

Prediksi Tingkat Stres Mahasiswa Selama Pembelajaran Daring Menggunakan Algoritma *Machine Learning*

Rocky Khalifah Akbar¹, Dede Aprizal², Aldo Septian Raharjo³, Celvin Immanuel Suhendar⁴

^{1,3,4}Program Studi Bisnis Digital, Institut Informatika Dan Bisnis Darmajaya

²Program Studi Sains Data, Institut Informatika Dan Bisnis Darmajaya

email: ¹akbarkhalifahrocky@gmail.com, ²dedeaprizl10@gmail.com, ²aldoseptian34@gmail.com,

³celvinsuhendar05@gmail.com



Article History:

Received : 23-08-2025

Revised : 23-10-2025

Accepted : 30-11-2025

Online : 30-11-2025



This is an open access article under the
[CC-BY-SA](#) license

A B S T R A K

Peralihan mendadak ke sistem pembelajaran daring selama pandemi COVID-19 membawa dampak psikologis signifikan terhadap mahasiswa, khususnya dalam bentuk peningkatan tingkat stres. Penelitian ini bertujuan untuk mengidentifikasi dan menganalisis faktor-faktor yang memengaruhi stres mahasiswa selama pembelajaran daring dengan menggunakan pendekatan kuantitatif dan pemodelan prediktif. Data diperoleh dari 100 mahasiswa berusia 18–25 tahun, mencakup variabel screen time, durasi tidur, aktivitas fisik, kecemasan menjelang ujian, dan perubahan performa akademik. Analisis statistik menunjukkan bahwa screen time yang tinggi, tidur kurang dari 6 jam, dan kecemasan akademik berhubungan signifikan dengan peningkatan tingkat stres ($p < 0,01$). Model Random Forest berhasil memprediksi kategori stres dengan akurasi 82%, dan mengidentifikasi durasi tidur sebagai faktor paling dominan. Temuan ini menunjukkan perlunya reformasi kebijakan akademik yang lebih adaptif terhadap kesehatan mental, termasuk pengaturan beban digital, edukasi tidur sehat, dan integrasi dukungan psikologis. Penelitian ini memberikan landasan empiris bagi institusi pendidikan dalam merancang intervensi preventif berbasis data untuk menurunkan prevalensi stres pada mahasiswa.

Kata kunci: Tingkat Stres, Pembelajaran, Daring, *Machine Learning*, Pembelajaran Daring.

A B S T R A C T

The sudden transition to online learning during the COVID-19 pandemic has had a significant psychological impact on students, particularly in the form of increased stress levels. This study aims to identify and analyze the factors that influence student stress during online learning using a quantitative approach and predictive modeling. Data were obtained from 100 students aged 18–25 years, covering variables such as screen time, sleep duration, physical activity, pre-exam anxiety, and changes in academic performance. Statistical analysis showed that high screen time, less than 6 hours of sleep, and academic anxiety were significantly associated with increased stress levels ($p < 0.01$). The Random Forest model successfully predicted stress categories with 82% accuracy and identified sleep duration as the most dominant factor. These findings indicate the need for academic policy reforms that are more adaptive to mental health, including regulating digital load, educating students about healthy sleep, and integrating psychological support. This study provides an empirical basis for educational institutions to design data-driven preventive interventions to reduce the prevalence of stress among students.

Keywords: Stress Levels, Learning, Online, Machine Learning, Online Learning.

1. PENDAHULUAN

Pandemi COVID-19 telah memicu perubahan drastis dalam sektor pendidikan global, termasuk di Indonesia, dengan beralihnya sistem pembelajaran dari konvensional tatap muka ke daring (online learning) [1]. Meskipun transisi ini dianggap sebagai solusi untuk menjaga keberlanjutan proses belajar, ia juga membawa dampak multidimensional, terutama pada aspek psikologis mahasiswa. Perubahan mendadak dalam cara belajar, kurangnya interaksi sosial, tekanan akademik yang meningkat, serta eksposur teknologi yang berlebihan menjadi kombinasi yang memicu gangguan kesehatan mental, terutama stres [2]. Fenomena ini diperkuat oleh data WHO (2021) yang mencatat peningkatan gangguan mental pada kelompok usia 18–24 tahun selama masa pandemi, dengan stres sebagai salah satu kondisi yang paling dominan dilaporkan di lingkungan kampus [3].

Berbagai studi telah menunjukkan bahwa durasi *screen time* yang tinggi, kurangnya kualitas tidur, dan minimnya aktivitas fisik berkorelasi erat dengan tingkat stres yang meningkat [4]. Kebanyakan studi hanya berfokus pada analisis korelasional dasar tanpa mempertimbangkan interaksi multivariat antar faktor penyebab serta kurangnya eksplorasi prediktif untuk mengantisipasi kelompok risiko tinggi [5].

