena, M. C., Setyawan, D., Alfian, R., Lestari, D., & Girsang, D. G. (2025). Terapi Pijat sebagai Alternatif Pengelolaan Kesehatan Mental: Studi Kasus pada Mahasiswa STOK Bina Guna Tahun 2024. *JURNAL PENGABDIAN MASYARAKAT BANGSA*, 3(1), 72–77.
- Anisa, S., Komarudin, A., & Ramadhan, E. (2024). Sistem Klasifikasi Untuk Menentukan Tingkat Stress 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>
- Awara, J. P., Bina, U., Gorontalo, T., Katili, A. Y., Ade, S., Gobel, M., Akhirun, L., Bina, U., Gorontalo, T., & Digital, E. (2024). PENCEGAHAN DEPRESI DAN KESEHATAN MENTAL GENERASI-Z, DALAM MENJAWAB KECEMASAN DI ERA. *Jurnal Pengabdian Awara*, 1(November), 35–50.
- Devianto, Y., Setiawan, A., Dewi, C., Iriani, A., Dwi Purnomo, H., & Sembiring, I. (2024). Systematic Literature Review: On Measuring the Level of Emotional Experience Based on EEG Signals. *2024 2nd International Conference on Technology Innovation and Its Applications (ICTIIA)*, 1–5. <https://doi.org/10.1109/ICTIIA61827.2024.10761523>
- Fadilla, M., Hartantri, S., Siagian, S., Dasopang, W., & Syekh Abdul Halim Hasan Binjai, I. (2024). Analisis Faktor Penyebab Stres Pada Mahasiswa dan Dampaknya Terhadap Kesehatan Mental. *Jurnal Inovasi Riset Ilmu Kesehatan*, 4(1), 1–11. <https://jayapanguspress.penerbit.org/index.php/metta>
- Fallo, S. I. (2025). CLASSIFICATION OF SUPPORT VECTOR MACHINE AND RANDOM FOREST ON BIOMEDICAL DATA: APPLICATIONS IN DIABETES DISEASE DATA ANALYSIS. *JURNAL KEPENDIDIKAN MATEMATIKA*, 6(1).
- Farhan, N. M., & Setiaji, B. (2023). Penentuan Tingkat Stres berdasarkan Bio-Parameter Menggunakan Variasi Kernel Support Vector Machine. *Indonesian Journal of Computer Science*, 12(2), 284–301. <http://ijcs.stmikindonesia.ac.id/ijcs/index.php/ijcs/article/view/3135>
- Gustiadi, A., Lazuardi, L., Gizi, P., Tasikmalaya, P. K., Mada, U. G., & Tasikmalaya, P. (2025). GAMBARAN KESEHATAN MENTAL PADA MAHASIWA POLTEKKES TASIKMALAYA. *Jurnal Ilmiah Keperawatan*, 13(1), 76–85. <https://doi.org/10.52236/ih.v13i1.685>
- Irmayanti, Tari Mokui, H., Wa Ode Siti Nur Alam, dan, & Author, C. (2022). Sistem Pendeteksi Stres pada Manusia Menggunakan Metode Fuzzy Logic Berbasis Internet of Things. *Jurnal Fokus Elektroda*, 7(3), 185–192. <https://elektroda.uho.ac.id/>
- Irwin Hidayat. (2019). Optimalisasi Pendidikan Islam dalam Meningkatkan Kesejahteraan Mental Serta Mengurangi Burnout di Kalangan Pelajar. *Jurnal Al-Qalam: Jurnal Kajian Islam Dan Pendidikan*, Volume 11(2 issues per year (June & December)), 66–67. <https://doi.org/10.47435/al-qalam.v16i1.3282>
- Juliantino, Y. R., & Widasari, E. R. (2025). Implementasi Metode K-Nearest Neighbor untuk Deteksi Dini Stres Berbasis Neurosky Electroencephalogram Sensor. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 9(5), 1–8.
- Lilyanti, H. (2025). Deteksi tingkat kelelahan pekerja berbasis smartwatch dengan pendekatan machine learning pada perusahaan manufaktur di Kabupaten Karawang: Mixed method study. *Holistik Jurnal Kesehatan*, 18(12), 1468–1477.
