SHAP dalam Explainable AI untuk Deteksi Depresi Mahasiswa Menggunakan AdaBoost

Irda Syahrani Tamsir
Fakultas Informatika
Universitas Telkom
Bandung
irdasyahranii@students.telkomuniversity.ac.id

Aji Gautama Putrad
Fakultas Informatika
Universitas Telkom
Bandung
ajigps@telkomuniversity.ac.id

Ryan Lingga Wicaksono
Fakultas Informatika
Universitas Telkom
Bandung
wicaksonoryan@telkomuniversity.ac.id

Depresi pada mahasiswa merupakan masalah kesehatan mental yang perlu dideteksi secara dini agar intervensi dapat dilakukan dengan lebih tepat. Penelitian ini berfokus pada deteksi depresi mahasiswa menggunakan algoritma Adaptive Boosting (AdaBoost) yang dipadukan dengan metode Explainable Artifical Intelligence (XAI) berupa SHAP untuk memberikan interpretasi terhadap kontribusi setiap fitur dalam proses prediksi. Dua dataset depresi mahasiswa dari Kaggle digunakan untuk membandingkan pengaruh kualitas dan karakteristik data terhadap performa model. Pada masing-masing dataset, dilakukan pelatihan model AdaBoost dan evaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score, serta analisis interpretabilitas menggunakan SHAP yang kemudian dibandingkan dengan Feature Importance bawaan AdaBoost. Hasil pengujian menunjukkan bahwa dataset Jatmiko et al. menghasilkan akurasi yang lebih tinggi dibandingkan dataset Shodolamu Opeyami, sehingga diniliai memiliki kualitas yang lebih baik. Analisis SHAP juga mengungkap bahwa fitur terkait pikiran bunuh diri merupakan faktor paling dominan dalam prediksi pada kedua dataset. Selain itu, SHAP terbukti lebih stabil dan reliabel dibandingkan Feature Importance, sehingga lebih sesuai digunakan sebagai metode interpretabilitas pada model deteksi depresi mahasiswa.

Kata kunci: depresi mahasiswa, machine learnng, adaboost, explainable ai, shap, interpretabilitas

Abstract

Depression among college students is a critical mental health issue that requires early detection to enable timely intervention. This study focuses on detecting students' depression using the Adaptive Boosting (AdaBoost) algorithm combined with Explainable Artificial Intelligence (XAI) through SHAP to interpret the contribution of each feature in the prediction process. Two student depression datasets from Kaggle are used to compare the effect of data quality and characteristics on model performance. For each dataset, an AdaBoost model is trained and evaluated using accuracy, precision, recall, and F1-score, followed by interpretability analysis using SHAP, which is then compared with the built-in Feature Importance of AdaBoost. The experimental results show that the dataset by Jatmiko et al. yields higher accuracy than the dataset by Shodolamu Opeyemi, indicating better data quality. SHAP analysis further reveals that suicidal thoughts are the most dominant factor in depression prediction across both datasets. In addition, SHAP proves to be more stable and reliable than Feature Importance, making it more suitable as an interpretability method for depression detection models in student populations.

Keywords: student depression, machine learning, adaboost, explainable ai, shap, interpretability

1. Pendahuluan

Latar Belakang

Depresi merupakan masalah kesehatan mental yang cukup signifikan di kalangan mahasiswa, ditandai dengan gejala psikologis seperti perasaan sedih berkepanjangan, kehilangan minat terhadap konsentrasi, perasaan putus asa, dan rendah diri [1][2]. Pada sisi klinis, depresi juga dapat memunculkan gejala fisik seperti gangguan pola tidur, perubahan nafsu makan, dan kelelahan kronis yang sebagaimana dijelaskan oleh Andriichuk et al [3]. Menurut Survei Kesehatan Indonesia tahun 2023, pravelensi depresi di Indonesia sebesar 1,4% dari 154 juta orang di seluruh dunia dengan prevalensi tertiggi pada anak muda (2%). Faktor pemicu seperti tekanan akademik, masalah finansial, dan isolasi sosial sering kali memperburuk kondisi ini, meningkatkan risiko penurunan prestasi akademik, penurunan kualitas hidup, hingga ide bunuh diri [4]. Ini menunjukkan kebutuhan untuk pendeteksian dini yang efektif sehingga dapat diintervensi dengan tepat waktu.

Deteksi depresi secara manual seperti wawancara terkadang memakan waktu yang lama, membutuhkan biaya yang tinggi, dan keterbatasan dalam hal skalabilitas. Untuk mengatasi hal ini, Premalatha et al. [5] menggunakan machine learning dalam membantu membuat keputusan lebih cepat menggunakan machine learning. Oleh karena itu, dibutuhkan pendekatan berbasis teknologi yang tidak hanya efisien dan akurat, tetapi juga mampu mendukung pengambilan keputusan klinis secara lebih cepat. Salah satu pendekatan dari teknologi yang dapat dilakukan adalah menggunakan machine learning (ML) dalam pendeteksi depresi pada mahasiswa [6].

