

Machine Learning untuk Deteksi Stres Pelajar: Perceptron sebagai Model Klasifikasi Efektif untuk Intervensi Dini

Febrina Nabila Zahrah¹, Muljono^{1,*}

¹ Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

* Correspondence: muljono@dsn.dinus.ac.id

Copyright: © 2024 by the authors

Received: 31 Oktober 2024 | Revised: 17 November 2024 | Accepted: 3 Desember 2024 | Published: 19 Desember 2024

Abstrak

Stres merupakan tantangan serius bagi pelajar yang dapat berdampak negatif pada kesehatan fisik, mental, dan kinerja akademik. Namun, pendekatan deteksi stres yang akurat dan efektif untuk mendukung intervensi dini masih sangat terbatas. Penelitian ini bertujuan mengevaluasi model *machine learning* untuk mendeteksi tingkat stres pelajar dengan akurasi yang optimal guna mendukung intervensi dini. Penelitian ini menggunakan pendekatan kuantitatif dengan dataset berisi 1.100 sampel pelajar dari Nepal, mencakup 20 fitur faktor stres dari aspek psikologis, sosial, akademik, lingkungan, dan fisiologis. Data dikumpulkan melalui kuesioner berbasis *self-report*, diproses menggunakan *preprocessing* berupa *scaling* dengan *StandardScaler*, dan dianalisis dengan teknik *10-fold cross-validation*. Model yang diuji meliputi *Perceptron*, *Gradient Boosting Trees Classifier* (GBTC), *Naive Bayes* (NB), *Logistic Regression* (LR), dan *AdaBoost*. Hasil penelitian menunjukkan bahwa *Perceptron* memiliki kinerja terbaik dengan akurasi (97,27%), diikuti oleh NB (95,45%), GBTC (94,54%), LR (94,54%), dan *AdaBoost* (93,63%). *Perceptron*, dengan keunggulan linearitas dan evaluasi melalui *10-fold cross-validation*, menunjukkan potensi besar sebagai model klasifikasi efektif untuk deteksi stres pelajar, yang dapat mempercepat intervensi dini dan meningkatkan kesejahteraan serta lingkungan belajar.

Kata kunci: deteksi stres; *machine learning*; *perceptron*; stres pelajar;

Abstract

Stress is a serious challenge for students that can negatively impact physical health, mental well-being, and academic performance. However, accurate and effective stress detection approaches to support early intervention are still limited. This study aims to evaluate machine learning models for detecting student stress levels with optimal accuracy to facilitate early intervention. The research employs a quantitative approach using a dataset containing 1,100 student samples from Nepal, encompassing 20 stress-related features from psychological, social, academic, environmental, and physiological aspects. Data were collected via a self-report questionnaire, processed with StandardScaler scaling, and analyzed using 10-fold cross-validation. The models tested include Perceptron, Gradient Boosting Trees Classifier (GBTC), Naive Bayes (NB), Logistic Regression (LR), and AdaBoost. The results show that Perceptron performed the best with an accuracy of 97.27%, followed by NB (95.45%), GBTC (94.54%), LR (94.54%), and AdaBoost (93.63%). Perceptron, with its advantage in linearity and evaluation through 10-fold cross-validation, shows great potential as an effective classification model for student stress detection, which can accelerate early intervention and enhance student well-being and learning environments.

Keywords: *stress detection; machine learning; perceptron; student stress*



PENDAHULUAN

Stres merupakan salah satu tantangan utama yang dihadapi pelajar di berbagai jenjang pendidikan, terutama di lingkungan akademik yang kompetitif. Data menunjukkan bahwa tingkat stres pada mahasiswa mencapai 84,4% disertai kecemasan dan depresi yang umum dialami (Asif et al., 2020; Nakie et al., 2022). Menurut *World Health Organization* (WHO) lebih dari 720.000 kematian akibat bunuh diri setiap tahun, menjadikannya penyebab kematian tertinggi kedua di kalangan remaja (World Health Organization, 2023). Apabila tidak diatasi dengan baik, stres ini dapat berkembang menjadi kondisi kronis dengan dampak ekstrem, termasuk risiko bunuh diri (Montgomery et al., 2024).

Meskipun dampak stres begitu serius, banyak pelajar enggan mencari bantuan profesional karena stigma sosial dan khawatir akan penilaian negatif, sehingga memilih menyembunyikan masalah kesehatan mentalnya (Emmer et al., 2020). Deteksi stres medis saat ini mengandalkan pengukuran kadar kortisol melalui sampel darah atau urin yang memakan waktu, tidak nyaman, dan berbiaya tinggi, dengan rata-rata biaya mencapai \$50 hingga \$150 per tes (Iqbal et al., 2023; Sekar et al., 2020). Oleh karena itu, diperlukan metode deteksi stres yang efisien, menjaga privasi, serta mengurangi ketakutan terhadap penilaian negatif. Teknologi *machine learning* menawarkan solusi praktis dan non-invasif dengan menganalisis data perilaku untuk mendeteksi pola stres tanpa interaksi langsung (Shahapur et al., 2024; Susanti, 2024).