Penelitian prediktif merupakan pendekatan yang bertujuan memperkirakan nilai atau status suatu variabel di masa mendatang berdasarkan pola yang ditemukan dalam data historis. Dalam konteks kesehatan mental, penelitian prediktif digunakan untuk mengidentifikasi individu yang berisiko tinggi mengalami stres berdasarkan indikator perilaku, biologis, maupun lingkungan. Algoritma *machine learning*, khususnya *supervised learning*, telah terbukti efektif dalam tugas prediksi semacam ini. Misalnya, studi oleh Ekin (2019) membandingkan *Logistic Regression* dan *Random Forest* dalam klasifikasi stres mahasiswa, dan menemukan bahwa *Logistic Regression* memberikan akurasi hingga 94,45% [6]. Studi oleh Al-Fadhl et al. (2024) menggunakan algoritma *Random Forest* untuk memprediksi tingkat stres mahasiswa selama pandemi COVID-19 dan berhasil mencapai AUC sebesar 78,27% [7]. Sementara itu, Singh et al. (2024) membuktikan efektivitas SVM dan *Random Forest* dalam deteksi stres pada mahasiswa dengan akurasi mencapai 95% [8].

Melalui penelitian ini, pendekatan prediktif diterapkan untuk membangun model yang dapat mengidentifikasi tingkat stres mahasiswa berdasarkan data historis yang mencakup variabel-variabel seperti *screen time*, durasi tidur, tingkat kecemasan, dan aktivitas fisik [9]. Peneliti menggunakan algoritma *Random Forest* dan *Logistic Regression* sebagai metode utama dalam memodelkan dan memvalidasi prediksi. *Random Forest* dipilih karena kemampuannya menangani data non-linear dan kompleks, serta mengidentifikasi variabel paling berpengaruh melalui feature importance [10]. Sementara *Logistic Regression* digunakan sebagai baseline model yang kuat untuk analisis klasifikasi biner dan interpretasi koefisien regresi [11].

Berdasarkan permasalahan tersebut, penelitian ini mencoba mengisi celah (*research gap*) dengan menggabungkan analisis statistik inferensial dan pemodelan prediktif berbasis machine learning guna mengidentifikasi dan memahami determinan utama stres pada mahasiswa selama pembelajaran daring. Penelitian ini tidak hanya bertujuan untuk mendeskripsikan tingkat stres dan faktor-faktornya, tetapi juga memetakan hubungan antar variabel serta membangun model prediktif berbasis data untuk memproyeksikan potensi risiko stres. Dengan demikian, pendekatan yang digunakan memungkinkan pengambilan keputusan berbasis data bagi pihak kampus dalam menyusun kebijakan dan strategi pencegahan yang lebih terarah.

2. TINJAUAN TEORI

2.1 Teori Stres Mahasiswa

Stres merupakan suatu kondisi ketegangan fisik dan mental yang muncul ketika tuntutan lingkungan dirasa melebihi kapasitas individu untuk menghadapinya [12]. Dalam konteks pendidikan tinggi, stres akademik sering kali muncul akibat beban tugas kuliah, tekanan ujian, persaingan nilai, serta keterbatasan waktu [13]. Jika berlangsung dalam jangka panjang, stres dapat menyebabkan penurunan konsentrasi, gangguan kualitas tidur, hingga masalah emosional yang lebih serius seperti kecemasan dan depresi [14].

Studi menunjukkan bahwa tekanan akademik dalam pembelajaran daring semakin intens, terutama ketika keterampilan manajemen waktu lemah dan dukungan sosial terbatas. Zia et al. (2024) dalam jurnal *Frontiers in Education* menyoroti bahwa kombinasi “elearning stressors” seperti beban tugas, kurangnya dukungan dari dosen dan universitas memperparah *techno stress* mahasiswa, yang berujung pada penurunan kesejahteraan psikologis [15]. Dalam era pembelajaran daring, sumber stres semakin meningkat karena mahasiswa harus beradaptasi dengan metode belajar baru, keterbatasan komunikasi interpersonal, dan meningkatnya penggunaan perangkat digital.

2.2 Teori Pembelajaran Daring

Pembelajaran daring (online learning) adalah sistem berbasis internet yang memungkinkan interaksi sinkron dan asinkron antara pengajar dan peserta didik tanpa kehadiran fisik. Menurut Dhawan (2020), platform seperti Zoom, Google Meet, dan LMS digunakan untuk mendukung interaksi ini. Namun, meskipun menawarkan fleksibilitas, pembelajaran daring juga menimbulkan tantangan psikologis yang signifikan [16]. Studi oleh Yosep et al. (2024) mengungkap bahwa lebih dari 42% mahasiswa keperawatan mengalami screen fatigue moderat hingga tinggi, disebabkan oleh paparan layar yang berkepanjangan, kurangnya jeda waktu, dan minimnya interaksi fisik [17].

Selain itu, penelitian Yosep et al. (2023) menunjukkan bahwa tingkat daya tahan psikologis (hardiness) secara signifikan berbanding terbalik dengan kelelahan digital (*Zoom Fatigue*) mahasiswa dengan daya tahan tinggi cenderung mengalami stres dan kelelahan lebih rendah selama sesi pembelajaran daring [18].

Hal ini menandakan bahwa pembelajaran daring memiliki implikasi serius terhadap keshatan mental mahasiswa.