Machine learning memungkinkan sistem untuk belajar dari data dan meningkatkan kinerjanya tanpa perlu diprogram lagi secara eksplisit [7]. Zhou et al. [8] memanfaatkan machine learning dalam memprediksi depresi pada individu yang menjalani karantina Covid-19, dengan melakukan perbandingan pada 15 algoritma. Hasilnya AdaBoost menunjukkan kinerja terbaik dengan hasil akurasi sebesar 79.17%. Algoritma AdaBoost juga merupakan salah satu model yang sering digunakan dalam mendeteksi depresi karena kinerja yang bagus [8]. Meskipun demikian, penerapan machine learning masih menghadapi berbagai tantangan, salah satunya keterbatasan interprebalitas model. Ini merupakan hal yang penting ketika diterapkan dalam konteks data yang sensitif seperti prediksi depresi karena pemahaman terhadap faktor-faktor penyebab sangat krusial [9]. Kurangnya interpretabilitas dapat menyebabkan akuntabilitas yang tidak memadai dan terjadinya penurunan kualitas hasil prediksi model [10].

Untuk mengatasi masalah ini, digunakan SHAP (SHapley Additive ExPlanation) untuk meningkatkan interpleblitias dan transparansi model machine learning. Balbino et al. [11] menggunakan metode SHAP untuk mengetahui faktor-faktor yang berkontribusi besar

dalam mendeteksi depresi anak dan remaja. Hasilnya menunjukkan bahwa fitur *feelings of lonely* merupakan fitur dengan kontribusi terbesar dalam memprediksi kondisi depresi pada anak dan remaja.
Penelitian ini diharapkan dapat memberi kontribusi untuk memban tu tenaga kesehatan dalam mendeteksi dini depresi dengan menggunakan al goritma AdaBoost untuk mengidentifikasi faktor kontribusi terbesar melalaui pnedekatan SHAP.

Topik dan Batasannya

Topik penelitian ini berfokus pada deteksi depresi mahasiswa menggunakan algoritma *adaptive boosting* (AdaBoost) yang dilengkapi dengan metode *Explainable Artificial Intelligence* (XAI) berupa SHAP untuk memberikan interpretasi yang jelas terhadap kontribusi setiap fitur dalam proses prediksi. Permasalahan utama yang diangkat berawal dari meningkatnya prevalensi depresi di kalangan mahasiswa serta kebutuhan akan metode deteksi yang bukan hanya akurat, tetapi juga dapat dijelaskan secara transparan. Model machine learning dengan performa tinggi sering kali menjadi "black-box", sehingga sulit bagi peneliti, tenaga profesional, atau lembaga pendidikan untuk memahami faktor apa yang sesungguhnya berkontribusi dalam proses pengambilan keputusan. Kondisi ini menimbulkan kesenjangan antara efektivitas prediksi dan kebutuhan untuk menginterpretasikan hasil secara jelas, terutama dalam konteks kesehatan mental yang sangat sensitif dan memerlukan akuntabilitas tinggi.
Penelitian ini memanfaatkan dua dataset publik yang berkaitan dengan kondisi psikologi mahasiswa. Dataset tersebut mencakup variabel-variabel seperti jenis kelamin, usia, tekanan akademik, kepuasan belajar, durasi tidur, kebiasaan diet, faktor finansial, jam belajar, riwayat kesehatan mental keluarga, hingga indikator kritis seperti pertanyaan mengenai pikiran bunuh diri. Variabel-variabel tersebut dipandang sebagai faktor risiko yang dapat memengaruhi kondisi kesehatan mental mahasiswa. Dengan mengolah data tersebut menggunakan AdaBoost, penelitian ini menghasilkan *output* berupa klasifikasi depresi (depressed / not depressed), sementara SHAP memberikan kontribusi fitur yang rinci dalam bentuk nilai dan visualisasi yang membantu menjelaskan pengaruh setiap variabel terhadap hasil prediksi model. Dengan demikian, sistem bukan hanya memberikan hasil klasifikasi, tetapi juga menawarkan pemahaman mendalam mengenai mekanisme keputusan model.
Input penelitian ini berupa data numerik dan kategorikal yang telah melalui tahap pre-pemrosesasn seperti *encoding* dan standardisasi, sedangkan output mencakup label depresi dan nilai SHAP. Untuk menjaga ruang lingkup penelitian tetap realistis, penelitian dibatasi pada dataset publik dari Kaggle, penggunaan algoritma AdaBosst sebagai model utama, serta penerapan metode interpretabilitas SHAP tanpa membahas teknik XAI lain..
Penetapan batasan tersebut bertujuan afar penelitian tetap terarah, mendalam, dan sesuai dengan tujuan utama yaitu menganalisis performa AdaBoost dan interpretabilitas SHAP dalam konteks deteksi depresi mahasiswa. Selain itu, batasan ini juga memberikan ruang bagi penelitian lanjutan untuk meperluas cakupan, seperti integrasi ke sistem konseling universitas, penambahan dataset lokal, pemnambahan fitur psikologis yang lebih kaya, atau perbandingan metode XAI lainnya. Pada akhirnya, penelitian ini diharapkan dapat memberikan kontribusi ilmiah yang kuat terkait pemanfaatan metode ensemble dan XAI untuk mendukung pendekatan pencegahan depresi di lingkungan pendidikan tinggi.

