Journal of Vocational Education and Information Technology
Vol. 7, No. 2, Desember 2026, 703 - 712
E-ISSN: 2722-5305
Terakreditasi **SINTA Peringkat 4**
Surat Keputusan Direktur Jenderal Pendidikan Tinggi, Riset, dan Teknologi, Nomor: 230/E/KPT/2024

Optimasi Algoritma Xgboost Dengan Hyperparameter Tuning Menggunakan Gridsearchcv Dalam Klasifikasi Tingkat Depresi Mahasiswa

Khairunnisa [1], Faisal Muttaqin [2*], Chrystia Aji Putra [2]

[1,2,3] Jurusan Informatika, UPN Veteran Jawa Timur.
22081010325@student.upnjatim.ac.id , faisalmuttaqin.if@upnjatim.ac.id , ajiputra@upnjatim.ac.id

* Korespondensi: e-mail: faisalmuttaqin.if@upnjatim.ac.id ,

Diterima: 10-08-2026 ; Review: 13-10-2026 ; Disetujui: 28-11-2026,

Abstrak: Depresi merupakan salah satu gangguan kesehatan mental yang banyak dialami mahasiswa akibat tekanan akademik dan berbagai faktor psikologis. Deteksi dini tingkat depresi menjadi penting untuk mendukung penanganan yang lebih cepat dan tepat. Penelitian ini bertujuan mengoptimalkan performa algoritma *Extreme Gradient Boosting* (XGBoost) dalam klasifikasi tingkat depresi mahasiswa melalui penerapan *hyperparameter tuning* menggunakan metode GridSearchCV. Dataset yang digunakan terdiri dari 306 data mahasiswa yang diperoleh melalui penyebaran kuesioner daring menggunakan instrumen PHQ-9, GAD-7, dan ERQ. Tahapan penelitian meliputi *data cleaning*, transformasi data, penentuan label, pembagian data dengan rasio 80:20, 70:30, dan 60:40, proses *hyperparameter tuning*, serta evaluasi model menggunakan *confusion matrix* dan nilai akurasi. Hasil optimasi menunjukkan bahwa konfigurasi parameter terbaik pada rasio 80:20 adalah *n_estimators* = 150, *learning_rate* = 0,15, dan *max_depth* = 6, sedangkan pada rasio 70:30 dan 60:40 diperoleh *n_estimators* = 200, *learning_rate* = 0,15, dan *max_depth* = 3. Hasil evaluasi menunjukkan bahwa penerapan *hyperparameter tuning* menghasilkan perubahan nilai akurasi yang berbeda pada setiap skenario pembagian data. Pada rasio 80:20, akurasi mengalami penurunan dari 0,90 menjadi 0,89, sedangkan pada rasio 70:30 akurasi mengalami peningkatan dari 0,88 menjadi 0,89. Adapun pada rasio 60:40, akurasi mengalami peningkatan dari 0,83 menjadi 0,84. Hasil tersebut menunjukkan bahwa GridSearchCV menghasilkan konfigurasi *hyperparameter* terbaik berdasarkan proses pencarian parameter yang dilakukan, meskipun perubahan performa model bervariasi pada setiap skenario pembagian data. Dengan demikian, optimasi *hyperparameter* dapat memengaruhi performa klasifikasi XGBoost, tetapi peningkatan akurasi tidak terjadi secara konsisten pada seluruh skenario pengujian.
Kata kunci: XGBoost, GridSearchCV, hyperparameter tuning, klasifikasi

Abstract: *Depression is one of the mental health disorders commonly experienced by university students due to academic pressure and various psychological factors. Early detection of depression severity is essential to facilitate timely and appropriate intervention. This study aims to optimize the performance of the Extreme Gradient Boosting (XGBoost) algorithm in classifying depression levels among university students through hyperparameter tuning using GridSearchCV. The dataset consists of 306 student records collected through an online questionnaire using the PHQ-9, GAD-7, and ERQ instruments. The research stages include data cleaning, data transformation, label determination, dataset splitting using ratios of 80:20, 70:30, and 60:40, hyperparameter tuning, and model evaluation using a confusion matrix and accuracy. The optimization results indicate that the best parameter configuration for the 80:20 split is n_estimators = 150, learning_rate = 0.15, and max_depth = 6, while the 70:30 and 60:40 splits yield n_estimators = 200, learning_rate = 0.15, and max_depth = 3. The evaluation results demonstrate that hyperparameter tuning leads to varying changes in accuracy across different*

Copyright@2024. LEMBAGA PENGEMBANGAN DAN INOVASI UNDHARI

Vol. 7, No. 2, Desember 2026, 703 - 712

dataset splitting scenarios. For the 80:20 split, accuracy decreases from 0.90 to 0.89, whereas for the 70:30 split, accuracy increases from 0.88 to 0.89. Meanwhile, for the 60:40 split, accuracy improves from 0.83 to 0.84. These findings indicate that GridSearchCV identifies the best hyperparameter configuration based on the parameter search process, although the resulting model performance varies across dataset splitting scenarios. Therefore, hyperparameter optimization can influence the classification performance of XGBoost; however, accuracy improvements are not consistently achieved across all evaluation scenarios.
***Keywords**: XGBoost, GridSearchCV, hyperparameter tuning, classification*

