

## Perbandingan Model Klasifikasi Multikelas Tingkat Depresi Mahasiswa dengan Skor PHQ-9

Felinda Arumningtyas<sup>1</sup>, Puce Angreni<sup>2</sup>, Lutfiah Maharani Siniwi<sup>3</sup>

<sup>1</sup>Program Studi Statistika, Universitas Jenderal Soedirman, [felinda.arumningtyas@unsoed.ac.id](mailto:felinda.arumningtyas@unsoed.ac.id)

<sup>2</sup> Program Studi Statistika, Universitas Jenderal Soedirman, [puce.angreni@unsoed.ac.id](mailto:puce.angreni@unsoed.ac.id)

<sup>3</sup> Program Studi Statistika, Universitas Jenderal Soedirman, [lutfiah.maharani@unsoed.ac.id](mailto:lutfiah.maharani@unsoed.ac.id)

**Abstract.** Depression is one of the most common mental health disorders among university students and may adversely affect academic performance and social functioning. The severity of depression can be assessed using the Patient Health Questionnaire-9 (PHQ-9), which classifies individuals into several levels of depression severity. This study aims to compare several machine learning models for multiclass classification of student depression levels based on PHQ-9 scores. The study employed the PHQ-9 Student Depression Dataset consisting of 682 student records. Predictor variables included age, gender, the nine PHQ-9 items, sleep quality, study pressure, and financial pressure. The models evaluated were Logistic Regression, Decision Tree, Random Forest, Support Vector Machine (SVM), and XGBoost. Model performance was assessed using accuracy, precision, recall, and F1-score metrics. The results indicate that XGBoost achieved the best performance, with an accuracy of 78,10%, macro precision of 0,77, macro recall of 0,77, and macro F1-score of 0,77. These findings demonstrate that XGBoost provides relatively good performance in the multiclass classification of student depression levels. This study suggests that machine learning approaches have the potential to support the identification of depression severity among university students.

**Keywords:** *student depression; multiclass classification; machine learning; PHQ-9, XGBoost.*

**Abstrak.** Depresi merupakan salah satu gangguan kesehatan mental yang banyak dialami mahasiswa dan dapat memengaruhi kondisi akademik maupun sosial. Tingkat depresi dapat diidentifikasi menggunakan instrumen Patient Health Questionnaire-9 (PHQ-9) yang mengelompokkan individu ke dalam beberapa tingkat keparahan depresi. Penelitian ini bertujuan membandingkan beberapa model machine learning dalam melakukan klasifikasi multikelas tingkat depresi mahasiswa berdasarkan skor PHQ-9. Data yang digunakan merupakan PHQ-9 Student Depression Dataset yang terdiri atas 682 data mahasiswa. Variabel prediktor meliputi usia, jenis kelamin, sembilan item PHQ-9, kualitas tidur, tekanan akademik, dan tekanan finansial. Model yang dibandingkan adalah Regresi Logistik, Decision Tree, Random Forest, Support Vector Machine (SVM), dan XGBoost. Evaluasi model dilakukan menggunakan accuracy, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa XGBoost memberikan kinerja terbaik dengan akurasi sebesar 78,10%, precision makro sebesar 0,77, recall makro sebesar 0,77, dan F1-score makro sebesar 0,77. Hasil tersebut menunjukkan bahwa XGBoost mampu memberikan kinerja yang relatif baik dalam klasifikasi multikelas tingkat depresi mahasiswa. Penelitian ini menunjukkan bahwa pendekatan machine learning berpotensi digunakan sebagai alat bantu identifikasi tingkat depresi mahasiswa.

**Kata Kunci:** *depresi mahasiswa; klasifikasi multikelas; machine learning; PHQ-9; XGBoost.*

## **1 Pendahuluan**

Depresi merupakan salah satu gangguan mental yang menjadi perhatian serius dalam bidang kesehatan masyarakat karena prevalensinya terus meningkat dan berdampak luas terhadap kualitas hidup, produktivitas, fungsi sosial, hingga risiko bunuh diri. Organisasi Kesehatan Dunia menyatakan bahwa depresi termasuk masalah kesehatan masyarakat global yang memerlukan perhatian khusus karena dapat menyerang berbagai kelompok usia dan berpotensi menimbulkan beban sosial maupun ekonomi yang besar. Dalam konteks kesehatan mental, depresi tidak hanya dipahami sebagai kondisi emosional sesaat, tetapi sebagai gangguan yang dapat memengaruhi aspek kognitif, perilaku, dan fisik seseorang secara signifikan [1], [2].

