

Optimasi Hyperparameter Random Forest untuk Klasifikasi Depresi Mahasiswa Menggunakan GridSearchCV dan RandomizedSearchCV

Eka Wahyu Utami*, Defri Kurniawan

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: ^{1,*}111202214028@mhs.dinus.ac.id, ²defrikurniawan@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202214028@mhs.dinus.ac.id

Submitted: 08/02/2026; Accepted: 05/03/2026; Published: 06/03/2026

Abstrak—Kesehatan mental mahasiswa menjadi isu penting yang memerlukan pendekatan berbasis data untuk mendukung proses klasifikasi depresi mahasiswa. Penelitian ini bertujuan untuk menganalisis faktor-faktor penyebab depresi serta mengoptimalkan kinerja model klasifikasi dengan menerapkan algoritma *Random Forest*. Data yang digunakan dalam penelitian ini adalah data sekunder *Student Depression Dataset* yang diperoleh dari platform Kaggle, dengan total 27.901 data. Tahapan penelitian diawali dengan pengumpulan data dan dilanjutkan dengan *Exploratory Data Analysis* (EDA) yang mencakup analisis statistik deskriptif dan korelasi antar variabel menggunakan heatmap. Prapemrosesan data meliputi penghapusan fitur yang tidak relevan, penanganan nilai hilang, pengkodean data kategorikal, serta pembagian data menjadi data latih dan data uji. Pengembangan model dilakukan melalui tiga skenario, yaitu model *baseline*, optimasi *hyperparameter* menggunakan *GridSearchCV*, dan *RandomizedSearchCV*. Evaluasi performa model diukur menggunakan *Confusion Matrix* untuk menganalisis nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa seluruh model menghasilkan *accuracy* yang relatif stabil pada kisaran 0,84–0,85. Model dengan optimasi *GridSearchCV* memberikan performa terbaik dengan nilai *recall* sebesar 0,8869 dan *F1-score* sebesar 0,8719. Peningkatan *recall* ini penting untuk meminimalkan risiko *false negative* dalam mengidentifikasi mahasiswa yang mengalami depresi. Hasil penelitian ini diharapkan dapat berkontribusi sebagai sistem pendukung keputusan bagi institusi pendidikan dalam upaya deteksi dan manajemen kesehatan mental mahasiswa secara lebih akurat.

Kata Kunci: Kesehatan Mental; Depresi Mahasiswa; Random Forest; Optimasi Hyperparameter; Klasifikasi

Abstract—Student mental health is an important issue that requires a data-driven approach to support the classification process of student depression. This study aims to analyze the factors that cause depression and optimize the performance of the classification model by applying the Random Forest algorithm. The data used in this research is secondary data from the Student Depression Dataset obtained from the Kaggle platform, with a total of 27,901 data points. The research stages begin with data collection followed by Exploratory Data Analysis (EDA), which includes descriptive statistical analysis and correlation between variables using a heatmap. Data preprocessing involves removing irrelevant features, handling missing values, encoding categorical data, and splitting the data into training and testing sets. Model development is carried out through three scenarios: a baseline model, hyperparameter optimization using GridSearchCV, and RandomizedSearchCV. Model performance evaluation is measured using a Confusion Matrix to analyze accuracy, precision, recall, and F1-score. The results show that all models produce relatively stable accuracy in the range of 0.84–0.85. The model with GridSearchCV optimization provides the best performance with a recall value of 0.8869 and an F1-score of 0.8719. This increase in recall is important to minimize the risk of false negatives in identifying students experiencing depression. It is hoped that these findings can contribute as a decision support system for educational institutions in more accurately detecting and managing students' mental health.

Keywords: Mental Health; Student Depression; Random Forest; Hyperparameter Optimization; Classification

1. PENDAHULUAN

Kesehatan mental merupakan isu krusial yang berdampak langsung pada kesejahteraan individu maupun masyarakat. Menurut penelitian [1] mahasiswa merupakan kelompok yang sangat rentan terhadap gangguan emosional, terutama akibat isolasi sosial pasca-pandemi. Kesejahteraan mental mereka sangat bergantung pada dukungan sosial dan hubungan interpersonal, di mana tekanan yang tidak terdeteksi dapat memperburuk kualitas hidup serta performa akademik. Kondisi ini kian kompleks karena dipicu oleh berbagai faktor, mulai dari tekanan sosial hingga kurangnya dukungan kemandirian dari keluarga. Sejalan dengan hal tersebut, [2] menjelaskan bahwa variabel motivasi akademik dan efikasi diri berhubungan erat dengan pencapaian prestasi mahasiswa. Tekanan untuk meraih nilai akademik yang tinggi seringkali menjadi beban mental yang jika tidak didukung oleh lingkungan sosial yang baik, dapat memicu gangguan kesehatan mental yang lebih serius seperti depresi. Untuk memahami permasalahan tersebut secara lebih mendalam, analisis data dengan pendekatan machine learning dapat digunakan untuk mengidentifikasi faktor-faktor yang memengaruhi tingkat depresi pada mahasiswa.

Machine Learning merupakan sub-bidang dari *Artificial Intelligence* yang memungkinkan sistem komputer untuk menganalisis data, menemukan pola tersembunyi, dan meningkatkan kinerjanya dalam menghasilkan prediksi atau keputusan secara otomatis, tanpa memerlukan pemrograman eksplisit [3]. Secara umum, *machine learning* bekerja dengan menggunakan data historis guna membentuk model yang dapat mengidentifikasi pola dan melakukan prediksi terhadap data baru. Proses pengembangan model *machine learning* melibatkan serangkaian tahapan krusial dan iteratif, meliputi pengumpulan data, pembersihan dan prapemrosesan, pelatihan model menggunakan algoritma tertentu, serta evaluasi performa untuk memperoleh hasil yang optimal [4]. Dalam konteks deteksi depresi pada mahasiswa, algoritma *machine learning* berperan dalam memprediksi atau mengklasifikasikan tingkat risiko depresi berdasarkan data yang tersedia.

Salah satu algoritma yang menunjukkan kinerja unggul dalam tugas deteksi depresi pada berbagai jenis dataset dan konteks aplikasi adalah *Random Forest*. Penelitian yang dilakukan pada dataset teks media sosial dalam identifikasi pengguna Twitter yang mengalami depresi dan kecemasan, dimana model *Random Forest* mencapai akurasi tertinggi sebesar 0,957 lebih unggul daripada algoritma lain seperti *Decision Tree*, *Naive Bayes*, dan KNN [5]. Sementara pada dataset klinis anak-remaja dari Young Minds Matter, *Random Forest* memperoleh akurasi 95 % dan presisi 99 %, mengungguli metode lain seperti *XGBoost* dan *Naive Bayes* [6]. *Random Forest* juga secara konsisten melampaui algoritma *Logistic Regression* dan *Naive Bayes* di seluruh metrik evaluasi, termasuk *recall* dan *F1-score* yang masing-masing mencapai 89% [7]. Ketiga penelitian tersebut membuktikan bahwa *Random Forest* berhasil mendeteksi depresi dibanding beberapa algoritma lainnya.

Penelitian yang memanfaatkan dataset yang sama, *Student Depression Dataset* umumnya masih menggunakan subset data yang lebih kecil dengan penekanan pada teknik penanganan data tidak seimbang, sementara evaluasi komprehensif terhadap strategi optimasi hyperparameter belum menjadi fokus utama [8]. Selain itu, pendekatan yang membandingkan beberapa algoritma klasifikasi masih dilakukan pada tahap baseline tanpa pendalaman khusus pada satu algoritma maupun analisis keseimbangan metrik evaluasi yang digunakan [9]. Oleh karena itu, penelitian ini mengisi celah tersebut dengan melakukan analisis mendalam terhadap algoritma *Random Forest* melalui beberapa skenario optimasi *hyperparameter*, disertai proses data cleaning yang disesuaikan dengan konteks mahasiswa serta penggunaan metrik *F1-score* dan *recall* sebagai fokus evaluasi untuk meminimalkan kesalahan *false negative* dalam deteksi depresi.