Tujuan

Tujuan utama dari penelitian ini adalah untuk membandingkan dua dataset berbeda yang berkaitan dengan depresi pada mahasiswa serta mengidentifikasi fitur-fitur yang memberikan kontribusi paling besar dalam proses prediksi menggunakan metode SHAP. Untuk mencapai tujuan tersebut, penelitian ini menganalisis dataset dengan ukuran dan komposisi fitur yang berbeda guna mengetahui konsistensi dan kendalan kontribusi fitur pada populasi mahasiswa yang beragam. Selanjutnya, penelitian ini memanfaatkan SHAP untuk memberikan penjelasan yang transparan dan tidak bergantung pada jenis model mengenai bagaimana setiap fitur memengaruhi hasil prediksi. Selain itu, penelitian ini juga bertujuan untuk menemukan faktor risiko utama seperti tekanan akademik, stres finansial, maupun pikiran bunuh diri yang berperan signifikan dalam deteksi depresi sehingga dapat mendukung strategi intervensi dan pencegahan di lingkungan institusi pendidikan. Agar penelitian ini terarah dan kesimpulan yang diperoleh valid, seluruh tujuan tersebut menjadi dasar dari skenario pengujian dan analisis yang dilakukan pada penelitian ini.

TABEL 1
Keterkaitan antara tujuan, pengujian, dan kesimpulan

No	Tujuan Penelitian	Pengujian yang Dilakukan	Kesimpulan yang Diperoleh
1	Membandingkan dua dataset depresi mahasiswa berdasarkan performa model.	Pelatihan AdaBoost pada kedua dataset dan evaluasi menggunakan akurasi, presisi, recall, F1-score, serta k-fold cross validation.	Dataset Jatmiko et al. lebih baik (akurasi 0.98) dibanding Dataset Shodolamu (akurasi 0.85), menunjukkan dataset kecil dan terfokus lebih stabil.
2	Mengidentifikasi fitur yang paling berkontribusi dalam prediksi depresi mengguna	Perhitungan nilai SHAP (global dan lokal) pada model AdaBoo	Fitur "suicidal thoughts" konsisten menjadi fitur

	kan SHAP.	st untuk kedua dataset.	paling domina n pada kedua dataset.
3	Membandi ngkan reliabilitas interpretab ilitas SHAP dengan Feature Importanc e (FI).	Analisis perbandi ngan nilai SHAP vs FI pada kedua dataset (berdasa rkan Fig. 6 dan 7 pada paper).	SHAP lebih stabil dan reliabel dibandi ng Feature Importa nce, karena member ikan ranking fitur yang konsiste n antar dataset.

Organisasi Tulisan

Organisasi penulisan jurnal ini disusun sebagai berikut. Bagian II membahas sudi terkait yang menjadi dasar teori serta posisi penelitian ini terhadap penelitian sebelumnya. Bagian III menjelaskan metode penelitian, meliputi deskripsi dataset, tahapan pra-pemrosesan, pembagunan model AdaBoost, serta penggunaan SHAP untuk interpretabilitas. Bagian IV menyajikan hasil eksperimen dan pembahasan yang mencakup evaluasi performa model pada kedua dataset serta analisis kontribusi fitur. Terakhir, bagian V beriis kesimpulan yang diperoleh dari penelitian dan keterkaitannya dengan tujuan penelitian.

2. Studi Terkait

Penelitian mengenai deteksi depresi pada mahasiswa telah dilakukan menggunakan berbagai metode machine learning. Torres et al. [12] menggunakan naïve bayes dan memperoleh akurasi 78,03%, menunjukkan bahwa model sederhana dapat memberikan gambaran awal meskipun masih terbatas dalam menangani kompleksitasi faktor psikologis. Pendekatan *ensemble learning*, termasuk AdaBoost, mulai digunakan dalam penelitian serupa. Akinola et al. [13] menunjukkan bahwa AdaBoost dapat memberikan prediksi kesehatan mental yang lebih baik dibandingkan model lain, sedangkan El Morr et al. [14] menggunakan AdaBoost untuk memprediksi depresi mahasiswa selama pandemi dan mencapai akurasi 76,25%.

Permasalahan umum pada model deteksi depresi adalah kurangnya interpretabilitas. Untuk mengatasi hal tersebut, berbagai penelitian menggunakan metode Explainable AI seperti SHAP. Wang et al. [15] menggunakan SHAP untuk menjelaskan prediksi depresi berbasis suara pada remaja, sementara Enkhbayar et al. [16] dan Balbino et al. [11] menerapkannya pada data fisiologis serta psikososial dengan hasil interpretasi yang kosisten. Selain itu, FI (feature importance) pada AdaBoost juga digunakan sebagai pendekatan interpretabilitas, tetapi penelitian menunjukkan bahwa FI cenderung kurang stabil dibandingkan SHAP [17], [18].