Stres dalam penelitian ini didefinisikan sebagai respons fisiologis dan psikologis terhadap tekanan dari faktor akademik, sosial, dan lingkungan. Penelitian sebelumnya mengidentifikasi lima pemicu utama stres dijabarkan menjadi 20 fitur yang meliputi faktor psikologis (kecemasan, kepercayaan diri, riwayat kesehatan mental, dan depresi), faktor fisiologis (kualitas tidur, tekanan darah, sakit kepala, dan kesulitan bernapas), faktor lingkungan (kebisingan, kondisi tempat tinggal, rasa aman, dan kebutuhan dasar), faktor akademik (performa akademik, beban tugas, hubungan guru-murid, dan ketidakpastian karir), serta faktor sosial (dukungan sosial, tekanan teman sebaya, kegiatan ekstrakurikuler, dan perundungan) (Arya et al., 2024; De Filippis & Foysal, 2024). Pengukuran stres dilakukan melalui kuesioner *self-report* dan pengukuran objektif, yang menghasilkan klasifikasi stres ke dalam tiga tingkat: rendah, sedang, dan tinggi. Pendekatan ini memastikan seluruh faktor penyebab stres dipertimbangkan secara komprehensif untuk mendukung akurasi metode *machine learning* dalam mendeteksi stres pelajar (Jiménez-Mijangos et al., 2023; Mentis et al., 2024).

Berbagai penelitian telah menggunakan *machine learning* untuk mendeteksi tingkat stres pada pelajar dengan berbagai model dan pendekatan yang bervariasi. Pada penelitian (Rajeswari et al., 2024) mengusulkan model berbasis pohon keputusan seperti *decision tree*, *random forest*, *AdaBoost*, dan *XGBoost* untuk mendeteksi stres pada pelajar menggunakan dataset Kaggle berisi 1.100 sampel dengan 20 fitur faktor stres. Dataset ini dioptimalkan dengan *Principal Component Analysis* (PCA) yang mereduksi fitur menjadi 4 komponen utama serta tuning hiperparameter pada model. Hasil penelitian menunjukkan *random forest* sebagai algoritma terbaik dengan akurasi 90% dan *decision tree* terendah dengan 81%. Fokus penelitian adalah menggabungkan pengklasifikasi berbasis pohon guna meningkatkan akurasi.

Selain itu, penelitian yang dilakukan oleh Arya et al. (2024) memanfaatkan pendekatan *Support Vector Machine* (SVM) dan *Artificial Neural Network* (ANN) dengan menggunakan model seperti SVM, *random forest*, *gradient boosting*, *AdaBoost*, dan lainnya, pada dataset yang sama. Dataset, yang terdiri dari 1.100 baris data, dibagi 80% untuk pelatihan dan 20% untuk pengujian. Hasil penelitian menunjukkan bahwa *naive bayes* memberikan akurasi tertinggi sebesar 90%, sedangkan SVM mencatatkan performa terendah dengan akurasi 85,45% setelah melalui proses tuning hiperparameter. Penelitian kami juga mengidentifikasi

bahwa masa ujian menjadi periode yang paling menekan, dengan faktor akademik menjadi penyebab utama tingkat stres yang tinggi pada pelajar.

Kedua penelitian ini menggunakan dataset yang serupa. Namun, terdapat beberapa kelemahan metodologis, seperti hilangnya informasi penting akibat penerapan PCA, kurangnya analisis interaksi antar faktor dan terbatasnya evaluasi model pada metrik akurasi tanpa mempertimbangkan *Area Under the Curve* (AUC) dan *Receiver Operating Characteristic* (ROC) (Rajeswari et al., 2024). Selain itu, terfokus pada algoritma berbasis pohon keputusan, optimasi hiperparameter yang tidak merata, dan kurangnya evaluasi efisiensi pemrosesan seperti *time execution* menjadi aspek yang perlu diperbaiki (Arya et al., 2024).

Sebagai langkah untuk mengatasi berbagai keterbatasan yang ada, penelitian ini mengusulkan lima model *machine learning* terbaik, yaitu *perceptron* karena kesederhanaannya dalam menangani data linier (Alkhamees, 2022), *gradient boosting trees classifier* untuk menangkap interaksi kompleks fitur (Moreno-Ibarra et al., 2021). *Naive bayes* dalam penelitian Armansyah & Ramli (2022) menunjukkan efisiensi yang sempurna dalam menangani dataset besar. *Logistic regression* untuk kestabilannya dalam klasifikasi biner, dan *AdaBoost* karena kemampuannya meningkatkan akurasi model dasar (Góngora Alonso et al., 2022; Lai et al., 2021). Pemilihan model ini dilakukan berdasarkan eksplorasi terhadap 16 model linier, 10 model ensemble, dan 13 model non-linier, dengan fokus pada keseimbangan antara kompleksitas, efisiensi, dan akurasi. Setiap model dioptimalkan menggunakan *10-fold cross-validation* untuk memastikan prediksi yang andal (Lyu et al., 2022; Sari et al., 2020).

Evaluasi dilakukan menggunakan *metrik accuracy, precision, recall, F1-score, AUC-ROC, confusion matrix* dengan *execution time* guna memberikan kinerja yang komprehensif (Sharma et al., 2021). Penelitian ini bertujuan untuk menentukan model *machine learning* terbaik dalam mendeteksi tingkat stres pelajar secara akurat, yang dapat menjadi dasar pengembangan sistem deteksi stres otomatis guna mendukung intervensi dini yang tepat waktu. Temuan ini nantinya dapat membantu pendidik dalam intervensi efektif, serta berkontribusi pada pengembangan aplikasi untuk mencegah stres kronis dan menciptakan lingkungan belajar yang sehat.