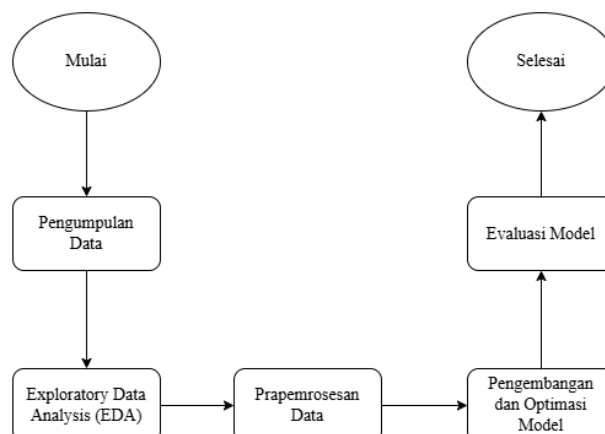
Salah satu penelitian menggunakan dataset berbasis teks dari forum daring mengenai klasifikasi depresi dan menggunakan algoritma *Random Forest*, menghasilkan tingkat akurasi yang tinggi, tetapi belum menerapkan teknik optimasi *hyperparameter* [10]. Penelitian lain membuktikan peningkatan performa *Random Forest* melalui penerapan *RandomizedSearchCV*, namun penelitian ini menggunakan dataset survei umum dengan konteks populasi yang berbeda serta data yang relatif lama [11]. Sementara itu, efektivitas *GridSearchCV* dalam mengoptimalkan algoritma *Random Forest* telah dibuktikan pada domain kesehatan lain dengan karakteristik data yang berbeda dari kasus deteksi depresi mahasiswa [12]. Perbedaan jenis data, konteks populasi, dan pendekatan evaluasi pada penelitian-penelitian tersebut menunjukkan bahwa efektivitas optimasi *hyperparameter* *Random Forest* masih belum banyak dianalisis secara komparatif pada kasus deteksi depresi mahasiswa menggunakan data survei terbaru. Oleh karena itu, penelitian ini bertujuan untuk mengisi celah tersebut dengan mengevaluasi dan membandingkan model *baseline*, model dengan optimasi *GridSearchCV*, dan *RandomizedSearchCV* pada algoritma *Random Forest* menggunakan dataset terbaru yang merepresentasikan populasi mahasiswa, sehingga diperoleh gambaran performa model yang lebih relevan.

Meskipun penelitian sebelumnya sudah banyak menggunakan algoritma *Random Forest* untuk klasifikasi depresi, sebagian besar masih belum membandingkan secara langsung metode optimasi *hyperparameter*. Selain itu, penelitian yang membahas secara mendalam keseimbangan metrik *recall* untuk menekan terjadinya *false negative* pada kasus berisiko tinggi juga masih terbatas. Oleh karena itu, penelitian ini bertujuan menunjukkan seberapa efektif *Random Forest* yang dioptimasi menggunakan *GridSearchCV* dan *RandomizedSearchCV* dalam mengklasifikasikan kondisi depresi mahasiswa dengan lebih akurat. Secara praktis, hasil penelitian ini diharapkan dapat menjadi dasar bagi institusi pendidikan dalam mengembangkan sistem identifikasi risiko kesehatan mental yang lebih responsif, sehingga kasus-kasus kritis dapat diprioritaskan untuk mendapatkan penanganan profesional secara cepat dan tepat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Alur metodologi penelitian terdiri atas pengolahan data hingga evaluasi model, dengan detail tahapan yang disajikan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian

Secara garis besar, tahapan penelitian yang disajikan pada Gambar 1 dibagi menjadi lima fase utama. Proses dimulai dengan pengumpulan data dari sumber publik Kaggle yang mencakup variabel demografi dan akademik mahasiswa. Langkah kedua dilakukan EDA untuk memahami struktur dan isi data. Tahap berikutnya adalah prapemrosesan data, yang mencakup pembersihan, pengodean (*encoding*), dan pemisahan variabel fitur serta target sebelum masuk ke tahap pemodelan.

Setelah data siap, alur dilanjutkan pada tahap pemodelan dan optimasi. Pada fase ini, dibangun model baseline sebagai parameter acuan, yang kemudian diikuti dengan proses *hyperparameter* tuning menggunakan metode *GridSearchCV* dan *RandomizedSearchCV* untuk mencari kombinasi parameter terbaik. Seluruh proses diakhiri dengan tahap evaluasi untuk mengukur kinerja model secara akurat dan stabil berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

2.2 Pengumpulan Dataset

Dalam penelitian ini, data diperoleh dari platform Kaggle, yaitu *Student Depression Dataset* yang berjumlah 27.901 data dengan 17 variabel label dan 1 variabel target. Dataset ini mencakup berbagai faktor yang berkaitan dengan kondisi mahasiswa, seperti informasi demografis, capaian akademik, kebiasaan gaya hidup, serta aspek psikologis. Fokus utama penelitian ini adalah variabel Depression, yang digunakan sebagai variabel target. Rincian mengenai variabel yang digunakan dalam penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Informasi Dataset

No	Nama Kolom	Tipe Data	Deskripsi Singkat
1	id	Numerik	Nomor unik setiap responden.
2	Gender	Kategorikal	Jenis kelamin dari responden (Laki-laki/ Perempuan)
3	Age	Numerik	Usia responden (rentang 18-59 tahun).
4	City	Kategorikal	Nama kota tempat tinggal responden.
5	Profession	Kategorikal	Pekerjaan atau status profesi responden (didominasi oleh pelajar).
6	Academic Pressure	Numerik	Skala yang menunjukkan tingkat tekanan akademik yang dirasakan responden (0-5).
7	Work Pressure	Numerik	Skala yang menunjukkan tingkat tekanan dari pekerjaan yang dialami responden (rentang 0-5).
8	CGPA (Cumulative Grade Point Average)	Numerik	Nilai Indeks Prestasi Kumulatif (IPK) responden.
9	Study Satisfaction	Numerik	Tingkat kepuasan responden terhadap proses belajar yang dijalani (0-5).
10	Job Satisfaction	Numerik	Tingkat kepuasan responden terhadap pekerjaan yang dimiliki (0-4).
11	Sleep Duration	Kategorikal	Rata-rata durasi tidur harian responden (Less than 5 hours, 5-6 hours, 7-8 hours, More than 8 jam, dan Others).
12	Dietary Habits	Kategorikal	Pola/kebiasaan makan responden sehari-hari (Healthy, Moderate, Unhealthy, Others).
13	Degree	Kategorikal	Jenjang pendidikan atau gelar yang sedang atau telah ditempuh.
14	Have you ever had suicidal thoughts?	Kategorikal	Keterangan apakah responden pernah memiliki pikiran untuk bunuh diri (Yes/No).
15	Work/Study Hours	Numerik	Total jam yang dihabiskan untuk belajar atau bekerja dalam sehari (0-12).
16	Financial Stress	Numerik	Skala yang menggambarkan tingkat stres akibat masalah keuangan (1-5).
17	Family History of Mental Illness	Kategorikal	Keterangan apakah ada riwayat penyakit mental dalam keluarga (Yes/No).
18	Depression	Kategorikal	Status depresi responden (Yes/No).

2.3 Exploratory Data Analysis (EDA)

Exploratory Data Analysis (EDA) dilakukan sebagai tahap awal untuk mengevaluasi karakteristik dataset, mengungkap pola distribusi data, serta mengidentifikasi anomali dan outlier. Melalui pendekatan statistik deskriptif dan visualisasi, EDA berfungsi sebagai landasan dalam memvalidasi asumsi awal dan merancang proses transformasi data yang sesuai [13].