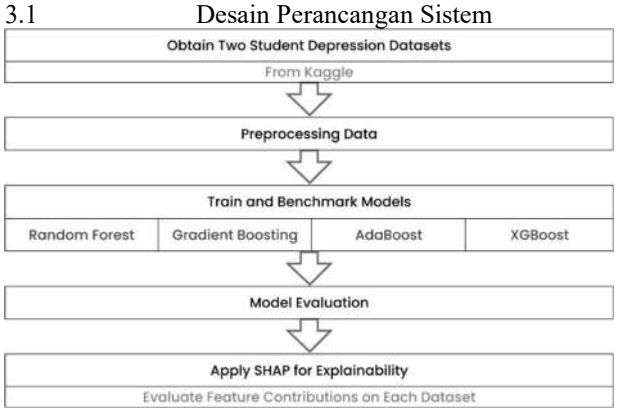
TABEL 2
Perbandingan penelitian terdahulu pada deteksi depresi

Penelitian	Topik Depresi	Mahasiswa	AdaBoost	SHAP	Feature Importance (FI)
[12]	✓	✓	✗	✗	✗
[19]	✓	✗	✓	✓	✗
[16]	✓	✗	✗	✓	✗
[11]	✓	✗	✗	✓	✗
[17]	✗	✗	✓	✗	✓
[18]	✗	✗	✓	✗	✓
Penelitian ini	✓	✓	✓	✓	✓

Dari studi-studi tersebut dapat disimpulkan bahwa pendekatan yang menggabungkan model klasifikasi yang kuat seperti AdaBoost dengan metode interpretabilitas yang reliable seperti SHAP masih jarang diimplementasikan, khususnya pada konteks depresi mahasiswa. Penelitian ini berupaya mengisi celah tersebut dengan membandingkan dua dataset depresi mahasiswa dan menganalisis kontribusi fitur menggunakan SHAP untuk menghasilkan interpretasi yang lebih transparan.

3. Sistem yang Dibangun

3.1 Desain Perancangan Sistem



GAMBAR 1
Workflow deteksi depresi menggunakan AdaBoost dan SHAP

Sistem yang dibangun dalam penelitian ini dirancang untuk melakukan pemodelan deteksi depresi secara komparatif pada dua dataset mahasiswa. Alur sistem dimulai dari akuisisi dataset dari Kaggle, kemudian dilanjutkan dengan proses pra-pemrosesan untuk menyiapkan data agar kompatibel dengan model. Data

yang telah diproses kemudian digunakan untuk melatih dua jalur model AdaBoost terpisah, masing-masing untk dataset 1 dan dataset 2.
Setelah proses pelatihan selesai, model dievaluasi menggunakan metrik klasifikasi untuk memastikan perbandingan performa yang adil. Tahap terakhir adalah analisis interpretabilitias menggunakan SHAP untuk mengidentifikasi fitur paling berpengaruh pada masing-masing dataset dan menilai konsistensi kontribusi fitur secara menyeluruh.

3.2 Dataset

Penelitian ini menggunakan dua dataset terkait deteksi depresi pada mahasiswa yang bersumber dari Kaggle. Dataset ini dipilih karena menyajikan kondisi kesehatan mental siswa berdasarkan data survei serta indikator akademik dan psikologi. Perbedaan kedua dataset tersebut dapat dilihat pada table berikut.

TABEL 3
Perbandingan Kedua Dataset Depresi Mahasiswa

Aspek	Dataset 1 (Shodolamu Opeyemi)	Dataset 2 (Jatmiko et al.)
Nama Dataset	Student Depression Dataset	Depression Student Dataset
Sumber	Kaggle (diunggah oleh Shodolamu Opeyemi)	Kaggle (diunggah oleh Jatmiko et al.)
Jumlah Data	27.901	502
Jumlah Fitur	16	10
Tipe Label	Biner (Depressed / Not Depressed)	Biner (Depressed / Not Depressed)
Daftar Fitur	id, Gender, Age, City, Profession, Academic Pressure, Work Pressure, CGPA, Study Satisfaction, Job Satisfaction, Sleep Duration, Dietary Habits, Degree, Have you ever had suicidal thoughts?, Work/Study Hours, Financial Stress, Family History of Mental Illness	Gender, Age, Academic Pressure, Study Satisfaction, Sleep Duration, Dietary Habits, Have you ever had suicidal thoughts?, Study Hours, Financial Stress, Family History of Mental Illness
Fitur yang Tidak Ada Dibanding Dataset 1	–	id, City, Profession, Work Pressure, CGPA, Job Satisfaction, Degree, Work/Study Hours
Tujuan / Penggunaan	Penelitian psikologi, data science, dan pendidikan terkait depresi mahasiswa	Deteksi dan analisis depresi mahasiswa dengan data yang lebih sederhana dan kecil