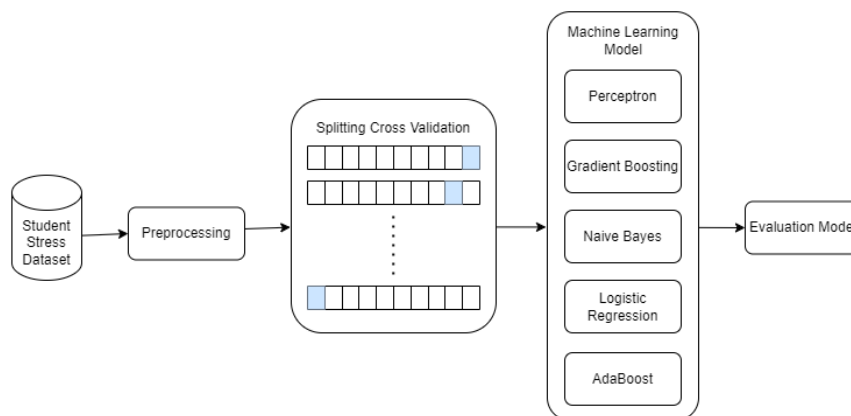
METODE

Penelitian ini melakukan deteksi stres pada pelajar dengan menggunakan model *machine learning*. Sebagaimana diilustrasikan dalam gambar 1, mencakup serangkaian tahapan mulai dari pengolahan dataset hingga evaluasi kinerja model. Dataset yang digunakan diperoleh dari platform Kaggle, yang terdiri dari 1.100 sampel pelajar SMA dan perguruan tinggi di Nepal. Dataset ini memiliki satu kolom target, yaitu *stress_level*, yang dikelompokkan ke dalam tiga kategori: Stres Level 0 (rendah) dengan 373 sampel, Stres Level 1 (sedang) sebanyak 358 sampel, dan Stres Level 2 (tinggi) dengan 369 sampel. Distribusi data yang seimbang ini mendukung penerapan teknik *machine learning* secara optimal. Selain itu, dataset ini mencakup 20 fitur yang mencakup faktor psikologis, akademis, sosial, lingkungan, dan fisiologis.

Dataset kemudian melalui proses *preprocessing*, tanpa ditemukan duplikasi, *missing value*, atau *outlier* yang signifikan. Semua kolom berupa tipe data integer, kecuali label kelas yang dikonversi menjadi tipe kategori untuk mendukung klasifikasi. Data kemudian di-*scaling* menggunakan *StandardScaler* mengubah fitur memiliki rata-rata 0 dan deviasi standar 1, guna memastikan semua fitur memiliki skala yang konsisten sehingga dapat meningkatkan performa. Proses *feature selection* menggunakan *Recursive Feature Elimination* (RFE) dan *Hyperparameter tuning* dengan *GridSearchCV* sempat diterapkan. Namun, seperti penelitian (Arya et al., 2024; Rajeswari et al., 2024) yang menggunakan teknik ini menghasilkan performa yang lebih rendah. Hal serupa juga ditemukan dalam penelitian ini, di mana hasil evaluasi

menunjukkan bahwa kedua teknik tersebut tidak meningkatkan akurasi model. Oleh karena itu, teknik tersebut tidak diterapkan dalam analisis akhir.

Dataset dibagi menggunakan metode *10-fold cross-validation*, yang membagi data menjadi 10 subset, masing-masing berisi 110 sampel. Setiap iterasi menggunakan satu fold sebagai data testing dan sembilan fold sebagai data training, diulang 10 kali untuk memastikan setiap data digunakan sebagai *data testing* dan *training*. Metode ini dipilih untuk memaksimalkan penggunaan dataset dan memberikan evaluasi yang lebih stabil dibandingkan *train-test split* sederhana (Malakouti et al., 2023). Pada tahap berikutnya, berbagai model *machine learning* dieksplorasi untuk menangani tugas klasifikasi stres. Sebanyak 16 model linier, 10 model ensemble, dan 13 model non-linier digunakan untuk mengevaluasi performa. Model linier seperti *Logistic Regression* dan *Perceptron* dipilih karena efisiensi dan interpretabilitasnya, sementara model ensemble seperti *Gradient Boosting* dan *AdaBoost* digunakan untuk meningkatkan akurasi. Model non-linier, seperti *Naive Bayes*, menangkap pola kompleks dalam data. Berdasarkan evaluasi metrik akurasi dan efisiensi, lima model terbaik yang dipilih adalah *perceptron*, *gradient boosting*, *naive bayes*, *logistic regression*, dan *AdaBoost*.



Gambar 1. Alur metode kalsifikasi yang digunakan

Kinerja model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *f1-score*, AUC-ROC, *Confusion Matrix* dan *time exceution*. *Accuracy* mengukur prediksi benar terhadap total data, sementara *precision*, *recall*, dan *f1-score* menilai keseimbangan prediksi positif dan sensitivitas model. AUC dan ROC mengevaluasi *trade-off* sensitivitas dan spesifisitas, memberikan gambaran menyeluruh terhadap kinerja model. *Confusion matrix* digunakan untuk menganalisis pola kesalahan prediksi, sedangkan *time execution* menilai efisiensi pemrosesan model. Evaluasi ini memberikan pandangan komprehensif untuk menentukan model terbaik yang akurat dan implementatif.