- Distribusi Variabel *Profession*: Hasil eksplorasi awal menunjukkan bahwa variabel *Profession* pada dataset tidak hanya terdiri dari responden mahasiswa, tetapi juga mencakup berbagai profesi lain seperti tenaga kesehatan dan pekerja profesional. Temuan ini menunjukkan bahwa dataset bersifat beragam dari sisi latar belakang responden. Hal ini penting dicek karena untuk menjaga konsistensi konteks penelitian.

- b. Statistik Deskriptif Dataset: Statistik deskriptif digunakan untuk memberikan gambaran umum mengenai karakteristik data, seperti nilai rata-rata, simpangan baku, serta rentang nilai setiap fitur numerik. Informasi ini membantu memahami distribusi data sebelum dilakukan tahap pemrosesan dan pemodelan lebih lanjut.
- c. Korelasi Heatmap: *Heatmap* korelasi umumnya diterapkan pada fitur numerik, namun dalam penelitian ini, variabel kategorikal tetap diikutsertakan dengan melakukan konversi ke bentuk numerik secara sementara. Langkah ini bertujuan untuk memberikan gambaran awal mengenai hubungan antarfitur terhadap variabel target guna memahami pola data, bukan untuk tujuan eliminasi fitur pada tahap awal.

2.4 Prapemrosesan Data

Tahap ini bertujuan untuk meningkatkan kualitas data sehingga proses pengolahan dan pemodelan pada tahap selanjutnya dapat berjalan secara lebih efektif [14]. Berikut adalah tahapan prapemrosesan yang dilakukan:

- a. Pembersihan Data: Dari analisis korelasi heatmap, tahap pertama prapemrosesan yaitu pembersihan data dengan mengeliminasi atribut yang tidak memiliki hubungan dengan variabel target.
 1. Variabel *id*: Dihapus karena hanya berfungsi sebagai penanda unik dan tidak berkontribusi pada proses pemodelan.
 2. Variabel *Profession*: Pada tahap EDA terdeteksi bahwa variabel *Profession* bukan hanya *Student*, jadi dilakukan penyaringan terlebih dahulu. Setelah proses penyaringan data hanya tersisa responden dengan kategori mahasiswa (*Student*), sehingga variabel tersebut tidak lagi memiliki variasi dan tidak memberikan informasi tambahan bagi model.
 3. Variabel *City*: Variabel ini dihapus karena bersifat kategorikal dengan tingkat keragaman tinggi serta tidak secara langsung merepresentasikan kondisi psikologis responden.
 4. Variabel *Work Pressure* dan *Job Satisfaction*: Variabel ini juga dihapus karena lebih merepresentasikan konteks pekerja, sementara fokus penelitian ini adalah deteksi depresi pada mahasiswa. Meskipun sebagian mahasiswa memiliki aktivitas kerja, variabel tersebut tidak digunakan untuk menjaga konsistensi konteks data dan menghindari potensi bias.
- b. Pencarian Nilai Hilang: Langkah selanjutnya yaitu, mencari nilai hilang (*missing values*) secara eksplisit maupun implisit pada variabel. Pencarian *missing values* implisit dilakukan menggunakan fungsi *.nunique()* untuk menghitung jumlah nilai unik dalam setiap kolom. Dari jumlah nilai unik dianalisis untuk mengidentifikasi potensi nilai hilang implisit seperti nilai nol (0) atau “Others”.
- c. Penanganan Nilai Hilang: Setelah *missing values* ditemukan, langkah selanjutnya adalah menanganinya. Ada dua penanganan, yang pertama yaitu mengubah nilai nol (0) menjadi NaN lalu melakukan diimputasi *median* untuk mengurangi bias akibat keberadaan outlier. Metode *median imputation* ini dipilih karena lebih stabil dibandingkan *mean imputation* dan terbukti memberikan hasil yang lebih akurat pada dataset dengan variasi nilai yang besar [15]. Langkah ini juga bertujuan untuk melakukan standarisasi data pada tahap *preprocessing* agar model dapat beroperasi pada dataset yang lengkap dan bersih. Kedua, pada nilai “Others” dihapus karena jumlahnya hanya sedikit, jadi tidak terlalu mempengaruhi pemodelan.
- d. Transformasi Data (Encoding): Algoritma *Random Forest* memerlukan tipe data numerik, maka dilakukan proses Encoding. Variabel yang memiliki urutan logis seperti *Sleep Duration*, *Dietary Habits*, dan *Degree* dikonversi menggunakan ordinal encoding untuk mempertahankan informasi berjenjang antar kategori. Sementara itu, variabel dengan dua kategori seperti *Gender*, *Have you ever had suicidal thoughts?*, dan *Family History of Mental Illness* dikonversi menggunakan binary encoding (0 dan 1). Pada variabel *Degree* dilakukan penyederhanaan menjadi empat tingkat pendidikan (*secondary*, *undergraduate*, *postgraduate*, dan *doctoral/professional*) untuk merepresentasikan jenjang akademik secara lebih terstruktur serta mengurangi kompleksitas fitur.
- e. Pembagian Data: Penelitian ini membagi data dengan rasio 80:20. Untuk menghindari bias sampling akibat distribusi kelas yang tidak seimbang, digunakan teknik *stratified sampling* untuk menjamin proporsi kelas target pada data latih dan data uji tetap konsisten dengan distribusi kelas terhadap dataset asli [16].

2.5 Random Forest

Random Forest merupakan algoritma pembelajaran mesin ensemble yang membangun sekumpulan pohon keputusan dari *bootstrap* sampel data acak serta memilih subset fitur secara acak pada setiap percabangan, sehingga menghasilkan model yang robust terhadap overfitting dan mampu menangani data tidak seimbang serta nilai yang hilang [17]. Meskipun *Random Forest* mampu menangani nilai hilang secara otomatis, pada penelitian ini tetap dilakukan imputasi manual pada tahap prapemrosesan. Langkah ini dilakukan untuk memastikan konsistensi data serta meningkatkan stabilitas hasil prediksi, karena imputasi yang tepat umumnya dapat menghasilkan performa model yang lebih optimal dibandingkan membiarkan nilai hilang ditangani oleh algoritma secara langsung.

Model *Random Forest* bergantung pada empat parameter utama yang harus ditingkatkan untuk mencapai kinerja terbaik. Secara umum, parameter ini berfungsi sebagai tuas kendali untuk mengontrol kompleksitas dan stabilitas model. Untuk mengontrol risiko overfitting atau underfitting, *n_estimators* (jumlah pohon) dan *max_depth* (kedalaman pohon) disetel. Ada juga *max_features* untuk menjamin keacakan antar-pohon dan kriteria untuk mengukur kualitas pemisahan data di setiap node. Dengan menyetel keempat komponen ini, tujuan utamanya adalah meningkatkan kemampuan model untuk menggeneralisasi dan menghasilkan hasil prediksi yang akurat pada data baru [18].

2.6 Pengembangan dan Optimasi Model

Tahap ini merupakan inti dari penelitian untuk menentukan performa algoritma *Random Forest* dalam mengklasifikasikan tingkat depresi. Eksperimen dibagi menjadi tiga skenario utama, yaitu pembangunan model baseline serta optimasi *hyperparameter* menggunakan *GridSearchCV* dan *RandomizedSearchCV*, yang bertujuan untuk mengevaluasi efektivitas strategi pencarian parameter terhadap peningkatan performa model.