Mahasiswa merupakan salah satu kelompok yang rentan mengalami depresi karena berada pada fase transisi dari remaja menuju dewasa yang ditandai oleh meningkatnya tuntutan akademik, tekanan untuk mempertahankan prestasi, penyesuaian terhadap lingkungan sosial baru, serta masalah finansial yang sering kali menyertai masa studi. Berbagai tekanan tersebut dapat memicu stres berkepanjangan, gangguan tidur, penurunan motivasi belajar, dan pada akhirnya meningkatkan risiko gangguan kesehatan mental. Kondisi ini menjadikan mahasiswa sebagai populasi yang penting untuk diteliti, terutama dalam upaya skrining dini dan identifikasi tingkat depresi secara lebih cepat dan tepat [3], [4].

Salah satu instrumen yang banyak digunakan untuk mengukur gejala depresi adalah Patient Health Questionnaire-9 (PHQ-9), yaitu kuesioner yang terdiri atas sembilan pertanyaan berdasarkan gejala depresi dalam dua minggu terakhir. Setiap item PHQ-9 menggunakan skala penilaian tertentu yang menghasilkan skor total, kemudian skor tersebut dapat diklasifikasikan ke dalam beberapa tingkat keparahan, seperti minimal, ringan, sedang, sedang berat, dan berat. Penggunaan PHQ-9 dinilai praktis, efisien, dan cukup relevan untuk keperluan skrining, sehingga instrumen ini sering dijadikan dasar dalam penelitian klasifikasi tingkat depresi, termasuk pada populasi mahasiswa [1], [2].

Seiring berkembangnya ketersediaan data kesehatan mental dan survei psikologis, pendekatan machine learning semakin banyak dimanfaatkan untuk mengenali pola-pola kompleks yang sulit diidentifikasi secara manual. Dalam bidang kesehatan mental, machine learning telah digunakan untuk membantu skrining depresi melalui berbagai sumber data, mulai dari kuesioner, suara, teks, hingga kombinasi multimodal. Penelitian terbaru menunjukkan bahwa integrasi fitur tambahan dengan PHQ-9 dapat meningkatkan performa model klasifikasi, sementara studi lain membuktikan bahwa algoritma machine learning seperti Naïve Bayes mampu melakukan klasifikasi multikelas tingkat depresi mahasiswa dengan akurasi yang cukup tinggi [5]. Hal ini menunjukkan bahwa pendekatan machine learning memiliki potensi besar untuk mendukung deteksi dini depresi secara lebih cepat dan terukur [1], [6], [7], [8].

Meskipun demikian, masih terdapat beberapa research gap yang penting. Banyak penelitian sebelumnya masih berfokus pada klasifikasi biner, yaitu membedakan depresi dan tidak depresi, sehingga informasi mengenai tingkat keparahan depresi belum tergalai secara lebih rinci. Selain itu, sejumlah studi menggunakan data survei yang dikembangkan sendiri sehingga sulit dibandingkan secara langsung dengan penelitian lain, sedangkan penggunaan dataset publik

PHQ-9 yang terstandar masih relatif terbatas. Penelitian yang secara khusus mengkaji klasifikasi multikelas tingkat depresi mahasiswa dengan membandingkan beberapa algoritma machine learning pada dataset PHQ-9 publik juga masih belum banyak ditemukan, padahal pendekatan ini penting untuk mengetahui model mana yang paling sesuai dari sisi performa dan stabilitas prediksi. Dengan demikian, diperlukan kajian yang tidak hanya mengevaluasi satu algoritma, tetapi juga membandingkan beberapa model agar hasil penelitian lebih komprehensif[3], [4], [7].

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk membandingkan beberapa model machine learning, yaitu regresi logistik, decision tree, random forest, support vector machine, dan XGBoost dalam melakukan klasifikasi multikelas tingkat depresi mahasiswa berdasarkan skor PHQ-9. Perbandingan ini diharapkan dapat memberikan gambaran yang lebih jelas mengenai algoritma yang paling efektif untuk dataset PHQ-9 publik, sekaligus menjadi dasar pengembangan sistem skrining depresi yang lebih objektif, efisien, dan aplikatif pada lingkungan pendidikan tinggi[9].