HASIL DAN PEMBAHASAN

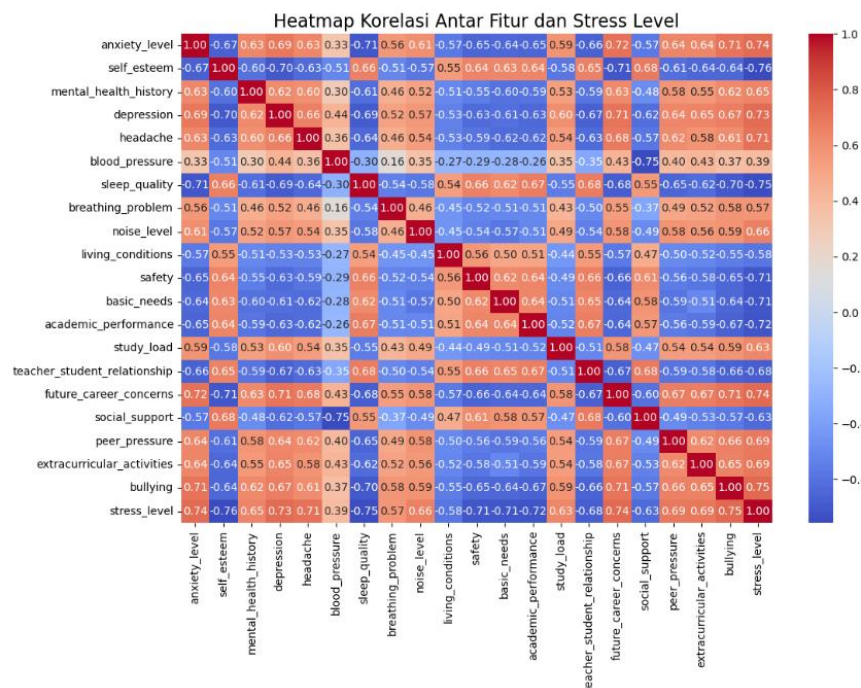
Hasil

Dataset yang diperoleh dari kuesioner *self-report* dan data objektif telah dianalisis secara deskriptif pada tabel 1, yang menunjukkan bahwa sebagian besar fitur memiliki distribusi data yang simetris, dengan rata-rata (*mean*) dan median yang relatif berdekatan. Beberapa fitur, seperti *self_esteem* (standar deviasi 8,94) dan *depression* (standar deviasi 7,72), memiliki variabilitas yang tinggi, menunjukkan adanya perbedaan signifikan di antara responden. Fitur seperti *mental_health_history* (rata-rata 0,49) dan *blood_pressure* (rata-rata 2,18) memiliki rentang nilai terbatas, mencerminkan sifat data biner atau kategorikal. Sebaliknya, fitur seperti *peer_pressure* dan *bullying* menunjukkan persebaran yang cukup merata. Data ini telah melalui proses pembersihan sehingga tidak ada duplikasi, *missing value*, atau *outlier* signifikan, dan

menunjukkan distribusi serta variabilitas yang memadai untuk mendukung analisis lanjutan, termasuk eksplorasi hubungan antar variabel yang divisualisasikan dalam *heatmap* pada gambar 2.

Tabel 1. Dataset Statistik Deskriptif

Features	count	mean	std	min	25%	50%	75%	max
<i>anxiety_level</i>	1100	11,06	6,11	0	6	11	16	21
<i>self_esteem</i>	1100	17,77	8,94	0	11	19	26	30
<i>mental_health_history</i>	1100	0,49	0,50	0	0	0	1	1
<i>depression</i>	1100	12,55	7,72	0	6	12	19	27
<i>headache</i>	1100	2,50	1,41	0	1	3	3	5
<i>blood_pressure</i>	1100	2,18	0,83	1	1	2	3	3
<i>sleep_quality</i>	1100	2,66	1,54	0	1	2,5	4	5
<i>breathing_problem</i>	1100	2,75	1,40	0	2	3	4	5
<i>noise_level</i>	1100	2,64	1,32	0	2	3	3	5
<i>living_conditions</i>	1100	2,51	1,11	0	2	2	3	5
<i>safety</i>	1100	2,73	1,41	0	2	2	4	5
<i>basic_needs</i>	1100	2,77	1,43	0	2	3	4	5
<i>academic_performance</i>	1100	2,77	1,41	0	2	2	4	5
<i>study_load</i>	1100	2,62	1,31	0	2	2	3	5
<i>teacher_student_relationship</i>	1100	2,64	1,38	0	2	2	4	5
<i>future_career_concerns</i>	1100	2,64	1,52	0	1	2	4	5
<i>social_support</i>	1100	1,88	1,04	0	1	2	3	3
<i>peer_pressure</i>	1100	2,73	1,42	0	2	2	4	5
<i>extracurricular_activities</i>	1100	2,76	1,41	0	2	2,5	4	5
<i>bullying</i>	1100	2,61	1,53	0	1	3	4	5