1. Pendahuluan

Depresi merupakan gangguan suasana hati yang ditandai oleh kesedihan berkepanjangan, perasaan bersalah, keputusasaan, serta perasaan tidak berharga. Kondisi ini dapat dialami oleh mahasiswa dan dipengaruhi oleh berbagai permasalahan, seperti tuntutan perkuliahan, kondisi keuangan, maupun persoalan keluarga. Depresi tidak hanya berdampak pada kondisi emosional, tetapi juga dapat memengaruhi aspek kognitif, motivasi, aktivitas sehari-hari, kondisi fisik, serta hubungan interpersonal [1]. Kondisi ini ditandai dengan perasaan sedih atau kehilangan semangat, serta tidak tertarik melakukan aktivitas yang biasanya disukai, serta suasana hati yang menurun dalam jangka waktu yang cukup lama. Depresi berbeda dengan kesedihan biasa yang terjadi dalam kehidupan sehari-hari. Depresi biasanya terjadi hampir setiap hari, selama setidaknya dua minggu [2]. Gejala depresi meliputi perubahan perilaku, suasana hati yang tidak stabil, kesulitan berpikir, penurunan berat badan, hingga tindakan yang membahayakan diri sendiri maupun orang lain, sehingga dapat menimbulkan masalah kesehatan yang lebih serius bagi penderitanya [3],[4].

Mahasiswa termasuk kelompok yang rentan mengalami depresi karena berada pada fase transisi dari masa remaja menuju dewasa serta dihadapkan pada berbagai tuntutan akademik, sosial, dan personal. Pada fase ini, mahasiswa dituntut untuk mampu menyesuaikan diri dengan lingkungan pendidikan tinggi, menyelesaikan berbagai tugas akademik, mempertahankan prestasi, serta mulai mempersiapkan diri untuk menghadapi kehidupan setelah menyelesaikan pendidikan. Berbagai tuntutan tersebut dapat menjadi sumber tekanan apabila tidak diimbangi dengan kemampuan individu dalam mengelola stres dan permasalahan yang dihadapi. Penelitian pada mahasiswa tingkat akhir menunjukkan bahwa stres akademik sering ditandai dengan kesulitan berkonsentrasi, kecemasan, kelelahan, serta tekanan ketika berinteraksi dengan dosen pembimbing [5]. Kondisi tersebut dapat semakin meningkat ketika mahasiswa menghadapi proses penyelesaian tugas akhir yang membutuhkan kemampuan dalam mengatur waktu, menyelesaikan penelitian, memenuhi tuntutan akademik, serta menghadapi berbagai revisi. Tekanan akademik yang berlangsung secara terus-menerus berpotensi memengaruhi kondisi psikologis mahasiswa dan meningkatkan risiko munculnya gangguan emosional, termasuk kecemasan dan depresi. Depresi juga diketahui memberikan dampak negatif terhadap prestasi akademik mahasiswa [6]. Berbagai penelitian menunjukkan bahwa mahasiswa yang mengalami depresi cenderung mengalami penurunan performa akademik, baik pada tingkat depresi ringan, sedang, maupun berat [7]. Kondisi tersebut dapat terjadi karena gejala depresi, seperti rendahnya motivasi, kesulitan berkonsentrasi, kelelahan, perasaan tidak berharga, dan kehilangan minat terhadap aktivitas, dapat menghambat kemampuan mahasiswa dalam mengikuti proses pembelajaran maupun menyelesaikan kewajiban akademiknya. Selain berdampak pada aspek akademik, depresi dan tekanan psikologis juga dapat memengaruhi hubungan sosial serta aktivitas sehari-hari mahasiswa. Pada mahasiswa tingkat akhir, kecemasan menjadi salah satu permasalahan yang umum ditemukan akibat tuntutan akademik dan proses penyelesaian tugas akhir. Penelitian menunjukkan bahwa sebagian besar mahasiswa mengalami gejala kecemasan pada tingkat ringan hingga sedang [8]. Kecemasan yang tidak dikelola dengan baik dapat menyebabkan mahasiswa mengalami kekhawatiran berlebihan, kesulitan berkonsentrasi, gangguan tidur, serta penurunan kemampuan dalam menyelesaikan tugas akademik. Oleh karena itu, kemampuan regulasi emosi diperlukan untuk membantu mahasiswa mengenali, mengendalikan, dan menyesuaikan respons emosional terhadap berbagai tekanan yang dihadapi. Kemampuan regulasi emosi yang baik dapat membantu mahasiswa mengelola tekanan akademik secara lebih adaptif sehingga dapat mengurangi dampak negatif kecemasan dan tekanan psikologis terhadap kondisi mental maupun aktivitas akademiknya.

Vol. 7, No. 2, Desember 2026, 703 - 712

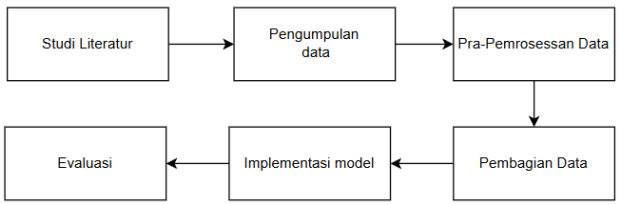
Regulasi emosi kognitif berperan penting dalam mengurangi tingkat kecemasan dan depresi. Kemampuan ini membantu individu mengelola emosi secara lebih positif ketika menghadapi situasi yang menimbulkan stres, sehingga dapat menjaga kesehatan mental dan mendukung penyelesaian masalah akademik maupun non-akademik. Regulasi emosi dipengaruhi oleh berbagai faktor, seperti usia, keluarga, dan lingkungan sosial, yang membentuk cara seseorang merespons suatu peristiwa [9]. Untuk mendukung deteksi dini tingkat depresi, pendekatan machine learning telah banyak digunakan karena mampu melakukan prediksi secara lebih cepat dan akurat [10]. Salah satu pendekatan yang menunjukkan hasil menjanjikan adalah teknik boosting, yaitu metode yang menggabungkan beberapa model sederhana untuk menghasilkan performa prediksi yang lebih baik, termasuk dalam klasifikasi tingkat depresi [11].