- Pengembangan Model *Baseline*: Skenario pertama dimulai dengan membangun model *baseline* menggunakan algoritma *Random Forest* dengan konfigurasi parameter standar. Model ini digunakan memberikan tolok ukur awal terhadap performa klasifikasi, sehingga hasilnya dapat dibandingkan dengan model lain yang telah melalui proses tuning [19]. Hasil prediksi dari model ini dievaluasi untuk melihat kelemahan awal model dalam mendeteksi variabel target.
- Optimasi menggunakan *GridSearchCV*: Tahap selanjutnya adalah melakukan optimasi *hyperparameter* secara menyeluruh menggunakan metode *GridSearchCV*. *GridSearchCV* merupakan teknik optimasi *hyperparameter* yang bekerja dengan menguji berbagai kombinasi parameter secara sistematis. Melalui mekanisme *cross-validation*, metode ini mengevaluasi setiap kombinasi untuk menemukan pengaturan yang menghasilkan performa model paling optimal [20].
- Optimasi menggunakan *RandomizedSearchCV*: Tahap berikutnya menerapkan metode *RandomizedSearchCV*. Berbeda dengan *GridSearchCV*, metode ini melakukan pencarian *hyperparameter* secara acak (*random search*) pada ruang parameter yang telah ditentukan. Biasanya proses optimasi berlangsung lebih ringkas dan memiliki efisiensi komputasi yang lebih tinggi dibandingkan *GridSearchCV*, terutama ketika diterapkan pada dataset berukuran besar [21].

Detail ruang pencarian *hyperparameter* dan jumlah iterasi untuk kedua optimasi model disajikan dalam Tabel 2.

Tabel 2. Ruang Pencarian *Hyperparameter* untuk Optimasi Model

Parameter	<i>GridSearchCV</i>	<i>RandomizedSearchCV</i>
<i>n_estimators</i>	100, 200, 300, 400	Acak pada rentang 100-400
<i>max_depth</i>	10, 20, None	10, 20, None
<i>min_samples_split</i>	2, 10	Acak pada rentang 2-10
<i>min_samples_leaf</i>	1, 4	Acak pada rentang 1-4
<i>max_features</i>	sqrt, log 2	sqrt, log 2
<i>bootstrap</i>	True	True
Jumlah kombinasi / iterasi	48 kombinasi	48 iterasi
Skema validasi silang	5-fold	5-fold
Total pelatihan model	240 model	240 model

Proses optimasi pada *RandomizedSearchCV* ditetapkan sebanyak 48 iterasi acak, disetarakan dengan jumlah kombinasi pada *GridSearchCV*. Penyetaraan ini berfungsi sebagai *fixed computational budget* untuk memastikan perbandingan yang adil dalam mengevaluasi efektivitas strategi pencarian parameter. Batasan ini juga diterapkan untuk menjaga efisiensi waktu pelatihan mengingat volume dataset yang cukup besar, sehingga fokus evaluasi terletak pada kemampuan tiap metode menemukan parameter optimal dalam sumber daya komputasi yang terbatas.

2.7 Evaluasi Model

Setiap skenario model (*Baseline*, *GridSearchCV*, dan *RandomizedSearchCV*) dievaluasi menggunakan *Confusion Matrix* untuk menganalisis kemampuan model dalam meminimalkan kesalahan prediksi, khususnya pada kelas mahasiswa yang mengalami depresi. Dalam penelitian ini, metrik *F1-score* menjadi fokus utama karena mampu menyeimbangkan *precision* dan *recall*, sehingga model tidak hanya akurat secara keseluruhan tetapi juga sensitif dalam mendeteksi kasus depresi yang sebenarnya.

Confusion Matrix menunjukkan data yang diklasifikasikan dengan tepat maupun salah oleh model. Empat komponen penyusun utama *Confusion Matrix* meliputi *False Positive* (FP), *True Positive* (TP), *False Negative* (FN), *True Negative* (TN). Untuk menghindari bias akibat satu pembagian data, *Confusion Matrix* sebaiknya dikombinasikan dengan *k-fold cross-validation*. Pendekatan ini meningkatkan keandalan dan konsistensi evaluasi model, sehingga performa prediksi terhadap data baru menjadi lebih valid dan tepercaya [13]. Keempat komponen penyusun ini menunjukkan hubungan antara prediksi yang dihasilkan model dan nilai sebenarnya, dengan rincian lengkap disajikan pada Tabel 3.

Tabel 3. Komponen Penyusun *Confusion Matrix*

Komponen Penyusun	Deskripsi
<i>True Positive</i>	Jumlah data yang diprediksi oleh model sebagai depresi dan sesuai dengan kondisi sebenarnya.
<i>False Positive</i>	Jumlah data yang diprediksi sebagai depresi tetapi sebenarnya tidak mengalami depresi.

Komponen Penyusun	Deskripsi
<i>False Negative</i>	Jumlah data yang diprediksi sebagai tidak depresi, padahal sebenarnya mengalami depresi.
<i>True Negative</i>	Jumlah data yang diprediksi sebagai tidak depresi dan sesuai dengan kondisi sebenarnya.

Keempat elemen tersebut berperan sebagai dasar untuk menghitung metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, yang ditunjukkan melalui persamaan (1), (2), (3) dan (4).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \tag{1}$$

Accuracy merupakan metrik yang mengukur persentase total prediksi yang benar, baik untuk individu yang dikategorikan depresi maupun tidak depresi, terhadap keseluruhan data yang diuji.

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

Precision mengukur ketepatan prediksi positif. Presisi yang tinggi sangat penting untuk meminimalisir *False Positive* agar orang sehat tidak mendapatkan diagnosis atau penanganan medis yang salah.

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

Recall mengukur kemampuan model dalam mendeteksi seluruh kasus depresi yang sebenarnya. Metrik ini penting dalam konteks kesehatan karena berkaitan dengan kemampuan mengurangi kesalahan *false negative*.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{4}$$

F1-score merupakan rata-rata antara *precision* dan *recall* yang digunakan untuk menilai keseimbangan performa model secara keseluruhan.

3. HASIL DAN PEMBAHASAN

3.1 Exploratory Data Analysis (EDA)

a. Distribusi Variabel Profession

Variabel *Profession* dianalisis untuk mengetahui latar belakang pekerjaan responden. Analisis ini bertujuan untuk memberikan gambaran umum mengenai komposisi dalam dataset serta berapa banyak jumlah responden tiap profesi yang akan menjadi dasar analisis lebih lanjut. Rincian kategori profesi responden dalam penelitian ini ditunjukkan pada Gambar 2.

Profession	
Student	27870
Architect	8
Teacher	6
Digital Marketer	3
Chef	2
Content Writer	2
Pharmacist	2
Doctor	2
UX/UI Designer	1
Civil Engineer	1
Manager	1
Educational Consultant	1
Lawyer	1
Entrepreneur	1

Gambar 2. Jumlah Responden Tiap Profesi

Berdasarkan Gambar 2, sebagian besar responden berasal dari *Student* dengan jumlah 27.870 data, sedangkan responden bukan mahasiswa jumlahnya jauh lebih sedikit dan tersebar pada berbagai profesi. Karena penelitian ini berfokus pada analisis depresi di kalangan mahasiswa, keberadaan data bukan mahasiswa berpotensi menimbulkan ketidakkonsistenan dalam populasi penelitian. Oleh sebab itu, pada tahap prapemrosesan, data responden selain mahasiswa dihapus agar dataset sesuai dengan ruang lingkup penelitian.

b. Statistik Deskriptif Dataset



Statistik deskriptif digunakan untuk memberikan gambaran umum karakteristik data, seperti sebaran, variasi, dan rentang nilai seperti yang ditunjukkan pada Gambar 3. Ringkasan ini juga membantu identifikasi nilai hilang guna memahami kondisi data sebelum tahap analisis dan pemodelan lebih lanjut.


