

Deteksi Kesehatan Mental Mahasiswa Muslim dengan Pendekatan Pendidikan Islam menggunakan Machine Learning

Detecting Muslim Students Mental Health with an Islamic Educational Approach Using Machine Learning

¹Taftazani Ghazi Pratama*, ²Toni Ardi Rafsanjani, ³Riana Putri Rahmawati, ⁴Helmi Imaduddin

¹Program Studi Ilmu Komputer, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Kudus

²Program Studi Keperawatan, Fakultas Ilmu Kesehatan, Universitas Muhammadiyah Kudus

³Program Studi Farmasi, Fakultas Farmasi, Universitas Muhammadiyah Kudus

⁴Program Studi Teknik Informatika, Fakultas Komunikasi dan Informatika, Universitas Muhammadiyah Surakarta

^{1,2,3}Jl. Kudus-Jepara No. 519 Prambatan Lor, Kec. Kaliwungu Kab. Kudus 59332, Jawa Tengah, Indonesia

⁴Jl. Ahmad Yani, Pabelan, Kartasura, Sukoharjo 57169, Jawa Tengah, Indonesia

*e-mail: taftazanighazi@umkudus.ac.id

(received: 1 September 2025, revised: 4 November 2025, accepted: 7 November 2025)

Abstrak

Kesehatan mental mahasiswa kini menjadi perhatian utama dalam dunia pendidikan tinggi, terlebih di era pasca-pandemi yang menyisakan berbagai tekanan akademik, sosial, dan psikologis. Sayangnya, upaya deteksi dini gangguan mental di lingkungan kampus masih minim, terlebih dalam konteks mahasiswa Muslim yang hidup dalam kultur keislaman. Penelitian ini menawarkan pendekatan inovatif dengan menggabungkan kecanggihan teknologi machine learning dan kedalaman nilai-nilai pendidikan Islam untuk membangun sistem deteksi dini yang tidak hanya akurat, tetapi juga humanistik dan kontekstual. *Dataset* yang digunakan dalam penelitian ini diperoleh melalui survei terhadap 127 mahasiswa Universitas Muhammadiyah Kudus yang terdiri dari variabel kondisi psikologis dan intensitas praktik keagamaan digunakan untuk mendeteksi apakah mahasiswa mengalami mental bermasalah atau mental sehat. Metode penelitian terdiri dari pengumpulan data, pra pemrosesan data, analisis fitur, pembangunan model menggunakan algoritma klasifikasi seperti Random Forest, SVM, KNN, dan Decision Tree, optimasi kinerja model menggunakan GridSearchCV, dan evaluasi model. Hasil evaluasi dari empat model tersebut menunjukkan bahwa model sebelum dioptimasi yang memperoleh kinerja terbaik yaitu model SVM dan KNN yang sama-sama menghasilkan kinerja akurasi sebesar 88,46%. Setelah dioptimasi menggunakan GridSearchCV, SVM menjadi model terbaik dengan mengalami peningkatan kinerja akurasi lebih dari 5% menjadi 94,05%. Analisis fitur mengungkap bahwa tingkat kekhawatiran, kelelahan, serta praktik ibadah seperti do'a dan berdzikir menjadi penentu utama dalam memetakan kondisi mental mahasiswa. Temuan ini menunjukkan bahwa nilai-nilai Islam seperti tawakal, sabar, dan syukur bukan hanya konsep teologis, tetapi juga instrumen ilmiah yang dapat dikonversi menjadi fitur prediktif dalam teknologi berbasis data. Penelitian ini membuktikan bahwa model SVM yang dioptimasi menggunakan GridSearchCV efektif dalam mendeteksi kesehatan mental mahasiswa dan berpotensi menjadi sistem peringatan dini di kampus Islam.

Kata kunci: kesehatan mental, *machine learning*, mahasiswa muslim, pendidikan Islam.