Penelitian terdahulu telah menunjukkan bahwa optimasi hyperparameter dapat menjadi salah satu pendekatan dalam meningkatkan maupun mengevaluasi kinerja algoritma XGBoost pada permasalahan klasifikasi. Penelitian [12] menerapkan GridSearch dan Random Search pada algoritma XGBoost untuk klasifikasi penyakit diabetes. Hasil penelitian tersebut menunjukkan bahwa model tanpa optimasi memperoleh nilai *negative log loss* sebesar 25%, sedangkan model yang menggunakan GridSearch dan Random Search memperoleh nilai sebesar 5%. Temuan tersebut menunjukkan bahwa pemilihan konfigurasi hyperparameter dapat berpengaruh terhadap kinerja model dalam proses klasifikasi. Penelitian serupa dilakukan oleh [13] dengan menerapkan GridSearchCV dan RandomSearchCV pada algoritma XGBoost untuk mendeteksi diabetes. Hasil penelitian menunjukkan bahwa model XGBoost yang dioptimasi menggunakan GridSearchCV dengan penerapan SMOTE memperoleh akurasi sebesar 85%, sedangkan model dengan RandomSearchCV memperoleh akurasi sebesar 83%. Kedua penelitian tersebut menunjukkan bahwa optimasi hyperparameter merupakan salah satu pendekatan yang dapat diterapkan untuk mengevaluasi dan memperoleh konfigurasi model XGBoost yang sesuai dengan karakteristik dataset yang digunakan. Sementara itu, Penelitian [14] menerapkan RandomizedSearchCV pada klasifikasi risiko depresi mahasiswa dan memperoleh akurasi sebesar 82,18% pada skenario pembagian data 80:20

Berdasarkan penelitian tersebut, optimasi hyperparameter XGBoost telah diterapkan pada berbagai permasalahan klasifikasi, termasuk diabetes dan depresi mahasiswa. Oleh karena itu, penelitian ini berfokus pada evaluasi optimasi hyperparameter menggunakan GridSearchCV terhadap kinerja XGBoost dalam klasifikasi tingkat depresi mahasiswa berdasarkan fitur PHQ-9, GAD-7, dan ERQ. Pengujian dilakukan melalui tiga skenario pembagian data, yaitu 80:20, 70:30, dan 60:40, dengan membandingkan kinerja model sebelum dan sesudah tuning. Penelitian ini diharapkan dapat memberikan gambaran mengenai pengaruh optimasi hyperparameter dan variasi rasio pembagian data terhadap kinerja klasifikasi tingkat depresi mahasiswa.

2. Metode Penelitian

Metodologi penelitian ditunjukkan pada Gambar 1 dimana terdapat beberapa tahapan yang dilakukan yaitu dimulai dari studi literatur, pengumpulan, pra pemrosesan data, pembagian data, pengembangan model dan evaluasi performa sistem. Setiap tahapan diimplementasikan menggunakan Bahasa pemrograman python.



Gambar 1. Alur Metode Penelitian

2.1 Studi Literatur

Studi literatur juga dilakukan untuk memahami keterkaitan antara tingkat depresi, kecemasan, dan regulasi emosi pada mahasiswa. Depresi dan kecemasan merupakan kondisi psikologis yang dapat saling berkaitan dan berpotensi memengaruhi kemampuan mahasiswa dalam menjalankan aktivitas akademik maupun sosial. Sementara itu, regulasi emosi berperan

dalam kemampuan individu untuk mengenali, mengendalikan, dan menyesuaikan respons emosional ketika menghadapi tekanan. Oleh karena itu, ketiga aspek tersebut dipertimbangkan sebagai karakteristik yang relevan dalam proses klasifikasi tingkat depresi mahasiswa. Kajian terhadap penelitian terdahulu digunakan untuk mengidentifikasi faktor-faktor psikologis yang berkaitan dengan depresi serta menentukan karakteristik data yang sesuai untuk digunakan sebagai fitur masukan dalam model *machine learning*. Selain itu, studi literatur mengenai algoritma XGBoost dan metode penanganan ketidakseimbangan kelas dilakukan sebagai dasar dalam menentukan pendekatan pemodelan yang sesuai dengan karakteristik dataset penelitian. Hasil kajian tersebut selanjutnya menjadi landasan dalam menentukan tahapan pengolahan data, pemilihan fitur, pembangunan model klasifikasi, serta metode evaluasi yang digunakan untuk memperoleh model yang mampu mengklasifikasikan tingkat depresi mahasiswa secara optimal..