	id	Age	Academic Pressure	Work Pressure	CGPA	Study Satisfaction	Job Satisfaction	Work/Study Hours	Financial Stress	Depression
count	27901.000000	27901.000000	27901.000000	27901.000000	27901.000000	27901.000000	27901.000000	27901.000000	27898.000000	27901.000000
mean	70442.149421	25.822300	3.141214	0.000430	7.656104	2.943837	0.000681	7.156984	3.139867	0.585499
std	40641.175216	4.905687	1.381465	0.043992	1.470707	1.361148	0.044394	3.707642	1.437347	0.492645
min	2.000000	18.000000	0.000000	0.000000	0.000000	0.000000	0.000000	0.000000	1.000000	0.000000
25%	35039.000000	21.000000	2.000000	0.000000	6.290000	2.000000	0.000000	4.000000	2.000000	0.000000
50%	70684.000000	25.000000	3.000000	0.000000	7.770000	3.000000	0.000000	8.000000	3.000000	1.000000
75%	105818.000000	30.000000	4.000000	0.000000	8.920000	4.000000	0.000000	10.000000	4.000000	1.000000
max	140699.000000	59.000000	5.000000	5.000000	10.000000	5.000000	4.000000	12.000000	5.000000	1.000000

Gambar 3. Deskripsi Dataset

Pada Gambar 3 terlihat bahwa mayoritas responden berada pada usia produktif dengan rata-rata sekitar 25 tahun. Nilai *Academic Pressure* memiliki rata-rata 3,14 yang menunjukkan tingkat tekanan akademik sedang, sedangkan *Work Pressure* relatif rendah karena sebagian besar responden merupakan mahasiswa. Rata-rata CGPA sebesar 7,66 disertai tingkat *Study Satisfaction* yang cukup baik. Selain itu, rata-rata *Work/Study Hours* berada pada kisaran 7 jam per hari, dan *Financial Stress* berada pada tingkat sedang, meskipun variabel ini memiliki 3 data *missing values*. Variabel target *Depression* memiliki rata-rata 0,59, yang menunjukkan bahwa lebih dari setengah responden terindikasi mengalami depresi berdasarkan label dataset.

c. Analisis Heatmap Korelasi

Heatmap korelasi digunakan untuk memvisualisasikan hubungan linear antar variabel melalui gradasi warna dengan rentang nilai -1 hingga 1. Nilai yang mendekati 1 atau -1 menunjukkan hubungan kuat, sedangkan nilai mendekati 0 menandakan hubungan lemah atau tidak signifikan. Visualisasi ini membantu mengidentifikasi pola hubungan antar fitur secara cepat sebelum tahap pemrosesan data dan pemodelan, sebagaimana ditampilkan pada Gambar 4.



Gambar 4. Heatmap Korelasi

Berdasarkan hasil visualisasi heatmap korelasi pada Gambar 4, sebagian besar fitur memiliki korelasi rendah terhadap variabel *Depression* yang ditunjukkan oleh nilai korelasi mendekati nol. Hal ini menunjukkan bahwa depresi dipengaruhi oleh banyak faktor dan tidak bergantung pada satu variabel secara linear. Beberapa variabel memiliki korelasi positif cukup kuat, seperti *Have you ever had suicidal thoughts?* (0,55) dan *Academic Pressure*

(0,47). Temuan ini mengindikasikan bahwa tekanan akademik dan kondisi psikologis yang lebih serius memiliki hubungan yang cukup kuat dengan tingkat depresi pada responden. Selain itu, *Financial Stress* (0,36) dan *Work/Study Hours* (0,21), yang menandakan bahwa beban finansial serta intensitas aktivitas kerja atau studi berpotensi berkontribusi terhadap peningkatan risiko depresi. Sebaliknya, *Age* dan *Study Satisfaction* memiliki korelasi negatif, yang menandakan bahwa usia yang lebih tinggi dan kepuasan belajar yang tinggi cenderung berkaitan dengan tingkat depresi yang lebih rendah.

3.2 Prpemrosesan Data

Tahap ini mencakup proses pembersihan fitur tidak relevan, pencarian dan penanganan *missing values*, transformasi data kategorikal ke numerik, analisis distribusi target, dan pembagian data.

a. Hasil Penghapusan Fitur dan Penanganan Missing Value

Pada Gambar 3 menunjukkan adanya *missing value* eksplisit melalui perbedaan nilai *count* pada fitur *Financial Stress*. Selain itu, ditemukan juga *missing value* implisit berupa data tidak valid yang diidentifikasi melalui eksplorasi data lebih lanjut. Kedua jenis nilai hilang ini, beserta fitur yang tidak relevan, ditangani pada tahap ini untuk menghasilkan dataset yang bersih dan konsisten dengan hasil akhir yang ditampilkan pada Tabel 4.

Tabel 4. Struktur Dataset Sebelum dan Sesudah Prapemrosesan Data

Kondisi Data	Jumlah Fitur (termasuk Target)	Jumlah Data	Missing Values
Sebelum	18	2.7901	31
Setelah	13	2.7805	0

Berdasarkan hasil yang disajikan pada Tabel 4, pemeriksaan struktur data sebelum dan sesudah penghapusan fitur dan penanganan *missing values*, jumlah fitur berkurang dari 18 menjadi 13 dan jumlah data berkurang dari 2.7901 menjadi 2.7805 karna ada proses penghapusan.

b. Encoding

Tahap selanjutnya yaitu melakukan proses *encoding* pada variabel kategorikal sehingga dapat dikenali oleh model *machine learning*. Tahapan ini diperlukan karena algoritma *Random Forest* hanya mampu mengolah data yang berbentuk numerik. Hasil dari proses *encoding* tersebut ditampilkan pada Gambar 5.

```

=== Before Encoding ===

```

	Sleep Duration	Dietary Habits	Have you ever had suicidal thoughts ?	Family History of Mental Illness	Gender	Degree
0	5-6 hours	Healthy	Yes	No	Male	B.Pharm
1	5-6 hours	Moderate	No	Yes	Female	BSc
2	Less than 5 hours	Healthy	No	Yes	Male	BA
3	7-8 hours	Moderate	Yes	Yes	Female	BCA
4	5-6 hours	Moderate	Yes	No	Female	M.Tech

```

=== After Encoding ===

```

	Sleep Duration	Dietary Habits	Have you ever had suicidal thoughts ?	Family History of Mental Illness	Gender	Degree
0	1	2	1	0	0	1
1	1	1	0	1	1	1
2	0	2	0	1	0	1
3	2	1	1	1	1	1
4	1	1	1	0	1	2

Gambar 5. Hasil Sebelum dan Sesudah Encoding

Gambar 5 menyajikan perbandingan data sebelum dan sesudah tahap *encoding*. Variabel kategorikal yang semula berupa teks ditransformasi menjadi numerik, sehingga seluruh dataset siap digunakan dalam pelatihan model. Tabel ‘After’ menunjukkan transformasi ini secara keseluruhan, menegaskan bahwa data telah siap untuk pemodelan tanpa perlu manipulasi lebih lanjut.

c. Analisis Distribusi Target

Sebelum pemodelan, distribusi kelas pada variabel target dianalisis untuk mengetahui proporsi antara data depresi dan tidak depresi sebagai bagian dari proses eksplorasi awal. Analisis ini bertujuan untuk memastikan tidak terdapat ketidakseimbangan kelas yang ekstrem yang berpotensi memengaruhi proses pelatihan dan evaluasi model. Hasil penghitungan proporsi antara kelas depresi dan tidak depresi tersebut disajikan pada Gambar 6.

```

=== Distribusi Target (0: Tidak Depresi; 1: Depresi) ===
Depression
1 16270
0 11535

```

Gambar 6. Distribusi Kelas Target

Distribusi kelas target pada Gambar 6 menunjukkan proporsi yang relatif seimbang antara kelas ‘Depresi’ sebanyak 16.270 sampel dan ‘Tidak Depresi’ sebanyak 11.535 sampel. Melihat rasio antar kelas yang tidak terpaut jauh dan didukung oleh volume data yang besar, ketidakseimbangan ini dinilai tidak akan mempengaruhi performa

model secara signifikan. Oleh karena itu, penelitian ini tidak menerapkan teknik penanganan data tidak seimbang dan model dilatih menggunakan data asli tanpa menerapkan teknik penanganan kelas tidak seimbang.

d. Pembagian Data

Hasil pembagian dataset menghasilkan dua kelompok data, yaitu data latih dan data uji. Pembagian ini memastikan bahwa evaluasi kinerja model dapat dilakukan secara konsisten pada data yang tidak digunakan selama proses pelatihan. Rincian jumlah data pada masing-masing kelompok disajikan pada Gambar 7.