## 2 Metode Penelitian

### 2.1 Data Penelitian

Penelitian ini menggunakan data sekunder yang diperoleh dari PHQ-9 Student Depression Dataset yang tersedia secara publik pada Mendeley Data. Dataset terdiri atas 682 data mahasiswa berusia 17–26 tahun. Data memuat karakteristik demografi, sembilan item PHQ-9, kualitas tidur, tekanan akademik, tekanan finansial, dan tingkat depresi mahasiswa.

### 2.2 Variabel Penelitian

Variabel target dalam penelitian ini adalah PHQ Severity yang menunjukkan tingkat depresi mahasiswa berdasarkan skor total PHQ-9. Tingkat depresi dibagi menjadi lima kategori, yaitu minimal (0–4), mild (5–9), moderate (10–14), moderately severe (15–19), dan severe (20–27). Kelima kategori tersebut digunakan sebagai kelas pada proses klasifikasi multikelas. Variabel prediktor terdiri atas usia (Age), jenis kelamin (Gender), sembilan item PHQ-9 (Q1–Q9), kualitas tidur (Sleep Quality), tekanan akademik (Study Pressure), dan tekanan finansial (Financial Pressure). Variabel-variabel tersebut dipilih karena dapat merepresentasikan kondisi psikologis, demografis, dan faktor lingkungan yang berkaitan dengan tingkat depresi mahasiswa.

### 2.3 Teknik Analisis Data

Adapun langkah-langkah dalam penelitian ini adalah sebagai berikut:

- a. Melakukan penelaahan data, yaitu pemeriksaan kualitas data meliputi *missing value*, data duplikat, dan *outlier*.
- b. Melakukan pra-pemrosesan data (*pre-processing*), yang meliputi pembersihan data, transformasi variabel kategorik, serta persiapan data untuk proses pemodelan.
- c. Mengkaji karakteristik data, meliputi analisis deskriptif terhadap variabel penelitian dan distribusi tingkat depresi mahasiswa.

- d. Melakukan pembagian data (*data splitting*), yaitu membagi data menjadi data pelatihan (*training data*) dan data pengujian (*testing data*) dengan proporsi tertentu, misalnya 80:20.
- e. Membangun model klasifikasi multikelas, menggunakan metode Regresi Logistik, Decision Tree, Random Forest, Support Vector Machine (SVM), dan XGBoost.
- f. Melakukan evaluasi kinerja model, menggunakan ukuran akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*.
- g. Membandingkan kinerja model klasifikasi untuk menentukan model terbaik berdasarkan hasil evaluasi.
- h. Menentukan model terbaik, yaitu model yang memiliki kinerja paling optimal dalam mengklasifikasikan tingkat depresi mahasiswa.

### 3 Hasil dan Pembahasan

#### 3.1 Karakteristik Data Penelitian

##### a. Karakteristik Responden

**Tabel 1.** Distribusi Usia Responden

Kelompok Usia	Jumlah Responden	Persentase
17 – 19	218	31,96
20 – 22	202	29,62
23 – 25	206	30,21
26	56	8,21

Sebagaimana yang ditampilkan pada Tabel 1, proporsi responden terbesar berada pada kelompok usia 17–19 tahun dengan jumlah 218 responden atau 31,96%. Responden berusia 26 tahun merupakan kelompok terkecil, sebesar 56 responden atau 8,21%. Secara keseluruhan, responden berusia antara 17 hingga 25 tahun sudah sesuai dengan rentang usia umum mahasiswa.