2.2 Pengumpulan data

Tahap pengumpulan data dilakukan melalui penyebaran kuesioner daring menggunakan Google Form kepada 306 mahasiswa dari berbagai perguruan tinggi. Penelitian menggunakan pendekatan kuantitatif dengan desain cross-sectional untuk memperoleh data yang diperlukan dalam proses klasifikasi tingkat depresi mahasiswa. Instrumen yang digunakan meliputi PHQ-9 untuk mengukur tingkat depresi, GAD-7 untuk mengukur kecemasan, dan ERQ untuk menilai regulasi emosi. Dataset yang diperoleh terdiri dari 306 responden dengan 34 atribut yang mencakup data demografis dan indikator psikologis. Data tersebut selanjutnya digunakan sebagai input dalam pemodelan klasifikasi menggunakan algoritma XGBoost dan CatBoost.

2.3 Pra-pemrosesan

Sebelum model dikembangkan, dilakukan beberapa tahap pemrosesandata sebagai berikut:

1. *Data Cleaning*

Tahap *data cleaning* dilakukan untuk meningkatkan kualitas dataset dengan menangani data yang tidak lengkap, tidak valid, atau duplikat. Proses ini mencakup pemeriksaan nilai kosong pada atribut penelitian serta penghapusan atau penyesuaian data yang bermasalah sesuai kebutuhan. Selain itu, dilakukan identifikasi data duplikat untuk memastikan setiap responden hanya tercatat satu kali. Tahap ini bertujuan mengurangi bias dan meningkatkan keakuratan hasil pemodelan klasifikasi.

2. Tranformasi data

Tahap transformasi data dilakukan dengan mengubah seluruh atribut ke dalam format numerik agar dapat diproses oleh algoritma machine learning. Atribut kategorikal, seperti jenis kelamin dan tempat tinggal, dikonversi menjadi nilai numerik untuk mendukung proses pemodelan dan analisis data.

3. Penentual label

Tahap penentuan label dilakukan untuk menetapkan kelas tingkat depresi sebagai target dalam proses klasifikasi. Label ditentukan berdasarkan skor total PHQ-9 yang diperoleh dari penjumlahan sembilan butir pertanyaan kuesioner. Skor tersebut kemudian digunakan untuk mengelompokkan responden ke dalam kategori tingkat depresi sesuai dengan kriteria yang telah ditetapkan.

2.4 Pembagian data

Tahap pembagian data dilakukan dengan membagi dataset menjadi data latih (training set) dan data uji (testing set). Data latih digunakan untuk membangun model klasifikasi menggunakan algoritma XGBoost, sedangkan data uji digunakan untuk mengevaluasi kinerja model. Dalam penelitian ini digunakan rasio pembagian data 80:20, 70:30, dan 60:40 untuk membandingkan kemampuan model dalam mempelajari pola data dan melakukan generalisasi terhadap data baru.

Vol. 7, No. 2, Desember 2026, 703 - 712

2.5 XGBoost

XGBoost merupakan algoritma machine learning berbasis ensemble learning dengan pendekatan gradient boosting yang membangun sejumlah pohon keputusan secara bertahap untuk meningkatkan akurasi prediksi. Algoritma ini memiliki mekanisme regularisasi yang membantu mengurangi overfitting serta optimasi berbasis gradien yang membuat proses pelatihan lebih efisien dan stabil. Berbagai penelitian menunjukkan bahwa XGBoost mampu menghasilkan performa klasifikasi yang tinggi, ditunjukkan oleh nilai akurasi, presisi, recall, dan F1-score yang baik, sehingga efektif digunakan untuk menangani data yang kompleks dan berdimensi tinggi [15]. Selanjutnya, berikut disajikan tahapan penyusunan algoritma *Extreme Gradient Boosting*:

1. Prediksi awal

Pada tahap awal, XGBoost menghasilkan nilai prediksi awal untuk setiap data. Pada kasus klasifikasi multikelas, nilai tersebut kemudian dikonversi menjadi probabilitas menggunakan fungsi softmax sehingga diperoleh peluang masing-masing kelas yang jumlah totalnya bernilai satu. Probabilitas setiap kelas pada klasifikasi multikelas dihitung menggunakan fungsi *softmax* yang dinyatakan pada Persamaan (3).

$$p_k = \frac{e^{F_{k(x)}}}{\sum_{j=1}^{K} e^{f_{j(x)}}} \tag{3}$$

2. Perhitungan Loss, Gradien, dan Hessian

Setelah memperoleh prediksi awal, XGBoost menghitung nilai kesalahan menggunakan fungsi loss. Selanjutnya, gradien dan hessian dihitung untuk menentukan arah serta besarnya perbaikan model pada iterasi berikutnya sehingga prediksi dapat menjadi lebih akurat. Untuk menentukan arah perbaikan model pada iterasi berikutnya, nilai gradien dihitung menggunakan Persamaan (4) dan (5).

$$g_i = \frac{\partial L(y_i, \hat{y}_l)}{\partial \hat{y}_l} \tag{4}$$

$$h_i = \frac{\partial^2 L(y_i, \hat{y}_l)}{\partial \hat{y}^2{}_l} \tag{5}$$

3. Pembentukan pohon

Berdasarkan nilai gradien dan hessian, XGBoost membangun pohon keputusan baru untuk memperbaiki kesalahan prediksi sebelumnya. Proses ini dilakukan dengan membagi data ke dalam beberapa node dan setiap daun (*leaf node*) memiliki bobot yang dihitung menggunakan persamaan (5).

$$w_j = -\frac{\sum i \in j g_i}{\sum i \in j h_i + \lambda} \tag{5}$$

4. Menghitung Nilai Gain untuk Split

Pada proses pembentukan pohon, setiap kemungkinan pemisahan node dievaluasi menggunakan nilai gain. Pemisahan dengan nilai gain terbesar dan positif dipilih karena mampu memberikan peningkatan kinerja model yang paling optimal. Secara matematis, nilai *gain* dinyatakan dengan persamaan (6).