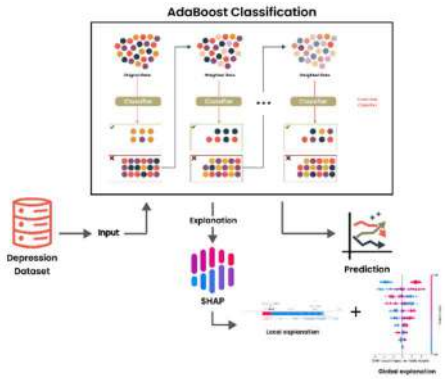
3.3 Adaptive Boosting

AdaBoost (Adaptive Boosting) adalah algoritma pembelajaran ansambel yang bertujuan untuk meningkatkan akurasi dengan menggabungkan beberapa pohon keputusan. Algoritma ini memberikan bobot lebih besar pada data yang sebelumnya salah diklasifikasikan, sehingga model berikutnya akan lebih fokus pada kesalahan tersebut [20]. Proses boosting menggabungkan beberapa classifier lemah secara berurutan, masing-masing mencoba memperbaiki kesalahan prediksi dari classifier sebelumnya. Boosting menggabungkan classifier lemah secara berurutan untuk menghasilkan classifier yang kuat. Seperti algoritma berbasis pohon keputusan lainnya, AdaBoost juga menggunakan proses iteratif dalam penentuan modelnya [21]. Setiap iterasi fokus pada kesalahan yang dibuat oleh model sebelumnya [22]. Model akhir menggabungkan semua model sebelumnya, masing-masing diberi bobot berdasarkan kinerjanya. Model dengan kinerja lebih baik akan memiliki bobot lebih tinggi, sedangkan model yang kurang akurat diberikan bobot lebih rendah. Hasil prediksi $H(x)$ yang digunakan dalam penelitian ini adalah:

$$H(x) = sign\left(\sum_{t=1}^{T} \alpha_t \cdot h_t(x)\right)$$

dimana $h_t(x)$ merupakan klasifikasi lemah ke-t, α_t merupakan bobot dari klasifikasi lemah tersebut, $sign$ menentukan apakah hasilnya positif atau negatif.

3.4 SHAP dalam XAI



GAMBAR 2
Arsitektur deteksi depresi menggunakan AdaBoost dan SHAP

XAI adalah metode kecerdasan buatan (AI) yang membuat model pengambilan keputusan lebih jelas, lebih mudah dipahami, dan lebih mudah dijelaskan kepada manusia [23]. Lawan dari XAI disebut model black-box, di mana model sulit dipahami dan sulit dipertanggungjawabkan. Penggunaan XAI sangat penting di bidang seperti hukum, kesehatan, dan keuangan, di mana keputusan yang salah bersifat sensitif dan berbahaya. XAI mencakup hal-hal seperti FI, yang memberikan setiap fitur penilaian tergantung pada perannya dalam sebuah model. SHAP adalah metode explainable AI (XAI) yang bertujuan untuk menjelaskan setiap model machine learning berdasarkan teori permainan [24]. Metode ini terdiri dari tiga atribut, yaitu permainan, pemain, dan pembayaran. Permainan adalah model machine learning, pemain adalah setiap fitur, dan pembayaran adalah hasil prediksi dari model. Dalam model berbasis pohon keputusan, seperti random forest, XGBoost, atau AdaBoost, pendekatan TreeSHAP digunakan untuk menghitung nilai kontribusi ini secara lebih efisien. Hasil prediksi O dalam TreeSHAP yang digunakan dalam penelitian ini adalah:

$$O = \phi_0 + \sum_{i=1}^{I} \phi_i$$

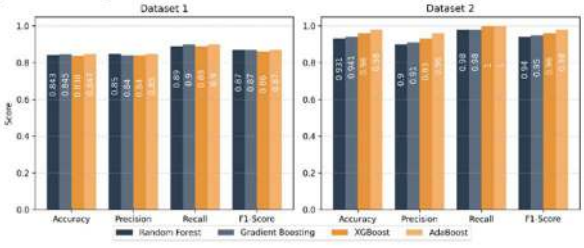
di mana ϕ_0 adalah output model yang diprediksi, I adalah total fitur, dan ϕ_i adalah kontribusi SHAP dari fitur ke-i.

4. Evaluasi

4.1 Hasil Pengujian

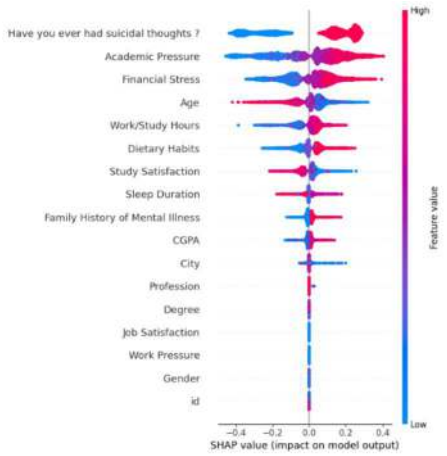
Hasil utama pengujian penelitian ini adalah kinerja model AdaBoosr pada dua dataset depresi mahasiswa. Tiga algoritma pembanding awal yaitu Random Forest, Gradient Boosting, dan XGBoost membandingkan hasil AdaBoost dengan lingkungan dan dataset yang sama. Evaluasi dilakukan menggunakan metrik *accuracy, precision, recall,* dan *F1-score*.

Pada Dataset 1 (Shodolamu Opeyemi), menunjukkan model AdaBoost dengan akurasi 0,85, yang merupakan nilai tertinggi diantara model lain. Dataset 2 (Jatmiko *et al.*) menunjukkan model AdaBoost dengan akurasi 0,98, yang juga merupakan nilai tertinggi diantara model pembanding lainnya. Grafik berikut menunjukkan perbandingan akurasi antar-model.