Gambar 2. Heatmap fitur level stres

Hubungan antar variabel terhadap *stress_level* pada gambar 2 menunjukkan pola signifikan yang mencerminkan lima faktor utama: psikologis, sosial, akademik, lingkungan, dan fisiologis. Pada faktor psikologis, *future_career_concerns* ($r = 0,74$), *anxiety_level* ($r = 0,74$), dan *depression* ($r = 0,73$) menunjukkan korelasi positif kuat, sementara pada faktor sosial, *peer_pressure* ($r = 0,69$) berkontribusi positif, dan *social_support* ($r = -0,63$) memiliki korelasi negatif, menandakan perannya dalam mengurangi stres. Faktor akademik seperti *study_load* ($r = 0,63$) meningkatkan stres, sedangkan *academic_performance* ($r = -0,72$) menurunkannya. Dari aspek lingkungan, *noise_level* ($r = 0,66$) dan *living_conditions* ($r = 0,56$) menunjukkan pengaruh signifikan, sedangkan faktor fisiologis seperti *headache* ($r = 0,66$) dan *sleep_quality* ($r = -0,64$) memperlihatkan hubungan yang relevan. Secara keseluruhan, *heatmap* ini menunjukkan bahwa faktor psikologis, sosial, akademik, lingkungan, dan fisiologis berperan signifikan dalam tingkat stres pelajar, sehingga mempertahankan semua fitur penting untuk integritas analisis.

Setelah analisis distribusi data dan hubungan antar variabel, dataset ini siap untuk pemodelan prediktif. Proses pemodelan dilakukan menggunakan teknik *10-fold cross-validation* untuk membagi data menjadi 10 subset. Lima algoritma *machine learning* diuji untuk menentukan model terbaik dalam mendeteksi stres pelajar, yaitu *perceptron*, *gradient boosting trees classifier*, *naive bayes*, *logistic regression*, dan *AdaBoost*. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *f1-score*, dengan tambahan *execution time* untuk mengukur efisiensi model.

Tabel 2. Hasil evaluasi eksperimen lima model

Algoritma	Accuracy (%)	Precision (%)	Sensitivity (%)	F1-Score (%)	Execution Time (s)
<i>Perceptron*</i>	97,27	97,50	97,43	97,36	0,011
<i>Gradient Boosting Trees Classifier</i>	94,54	94,53	94,52	94,51	0,623
<i>Naive Bayes</i>	95,45	96,05	95,39	95,56	0,003
<i>Logistic Regression</i>	94,54	94,57	94,92	94,66	0,020
<i>AdaBoost</i>	93,63	94,00	93,63	93,67	0,012

*Model algoritma terbaik

Hasil evaluasi pada tabel 2 menunjukkan bahwa algoritma *Perceptron* memberikan performa terbaik dengan akurasi tertinggi sebesar 97,27%, presisi 97,50%, sensitivitas 97,43%, dan *f1-score* 97,36%. Selain itu, *perceptron* juga memiliki waktu eksekusi tercepat, yaitu 0,011 detik, menjadikannya ideal untuk aplikasi deteksi tingkat stres. *Naive bayes* menempati posisi kedua dengan akurasi 95,45% dan *F1-Score* 95,56%, serta waktu eksekusi tercepat 0,003 detik, sehingga sangat efisien untuk penggunaan yang memprioritaskan kecepatan. *Gradient boosting trees classifier* dan *Logistic Regression* memiliki performa serupa, dengan akurasi masing-masing 94,54% dan *F1-Score* mendekati 94,5%, namun *gradient boosting* membutuhkan waktu eksekusi lebih lama, yaitu 0,623 detik, dibandingkan *logistic regression* yang hanya membutuhkan 0,020 detik, sehingga *logistic regression* lebih cocok untuk aplikasi yang membutuhkan efisiensi. Algoritma *AdaBoost* memiliki performa terendah dengan akurasi 93,63% dan *f1-score* 93,67%, serta waktu eksekusi 0,012 detik, menjadikannya kurang kompetitif dibandingkan model lainnya.

Sebagai upaya memberikan gambaran performa algoritma secara menyeluruh, Tabel 3 menyajikan *confusion matrix* yang merangkum hasil evaluasi berdasarkan metrik utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), *False Negative* (FN), akurasi, dan *error rate*, yang mencerminkan kemampuan model dalam menghasilkan prediksi yang akurat sekaligus mengidentifikasi potensi kelemahan pada algoritma tertentu.

Tabel 3. Hasil *confusion matrix*

Algoritma	TP	TN	FP	FN	Accuracy (%)	Error (%)
<i>Perceptron</i> *	107	214	3	3	97,27	2,73
<i>Gradient Boosting Trees Classifier</i>	104	211	3	5	94,54	3,64
<i>Naive Bayes</i>	105	210	5	5	95,45	4,55
<i>Logistic Regression</i>	104	208	6	5	94,54	5,45
<i>AdaBoost</i>	103	206	7	4	93,63	6,36