Abstract

Mental health among university students has become a major concern in higher education, particularly in the post-pandemic era, which has left students facing various academic, social, and psychological pressures. Unfortunately, efforts for early detection of mental health issues on campus remain limited, especially in the context of Muslim students who live within an Islamic cultural

framework. This study offers an innovative approach by integrating advanced machine learning technology with the depth of Islamic educational values to develop an early detection system that is not only accurate but also humanistic and contextually relevant. The dataset for this study was obtained through a survey of 127 students at Universitas Muhammadiyah Kudus, including variables related to psychological conditions and the intensity of religious practices, used to detect whether students experience mental health problems or maintain good mental health. The research methodology includes data collection, preprocessing, feature analysis, model development using classification algorithms such as Random Forest, SVM, KNN, and Decision Tree, model performance optimization using GridSearchCV, and evaluation. Evaluation of the four models indicated that prior to optimization, SVM and KNN achieved the best performance, both with an accuracy of 88.46%. After optimization with GridSearchCV, SVM became the top-performing model, achieving an accuracy improvement of more than 5%, reaching 94.05%. Feature analysis revealed that levels of anxiety, fatigue, and religious practices such as prayer and dhikr were the primary determinants in mapping students' mental health conditions. These findings suggest that Islamic values such as tawakkul (trust in God), sabr (patience), and syukur (gratitude) are not merely theological concepts but can also serve as scientific instruments, converted into predictive features in data-driven technologies. This study demonstrates that an SVM model optimized with GridSearchCV is effective in detecting university students' mental health and has the potential to serve as an early warning system in Islamic campus settings.

Keywords: Islamic education, machine learning, mental health, muslim students

1 Pendahuluan

Kesehatan mental mahasiswa semakin menjadi perhatian dalam dunia pendidikan tinggi, terutama pasca pandemi yang memicu peningkatan stres, kecemasan, dan depresi di kalangan mahasiswa. Di Universitas Muhammadiyah Kudus, sebagai institusi berbasis nilai-nilai Islam, pendekatan pendidikan Islam dapat berperan strategis dalam mendeteksi dan menangani isu-isu kesehatan mental secara preventif dan holistik. Nilai-nilai keislaman seperti tawakal, syukur, dan ukhuwah dapat membentuk ketahanan mental mahasiswa yang lebih baik melalui pendekatan spiritual dan moral dalam kehidupan akademik sehari-hari. Namun, keterbatasan dalam metode deteksi manual menuntut inovasi berbasis teknologi. Pemanfaatan *machine learning* memungkinkan analisis data mahasiswa secara cepat dan akurat untuk mengidentifikasi potensi gangguan mental melalui pola perilaku, teks, dan data survei. Integrasi kecerdasan buatan dengan pendekatan nilai-nilai Islam menciptakan sistem yang tidak hanya canggih secara teknis, tetapi juga kontekstual dan humanistik. Beberapa studi telah menunjukkan bahwa algoritma *machine learning* efektif dalam klasifikasi dan prediksi kondisi psikologis mahasiswa dengan tingkat akurasi tinggi [1], [2], [3]. Dengan demikian, pendekatan gabungan ini menjadi solusi inovatif dan sesuai dengan karakter keislaman kampus Muhammadiyah [4], [5].

Meskipun terdapat banyak penelitian tentang deteksi kesehatan mental menggunakan *machine learning*, sebagian besar studi masih berfokus pada populasi umum atau berbasis data klinis dari masyarakat non-Muslim, sehingga belum mempertimbangkan konteks nilai-nilai keislaman yang mendalam sebagai variabel psikososial yang relevan bagi mahasiswa Muslim [6], [7], [8]. Ini menciptakan kesenjangan riset dalam mengintegrasikan pendekatan teknologi dengan kerangka pendidikan Islam, terutama dalam lingkungan kampus berbasis nilai seperti Universitas Muhammadiyah Kudus. Teori integrasi ilmu pengetahuan dan agama dalam pendidikan Islam menyatakan bahwa pembinaan mental dan spiritual tidak dapat dipisahkan dari pembentukan akhlak dan karakter mahasiswa, namun pendekatan ini jarang diadopsi dalam pengembangan sistem berbasis kecerdasan buatan. Di sisi lain, pendekatan *machine learning* saat ini lebih menitikberatkan pada model prediksi berdasarkan data teksual atau perilaku digital tanpa mengindahkan latar belakang nilai religius mahasiswa sebagai faktor perlindungan atau risiko [9].