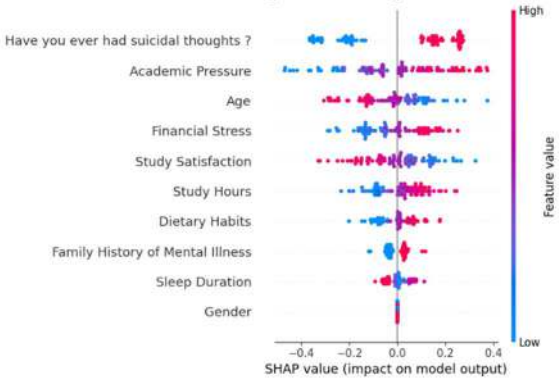


GAMBAR
Perbandingan 4 Algoritma pada Kedua Dataset

Untuk memastikan kestabilan model, dilakukan k-fold cross validation dengan k=5 pada Dataset 2. Hasilnya menunjukkan rata-rata akurasi 0.91 dengan standar deviasi 0.02 yang mengindikasikan bahwa model tidak mengalami overfitting dan memiliki performa yang konsisten.



GAMBAR 3
Visualisasi SHAP pada dataset pertama



GAMBAR 4
Visualisasi SHAP pada datset kedua

Hasil SHAP yang ditampilkan pada Gambar 4 dan Gambar 5 menunjukkan kontribusi fitur terhadap prediksi depresi. Kedua dataset memperlihatkan pola kontirbusi yang serupa, dimana fitur *Have you ever had suicidal thought?* Muncul sebagai fitur paling dominan. Secara keseluruhan, hasil pengujian menunjukkan bahwa AdaBoost merupakan model yang paling baik performanya untuk kedua dataset dan memberikan hasil yang stabil, serta SHAP mampu memberikan kontribusi fitur yang konsisten.

4.2 Analisis Hasil Pengujian

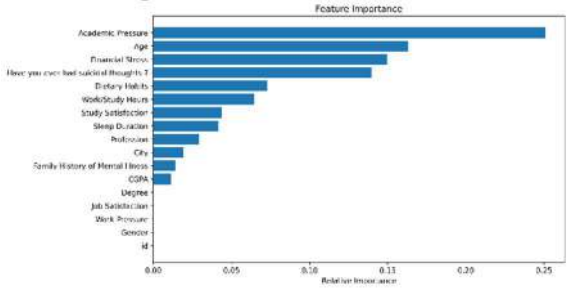
Analisis dilakukan untuk memahami lebih dalam pengaruh perbedaan dataset, stabilitas model, serta kontribusi fitur pada prediksi depresi.

Pertama, hasil pengujian menunjukkan bahwa dataset yang lebih kecil (Dataset 2) menghasilkan kinerja yang lebih baik daripada dataset yang lebih besar (Dataset 1). Analisis di kertas menunjukkan bahwa fitur fokus dan konsisten Dataset 2 membuatnya lebih mudah dipelajari oleh AdaBoost, sedangkan fitur Dataset 1 memliki variabilitas yang lebih besar dan tidak selalu relevan.

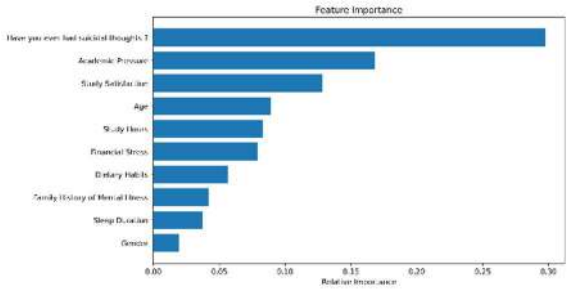
Kedua, analisis cross validation menunjukkan bahwa AdaBoost tidak mengalami overfitting. Hal ini dibtuktikan oleh standar deviasi yang rendah (0.02), yang berarti bahwa performa model tetap stabil di berbagai pembagian data.

Ketiga, analisis SHAP menunjukkan bahwa pada kedua dataset, karakteristik *suicidal thoughts* paling banyak memprediksi depresi. Faktor-faktor lain seperti tekanan *academic pressure, study satisfaction,* dan *financial stress* juga berkontribusi, tetapi tidak sekuat faktor pikiran bunuh diri. Gambar 6 dan 7 menunjukkan perbandingan hasil interpretabilitas dengan fitur penting bawaan AdaBoost, yang menunjukkan bahwa SHAP menghasilkan penjelasan yang lebih stabil dan konsisten

diantara dataset. Ini menunjukkan bahwa SHAP adalah metode interpretabilitas yang lebih tepat untuk mendeteksi depresi mahasiswa.



GAMBAR 5
AdaBoost FI pada dataset 1



GAMBAR 7
AdaBoost FI pada dataset 2

Secara keseluruhan, analisis memperlihatkan bahwa kualitas dataset memiliki pengaruh besar terhadap performa model, dan interpretabilitas SHAP memberikan wawasan yang akurat terdahap faktor risiko depresi. Temuan ini konsisten dengan tujuan penelitian, yaitu membandingkan dua dataset dan mengidentifikasi fitur penting yang berkontribusi pada prediksi.