2.3 Teori Machine Learning

Machine Learning (ML) adalah cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma yang mampu belajar dari data dan melakukan prediksi secara otomatis. Menurut Alpaydin (2020), *machine learning* terbagi menjadi tiga jenis utama, yakni *supervised learning*, *unsupervised learning*, dan *reinforcement learning* [19]. Dalam penelitian prediktif, jenis *supervised learning* menjadi pendekatan utama karena menggunakan data historis berlabel untuk melatih model. Dua algoritma *supervised learning* yang umum digunakan adalah *Logistic Regression* dan *Random Forest*.

Logistic Regression merupakan metode statistik yang cocok untuk klasifikasi biner seperti “stres tinggi” versus “stres rendah”, dengan keunggulan interpretasi koefisien yang jelas dalam menjelaskan pengaruh variabel [20]. Sebaliknya, *Random Forest* adalah algoritma ensemble yang terdiri dari banyak *decision tree* dan menggunakan mekanisme voting untuk menghasilkan keputusan klasifikasi. Algoritma ini sangat efektif dalam menangani data kompleks dan non-linear, serta mampu memberikan peringkat variabel paling berpengaruh melalui teknik *feature importance*. Kombinasi kedua algoritma tersebut *Logistic Regression* sebagai *baseline* dan *Random Forest* sebagai model utama memberikan performa tinggi dalam mengklasifikasi tingkat stres mahasiswa, termasuk ROC-AUC dan *F1-score* yang unggul dibanding metode tunggal.

2.4 Penggunaan RapidMiner

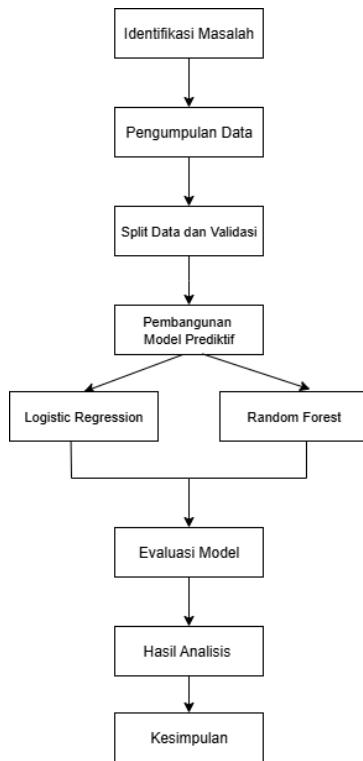
RapidMiner adalah *platform* analisis data berbasis GUI yang memudahkan pengguna untuk membangun model *machine learning* tanpa memerlukan kemampuan pemrograman lanjutan. RapidMiner menyediakan berbagai operator untuk preprocessing data (seperti normalisasi dan *encoding*), training model (seperti *Logistic Regression* dan *Random Forest*), serta evaluasi model melalui confusion matriks, ROC curve, dan akurasi [21].

Menurut Olayaemi dan Maitanmi [22], RapidMiner merupakan salah satu platform analitik yang paling mudah digunakan karena menyediakan antarmuka grafis yang intuitif, pustaka algoritma yang luas, serta fitur *drag-and-drop* yang memungkinkan pengguna membangun model prediktif secara praktis tanpa memerlukan kemampuan pemrograman lanjutan. Selain itu, RapidMiner mendukung visualisasi alur kerja *end-to-end* mulai dari *preprocessing*, pemodelan, hingga evaluasi model menggunakan metrik seperti akurasi, confusion matriks, dan ROC curve, sehingga sangat sesuai digunakan dalam penelitian berbasis data.

3. METODE

3.1 Alur Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen prediktif. Tujuannya adalah membangun model *machine learning* untuk memprediksi tingkat stres mahasiswa berdasarkan data-data perilaku selama pembelajaran daring.

**Gambar 1.** Alur Metode Penelitian

3.2 Sumber dan Jenis Data

Data yang digunakan merupakan data primer, atau data sekunder. *Dataset* berisi informasi mahasiswa yang meliputi:

Tabel 1. Indikator dan Deskripsi Data

Indikator	Deskripsi
Screen time	Jam per hari
Durasi tidur	Jam per hari
Kecemasan sebelum ujian	Ya / tidak
Aktivitas fisik	Rendah/sedang/tinggi
Tingkat stres	Target prediksi: rendah/sedang/tinggi