**Tabel 2.** Distribusi Jenis Kelamin Responden

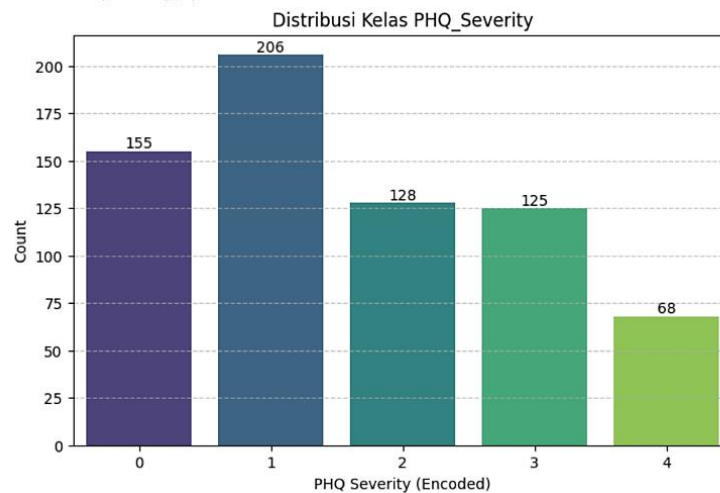
Jenis Kelamin	Jumlah Responden	Persentase
Laki-Laki	415	61,12
Perempuan	264	38,88

Terlihat pada Tabel 2 sebagian besar responden adalah laki-laki, yaitu sebanyak 415 responden atau 61,12%, sedangkan responden perempuan berjumlah 264 orang atau 38,88%. Dengan demikian, distribusi responden didominasi oleh mahasiswa laki-laki.

##### b. Distribusi Tingkat Depresi

**Tabel 3.** Distribusi Tingkat Depresi

PHQ-9 Severity	Proporsi
0	22,73
1	30,20
2	18,77
3	18,33
4	9,97



Gambar 1. Distribusi Tingkat Depresi

Berdasarkan tingkat keparahan depresi yang ditampilkan pada Tabel 3 dan Gambar 1, proporsi terbesar responden diklasifikasikan mengalami depresi ringan, yaitu sebanyak 206 responden atau 30,21%. Angka ini diikuti oleh responden dengan depresi minimal sebanyak 155 responden atau 22,73%. Sementara itu, 128 responden atau 18,77% mengalami depresi sedang, dan 125 responden atau 18,33% diklasifikasikan mengalami depresi sedang berat. Secara keseluruhan, 47,07% responden termasuk dalam kategori depresi sedang hingga berat, yang menunjukkan bahwa sebagian besar mahasiswa mengalami gejala depresi yang signifikan secara klinis.

### 3.2 Hasil Klasifikasi Model

Evaluasi kinerja model dilakukan untuk menilai kemampuan masing-masing algoritma klasifikasi dalam mengidentifikasi tingkat keparahan depresi. Evaluasi ini menggunakan beberapa metrik, yaitu akurasi, presisi, recall, dan F1-score, sehingga performa model dapat ditinjau secara lebih komprehensif, baik secara keseluruhan maupun pada setiap kategori tingkat keparahan depresi. Hasil perbandingan kinerja masing-masing model klasifikasi disajikan pada Tabel 4.

Tabel 4. Perbandingan Kinerja Model Klasifikasi

Model	Akurasi	Presisi Makro	Recall Makro	F1-Score Makro
Regresi Logistik	0,416	0,41	0,40	0,40
Decision Tree	0,650	0,65	0,63	0,63
Random Forest	0,752	0,76	0,74	0,74
XGBoost	<b>0,781</b>	<b>0,77</b>	<b>0,77</b>	<b>0,77</b>
Support Vector Machine	0,642	0,65	0,64	0,65

Analisis kinerja model juga dilakukan pada setiap kategori tingkat keparahan depresi menggunakan metrik F1-score. Evaluasi ini bertujuan untuk memberikan gambaran yang lebih rinci mengenai kemampuan masing-masing algoritma dalam mengklasifikasikan setiap kategori depresi, mengingat karakteristik dan tingkat kesulitan klasifikasi dapat berbeda antar kelas. Perbandingan nilai F1-score pada setiap tingkat keparahan depresi disajikan pada Tabel 5.

**Tabel 5.** Perbandingan F1-Score pada Setiap Tingkat Depresi

<b>Model</b>	Minimal (0)	Ringan (1)	Sedang (2)	Sedang Berat (3)	Berat (4)
Regresi Logistik	0,25	0,58	0,31	0,39	0,48
Decision Tree	0,55	0,79	0,49	0,65	0,69
Random Forest	0,69	0,89	0,50	<b>0,75</b>	<b>0,88</b>
XGBoost	<b>0,75</b>	<b>0,93</b>	<b>0,64</b>	0,69	0,83
Support Vector Machine	0,56	0,78	0,52	0,58	0,79

a. Regresi Logistik

Regresi Logistik menghasilkan kinerja terendah, dengan akurasi sebesar 41,61% dan F1-score sebesar 0,40, Model ini menunjukkan kinerja yang relatif lebih baik dalam mengidentifikasi depresi ringan, dengan F1-score sebesar 0,58. Hasil ini mengindikasikan bahwa hubungan antara variabel prediktor dan tingkat keparahan depresi mungkin tidak dapat direpresentasikan langsung dengan batas keputusan linear.