5. Kesimpulan

Penelitian ini dilakukan dengan tujuan membandingkan dua kumpulan data depresi mahasiswa, menemukan fitur yang paling signifikan dalam prediksi depresi dengan SHAP, dan mengevaluasi ketepatan metode interpretabilitas dibandingkan dengan Feature Importance bawaan AdaBoost. Hasil pengujian dan analisis menghasilkan kesimpulan berikut.

1. Hasil eksperimen menunjukkan bahwa dataset Jatmiko *et al.* memiliki performa model yang lebih baik (akurat 0,98), sementara dataset Shodalamu Opeyemi memiliki performa model yang lebih rendah (akurat 0,85). Hal ini menunjukkan bahwa dataset lebih bersih, lebih terstruktur, dan memiliki fitur yang relevan memberikan kualitas prediksi yang lebih stabil.
2. Berdasarkan analisis SHAP yang dilakukan pada kedua dataset, hasil prediksi dipengaruhi paling banyak oleh variabel yang berkaitan dengan pikiran bunuh diri. Selama setiap analisis, fitur ini selalu mendapat peringkat pertama, menunjukkan bahwa itu adalah pengukur risiko depresi yang paling signifikan.
3. Hasil penelitian menunjukkan bahwa Feature Importance menghasilkan peringkat fitur yang inkonsisten antardataset sedangkan SHAP memberikan kontribusi fitur yang stabil dan selaras untuk kedua dataset. Sehingga SHAP terbukti lebih dapat diandalkan untuk memberikan interpretasi pada model yang mendeteksi depresi

Saran untuk penelitian selanjutnya yaitu mempertimbanggan menggunakan metode interpretabilitas lain seperti LIME atau Integrated Gradients untuk membandingkan konsistensi hasil interpretasi dengan SHAP. Penggunaaan algoritma pembelajaran lain, baik model ensemble maupun model deep learning, juga dapat dieksplorasi untuk melihat apakah terdapat peningkatan performa prediksi pada konteks deteksi depresi mahasiswa..

REFERENSI

[1] S. Pattnaik, A. Nayak, S. Mishra, B. Brahma, and A. K. Bhoi, “Depression Assessment in Youths Using an Enhanced Deep Learning Approach,” *Studies in Computational Intelligence*, vol. 1108, pp. 287–299, 2023, doi: 10.1007/978-3-031-38281-9_13.

[2] Isam Eldin HA Magid *et al.*, “Symptoms and risk factors for depression among college Freshmen students,” *World Journal of Advanced Research and Reviews*, vol. 14, no. 1, pp. 601–606, Apr. 2022, doi: 10.30574/WJARR.2022.14.1.0379.

[3] O. Ya. Andriichuk and L. Y. Sakharuk, “ANALYSIS OF THE SOMATIC COMPONENT OF DEPRESSION IN THE DEVELOPMENT OF A PHYSICAL THERAPY PROGRAM,” *Art of Medicine*, pp. 12–17, Oct. 2022, doi: 10.21802/ARTM.2022.3.23.12.

[4] M. Moran, “Academic Stress, Failure May Be Underrecognized Trigger for Suicidal Thoughts, Behaviors,” *Psychiatr News*, vol. 57, no. 8, Aug. 2022, doi: 10.1176/APPI.PN.2022.08.8.34.

[5] J. Premalatha, S. Aswin, D. JaiHari, and K. Karamchand Subash, “Detecting Depression Using Quality-of-Life Attributes with Machine Learning Techniques,” *Lecture Notes in Networks and Systems*, vol. 728 LNNS, pp. 29–37, 2024, doi: 10.1007/978-981-99-3932-9_4.

[6] K. Sujigarasharma, M. L. Shri, and K. Santhi, “Smart Detection and Proactive Prevention of Student Depression: A DeepLearning Approach,” *TQCEBT 2024 - 2nd IEEE International Conference on Trends in Quantum Computing and Emerging Business Technologies 2024*, 2024, doi: 10.1109/TQCEBT59414.2024.10545088.

[7] M. Gupta, “A Comparative Study on Supervised Machine Learning Algorithm,” *Int J Res Appl Sci Eng Technol*, vol. 10, no. 1, pp. 1023–1028, Jan. 2022, doi: 10.22214/IJRASET.2022.39980.

[8] Y. Zhou, Z. Zhang, Q. Li, G. Mao, and Z. Zhou, “Construction and validation of machine learning algorithm for predicting depression among home-quarantined individuals during the large-scale COVID-19 outbreak: based on Adaboost model,” *BMC Psychology 2024 12:1*, vol. 12, no. 1, pp. 230-, Apr. 2024, doi: 10.1186/S40359-024-01696-8.

[9] H. Liu *et al.*, “Depression Detection via Capsule Networks with Contrastive Learning,” *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 38, no. 20, pp. 22231–22239, Mar. 2024, doi: 10.1609/AAAI.V38I20.30228.