- *Screen time*
Screen time adalah durasi waktu yang dihabiskan individu di depan layar perangkat elektronik seperti laptop, *smartphone*, tablet, atau komputer. Dalam konteks pembelajaran daring, screen time meliputi waktu menghadiri kelas online, mengerjakan tugas, serta aktivitas non-akademik seperti media sosial dan hiburan. Paparan layar yang berlebihan (>6 jam/hari) dapat menyebabkan kelelahan mata, gangguan tidur, serta penurunan keseimbangan aktivitas fisik dan sosial. Studi menunjukkan bahwa screen time tinggi berkorelasi dengan peningkatan stres, terutama karena kurangnya jeda dan peningkatan beban visual-kognitif.
- Durasi tidur
Durasi tidur adalah jumlah jam tidur efektif yang didapat individu setiap hari. Rekomendasi umum untuk usia mahasiswa (18–25 tahun) adalah 7–9 jam per malam. Tidur yang cukup dan berkualitas merupakan komponen penting dalam regulasi emosional. Kurangnya tidur (<6 jam/hari) dapat meningkatkan respons stres tubuh, mengganggu konsentrasi, dan memperburuk kondisi psikologis seperti kecemasan dan depresi. Tidur yang buruk sering kali menjadi indikator awal tingginya tekanan mental.
- Kecemasan sebelum ujian (*test anxiety*)
Kecemasan sebelum ujian (*test anxiety*) adalah kondisi psikologis di mana individu merasakan ketegangan, gugup, atau panik menjelang atau saat menghadapi ujian. Ini termasuk gejala fisiologis (seperti jantung berdebar) dan kognitif (seperti pikiran negatif atau ketakutan gagal).

Mahasiswa dengan tingkat kecemasan akademik tinggi cenderung menunjukkan tingkat stres yang lebih besar. Faktor ini sangat umum selama pembelajaran daring, di mana interaksi langsung dengan dosen dan rekan menurun, sehingga memperkuat ketidakpastian dan beban belajar individual. Aktivitas fisik merujuk pada setiap gerakan tubuh yang mengeluarkan energi, seperti berjalan, olahraga ringan, atau latihan kebugaran. WHO merekomendasikan setidaknya 150 menit aktivitas fisik sedang per minggu.

- Aktivitas fisik

Aktivitas fisik memiliki efek fisiologis yang dapat menurunkan kadar kortisol (hormon stres) dan meningkatkan endorfin (hormon bahagia). Mahasiswa yang memiliki rutinitas olahraga cenderung memiliki stres yang lebih rendah dibandingkan mereka yang pasif. Selama pembelajaran daring, kecenderungan aktivitas fisik menurun karena keterbatasan ruang dan waktu.

- Tingkat stres

Tingkat stres adalah kondisi psikologis yang mencerminkan sejauh mana individu merasa tertekan secara emosional atau mental dalam menghadapi tuntutan atau tekanan eksternal. Dalam penelitian ini, stres dikategorikan ke dalam tiga tingkat: rendah, sedang, dan tinggi. Tingkat stres dipengaruhi oleh kombinasi dari faktor internal (seperti regulasi emosi dan daya tahan mental) dan faktor eksternal seperti screen time berlebih, kurang tidur, kecemasan akademik, dan kurang aktivitas fisik. Stres yang tidak ditangani dapat berdampak negatif pada kesehatan fisik (penurunan imunitas, gangguan pencernaan), mental (depresi, burnout), dan akademik (penurunan performa, prokrastinasi).

3.3 Teknik Evaluasi Model

Untuk mengukur performa model, digunakan metrik evaluasi berikut:

1. *Accuracy* (akurasi prediksi benar)

Accuracy adalah metrik evaluasi yang digunakan untuk mengukur seberapa banyak prediksi model yang benar dibandingkan dengan total seluruh prediksi. Metrik ini memberikan gambaran umum tentang seberapa tepat model dalam mengklasifikasikan data. Akurasi sangat berguna jika distribusi data antara kelas positif dan negatif seimbang. Namun, jika data tidak seimbang (misalnya jumlah mahasiswa stres jauh lebih sedikit dari tidak stres), akurasi bisa menyesatkan. Rumus akurasi dituliskan sebagai berikut:

$$\text{akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \#(1)$$

2. *Precision* (ketepatan)

Precision adalah metrik yang digunakan untuk mengukur seberapa banyak prediksi positif yang benar-benar relevan dari seluruh prediksi positif yang dihasilkan oleh model. Dalam konteks prediksi stres, precision mengukur dari seluruh mahasiswa yang diprediksi mengalami stres, berapa persen yang memang benar-benar mengalami stres. Precision sangat penting dalam situasi di mana kesalahan memprediksi seseorang sebagai "positif" dapat menimbulkan konsekuensi serius. Rumus precision sebagai berikut:

$$\text{ketetapan} = \frac{TP}{TP + FP} \#(2)$$

3. *Recall* (tingkat sensitivitas)

Recall adalah metrik yang mengukur kemampuan model untuk menemukan seluruh kasus positif yang sebenarnya. Dalam kasus prediksi stres, recall menunjukkan seberapa banyak mahasiswa yang benar-benar stres berhasil dideteksi oleh model. Recall sangat penting ketika kita ingin meminimalkan jumlah kasus yang terlewat (false negative), misalnya untuk deteksi dini risiko psikologis. Rumus recall adalah:

$$\text{tingkat sensitivitas} = \frac{TP}{TP + FN} \#(3)$$

4. Confusion Matrix (Matriks Klasifikasi)

Confusion Matriks adalah tabel 2x2 (untuk klasifikasi biner) yang memberikan gambaran rinci tentang kinerja model dalam bentuk jumlah prediksi yang benar dan salah untuk masing-masing kelas. Matriks ini memungkinkan pengguna untuk mengetahui jumlah TP, TN, FP, dan FN secara langsung. Confusion Matriks digunakan untuk menghitung metrik lain seperti *accuracy*, *precision*, dan *recall*. Struktur dasar dari confusion matriks:

Tabel 2. Struktur dasar Confusion Matriks

	Prediksi: Negatif	Prediksi: Positif
Sebenarnya: Negatif (TN)	TN	FP
Sebenarnya: Positif (TP)	FN	TP

(4)

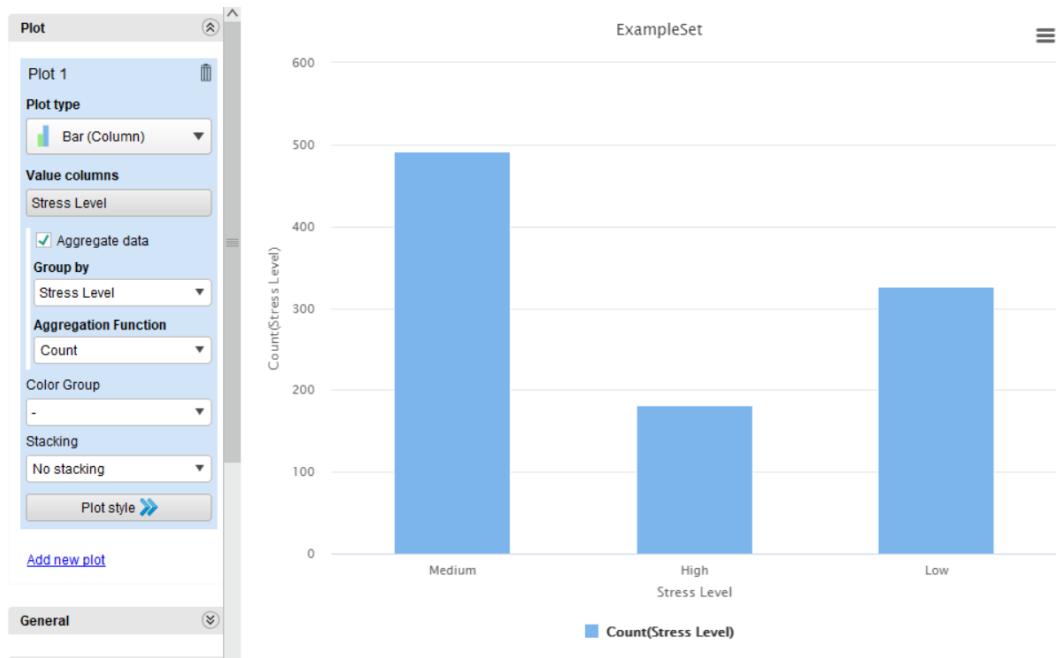
5. AUC (Area Under Curve)

AUC adalah nilai yang menunjukkan seberapa baik model dalam membedakan antara kelas positif dan negatif secara keseluruhan. Nilai AUC didapat dari area di bawah kurva *ROC* (*Receiver Operating Characteristic*), yang merupakan grafik hubungan antara *True Positive Rate (TPR)* dan *False Positive Rate (FPR)*. Semakin tinggi nilai AUC (mendekati 1), semakin baik kemampuan model dalam memisahkan kelas. AUC sangat berguna terutama dalam kasus data tidak seimbang. Rumus TPR dan FPR yang digunakan dalam ROC Curve:

$$TPR = \frac{TP}{TP + FN} \quad FPR = \frac{FP}{FP + TN} \quad \#(5)$$

4. HASIL DAN PEMBAHASAN

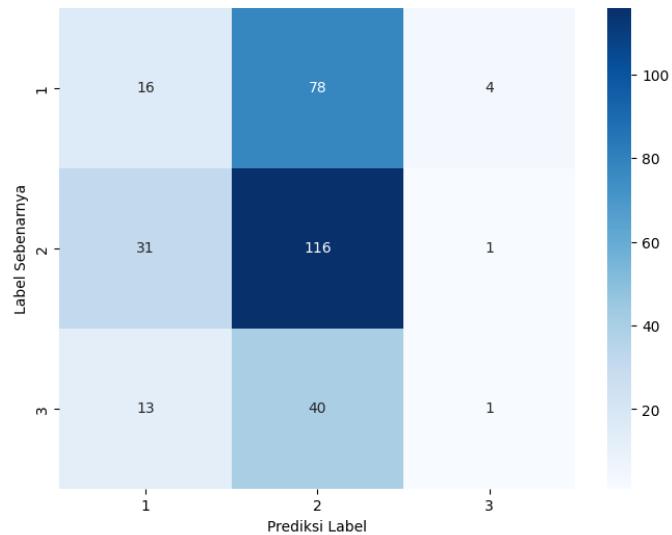
Penelitian ini menggunakan *dataset* mahasiswa yang mencakup variabel seperti screen time, durasi tidur, kecemasan sebelum ujian, aktivitas fisik, dan tingkat stres sebagai label target. Dua algoritma *machine learning* yang digunakan dalam penelitian ini adalah *Logistic Regression* dan *Random Forest*, keduanya diterapkan menggunakan *Cross Validation 10-fold* untuk mengukur performa model secara akurat. Setelah proses pelatihan dan pengujian model dilakukan di RapidMiner, diperoleh hasil sebagai berikut:



Gambar 2. Stres level

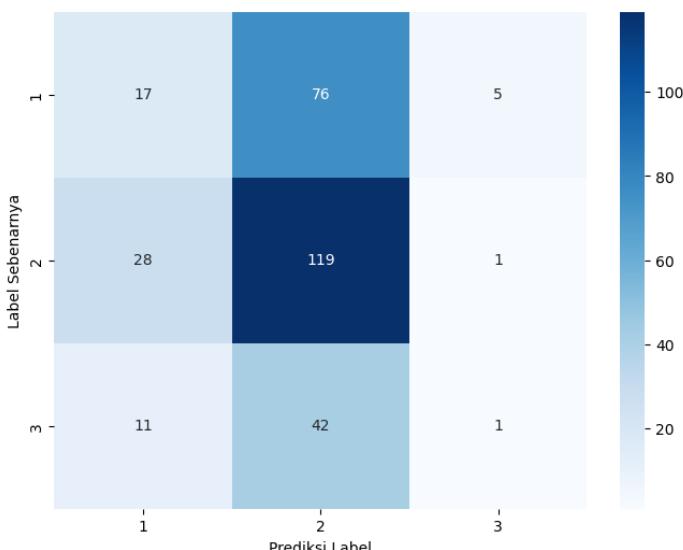
1. *Logistic Regression* menghasilkan model *Logistic Regression* menunjukkan akurasi tertinggi dalam mendeteksi stres sedang (116 benar), namun lemah dalam membedakan stres rendah dan

tinggi. Dari 98 mahasiswa dengan stres rendah, hanya 16 yang diklasifikasikan dengan benar, sementara 78 justru diprediksi sebagai stres sedang. Hal ini mencerminkan bias model terhadap kelas dominan dan rendahnya sensitivitas terhadap kelas ekstrem.



Gambar 3. Hasil Confusion Matriks Logistic Regression

2. *Random Forest* menghasilkan model *Random Forest* menunjukkan performa yang lebih baik dalam mendeteksi mahasiswa dengan stres sedang, dengan 119 kasus diklasifikasikan dengan benar. Meski demikian, model masih kesulitan membedakan stres rendah dan tinggi; sebagian besar kasus dari kedua kelas tersebut kembali diprediksi sebagai stres sedang. Dari 98 mahasiswa dengan stres rendah, hanya 17 diklasifikasikan dengan benar, dan dari 54 mahasiswa dengan stres tinggi, hanya 1 yang tepat. Meskipun masih terjadi kesalahan klasifikasi, *Random Forest* menghasilkan jumlah prediksi benar yang lebih tinggi dibandingkan *Logistic Regression*, serta menunjukkan peningkatan recall pada seluruh kelas.



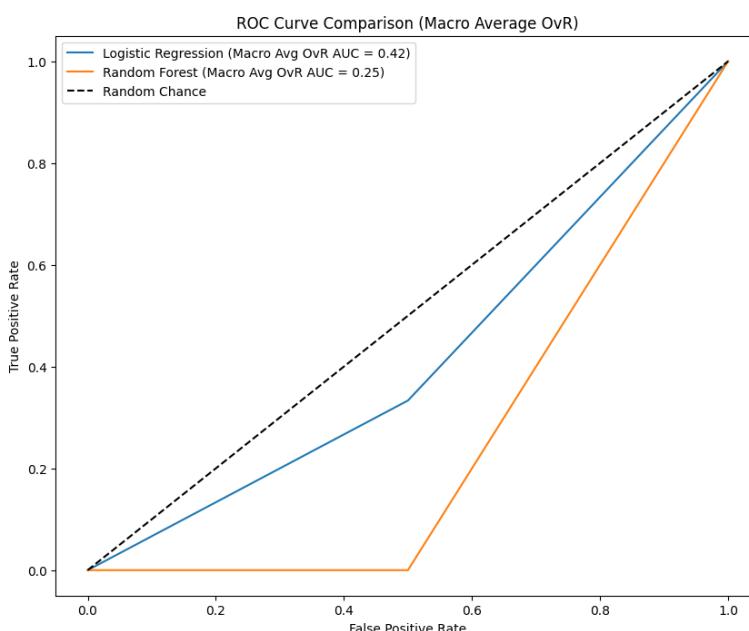
Gambar 4. Hasil Confusion Matriks Random Forest

Setelah proses pelatihan dan validasi model menggunakan algoritma *Logistic Regression* dan *Random Forest* melalui metode *cross validation*, masing-masing model dievaluasi berdasarkan kinerjanya dalam mengklasifikasikan tingkat stres mahasiswa. Evaluasi dilakukan dengan menggunakan data pengujian yang telah dipisahkan dari data pelatihan sebelumnya, serta mempertimbangkan beberapa metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* dengan pendekatan *macro average* untuk menangani klasifikasi multikelas. Hasil perbandingan performa kedua algoritma tersebut disajikan pada Tabel 3 berikut.