b. Decision Tree

Model Decision Tree mencapai akurasi sebesar 64,96% dan F1-score sebesar 0,63. Model ini menunjukkan kinerja terbaik dalam memprediksi depresi ringan dengan nilai recall 0,88. Meskipun Decision Tree mampu menangkap hubungan non-linear, model pohon tunggal dapat menjadi sensitif terhadap perubahan pada data pelatihan dan rentan terhadap *overfitting*.

c. Random Forest

Model Random Forest mencapai akurasi sebesar 75,18%. Model ini menunjukkan kinerja yang sangat baik dalam mengidentifikasi depresi ringan, dengan F1-score sebesar 0,89, serta depresi berat, dengan F1-score sebesar 0,88. Adapun nilai presisi 1 untuk kategori berat berarti seluruh responden yang diprediksi mengalami depresi berat oleh model telah diklasifikasikan dengan benar.

d. XGBoost

XGBoost menunjukkan kinerja keseluruhan terbaik, dengan mencapai akurasi sebesar 78,10% dan F1-score Makro sebesar 0,77. Model ini menunjukkan kinerja yang sangat baik dalam mengidentifikasi depresi ringan. Model ini juga memperlihatkan kinerja yang relatif seimbang pada kategori tingkat keparahan depresi lainnya. Dibandingkan dengan model-model lain, XGBoost mencapai F1-score tertinggi untuk kategori depresi minimal dan sedang.

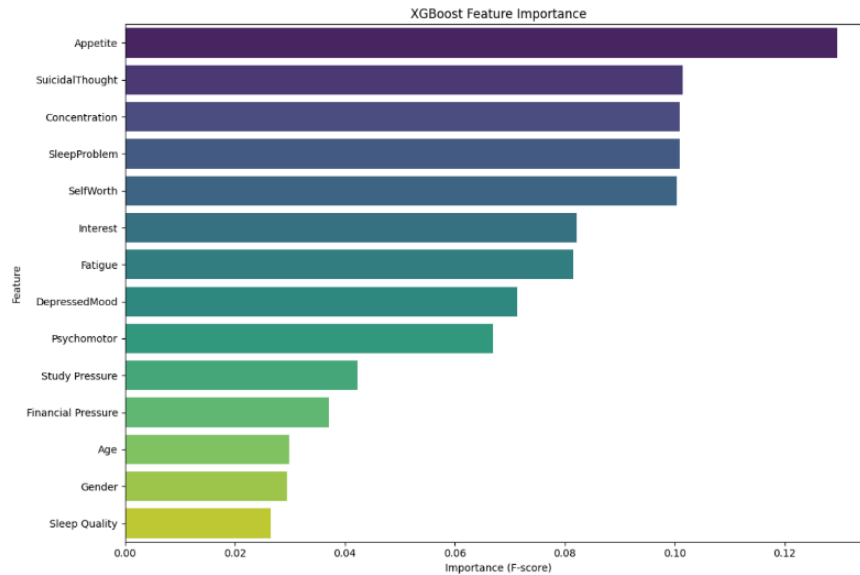
e. *Support Vector Machine*

*Support Vector Machine* mencapai akurasi sebesar 64,23%. Kinerja terbaiknya terlihat pada kasus depresi berat. Model ini juga menunjukkan kinerja yang cukup baik untuk depresi ringan, dengan F1-score sebesar 0,78. Namun, model tersebut mengalami kesulitan lebih besar dalam membedakan depresi tingkat minimal, sedang, dan cukup berat. Kinerjanya sebanding dengan Decision Tree, namun masih di bawah Random Forest dan XGBoost.