[10] M. Ennab and H. McHeick, “Designing an Interpretability-Based Model to Explain the

Artificial Intelligence Algorithms in Healthcare," *Diagnostics*, vol. 12, no. 7, p. 1557, Jul. 2022, doi: 10.3390/DIAGNOSTICS12071557.

[11] M. Balbino, R. Santana, M. Teodoro, M. Song, L. Zárate, and C. Nobre, "Predicting Depression in Children and Adolescents using the SHAP Approach," pp. 514–521, Feb. 2022, doi: 10.5220/0010842500003123.

[12] "Prediction of depression status in college students using a Naive Bayes classifier based machine learning model | Request PDF." Accessed: Nov. 27, 2025. [Online]. Available: https://www.researchgate.net/publication/372683794_Prediction_of_depression_status_in_college_students_using_a_Naive_Bayes_classifier_based_machine_learning_model

[13] E. O. Ogunseye, C. A. Adenusi, A. C. Nwanakwaugwu, S. A. Ajagbe, and S. O. Akinola, "Predictive Analysis of Mental Health Conditions Using AdaBoost Algorithm," *ParadigmPlus*, vol. 3, no. 2, pp. 11–26, Aug. 2022, doi: 10.55969/PARADIGMPLUS.V3N2A2.

[14] "Predictive Machine Learning Models for Assessing Lebanese University Students' Depression, Anxiety, and Stress During COVID-19 - Christo El Morr, Manar Jammal, Imad Bou-Hamad, Sahar Hijazi, Dinah Ayna, Maya Romani, Reem Hoteit, 2024." Accessed: Nov. 27, 2025. [Online]. Available: https://journals.sagepub.com/doi/10.1177/21501319241235588

[15] D. Wang, Q. Li, Y. Gao, Y. Liu, and Y. Li, "Exploring the interpretability in speech-based adolescent depression detection by SHAP," *ACM International Conference Proceeding Series*, pp. 562–567, Dec. 2023, doi: 10.1145/3638884.3638972.

[16] D. Enkhbayar *et al.*, "Explainable Artificial Intelligence Models for Predicting Depression Based on Polysomnographic Phenotypes," *Bioengineering*, vol. 12, no. 2, Feb. 2025, doi: 10.3390/BIOENGINEERING12020186.

[17] R. J. Kiran, J. Sanil, and S. Asharaf, "A Novel Approach for Model Interpretability and Domain Aware Fine-Tuning in AdaBoost," *Human-Centric Intelligent Systems*, vol. 4, no. 4, pp. 610–632, Sep. 2024, doi: 10.1007/S44230-024-00082-2.

[18] F. Ferren and F. I. Kurniadi, "Enhancing Bankruptcy Prediction with Feature Selection in AdaBoost Algorithm," *10th International Conference on ICT for Smart Society, ICISS 2023 - Proceeding*, 2023, doi: 10.1109/ICISS59129.2023.10291988.

[19] Y. Lin, C. Li, and H. Li, "Machine learning-driven risk prediction and feature identification for major depressive disorder and its progression: an exploratory study based on five years of longitudinal data from the US national health survey," *J Affect Disord*, vol. 381, pp. 573–583, Jul. 2025, doi: 10.1016/J.JAD.2025.04.056.

[20] M. N. Fauzan, A. G. Putrada, N. Alamsyah, and S. F. Pane, "PCA-AdaBoost Method for a Low Bias and Low Dimension Toxic Comment Classification.," *ICACNIS 2022 - 2022 International Conference on Advanced Creative Networks and Intelligent Systems: Blockchain Technology, Intelligent Systems, and the Applications for Human Life, Proceeding*, 2022, doi: 10.1109/ICACNIS57039.2022.10055017.

[21] A. G. Putrada, M. Abdurohman, D. Perdana, and H. H. Nuha, "NoCASC: A Novel Optimized Cost-Complexity Pruning for AdaBoost Model Compression on Edge Computing-Based Smart Lighting," *COMNETSAT 2024 - IEEE International Conference on Communication, Networks and Satellite*, pp. 729–734, 2024, doi: 10.1109/COMNETSAT63286.2024.10862047.

[22] A. N. Iman, A. G. Putrada, S. Prabowo, and D. Perdana, "Peningkatan Kinerja AMG8833 sebagai Thermocam dengan Metode Regresi AdaBoost untuk Pelaksanaan Protokol COVID-19," *Jurnal Elektro dan Telekomunikasi Terapan*, vol. 8, no. 1, p. 978, Aug. 2021, doi: 10.25124/JETT.V8I1.3894.

[23] G. Grillo, T. Torda, C. Voena, A. Ciardiello, and S. Giagu, "Integrating ChatGPT-4: A Novel XAI Interface for Enhanced Clinician Understanding of MRI Image Segmentation Results," *Proc IEEE Symp Comput Based Med Syst*, pp. 320–325, 2024, doi: 10.1109/CBMS61543.2024.00060.

[24] "(PDF) Local Interpretable Model Agnostic Shap Explanations for machine learning models." Accessed: Nov. 27, 2025. [Online]. Available: https://www.researchgate.net/publication/364522755_Local_Interpretable_Model_Agnostic_Shap_Explanations_for_machine_learning_models