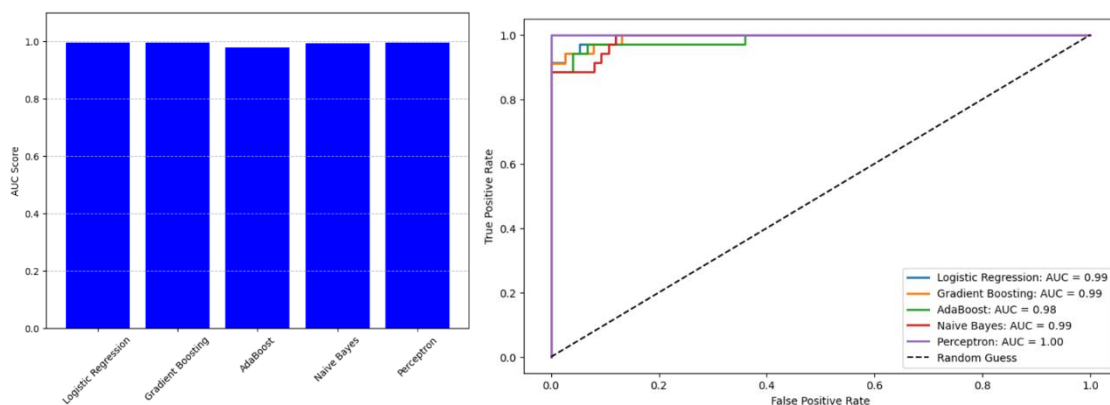
*Model algoritma terbaik

Hasil *Confusion matrix* pada tabel 3 menunjukkan performa lima algoritma dalam mendeteksi tingkat stres pelajar. *Perceptron*, dengan akurasi 97,27% dan *error* 2,73%, menjadi algoritma terbaik berdasarkan evaluasi ini. *Gradient Boosting Trees Classifier* memiliki akurasi 94,54% dengan *error* 3,64%, diikuti oleh *Naive Bayes* dengan akurasi 95,45% dan *error* 4,55%. *logistic regression* mencatat akurasi 94,54% dengan *error* 5,45%, sementara *AdaBoost* memiliki akurasi terendah sebesar 93,63% dan *error* tertinggi 6,36%. Secara keseluruhan, algoritma *Perceptron* menunjukkan performa unggul dibandingkan algoritma lain, yang menarik untuk dibandingkan lebih lanjut dengan hasil penelitian sebelumnya.

Tabel 4. Perbandingan hasil klasifikasi deteksi stres dengan penelitian terkait

Metode	Accuracy (%)	Precision (%)	Sensitivity (%)	F1-Score (%)
Metode (Rajeswari et al., 2024)	90,00	78,41	97,18	86,79
Metode (Arya et al., 2024)	90,00	94,00	88,00	91,00
Metode yang diusulkan	97,27	97,50	97,43	97,36

Seperti yang dirangkum dalam tabel 4, metode *perceptron* yang diusulkan memiliki performa yang lebih unggul dibandingkan metode (Arya et al., 2024; Rajeswari et al., 2024) di semua metrik utama. Dengan akurasi 97,27%, metode ini mengungguli hasil akurasi 90,00% pada kedua penelitian sebelumnya dengan dataset yang sama, serta menunjukkan stabilitas yang lebih tinggi pada metrik lainnya. Analisis AUC-ROC (gambar 3) menunjukkan nilai AUC *Perceptron* mencapai 1,00. Sementara itu, model lain seperti *Logistic Regression*, *Gradient Boosting*, *Naive Bayes*, dan *AdaBoost* masing-masing memperoleh nilai AUC 0,99, yang masih menunjukkan performa klasifikasi yang sangat baik, meskipun sedikit lebih rendah dibandingkan dengan *Perceptron*.

**Gambar 3.** AUC-ROC curves

Hasil penelitian ini menunjukkan bahwa *perceptron* bukan hanya model terbaik secara keseluruhan, tetapi juga dapat mendukung pengembangan sistem deteksi stres berbasis *machine learning* yang efektif. Dengan kemampuan akurasi tinggi, efisiensi waktu, dan nilai AUC-ROC yang sempurna, *Perceptron* dapat diimplementasikan untuk mendukung intervensi dini, sehingga membantu menangani masalah stres pada individu secara lebih proaktif

Pembahasan

Hasil penelitian menunjukkan bahwa algoritma *perceptron* adalah model terbaik dalam mendeteksi stres pelajar, dengan akurasi 97,27%, *error* 2,73%, dan AUC-ROC 1,00. Akurasi ini mengukur kemampuan model dalam mengklasifikasikan stres pelajar berdasarkan aspek psikologis, sosial, dan akademis. Keunggulan *Perceptron* terletak pada kemampuannya mengenali pola relevan dengan waktu eksekusi cepat (0,011 detik), menjadikannya efisien untuk deteksi stres *real-time*. Keberhasilan ini didorong oleh pemrosesan dataset yang komprehensif dan penggunaan *10-Fold Cross Validation* yang mengurangi risiko *overfitting*.

Meskipun menggunakan dataset yang sama, penelitian ini menunjukkan peningkatan kinerja signifikan dibandingkan penelitian sebelumnya (Arya et al., 2024; Rajeswari et al., 2024), yang meskipun menggunakan *feature selection* dan *hyperparameter tuning*, cenderung menghilangkan fitur penting seperti *anxiety_level* dan *peer_pressure*, serta menggunakan metode validasi sederhana berupa *splitting rasio*, yang kurang stabil dibandingkan *10-fold cross validation* yang diterapkan dalam penelitian ini. Selain itu, eksplorasi model yang lebih luas, termasuk *perceptron*, *naive bayes*, *gradient boosting trees*, *logistic regression*, dan *AdaBoost*, memungkinkan pemilihan algoritma terbaik untuk dataset ini. Berdasarkan faktor faktor tersebut, algoritma *perceptron* berhasil mencapai akurasi 97,27%, jauh lebih tinggi dibandingkan 90,00% dalam penelitian sebelumnya, menunjukkan bahwa kombinasi validasi silang yang kuat dan eksplorasi model yang tepat berkontribusi pada peningkatan kinerja.