### 3.3 Evaluasi Model Terbaik

Berdasarkan perbandingan lima algoritma klasifikasi, XGBoost diidentifikasi sebagai model dengan kinerja terbaik untuk memprediksi tingkat keparahan depresi responden. Model ini mencapai akurasi sebesar 78,10%, dengan presisi makro, recall makro, dan F1-score makro bernilai sama yaitu 77%. Hasil ini menunjukkan

bahwa XGBoost memberikan kinerja yang relatif seimbang di seluruh kategori tingkat keparahan depresi. Kinerja terbaik diamati pada kategori depresi ringan dengan F1-score sebesar 0,93, sementara kategori depresi sedang menjadi kategori yang paling sulit untuk diklasifikasikan.



Gambar 2. Feature Importance Model XGBoost

Analisis *feature importance* menunjukkan bahwa nafsu makan merupakan prediktor yang paling berpengaruh, diikuti oleh pikiran untuk bunuh diri, konsentrasi, masalah tidur, dan penilaian diri. Sebaliknya, faktor demografis dan eksternal seperti usia, jenis kelamin, tekanan finansial, dan kualitas tidur memiliki nilai kepentingan yang relatif lebih rendah. Perlu sebagai catatan bahwa *feature importance* hanya menggambarkan kontribusi relatif setiap fitur dalam proses prediksi dan tidak dapat digunakan untuk menyimpulkan adanya hubungan sebab-akibat.

### 3.4 Pembahasan

Hasil penelitian membuktikan bahwa XGBoost menunjukkan kinerja terbaik jika dibandingkan dengan Regresi Logistik, Decision Tree, Random Forest, dan Support Vector Machine dalam melakukan pengklasifikasian tingkat depresi mahasiswa. Hal ini terkait dengan prinsip *boosting* dalam proses pengembangan algoritma pada model XGBoost yang merupakan pembentukan model secara bertahap dan dengan cara meminimalisir kesalahan dari model yang telah ada sebelumnya. Pendekatan ini menciptakan kondisi yang memungkinkan XGBoost mengidentifikasi pola yang kompleks dan non linear antar faktor seperti perubahan nafsu makan, pikiran bunuh diri, masalah konsentrasi, gangguan tidur, dan penilaian diri. Kemampuan tersebut membuat XGBoost lebih sesuai dibandingkan model linear ketika hubungan antara variabel prediktor dan tingkat depresi tidak mengikuti pola yang sederhana.

Meskipun demikian, klasifikasi tingkat depresi dalam penelitian ini tergolong kompleks karena melibatkan lima kelas, yaitu minimal, ringan, sedang, sedang berat, dan berat. Gejala pada dua kelas yang berdekatan bisa mirip sehingga perbedaan antar kelas menjadi tidak jelas. Hal ini tampak dalam kelas penyakit depresi sedang yang memiliki nilai F1-score lebih rendah daripada kelas-kelas

lainnya. Model kemungkinan lebih sulit membedakan responden dengan tingkat depresi sedang dari responden dengan depresi ringan atau sedang berat karena karakteristik gejalanya saling tumpang tindih. Banyaknya data yang ada di masing-masing tingkat depresi juga menjadi salah satu faktor yang dapat berpengaruh terhadap kemampuan model dalam melakukan analisis.

Hasil ini sejalan dengan penelitian Priya, Garg, dan Tigga [10], yang menunjukkan bahwa algoritma *machine learning* dapat digunakan untuk memprediksi kondisi depresi, kecemasan, dan stres berdasarkan berbagai karakteristik responden. Penelitian tersebut menegaskan bahwa pendekatan *machine learning* mampu mengolah hubungan yang kompleks antarfaktor psikologis dan karakteristik individu sehingga berpotensi mendukung proses identifikasi kondisi kesehatan mental. Secara lebih luas, Shatte, Hutchinson, dan Teague [11] juga menjelaskan bahwa *machine learning* telah banyak diterapkan dalam bidang kesehatan mental, termasuk untuk klasifikasi, prediksi risiko, dan identifikasi faktor-faktor yang berkaitan dengan gangguan psikologis.