$$Gain = \frac{1}{2}\left(\frac{G^2 L}{H_L + \lambda} + \frac{G^2 R}{H_R + \lambda} - \frac{G^2}{H + \lambda}\right) - \gamma \tag{6}$$

5. Pembaruan Model

Setelah pohon keputusan baru terbentuk, XGBoost memperbarui nilai prediksi dengan menambahkan kontribusi dari pohon tersebut ke hasil prediksi sebelumnya. Proses ini dilakukan secara bertahap untuk meningkatkan akurasi model. Proses pembaruan ini dinyatakan dengan persamaan (7)

$$\hat{y}^{(t)} = \hat{y}^{(t-1)} + n f_t(x) \tag{7}$$

6. Iterasi dan Prediksi akhir

Setelah seluruh pohon keputusan selesai dibangun, prediksi akhir diperoleh dari gabungan kontribusi semua pohon. Prediksi akhir dinyatakan dengan persamaan (8)

$$\hat{y} = \sum_{k=1}^{k} f_k(x) \quad (8)$$

2.6 Hyperparameter dalam XGBoost

Hyperparameter yang digunakan dalam proses optimasi meliputi *n_estimators*, *learning rate*, dan *max_depth*. Parameter *n_estimators* menunjukkan jumlah pohon keputusan (*decision tree*) yang dibangun dalam model, sehingga jumlah pohon yang lebih banyak memungkinkan model mempelajari pola data secara lebih kompleks, tetapi juga dapat meningkatkan risiko *overfitting* apabila tidak dikendalikan. Parameter *learning rate* menentukan besarnya kontribusi setiap pohon terhadap pembentukan model secara keseluruhan. Nilai *learning rate* yang lebih kecil memungkinkan proses pembelajaran berlangsung secara lebih bertahap, sedangkan nilai yang lebih besar dapat mempercepat proses pembelajaran namun berpotensi menghasilkan model yang kurang optimal. Sementara itu, *max_depth* menentukan kedalaman maksimum setiap pohon keputusan dan berpengaruh terhadap tingkat kompleksitas pola yang dapat dipelajari oleh model. Kedalaman pohon yang terlalu besar dapat menyebabkan model terlalu menyesuaikan diri dengan data latih (*overfitting*), sedangkan kedalaman yang terlalu rendah dapat menyebabkan model kurang mampu menangkap pola data (*underfitting*). Oleh karena itu, kombinasi nilai dari ketiga hyperparameter tersebut diuji menggunakan *GridSearchCV* untuk memperoleh konfigurasi yang memberikan performa terbaik berdasarkan proses *cross-validation*. Hasil konfigurasi terbaik selanjutnya digunakan dalam pembangunan model XGBoost pada masing-masing skenario pembagian data sehingga diperoleh model dengan parameter yang telah dioptimalkan sebelum dilakukan evaluasi menggunakan data uji.

Tabel 2. Hyperparameter yang digunakan pada XGBoost

Parameter	Rentang Nilai
N_estimators	50, 100, 150, 200
Learning_rate	0.01, 0.05, 0.1, 0.15, 0.3
Max_depth	3, 4, 5, 6