Keterangan	Jumlah Baris	Jumlah Fitur	Persentase
Data Latih (Training)	22244	12	80%
Data Uji (Testing)	5561	12	20%

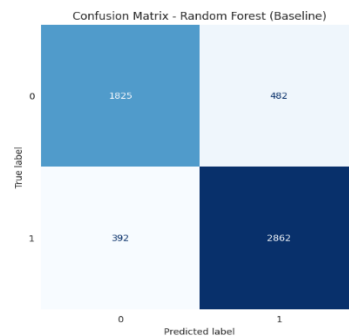
Gambar 7. Hasil Pembagian Data Latih dan Data Uji

Gambar 7, menyajikan hasil implementasi pembagian data terhadap total 27.805 data yang tersedia. Sebanyak 22.244 sampel, yang merupakan 80% dari total populasi data, dialokasikan sebagai data latih untuk proses pembangunan model. Sementara itu, 5.561 sampel sisanya (20%) dipisahkan sebagai data uji yang hanya akan digunakan pada tahap akhir untuk mengevaluasi generalisasi model. Konsistensi jumlah fitur sebanyak 12 kolom pada kedua himpunan data mengindikasikan bahwa struktur data tetap terjaga utuh selama proses pembagian.

3.3 Pengembangan dan Optimasi Model

a. Model Baseline

Tahap awal pengujian dilakukan dengan membangun model *baseline*, yaitu model yang menggunakan konfigurasi parameter default. Hasil evaluasi awal dari model baseline ini disajikan melalui Confusion Matrix pada Gambar 8.

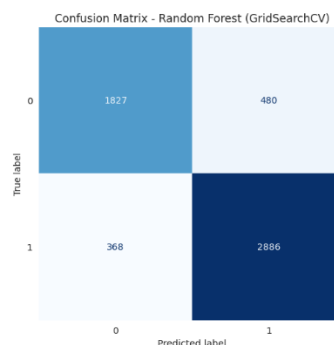


Gambar 8. Confusion Matrix Model Random Forest (Baseline)

Berdasarkan hasil pengujian model baseline pada Gambar 8, diperoleh 1.825 data tidak depresi yang terklasifikasi dengan benar (*true negative*) dan 2.862 data depresi yang terklasifikasi dengan benar (*true positive*). Namun, masih terdapat 482 data tidak depresi yang salah diprediksi sebagai depresi (*false positive*) serta 392 data depresi yang salah diprediksi sebagai tidak depresi (*false negative*). Nilai *false negative* yang masih cukup tinggi menunjukkan bahwa model baseline belum optimal dalam mendeteksi seluruh kasus depresi, sehingga berpotensi menyebabkan beberapa individu yang mengalami depresi tidak teridentifikasi.

b. Optimasi menggunakan *GridSearchCV*

Setelah mengevaluasi model *baseline*, tahap berikutnya adalah meningkatkan performa melalui optimasi hiperparameter menggunakan *GridSearchCV*. Pendekatan ini dilakukan untuk melihat sejauh mana akurasi dapat ditingkatkan dibandingkan dengan model *baseline*. Hasil optimasi ditampilkan dalam bentuk Confusion Matrix pada Gambar 9.




Gambar 9. Confusion Matrix Model Random Forest (GridSearchCV)

Berdasarkan Gambar 9, model *Random Forest* dengan optimasi *GridSearchCV* menunjukkan peningkatan kinerja dibandingkan model baseline, yang ditandai dengan meningkatnya jumlah *true positive* menjadi 2.886 data dan menurunnya *false negative* menjadi 368 data. Penurunan *false negative* ini menunjukkan bahwa model hasil optimasi memiliki sensitivitas yang lebih baik dalam mendeteksi responden yang mengalami depresi. Sementara itu, jumlah *false positive* tercatat sebesar 480 data, sedikit lebih rendah dibandingkan model *baseline* yang sebelumnya mencapai 482 data. Secara keseluruhan, *GridSearchCV* menghasilkan model yang lebih optimal dan stabil dibandingkan model awal.

c. Optimasi menggunakan *RandomizedSearchCV*

Sebagai pembandingan dari dua skenario model sebelumnya dilakukan juga optimasi menggunakan *RandomizedSearchCV*. Hasil dari optimasi dengan *RandomizedSearchCV* ditampilkan dalam bentuk *Confusion Matrix* pada Gambar 10.



Gambar 10. Confusion Matrix Model Random Forest (RandomizedSearchCV)


Berdasarkan Gambar 10, model *Random Forest* yang dioptimasi menggunakan *RandomizedSearchCV* menunjukkan kinerja yang baik, dengan 2.869 data depresi terklasifikasi dengan benar (*true positive*) dan 1.840 data tidak depresi terklasifikasi dengan benar (*true negative*). Jumlah *false negative* tercatat sebanyak 385 data dan *false positive* sebanyak 467 data. Hasil ini menunjukkan bahwa *RandomizedSearchCV* mampu meningkatkan performa dibandingkan model baseline, khususnya dalam mendeteksi kasus depresi. Dibandingkan dengan *GridSearchCV*, performa yang dihasilkan relatif sebanding meskipun terdapat sedikit peningkatan *false negative*, sehingga *RandomizedSearchCV* tetap dapat dipertimbangkan sebagai pendekatan optimasi hiperparameter yang efektif.

3.4 Evaluasi Model

Tahap evaluasi model merupakan langkah penting untuk menilai sejauh mana algoritma *Random Forest* dapat diandalkan sebagai pendekatan pemodelan untuk deteksi depresi. Pengujian dilakukan dengan membandingkan tiga skenario pemodelan, yaitu model baseline sebagai representasi performa awal tanpa optimasi hiperparameter, serta dua model yang dioptimasi menggunakan *GridSearchCV* dan *RandomizedSearchCV*. Dalam evaluasi ini, perhatian utama tidak hanya diberikan pada tingkat *accuracy* secara keseluruhan, tetapi juga pada kemampuan model dalam meminimalkan kesalahan klasifikasi, khususnya kasus *false negative* atau penderita depresi yang tidak berhasil terdeteksi. Tabel 5 menyajikan perbandingan kinerja ketiga skenario tersebut, sementara visualisasi perbandingannya dalam bentuk grafik batang ditampilkan pada Gambar 11.

Tabel 5. Perbandingan Kinerja Model

Model	Accuracy	Precision	Recall	F1-score
Baseline	0.8428	0.8559	0.8795	0.8675
Optimasi <i>GridSearchCV</i>	0.8475	0.8574	0.8869	0.8719
Optimasi <i>RandomizedSearchCV</i>	0.8452	0.8583	0.8808	0.8694



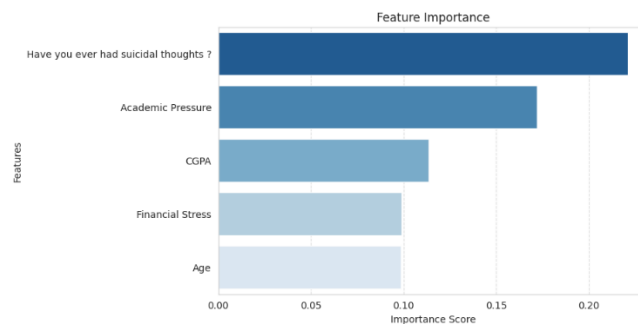
Gambar 11. Perbandingan Kinerja Model

Berdasarkan Tabel 5 dan Gambar 11, dapat diamati bahwa ketiga model menghasilkan nilai *accuracy* yang relatif serupa dan berada pada kisaran 0,84–0,85. Hal ini menunjukkan bahwa proses optimasi *hyperparameter* memberikan peningkatan yang tipis terhadap *accuracy* secara keseluruhan. Kondisi tersebut mengindikasikan bahwa model baseline *Random Forest* telah memiliki performa yang cukup optimal sejak awal, mengingat karakteristik algoritma ini yang cenderung stabil dan tidak terlalu sensitif terhadap perubahan parameter. Selain itu, keterbatasan informasi prediktif pada fitur yang tersedia juga menjadi faktor yang membatasi peningkatan *accuracy* secara signifikan. Dengan demikian, evaluasi performa model tidak dapat dinilai hanya berdasarkan metrik *accuracy*, melainkan perlu dianalisis lebih lanjut melalui metrik evaluasi lainnya.