Klasifikasi model yang dikembangkan bisa digunakan sebagai alat bantu untuk identifikasi level depresi pada mahasiswa maupun deteksi dini kondisi kesehatan mental di lingkungan universitas. Hasil prediksi dapat membantu unit layanan konseling atau pengelola perguruan tinggi menentukan mahasiswa yang memerlukan pemeriksaan lebih lanjut. Namun, model tidak dapat menggantikan diagnosis yang dilakukan oleh psikolog atau tenaga kesehatan profesional. Faktor lainnya adalah beberapa variabel yang memiliki nilai *feature importance* paling tinggi adalah komponen yang digunakan dalam menghitung PHQ, sehingga kinerja model berpotensi juga dipengaruhi oleh *overlapping* informasi antara variabel prediktor dengan variabel target. Dalam pengembangan ke depannya, lebih baik jika dilakukan uji coba model dengan faktor-faktor yang tidak terlibat dalam pembentukan skor PHQ-9 dan validasi pada data mahasiswa di lembaga yang berbeda.

## 4 Kesimpulan

Penelitian ini membandingkan lima model *machine learning* untuk klasifikasi multikelas tingkat depresi mahasiswa berdasarkan skor PHQ-9. Hasil penelitian menunjukkan bahwa XGBoost memberikan kinerja terbaik dengan akurasi sebesar 78,10% dan F1-score makro sebesar 0,77. Temuan ini menunjukkan bahwa XGBoost memiliki potensi sebagai model klasifikasi tingkat depresi mahasiswa. Penelitian selanjutnya dapat melakukan optimasi parameter model serta pengujian pada data mahasiswa yang lebih beragam untuk meningkatkan kinerja dan kemampuan generalisasi model.

## 5 Daftar Pustaka

- [1] A, Maulana and M, Sadikin, "Implementasi Sistem Informasi Manajemen Inventaris Berbasis Web Di Pusat Teknologi Informasi Dan Komunikasi-BPPT," *Arief Izzuddin/ Setrum*, vol, 7, no, 1, pp, 182–196, 2018,
- [2] X, Li, W, Jin, L, Han, X, Chen, and L, Li, "Comparison and application of depression screening tools for adolescents: scale selection and clinical

- practice,” Dec, 01, 2025, *BioMed Central Ltd*, doi: 10,1186/s13034-025-00908-2,
- [3] Y, Jiang, “Predicting Student Depression using Machine Learning: A Comparative Study of Logistic Regression and Random Forest,” 2025,
- [4] A, Osman Hassan, I, Mohamed Jamal, S, Daud Ahmed, and A, Ugas Abdullahi, “Predicting Student Depression using Machine Learning: A Comparative Analysis of Machine Learning Algorithms for Early Depression Detection in Students”, doi: 10,63094/AITUSRJ,25,4,1,4,
- [5] S, Romora Karo Karo and M, Agus Wirawan, “Analisis Klasifikasi Tingkat Stres Mahasiswa Menggunakan Gaussian Naive Bayes dan Fisher’s Discriminant Ratio,” vol, 15, no, 2, 2026,
- [6] A, Daza Vergaray, J, C, H, Miranda, J, B, Cornelio, A, R, López Carranza, and C, F, Ponce Sánchez, “Predicting the depression in university students using stacking ensemble techniques over oversampling method,” *Inform, Med, Unlocked*, vol, 41, Jan, 2023, doi: 10,1016/j,imu,2023,101295,
- [7] P, W, Simarmata and P, T, Prasetyaningrum, “Development of a Student Depression Prediction Model Based on Machine Learning with Algorithm Performance Evaluation,” *Journal of Information Systems and Informatics*, vol, 7, no, 2, pp, 1283–1305, Jun, 2025, doi: 10,51519/journalisi,v7i2,1087,
- [8] Suprianto and D, Nur Wahyu Ningsih, “Deteksi Risiko Depresi pada Pengguna Media Sosial Indonesia Menggunakan Indobertweet,” 2025.
- [9] A, Kallila and M, B, U, -, “Prediksi Tingkat Depresi Mahasiswa Menggunakan Model Hybrid Xgboost dan SVM Berdasarkan PHQ-9, IPK, Tahun Akademik, dan Usia,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol, 14, no, 2, Apr, 2026, doi: 10,23960/jitet,v14i2,9307.
- [10] A. Priya, S. Garga and N. P. Tigga, "Predicting Anxiety, Depression and Stress in Modern Life using Machine Learning Algorithms," *Procedia Computer Science*, pp. 1258-1267, 2020.
- [11] A. B. R. Shatte, D. M. Hutchinson and S. J. Teague, "Machine learning in mental health: A systematic scoping review of methods and applications," *Psychol Med*, vol. 49, no. 9, pp. 1426-1448, 2019.