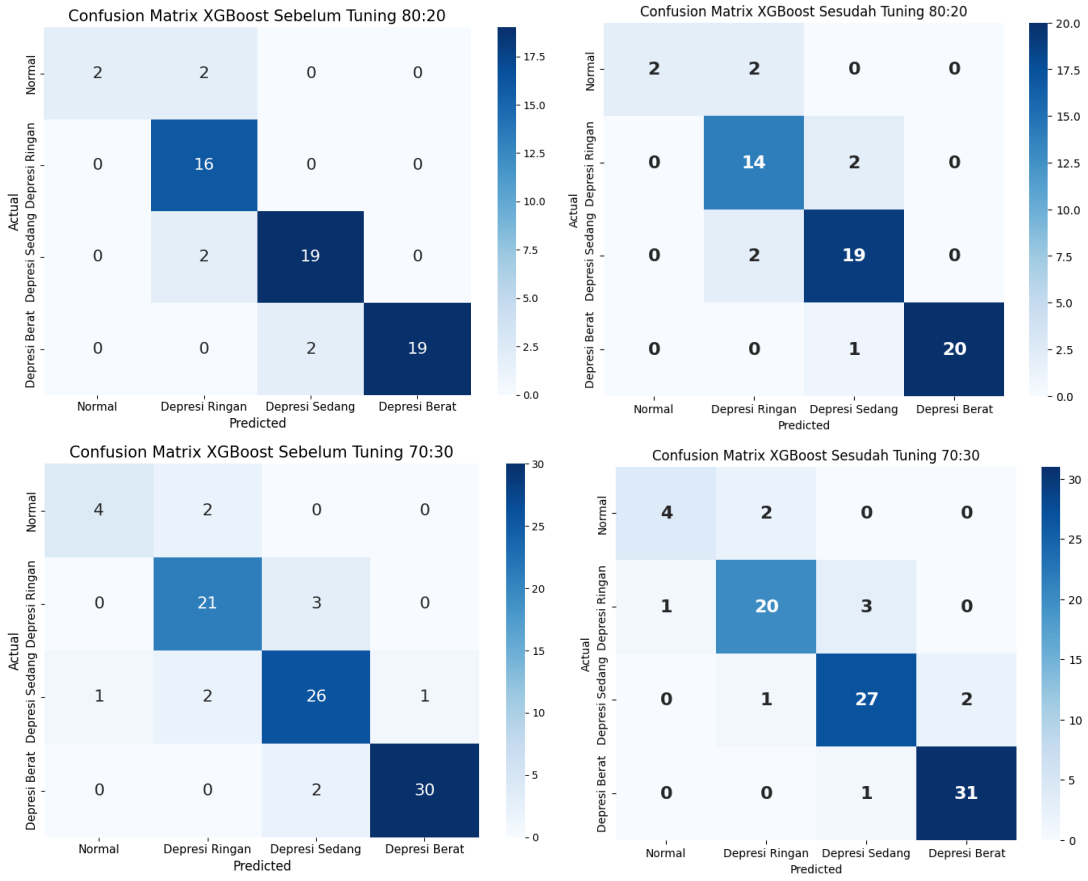
2.7 Evaluasi Model

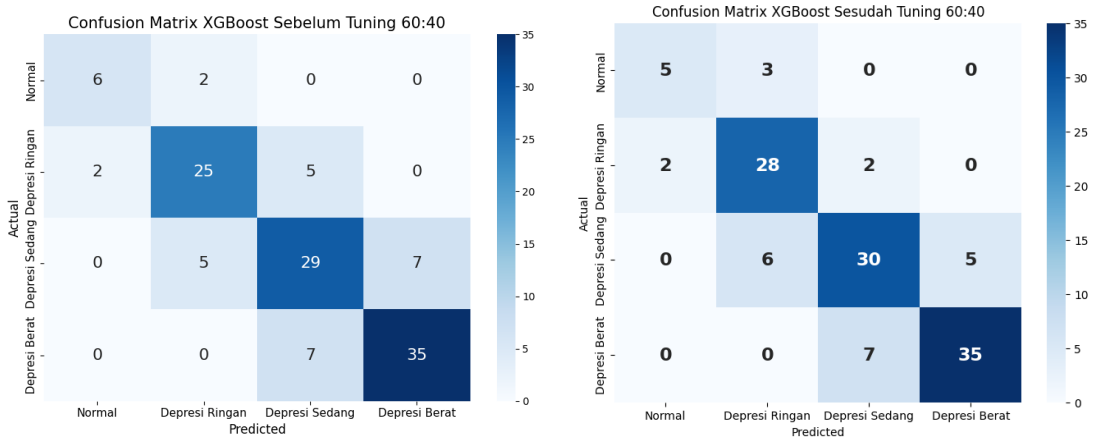
Evaluasi model dilakukan untuk mengetahui kemampuan XGBoost dalam mengklasifikasikan tingkat depresi mahasiswa secara tepat serta mengetahui kemampuan model dalam mengenali setiap kategori depresi. *Precision* digunakan untuk mengukur ketepatan prediksi model terhadap suatu kelas, yaitu proporsi data yang diprediksi sebagai suatu kelas dan benar-benar termasuk dalam kelas tersebut. *Recall* digunakan untuk mengukur kemampuan model dalam menemukan seluruh data yang sebenarnya termasuk dalam suatu kelas. Sementara itu, *F1-score* merupakan nilai gabungan antara *precision* dan *recall* yang memberikan gambaran keseimbangan antara ketepatan prediksi dan kemampuan model dalam mendeteksi anggota suatu kelas. Pada penelitian dengan klasifikasi multikelas, nilai evaluasi dihitung menggunakan *macro average*, yaitu menghitung metrik secara terpisah pada setiap kelas kemudian mengambil nilai rata-ratanya. Pendekatan tersebut digunakan agar setiap kategori tingkat depresi memperoleh bobot yang sama dalam evaluasi, sehingga performa model pada kelas dengan jumlah data yang lebih sedikit tetap diperhatikan. Selain metrik tersebut, *confusion matrix* digunakan untuk melihat distribusi hasil prediksi model pada masing-masing kelas, sehingga dapat diketahui kelas yang berhasil diklasifikasikan dengan tepat maupun kelas yang masih sering mengalami kesalahan klasifikasi. Hasil evaluasi selanjutnya digunakan sebagai dasar dalam menentukan skenario dan konfigurasi model XGBoost yang memberikan performa klasifikasi terbaik.

Vol. 7, No. 2, Desember 2026, 703 - 712

3. Hasil dan Pembahasan

Hasil penelitian mengacu pada tahapan pengujian yang telah diuraikan dalam metodologi penelitian. Pengujian diawali dengan proses *hyperparameter tuning* untuk memperoleh konfigurasi parameter XGBoost terbaik pada setiap skenario pembagian dataset. Model dengan konfigurasi parameter terpilih selanjutnya dilatih menggunakan data latih dan dievaluasi menggunakan data uji pada rasio pembagian 80:20, 70:30, dan 60:40. Evaluasi kinerja dilakukan dengan menggunakan metrik *precision*, *recall*, dan *F1-score* melalui pendekatan *macro average*. Hasil pengujian pada ketiga skenario pembagian data kemudian dibandingkan untuk mengetahui pengaruh proporsi data latih dan data uji terhadap kinerja model dalam mengklasifikasikan tingkat depresi mahasiswa. Selain berdasarkan nilai metrik evaluasi, analisis juga dilakukan terhadap *confusion matrix* untuk mengidentifikasi pola klasifikasi yang benar maupun kesalahan prediksi pada masing-masing kategori depresi, khususnya dalam mengenali kelas depresi berat. Confusion matrix hasil pengujian XGBoost sebelum dan sesudah *hyperparameter tuning* pada ketiga skenario pembagian data disajikan pada Gambar 2.