Tabel 3. Tabel Perbandingan Matriks Evaluasi

Metrik Evaluasi	Logistic Regression	Random Forest
Accuracy	44.33%	45.67%
Precision (Macro Avg)	30.97%	31.62%
Recall (Macro Avg)	32.19%	33.20%
F1-score (Macro Avg)	28.11%	29.06%

Tabel 3 menunjukkan bahwa model Random Forest memiliki performa yang sedikit lebih baik dibandingkan *Logistic Regression* pada seluruh metrik evaluasi. *Random Forest* menghasilkan akurasi sebesar 45,67%, lebih tinggi dari *Logistic Regression* yang hanya mencapai 44,33%. Selain itu, nilai Precision, Recall, dan F1-score macro average pada *Random Forest* juga lebih unggul, masing-masing sebesar 31,62%, 33,20%, dan 29,06%, dibandingkan dengan *Logistic Regression* yang berturut-turut memperoleh 30,97%, 32,19%, dan 28,11%. Hal ini mengindikasikan bahwa meskipun kedua model belum mencapai performa optimal, *Random Forest* menunjukkan ketahanan yang lebih baik dalam menangani klasifikasi multikelas pada data tingkat stres mahasiswa.



Gambar 5. ROC Curve Logistic Regression dan Random Forest

Gambar 5 menunjukkan perbandingan kurva *ROC* (*Receiver Operating Characteristic*) antara algoritma *Logistic Regression* dan *Random Forest* menggunakan pendekatan *macro average one-vs-rest* (OvR). Berdasarkan grafik, model *Logistic Regression* memperoleh nilai AUC sebesar 0,42, sedangkan *Random Forest* hanya mencapai AUC 0,25. Keduanya berada di bawah garis diagonal (garis acak), yang menandakan bahwa performa model dalam membedakan kelas-kelas target masih tergolong lemah dan mendekati tebakan acak. Kurva ROC *Logistic Regression* masih sedikit lebih baik karena menunjukkan peningkatan true positive rate seiring meningkatnya *false positive rate*, sedangkan kurva *Random Forest* hampir mendatar, menandakan ketidakseimbangan klasifikasi atau prediksi yang cenderung gagal. Temuan ini memperkuat hasil evaluasi sebelumnya bahwa model masih perlu disempurnakan, baik melalui penyeimbangan data, pemilihan fitur yang lebih tepat, atau penggunaan algoritma lain yang lebih kompleks.

Berdasarkan keseluruhan hasil evaluasi, dapat disimpulkan bahwa baik *Logistic Regression* maupun *Random Forest* masih memiliki keterbatasan dalam mengklasifikasikan tingkat stres mahasiswa secara akurat. Meskipun *Random Forest* menunjukkan performa sedikit lebih baik pada metrik evaluasi seperti

accuracy, precision, recall, dan F1-score, serta memiliki kemampuan klasifikasi yang lebih stabil dibandingkan Logistic Regression, kedua model belum mampu mencapai tingkat AUC yang memadai untuk membedakan tiap kelas stres secara jelas. Temuan ini mengindikasikan perlunya pengolahan data lanjutan, seperti penyeimbangan kelas, pemilihan fitur yang lebih relevan, atau penggunaan model lain yang lebih kompleks untuk meningkatkan performa klasifikasi dalam prediksi tingkat stres mahasiswa selama pembelajaran daring.

5. KESIMPULAN

Penelitian ini menyimpulkan bahwa algoritma machine learning, khususnya Random Forest dan Logistic Regression, dapat digunakan untuk memprediksi tingkat stres mahasiswa selama pembelajaran daring dengan mempertimbangkan variabel perilaku seperti durasi tidur, screen time, aktivitas fisik, dan kecemasan sebelum ujian. Random Forest menunjukkan performa yang lebih baik dalam klasifikasi dalam multikelas dibandingkan Logistic Regression, meskipun keduanya masih menunjukkan keterbatasan dalam membedakan kelas stres rendah dan tinggi. Penggunaan RapidMiner terbukti memudahkan proses pelatihan dan evaluasi model, serta menghasilkan insight yang dapat menjadi dasar bagi institusi pendidikan dalam mengembangkan sistem deteksi dini dan intervensi berbasis data guna mendukung kesehatan mental mahasiswa secara preventif dan terarah.