- Lubis, A., Irawan, Y., Junadhi, & Defit, S. (2024). Leveraging K-Nearest Neighbors with SMOTE and Boosting Techniques for Data Imbalance and Accuracy Improvement. *Journal of Applied Data Sciences*, 5(4), 1625–1638. <https://doi.org/10.47738/jads.v5i4.3>

- 43
- Manullang, B., Pane, E. P., Sistem, S., Fakultas, I., Komputer, I., & Lancang, U. (2024). Sistem Pakar Untuk Diagnosa Kesehatan Mental Menggunakan Metode Decision Tree Berbasis Android. *Prosiding-Seminar Nasional Teknologi Informasi & Ilmu Komputer(SEMASTER)*, 3(1), 25–36.
- Mentis, A.-F. A., Lee, D., & Roussos, P. (2024). Applications of artificial intelligence–machine learning for detection of stress: a critical overview. *Molecular Psychiatry*, 29(6), 1882–1894. <https://doi.org/10.1038/s41380-023-02047-6>
- Natras, R., Soja, B., & Schmidt, M. (2022). Ensemble Machine Learning of Random Forest, AdaBoost and XGBoost for Vertical Total Electron Content Forecasting. *Remote Sensing*, 14(15), 1–34. <https://doi.org/10.3390/rs14153547>
- No, V., Syahreza, A., Ningrum, N. K., & Syahrazy, M. A. (2024). Perbandingan Kinerja Model Prediksi Cuaca: Random Forest, Support Vector Regression, dan XGBoost. *Jurnal Pendidikan Informatika*, 8(2), 526–534. <https://doi.org/10.29408/edumatic.v8i2.27640>
- Oktaviani, V., Rosmawarni, N., & Muslim, M. P. (2024). Perbandingan Kinerja Random Forest Dan Smote Random Forest Dalam Mendeteksi Dan Mengukur Tingkat Stres Pada Mahasiswa Tingkat Akhir. *Informatik: Jurnal Ilmu Komputer*, 20(1), 43–49. <https://doi.org/10.52958/iftk.v20i1.9158>
- Pratama, F. A., Pradana, A. I., & Hartanti, D. (2024). Pengembangan Aplikasi Mobile Untuk Monitoring Detak Jantung, Saturasi Oksigen Darah, Dan Suhu Tubuh Dengan Integrasi Iot Menggunakan Esp32. *Infotech: Journal of Technology Information*, 10(1), 27–36. <https://doi.org/10.37365/jti.v10i1.244>
- Raden, J. L., Pagar, F., Selebar, K., & Bengkulu, K. (2024). Tren Terbaru Penerapan Machine Learning Mendeteksi Masalah dalam Kesehatan Mental Perspektif Hukum Islam. *JURNAL HUKUM ISLAM DAN PERADILAN*, 9(2), 289–295.
- Ridha, D., Putri, D., Fahlevi, M. R., Sadikin, M., Rizki, M., & Utomo, F. (2024). Prediksi Tingkat Depresi Remaja Menggunakan Metode Naïve Bayes Classifier: Analisis Faktor Psikologis Dan Lingkungan. *KESATRIA: Jurnal Penerapan Sistem Informasi*, 5(4), 2034–2043.
- Solihah, S. L., Agusya, K. Z., Aulia, S. F., Asfi, M., Informatika, T., Catur, U., Cendekia, I., Informasi, S., Catur, U., Cendekia, I., Neighbor, K., & Karakter, P. (2025). Implementasi Metode K-Nearest Neighbor Untuk Mendeteksi Tingkat Stres Pelajar Berdasarkan Tingkat Perundungan. *Jurnal Aplikasi Bisnis Dan Komputer*, 5(1), 11–21.
- Sza, S., Larasati, A., Nuraida, E., Dewi, K., Farhansyah, B. H., Bachtiar, F. A., Pradana, F., Brawijaya, U., Korespondensi, P., & Forest, R. (2023). Penerapan Decision Tree Dan Random Forest Dalam Deteksi the Application of Decision Tree and Random Forest in Detecting Human Stress Levels Based on Sleep Conditions. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 10(7), 1503–1510. <https://doi.org/10.25126/jtiik.2024117993>