Perbedaan kinerja yang lebih menonjol terlihat pada metrik *recall*. Model *baseline* memiliki nilai *recall* sebesar 0,8795, sementara model dengan optimasi *GridSearchCV* dan *RandomizedSearchCV* meningkat menjadi 0,8869 dan 0,8808. Peningkatan ini menunjukkan bahwa model hasil optimasi memiliki sensitivitas yang lebih baik dalam mengidentifikasi responden yang mengalami depresi, sehingga mampu mengurangi risiko *false negative*. Dalam konteks kesehatan mental, kesalahan *false negative* memiliki dampak yang lebih serius dibandingkan *false positive*, sehingga peningkatan *recall* menjadi aspek yang sangat penting dalam evaluasi model.


Namun, peningkatan *recall* tersebut diikuti oleh sedikit penurunan pada metrik *precision*, terutama pada model hasil optimasi. Hal ini mengindikasikan adanya *trade-off* antara kemampuan model dalam mendeteksi sebanyak mungkin kasus depresi (*recall*) dan ketepatan model dalam memastikan hasil prediksi positif benar-benar akurat (*precision*). Model hasil optimasi cenderung lebih responsif dalam memprediksi kelas depresi, yang meskipun meningkatkan sensitivitas, hal ini berpotensi meningkatkan jumlah *false positive*, namun kasus *false positive* dapat divalidasi ulang melalui pemeriksaan klinis lebih lanjut. Kondisi ini menunjukkan bahwa optimasi *hyperparameter* tidak selalu meningkatkan seluruh metrik secara bersamaan, melainkan memengaruhi keseimbangan antar metrik evaluasi.

Jika ditinjau dari metrik *F1-score*, model dengan optimasi *GridSearchCV* memperoleh nilai tertinggi sebesar 0,8719, diikuti oleh *RandomizedSearchCV* sebesar 0,8694, dan *baseline* sebesar 0,8675. Meskipun selisih nilai *F1-score* antar model relatif kecil, hasil ini menunjukkan bahwa proses optimasi tetap memberikan perbaikan terhadap keseimbangan performa model dalam melakukan klasifikasi. Sebagai pelengkap analisis, visualisasi tingkat kepentingan setiap fitur pada model disajikan pada Gambar 12.



Gambar 12. Feature Importance Tertinggi

Berdasarkan Gambar 12, fitur yang paling berkontribusi dalam klasifikasi depresi adalah “*Have you ever had suicidal thoughts?*” dengan nilai *importance score* tertinggi di atas 0,20, sehingga menjadi prediktor paling dominan dalam model. Faktor berikutnya adalah *Academic Pressure* dengan skor di atas 0,15, yang menunjukkan bahwa tekanan akademik berperan besar terhadap kondisi kesehatan mental responden. Selain itu, fitur seperti *CGPA*, *Financial Stress*, dan *Age* juga memberikan kontribusi yang cukup stabil. Secara keseluruhan, dominasi faktor psikologis dan akademik ini mendukung tingginya nilai *recall* model dalam mendeteksi depresi. Dari sisi efisiensi komputasi, perbandingan waktu eksekusi kedua metode optimasi ditunjukkan pada Gambar 13.

 Perbandingan Waktu Eksekusi :
 - *RandomizedSearchCV*: 14.93 menit
 - *GridSearchCV*: 14.46 menit
GridSearchCV lebih cepat 0.47 menit dibanding *RandomizedSearchCV*.

Gambar 13. Perbandingan Waktu Eksekusi *RandomizedSearchCV* dan *GridSearchCV*

Berdasarkan Gambar 13, waktu eksekusi *GridSearchCV* dan *RandomizedSearchCV* relatif sebanding, masing-masing sebesar 14.46 menit dan 14.93 menit, dengan selisih waktu sekitar 0.47 menit. Waktu eksekusi yang hampir sebanding ini disebabkan oleh konfigurasi ruang pencarian dan skema validasi yang setara yang dijelaskan pada Tabel 2.

Berdasarkan seluruh parameter evaluasi, model *Random Forest* dengan optimasi *GridSearchCV* ditetapkan sebagai model terbaik. Pemilihan ini didasarkan pada keunggulan model dalam menghasilkan nilai *recall* (0,8869) dan *F1-score* (0,8719) tertinggi, yang merepresentasikan keseimbangan optimal antara sensitivitas deteksi depresi dan ketepatan prediksi secara keseluruhan.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma *Random Forest* mampu memberikan kinerja yang cukup stabil dan andal dalam melakukan klasifikasi depresi pada mahasiswa. Hasil perbandingan tiga skenario pemodelan menunjukkan bahwa proses optimasi *hyperparameter* menggunakan *GridSearchCV* dan *RandomizedSearchCV* tidak memberikan peningkatan yang signifikan pada metrik *accuracy*, yang tetap berada pada kisaran 0,84–0,85 untuk seluruh model. Meskipun demikian, penelitian ini menunjukkan bahwa optimasi *hyperparameter* memberikan dampak positif, terutama pada peningkatan *recall* dalam mendeteksi kasus depresi terutama pada model hasil optimasi. Di mana *GridSearchCV* menghasilkan nilai *recall* tertinggi sebesar 0,8869, lebih baik dibandingkan model baseline yang hanya mencapai 0,8795. Hasil ini mengindikasikan bahwa proses optimasi *hyperparameter* memiliki peran penting dalam meningkatkan sensitivitas model dengan keberhasilannya mengurangi jumlah *false negative*, yang merupakan aspek penting dalam konteks kesehatan mental agar individu yang mengalami depresi tidak luput dari sistem deteksi. Meskipun peningkatan *recall* tersebut diikuti oleh sedikit penurunan *precision*, nilai *F1-score* yang lebih tinggi sebesar 0,8719 pada model *GridSearchCV* menunjukkan keseimbangan performa yang lebih optimal antara sensitivitas dan ketepatan prediksi. Analisis *feature importance* menunjukkan bahwa faktor pemikiran bunuh diri (*Have you ever had suicidal thoughts?*) menjadi prediktor paling dominan, diikuti *Academic Pressure*, *CGPA*, *Financial Stress*, dan *Age*, yang mendukung kemampuan model dalam meminimalkan *false negative*. Dari sisi efisiensi komputasi, *GridSearchCV* dan *RandomizedSearchCV* dalam penelitian ini memiliki waktu eksekusi yang relatif sebanding, meskipun *GridSearchCV* sedikit lebih cepat beberapa detik dari *RandomizedSearchCV*. Kondisi ini terjadi karena jumlah kombinasi parameter yang diuji pada *GridSearchCV* disetarakan dengan jumlah iterasi pada *RandomizedSearchCV*, yaitu sebanyak 48 kombinasi/iterasi sesuai pada Tabel 2. Dengan ruang pencarian yang identik tersebut, perbedaan waktu eksekusi di antara kedua metode menjadi tidak signifikan secara komputasi. Oleh karena itu, model *Random Forest* dengan optimasi *GridSearchCV* dipilih sebagai model terbaik dalam penelitian ini berdasarkan pada keunggulan performa evaluatif, bukan hanya dari efisiensi waktu semata. Namun, penelitian ini masih memiliki keterbatasan, terutama pada cakupan data yang belum sepenuhnya merepresentasikan kondisi mahasiswa secara umum akibat penghapusan beberapa fitur, seperti *Job Satisfaction* dan *Work Pressure*. Selain itu, penelitian ini belum mengeksplorasi pendekatan pemodelan maupun teknik penanganan data tidak seimbang secara lebih kompleks. Oleh karena itu, penelitian selanjutnya disarankan untuk menerapkan metode penanganan ketidakseimbangan serta menambahkan fitur-fitur psikologis yang lebih spesifik guna meningkatkan performa dan kemampuan generalisasi model. Penelitian ini memberikan kontribusi dalam bidang kesehatan mental berbasis data dengan menunjukkan bahwa penggunaan *Random Forest* yang dioptimasi menggunakan *GridSearchCV* mampu meningkatkan sensitivitas model, yang ditunjukkan oleh nilai *recall* yang lebih tinggi dibandingkan model standar. Secara praktis, temuan ini menjadi landasan teknis bagi institusi pendidikan dalam mengembangkan sistem identifikasi risiko depresi yang lebih responsif, khususnya dalam meminimalkan *false negative* sehingga mahasiswa dengan risiko depresi berat dapat diprioritaskan untuk memperoleh penanganan profesional secara lebih cepat dan tepat.