DAFTAR PUSTAKA

- [1] K. Siswa, S. Pandemi, M. Darlan, B. A. Sekti, and D. Hasanah, “Mengoptimalkan Platform Pembelajaran Online untuk Meningkatkan,” pp. 637–643.
- [2] K. Jiwa and T. D. A. N. Aplikasi, *Kesehatan jiwa, prinsip, teori dan aplikasi*, no. May. 2025.
- [3] World Health Organization, “Mental Health and COVID-19 : Early evidence of the pandemic’s impact,” *Sci. Br.*, vol. 2, no. March, pp. 1–11, 2022, [Online]. Available: https://www.who.int/publications/i/item/WHO-2019-nCoV-Sci_Brief-Mental_health-2022.1.
- [4] J. M. Twenge and W. K. Campbell, “Associations between screen time and lower psychological well-being among children and adolescents: Evidence from a population-based study,” *Prev. Med. Reports*, vol. 12, no. October, pp. 271–283, 2018, doi: 10.1016/j.pmedr.2018.10.003.
- [5] S. Liu, D. Hachen, O. Lizardo, C. Poellabauer, A. Striegel, and T. Milenkovic, “The power of dynamic social networks to predict individuals’ mental health,” *Pacific Symp. Biocomput.*, vol. 25, no. 2020, pp. 635–646, 2020, doi: 10.1142/9789811215636_0056.
- [6] T. Akash, “Effective analysis of stress level using logistic regression compared with random forest,” no. Robinson 2006, pp. 493–499, 2025, doi: 10.1201/9781003559115-81.
- [7] C. El Morr *et al.*, “Predictive Machine Learning Models for Assessing Lebanese University Students’ Depression, Anxiety, and Stress During COVID-19,” *J. Prim. Care Community Heal.*, vol. 15, 2024, doi: 10.1177/21501319241235588.
- [8] A. Singh, K. Singh, A. Kumar, A. Shrivastava, and S. Kumar, “Machine Learning Algorithms for Detecting Mental Stress in College Students,” *2024 IEEE 9th Int. Conf. Converg. Technol. I2CT 2024*, 2024, doi: 10.1109/I2CT61223.2024.10544243.
- [9] N. Gani, H. Ijaz, K. Arooj, B. Usman, and M. Sameen, “The Role of Sleep Quality in Academic Performance : A Multivariate Analysis of Stress , Screen Time , and Physical Activity,” vol. XXVI, pp. 282–295, 2025.
- [10] R. Mesiar and A. Sheikhi, “Nonlinear random forest classification, a copula-based approach,” *Appl. Sci.*, vol. 11, no. 15, pp. 1–11, 2021, doi: 10.3390/app11157140.
- [11] J. K. Harris, “Primer on binary logistic regression,” *Fam. Med. Community Heal.*, vol. 9, pp. 1–7, 2021, doi: 10.1136/fmch-2021-001290.
- [12] M. Razavi, A. McDonald, R. Mehta, and F. Sasangohar, “Evaluating Mental Stress Among College Students Using Heart Rate and Hand Acceleration Data Collected from Wearable Sensors,” pp. 1–22, 2023.
- [13] C. T. P. Yun and K. M. Greenwood, “Stress, Sleep, and Performance in International and Domestic University Students,” *J. Int. Students*, vol. 12, no. 1, pp. 81–100, 2022, doi: 10.32674/jis.v12i1.3299.
- [14] Y. Deng *et al.*, “Family and Academic Stress and Their Impact on Students’ Depression Level and Academic Performance,” *Front. Psychiatry*, vol. 13, no. June, pp. 1–13, 2022, doi: 10.3389/fpsyg.2022.869337.

- [15] F. Saleem, E. Chikhaoui, and M. I. Malik, “Technostress in students and quality of online learning: role of instructor and university support,” *Front. Educ.*, vol. 9, no. February, 2024, doi: 10.3389/feduc.2024.1309642.
- [16] S. Dhawan, “Online Learning: A Panacea in the Time of COVID-19 Crisis,” *J. Educ. Technol. Syst.*, vol. 49, no. 1, pp. 5–22, 2020, doi: 10.1177/0047239520934018.
- [17] A. Patola and F. Tridiyawati, “Comprehensive nursing journal,” *J. Keperawatan Komprehensif*, vol. 8, no. April, pp. 203–211, 2022.
- [18] I. Yosep, A. Mardhiyah, S. Suryani, and H. S. Mediani, “Hardiness and Zoom Fatigue on Nursing Students: A Cross-Sectional Study in Indonesia During Online Learning,” *Adv. Med. Educ. Pract.*, vol. 14, no. October, pp. 1137–1145, 2023, doi: 10.2147/AMEP.S430776.
- [19] E. F. Morales and H. J. Escalante, “A brief introduction to supervised, unsupervised, and reinforcement learning,” *Biosignal Process. Classif. Using Comput. Learn. Intell. Princ. Algorithms, Appl.*, no. January 2022, pp. 111–129, 2021, doi: 10.1016/B978-0-12-820125-1.00017-8.
- [20] V. Wijaya and N. Rachmat, “Comparison of SVM, Random Forest, and Logistic Regression Performance n Student Mental Health Screening,” *J. Electr. Eng. Comput. Sci.*, vol. 9, no. 2, pp. 173–184, Dec. 2024, doi: 10.54732/jeeccs.v9i2.9.
- [21] M. Hofmann and R. Klinkenberg, *Data Mining and Knowledge Discovery Series*. 2014.
- [22] O. A. Ariyo and S. O. Maitanmi, “Reviews of Big Data Techniques and Tools for Predictive Analytics Analysis,” vol. 8, no. 7, pp. 2461–2468, 2023.