Dibandingkan dengan model lainnya, *naive bayes* menempati posisi kedua dengan akurasi 95,45% dan waktu eksekusi tercepat (0,003 detik), cocok untuk aplikasi yang memprioritaskan kecepatan, meskipun performanya masih di bawah *perceptron* karena sensitivitas terhadap distribusi data. *gradient boosting trees*, meskipun akurat (94,54%), memiliki waktu eksekusi yang lebih lama (0,623 detik), sehingga kurang cocok untuk aplikasi *real-time*. *Logistic regression* menawarkan keseimbangan antara akurasi (94,54%) dan efisiensi waktu (0,020 detik), menjadikannya pilihan yang baik untuk aplikasi sederhana, sedangkan *AdaBoost* menunjukkan performa terendah (93,63%) dan *error* tertinggi (6,36%).

Keberhasilan deteksi stres dipengaruhi oleh faktor psikologis, sosial, akademis, lingkungan, dan fisiologis yang saling berinteraksi. Faktor psikologis seperti *anxiety_level* dan *self_esteem*, serta faktor sosial seperti *social_support* dan *peer_pressure*, menunjukkan hubungan kuat dengan stres. Berdasarkan korelasi pada gambar 2, kombinasi kelima aspek ini memberikan gambaran komprehensif mengenai faktor-faktor penyebab stres. Pemahaman ini memungkinkan *Perceptron* untuk lebih akurat mengidentifikasi pola stres, yang dapat diterapkan dalam pemantauan dan intervensi dini. Meskipun *perceptron* menunjukkan kinerja unggul, model ini terbatas dalam menangani hubungan non-linear kompleks. Seperti yang dijelaskan Isabona et al. (2022), untuk meningkatkan akurasi dan generalisasi model, pengembangan model berbasis *deep learning* dapat menjadi solusi.

Secara keseluruhan, penggunaan model *perceptron* dalam deteksi stres berbasis *machine learning* memungkinkan pendidik untuk memantau dan memberikan intervensi dini terhadap tingkat stres pelajar. Hasil penelitian ini dapat digunakan untuk mengembangkan strategi pengelolaan stres berbasis data, seperti meningkatkan *social_support* dan mengurangi *peer_pressure*. Penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan beragam guna meningkatkan kemampuan generalisasi model dan penerapannya secara lebih luas. Dengan temuan ini, diharapkan pengembangan sistem deteksi stres berbasis

machine learning dapat memberikan dampak yang signifikan dalam mendukung kesejahteraan pelajar di berbagai konteks pendidikan.

SIMPULAN

Hasil penelitian ini mengidentifikasi algoritma *perceptron* sebagai model *machine learning* terbaik untuk mendeteksi tingkat stres pelajar, dengan akurasi tertinggi sebesar 97,27%, *error* terendah 2,73%, nilai AUC-ROC sebesar 1,00, dan waktu eksekusi tercepat 0,011 detik, yang divalidasi menggunakan teknik *10-fold cross-validation*. Model ini menunjukkan stabilitas dan keandalan dalam menganalisis berbagai faktor penyebab stres, menjadikannya dasar yang kuat untuk pengembangan sistem deteksi otomatis yang cepat, efisien, dan menjaga privasi pelajar. Sistem ini diharapkan dapat membantu pelajar mengenali dan mengelola stres melalui intervensi dini, serta menciptakan lingkungan belajar yang lebih sehat dan adaptif. Penelitian ini memiliki potensi untuk diterapkan di institusi pendidikan, memberikan pendidik alat untuk evaluasi dan intervensi tepat waktu dalam mendukung kesejahteraan mental pelajar.