Gambar 2. Confusion Matrix sebelum dan sesudah tuning pada model XGBoost

3.1 Hasil Hyperparameter tuning

Pengujian Optimasi *GridsearchCV* dilakukan terhadap 9 kombinasi hyperparameter pada model XGBoost dengan tiga skema rasio dataset. Hasil pengujian disajikan pada Tabel 3

Tabel 3. Hasil parameter terbaik berdasarkan rasio data

Parameter	Rasio	Rentang Nilai
N_estimators	80 :20	200
Learning_rate	80 :20	0.15
Max_depth	80 :20	3
N_estimators	70 :30	100
Learning_rate	70 :30	0.3
Max_depth	70 :30	3
N_estimators	60:40	100
Learning_rate	60:40	0.1
Max_depth	60:40	4

Proses *hyperparameter tuning* pada algoritma XGBoost dilakukan menggunakan metode GridSearchCV untuk memperoleh kombinasi parameter yang menghasilkan performa terbaik pada setiap skenario pembagian data. Berdasarkan hasil pengujian pada Tabel 3, diperoleh bahwa rasio data 80:20 menghasilkan parameter terbaik dengan n_estimators = 200, learning_rate = 0,15, dan max_depth = 3. Sementara itu, pada rasio 70:30 diperoleh kombinasi n_estimators = 100, learning_rate = 0,3, dan max_depth = 3. Hasil yang sama juga diperoleh pada rasio 60:40, yaitu n_estimators = 100, learning_rate = 0,1, dan max_depth = 4. Perbedaan konfigurasi tersebut menunjukkan bahwa jumlah data latih memengaruhi kompleksitas model yang optimal. Selanjutnya, kombinasi hyperparameter terbaik pada masing-masing rasio digunakan pada tahap pemodelan dan evaluasi performa algoritma XGBoost.

3.2 Evaluasi Model

Evaluasi kinerja model XGBoost dilakukan untuk membandingkan performa model sebelum dan sesudah proses *hyperparameter tuning* menggunakan GridSearchCV. Pengukuran performa dilakukan pada tiga skenario pembagian data, yaitu rasio 80:20, 70:30, dan 60:40. Nilai akurasi hasil evaluasi sebelum dan sesudah proses tuning disajikan pada Tabel 4.

Tabel 4. Evaluasi sebelum dan sesudah tuning pada model XGBoost

Model	Rasio	Sebelum Tuning	Sesudah Tuning
XGBoost	80 :20	0.90	0.89
XGBoost	70 :30	0.88	0.89
XGBoost	60 :40	0.77	0.80

Vol. 7, No. 2, Desember 2026, 703 - 712

Berdasarkan Tabel 4, evaluasi kinerja model XGBoost dilakukan dengan membandingkan nilai akurasi sebelum dan sesudah penerapan *hyperparameter tuning* menggunakan GridSearchCV pada tiga skenario pembagian data. Pada rasio pembagian data 80:20, nilai akurasi meningkat dari 0,90 sebelum tuning menjadi 0,89 setelah tuning. Pada rasio 70:30, nilai akurasi berubah dari 0,88 menjadi 0,89 setelah dilakukan tuning. Sementara itu, pada rasio 60:40, nilai akurasi meningkat dari 0,77 menjadi 0,80. Hasil tersebut menunjukkan bahwa penerapan *hyperparameter tuning* memberikan peningkatan kinerja pada skenario pembagian data 70:30 dan 60:40, sedangkan pada skenario 80:20 terjadi sedikit penurunan akurasi. Dengan demikian, *hyperparameter tuning* tidak selalu menghasilkan peningkatan akurasi pada seluruh skenario pembagian data, tetapi dapat menghasilkan konfigurasi parameter yang memberikan kinerja lebih baik pada skenario tertentu.

3. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, algoritma XGBoost mampu digunakan untuk melakukan klasifikasi tingkat depresi mahasiswa dengan memanfaatkan fitur yang diperoleh dari instrumen PHQ-9, GAD-7, dan ERQ. Pengujian dilakukan menggunakan tiga skenario pembagian dataset, yaitu rasio 80:20, 70:30, dan 60:40 untuk mengetahui pengaruh proporsi data latih dan data uji terhadap kinerja model. Hasil *confusion matrix* menunjukkan bahwa sebagian besar data pada setiap kategori tingkat depresi dapat diklasifikasikan dengan benar, meskipun masih ditemukan kesalahan klasifikasi, terutama pada kategori tingkat depresi yang memiliki karakteristik berdekatan. Proses *hyperparameter tuning* menggunakan GridSearchCV menghasilkan konfigurasi parameter terbaik yang berbeda pada setiap skenario. Pada rasio 80:20 diperoleh *n_estimators* = 150, *learning_rate* = 0,15, dan *max_depth* = 6, sedangkan pada rasio 70:30 dan 60:40 diperoleh *n_estimators* = 200, *learning_rate* = 0,15, dan *max_depth* = 3. Hasil pengujian menunjukkan bahwa penerapan *hyperparameter tuning* tidak selalu meningkatkan akurasi pada seluruh skenario pembagian data. Pada rasio 70:30, akurasi meningkat dari 0,88 menjadi 0,89, sedangkan pada rasio 60:40 meningkat dari 0,77 menjadi 0,80. Sementara itu, pada rasio 80:20 terjadi penurunan akurasi dari 0,90 menjadi 0,89 setelah dilakukan *tuning*. Perbedaan tersebut menunjukkan bahwa performa XGBoost tidak hanya dipengaruhi oleh jumlah data latih, tetapi juga oleh karakteristik data dan konfigurasi hyperparameter yang digunakan. Dengan demikian, penggunaan *hyperparameter tuning* berperan dalam memperoleh konfigurasi model yang lebih sesuai dengan karakteristik data, tetapi tidak dapat dipastikan selalu menghasilkan peningkatan akurasi pada setiap skenario. Secara keseluruhan, penelitian ini menunjukkan bahwa kombinasi fitur PHQ-9, GAD-7, dan ERQ dapat dimanfaatkan sebagai masukan dalam pengembangan model *machine learning* untuk klasifikasi tingkat depresi mahasiswa menggunakan XGBoost.