REFERENCES

- [1] A. Jameel, Z. Ma, M. Li, A. Hussain, M. Asif, and Y. Wang, "The effects of social support and parental autonomy support on the mental well-being of university students: the mediating role of a parent-child relationship," *Humanit. Soc. Sci. Commun.*, vol. 11, no. 1, pp. 1–8, 2024, doi: 10.1057/s41599-024-03088-0.
- [2] A. Hussain, Q. Safdar, and A. Khan, "Relationship Of academic motivation & self-efficacy with academic grades of students: Social support as A mediator," *Pakistan Journal of Social Research*, vol. 5, no. 02, pp. 803–811, Jun. 2023, doi: 10.52567/pjsr.v5i02.1193.
- [3] R. J. Woodman and A. A. Mangoni, "A comprehensive review of machine learning algorithms and their application in geriatric medicine: present and future," *Aging Clin. Exp. Res.*, vol. 35, no. 11, pp. 2363–2397, 2023, doi: 10.1007/s40520-023-02552-2.
- [4] A. Rizal, "Tahapan Desain dan Implementasi Model Machine Learning untuk Sistem Tertanam," *Ultima Computing: Jurnal Sistem Komputer*, vol. 12, no. 2, pp. 79–85, 2020, doi: 10.31937/sk.v12i2.1782.
- [5] K. Rahayu, V. Fitria, D. Septhya, R. Rahmaddeni, and L. Efrizoni, "Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 108–114, Sep. 2023, doi: 10.57152/malcom.v3i2.780.
- [6] U. M. Haque, E. Kabir, and R. Khanam, "Detection of child depression using machine learning methods," *PLoS One*, vol. 16, no. 12 December 2021, Dec. 2021, doi: 10.1371/journal.pone.0261131.
- [7] M. M. Hossain, M. Asadullah, M. A. Hossain, and M. S. Amin, "Prediction of Depression Using Machine Learning Tools Taking Consideration of Oversampling," *Malaysian Journal of Public Health Medicine*, vol. 2022, no. 2, pp. 244–253, 2022, doi: 10.37268/mjphm/vol.22/no.2/art.1564.
- [8] A. Y. Pratama, I. S. Maulana, F. K. Sari, S. D. Tiara, and I. Darmawan, "Prediksi Risiko Depresi pada Mahasiswa Menggunakan Algoritma Random Forest Berdasarkan Data Akademik dan Gaya Hidup," *JSITIK: Jurnal Sistem Informasi dan Teknologi Informasi Komputer*, vol. 4, no. 1, pp. 1–10, Dec. 2025, doi: 10.53624/jsitik.v4i1.696.
- [9] I. Setiawan, I. Yasin, and Y. Desianti, "Komparasi Kinerja Algoritma Random Forest, Decision Tree, Naïve Bayes, dan KNN dalam Prediksi Tingkat Depresi Mahasiswa menggunakan Student Depression Dataset," *Jurnal Ilmu Komputer dan Teknologi*, vol. 6, pp. 47–58, Dec. 2025, doi: 10.35960/ikomti.v6i1.1756.



- [10] M. Faisti, D. Kusumodestoni, and G. Wibowo, “Mental Health Classification Using Naïve Bayes and Random Forest Algorithms,” *Journal of Applied Informatics and Computing*, vol. 9, pp. 1740–1750, Dec. 2025, doi: 10.30871/jaic.v9i4.10144.
- [11] J.-P. Cheng and S.-C. Haw, “Mental Health Problems Prediction Using Machine Learning Techniques,” *International Journal on Robotics, Automation and Sciences*, vol. 5, no. 2, pp. 59–72, Sep. 2023, doi: 10.33093/ijoras.2023.5.2.7.
- [12] S. Rasheed, K. Ganipalli, D. Rani, M. P. Kantipudi, and A. M., “Heart Disease Prediction Using GridSearchCV and Random Forest,” *EAI Endorsed Trans. Pervasive Health Technol.*, Dec. 2024, doi: 10.4108/eetpht.10.5523.
- [13] L. M. Ni'mah and D. Kurniawan, “Model Klasifikasi Cerdas Gangguan Tidur Berbasis Machine Learning Random Forest pada Data Kesehatan dan Perilaku Harian,” *Technology and Science (BITS)*, vol. 7, no. 3, pp. 1717–1729, 2025, doi: 10.47065/bits.v7i3.8631.
- [14] S. Utiahman, H. Dalai, and A. Sabudi, “Optimasi K-Nearest Neighbor dengan Particle Swarm Optimization pada Klasifikasi Pelanggan Listrik Rumah Tangga Bersubsidi,” *Jurnal Teknologi dan Manajemen Informatika*, vol. 11, pp. 1–13, Dec. 2025, doi: 10.26905/jtmi.v11i1.14661.
- [15] L. Oluwaseye Joel, W. Doorsamy, and B. Sena Paul, “A Review of Missing Data Handling Techniques for Machine Learning,” *International Journal of Innovative Technology and Interdisciplinary Sciences www.IJITIS.org*, vol. 5, no. 3, pp. 971–1005, 2022, doi: 10.15157/IJITIS.2022.5.3.971-1005.
- [16] A. Géron, *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow Concepts, Tools, and Techniques to Build Intelligent Systems SECOND EDITION*, 2nd Edition. Sebastopol: O'Reilly Media, 2019.
- [17] H. A. Salman, A. Kalakech, and A. Steiti, “Random Forest Algorithm Overview,” *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Dec. 2024, doi: 10.58496/BJML/2024/007.
- [18] F. Rohman, F. Farikhin, and B. Surarso, “Hyperparameter Tuning of Random Forest Algorithm for Diabetes Classification,” *International Journal of Current Science Research and Review*, vol. 08, Dec. 2025, doi: 10.47191/ijcsrr/V8-i1-31.
- [19] H. Rosenbusch, F. Soldner, A. Evans, and M. Zeelenberg, “Supervised machine learning methods in psychology: A practical introduction with annotated R code,” *Soc. Personal. Psychol. Compass*, vol. 15, Dec. 2021, doi: 10.1111/spc3.12579.
- [20] I. Muhamad Malik Matin, “Hyperparameter Tuning Menggunakan GridsearchCV pada Random Forest untuk Deteksi Malware,” *MULTINETICS*, vol. 9, pp. 43–50, Feb. 2023, doi: 10.32722/multinetics.v9i1.5578.
- [21] U. Sunarya and T. Haryanti, “Perbandingan Kinerja Algoritma Optimasi pada Metode Random Forest untuk Deteksi Kegagalan Jantung,” *Jurnal Rekayasa Elektrika*, vol. 18, no. 4, Dec. 2022, doi: 10.17529/jre.v18i4.26981.