REFERENSI

- Alkhamees, B. F. (2022). An optimized single-layer perceptron-based approach for cardiocography data classification. *International Journal of Advanced Computer Science and Applications*, 13(10), 239-245. <https://doi.org/10.14569/IJACSA.2022.0131030>
- Armansyah, A., & Ramli, R. K. (2022). Model prediksi kelulusan mahasiswa tepat waktu dengan metode Naïve Bayes. *Edumatic: Jurnal Pendidikan Informatika*, 6(1), 1–10. <https://doi.org/10.29408/edumatic.v6i1.4789>
- Arya, S., Anju, A., & Azuana Ramli, N. (2024). Predicting the stress level of students using supervised machine learning and artificial neural networks (ANN). *Indian Journal of Engineering*, 21(56), 1–24. <https://doi.org/10.54905/disssi.v21i55.e9ije1684>
- Asif, S., Muddassar, A., Shahzad, T. Z., Raouf, M., & Pervaiz, T. (2020). Frequency of depression, anxiety, and stress among university students. *Pakistan Journal of Medical Sciences*, 36(5), 971–976. <https://doi.org/10.12669/pjms.36.5.1873>
- Emmer, C., Bosnjak, M., & Mata, J. (2020). The association between weight stigma and mental health: A meta-analysis. *Obesity Reviews*, 21(1), e12935. <https://doi.org/10.1111/obr.12935>
- Góngora Alonso, S., Marques, G., Agarwal, D., De La Torre Díez, I., & Franco-Martín, M. (2022). Comparison of machine learning algorithms in the prediction of hospitalized patients with schizophrenia. *Sensors*, 22(7), 2517. <https://doi.org/10.3390/s22072517>
- Iqbal, T., Elahi, A., Wijns, W., & Shahzad, A. (2023). Cortisol detection methods for stress monitoring in connected health. *Health Sciences Review*, 6, 100079. <https://doi.org/10.1016/j.hsr.2023.100079>
- Isabona, J., Imoize, A. L., Ojo, S., Karunwi, O., Kim, Y., Lee, C.-C., & Li, C.-T. (2022). Development of a multilayer perceptron neural network for optimal predictive modeling in urban microcellular radio environments. *Applied Sciences*, 12(11), 5713. <https://doi.org/10.3390/app12115713>
- Jiménez-Mijangos, L. P., Rodríguez-Arce, J., Martínez-Méndez, R., & Reyes-Lagos, J. J. (2023). Advances and challenges in the detection of academic stress and anxiety in the classroom: A literature review and recommendations. *Education and Information Technologies*, 28(4), 3637–3666. <https://doi.org/10.1007/s10639-022-11324-w>
- Lai, S. B. S., Binti Md Shahri, N. H. N., Mohamad, M. B., Rahman, H. A. B. A., & Rambli, A. B. (2021). Comparing the performance of AdaBoost, XGBoost, and logistic regression

- for imbalanced data. *Mathematics and Statistics*, 9(3), 379–385. <https://doi.org/10.13189/ms.2021.090320>
- Lyu, Z., Yu, Y., Samali, B., Rashidi, M., Mohammadi, M., Nguyen, T. N., & Nguyen, A. (2022). Back-propagation neural network optimized by K-fold cross-validation for prediction of torsional strength of reinforced concrete beam. *Materials*, 15(4), 1477. <https://doi.org/10.3390/ma15041477>
- Malakouti, S. M., Menhaj, M. B., & Suratgar, A. A. (2023). The usage of 10-fold cross-validation and grid search to enhance ML methods performance in solar farm power generation prediction. *Cleaner Engineering and Technology*, 15, 100664. <https://doi.org/10.1016/j.clet.2023.100664>
- 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>
- Montgomery, R. M., Antonia, M., & Vidigal Monteiro De Gouvea. (2024). Impact of chronic stress on physical and mental health: A detailed analysis. <https://doi.org/10.13140/RG.2.2.35357.73445>
- Moreno-Ibarra, M.-A., Villuendas-Rey, Y., Lytras, M. D., Yáñez-Márquez, C., & Salgado-Ramírez, J.-C. (2021). Classification of diseases using machine learning algorithms: A comparative study. *Mathematics*, 9(15), 1817. <https://doi.org/10.3390/math9151817>
- Nakie, G., Segon, T., Melkam, M., Desalegn, G. T., & Zeleke, T. A. (2022). Prevalence and associated factors of depression, anxiety, and stress among high school students in, Northwest Ethiopia, 2021. *BMC psychiatry*, 22(1), 739. <https://doi.org/10.1186/s12888-022-04393-1>
- Rajeswari, S., Gomathi, R., & Sujitha, I. (2024). Tree-based multiclass learning model for physiological stress detection from students' community. *2024 International Conference on Intelligent Systems for Cybersecurity (ISCS)*, 1–6. <https://doi.org/10.1109/ISCS61804.2024.10581339>
- Sari, V. R., Firdausi, F., & Azhar, Y. (2020). Perbandingan Prediksi Kualitas Kopi Arabika dengan Menggunakan Algoritma SGD, Naive Bayes, dan Random Forest. *Edumatic: Jurnal Pendidikan Informatika*, 4(2), 1-9.
- Sekar, M., Sriramprabha, R., Sekhar, P. K., Bhansali, S., Ponpandian, N., Pandiaraj, M., & Viswanathan, C. (2020). Review—Towards wearable sensor platforms for the electrochemical detection of cortisol. *Journal of The Electrochemical Society*, 167(6), 067508. <https://doi.org/10.1149/1945-7111/ab7e24>
- Shahapur, S. S., Chitti, P., Patil, S., Nerurkar, C. A., Shivannagol, V. S., Rayanaikar, V. C., Sawant, V., & Betageri, V. (2024). Decoding minds: Estimation of stress level in students using machine learning. *Indian Journal of Science and Technology*, 17(19), 2002–2012. <https://doi.org/10.17485/IJST/v17i19.2951>
- Sharma, S., Singh, G., & Sharma, M. (2021). A comprehensive review and analysis of supervised learning and soft computing techniques for stress diagnosis in humans. *Computers in Biology and Medicine*, 134, 104450. <https://doi.org/10.1016/j.combiomed.2021.104450>
- Susanti, L. (2024). Klasifikasi tingkat stres pada mahasiswa Teknik Informatika dalam melakukan perkuliahan metode hybrid menggunakan algoritma Naïve Bayes. *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, 8(3), 243-248. <https://doi.org/10.30998/string.v8i3.17096>
- World Health Organization. (2023). Suicide. *WHO*. <https://www.who.int/news-room/fact-sheets/detail/suicide>