Referensi

[1] J. Psikologi, N. Hidayatul Ma, A. nur Rumaisha, and F. Nashori, “Pengaruh Terapi Zikir Istigfar Terhadap Depresi Pada Mahasiswa”.

[2] D. Astri Andriani, N. Ariska Meritama, F. Kumala Sari, F. Meirina Andriani, and W. Fadillah, “Pendidikan Kesehatan Jiwa Tentang Depresi Pada Masyarakat Wilayah Puskesmas Karang Asam Samarinda.”

[3] I. Amira, H. Hendrawati, I. Maulana, and S. Senjaya, “Penyuluhan tentang Kesehatan Jiwa Remaja di Pondok Pesantren Miftahul Hidayah Kelurahan Lebakjaya Kecamatan Karangpawitan,” *Jurnal Kreativitas Pengabdian Kepada Masyarakat (PKM)*, vol. 6, no. 4, pp. 1693–1704, Apr. 2023, doi: 10.33024/jkpm.v6i4.9479.

[4] S. Khoiroh Muflihatin *et al.*, “Peduli Kesehatan Mental: Mengenal Dan Mengatasi Depresi Bersama,” Jun. 2025.

[5] W. Kurniawati and R. Setyaningsih, “Manajemen Stress Pada Mahasiswa Tingkat Akhir Dalam Penyusunan Skripsi.”

[6] dan Salvia, “Analisis Kesehatan Mental Mahasiswa Perguruan Tinggi Pada Awal Terjangkitnya Covid-19 di Indonesia,” *Jurnal Citizenship Virtues*, vol. 2021, no. 2, pp. 83–97.

[7] K. Fatonah, “Prediksi Kasus Tingkat Depresi Mahasiswa Semester Akhir Menggunakan Regresi Linear Sederhana,” vol. 7, 2024.
[8] E. Aprilia, F. Kusumawardhani Hidayah, and R. Anisa, “Perbedaan Ansietas Dan Pendekatan Belajar Selama Pembelajaran Daring Terhadap Mahasiswa Klinik Fakultas Kedokteran Universitas Islam Malang.”
[9] T. Diana, U. Hasanah, D. Erlina, and L. Widuri, “Regulasi Emosi Pada Ibu Single Parent.” [Online]. Available: www.pekka.or.id/data-perempuan-
[10] J. O. Kim, Y. S. Jeong, J. H. Kim, J. W. Lee, D. Park, and H. S. Kim, “Machine learning-based cardiovascular disease prediction model: A cohort study on the korean national health insurance service health screening database,” *Diagnostics*, vol. 11, no. 6, Jun. 2021, doi: 10.3390/diagnostics11060943.
[11] Panwasto Samosir P dan Umniy Salamah, “Perbandingan Performa Algoritma XGBoost, CatBoost Dan GBM Dalam Prediksi Penyakit Kardiovaskular,” Jan. 2025.
[12] G. Abdurrahman, H. Oktavianto, and M. Sintawati, “Optimasi Algoritma XGBoost Classifier Menggunakan Hyperparameter Gridesearch dan Random Search Pada Klasifikasi Penyakit Diabetes,” 2022.
[13] D. A. Dinanthi, E. Ramadanti, C. Sri, K. Aditya, and D. R. Chandranegara, “Diabetes Detection Using Extreme Gradient Boosting (XGBoost) with Hyperparameter Tuning,” *Indonesian Journal of Electronics, Electromedical Engineering, and Medical Informatics*, vol. 6, no. 2, pp. 78–84, 2024, doi: 10.35882/ijeeemi.v6i2.351.
[14] F. Pratama, E. Ali, Rahmaddeni, and W. Agustin, “Perbandingan Kinerja Xgboost Dan Lightgbm Dalam Klasifikasi Depresi Pada Mahasiswa Berdasarkan Faktor Demografi Dan Akademik,” *Jurnal Algoritma*, vol. 22, no. 2, pp. 53–64, Nov. 2025, doi: 10.33364/algoritma/v.22-2.2439.
[15] B. S. Bhati, G. Chugh, F. Al-Turjman, and N. S. Bhati, “An improved ensemble based intrusion detection technique using XGBoost,” *Transactions on Emerging Telecommunications Technologies*, vol. 32, no. 6, Jun. 2021, doi: 10.1002/ett.4076.