Dengan demikian, terdapat dua celah penting dalam kajian ini: pertama, minimnya sistem deteksi dini berbasis *machine learning* yang dirancang khusus untuk mahasiswa Muslim yang hidup dalam kerangka pendidikan Islam; kedua, belum adanya model konseptual yang secara terpadu menggabungkan indikator psikologis, dan nilai-nilai Islam dalam satu sistem pendekripsi. Celah ini menunjukkan perlunya penelitian interdisipliner yang menggabungkan ilmu komputer, psikologi

Islam, dan pendidikan tinggi berbasis agama. Penelitian ini tidak hanya memperkaya literatur akademik, tetapi juga berpotensi menghasilkan model intervensi yang lebih sesuai secara kultural dan spiritual bagi mahasiswa Muslim. Data kuantitatif menunjukkan bahwa prevalensi gangguan kesehatan mental di kalangan mahasiswa di Indonesia meningkat signifikan. Survei Kementerian Kesehatan RI pada tahun 2022 mengungkapkan bahwa sekitar 31,5% mahasiswa mengalami gejala kecemasan dan 25,8% mengalami depresi ringan hingga sedang [10], [11].

Temuan ini diperkuat oleh riset dari Universitas Indonesia yang menunjukkan bahwa 1 dari 4 mahasiswa mengalami tekanan psikologis akibat beban akademik dan faktor sosial ekonomi [12]. Di sisi lain, Universitas Muhammadiyah Kudus sebagai institusi pendidikan Islam memiliki pendekatan nilai religius yang khas, namun belum memiliki sistem berbasis teknologi yang mampu mendeteksi kondisi psikologis mahasiswa secara proaktif. Data ini menjadi landasan penting bahwa integrasi teknologi seperti *machine learning* dapat menjadi alat pendukung yang krusial dalam mengembangkan sistem pemantauan kesehatan mental yang lebih responsif dan kontekstual secara budaya[13]. Untuk mendasari integrasi nilai Islam dan teknologi dalam konteks pendidikan maka pendidikan harus mengembangkan aspek spiritual dan intelektual secara seimbang untuk membentuk manusia yang paripurna[14], [15].

Perkembangan teknologi kecerdasan buatan, khususnya *machine learning*, telah membantu dalam deteksi dini gangguan kesehatan mental. Klasifikasi gejala psikologis menggunakan algoritma *supervised learning* seperti Support Vector Machine (SVM) dan Random Forest telah terbukti mampu mendeteksi gejala depresi, stres, dan kecemasan dengan tingkat akurasi yang tinggi, bahkan mencapai 85–90% dalam beberapa studi. Di sisi lain, pendidikan Islam juga berkembang dalam mengintegrasikan nilai-nilai spiritual ke dalam pendekatan psikologis, seperti bimbingan konseling Islam dan terapi berbasis nilai-nilai Qur’ani. Namun, dua bidang ini masih berjalan secara terpisah dalam praktik dan penelitian akademik, sehingga menciptakan peluang integrasi antara teknologi dan pendekatan religius[16], [17]. Sampai saat ini, belum banyak riset yang mengembangkan sistem deteksi kesehatan mental berbasis *machine learning* dengan memperhatikan konteks nilai-nilai Islam, terutama pada mahasiswa Muslim di lingkungan perguruan tinggi Islam. Oleh karena itu, riset ini dapat menjembatani kesenjangan antara inovasi teknologi dan nilai-nilai keislaman dalam upaya menjaga kesehatan mental mahasiswa secara kontekstual dan preventif.

Di sisi lain, sistem pemantauan kesehatan mental yang digunakan di perguruan tinggi masih bersifat konvensional serta belum mampu menjangkau seluruh mahasiswa secara efektif dan efisien. Terlebih lagi, Universitas Muhammadiyah Kudus sebagai institusi berbasis nilai Islam, belum tersedia sistem pendekatan kesehatan mental yang mengintegrasikan pendekatan teknologi dengan nilai spiritual Islam seperti tawakkal, sabar, dan syukur padahal terbukti memiliki peran protektif terhadap tekanan psikologis [18]. Di tengah pesatnya perkembangan *machine learning* dalam deteksi kesehatan mental global, belum ada pengembangan model yang secara khusus dirancang untuk konteks mahasiswa Muslim dengan mempertimbangkan aspek spiritual dan psikis. Oleh karena itu, penelitian ini bertujuan untuk merancang model deteksi kesehatan mental berbasis *machine learning* yang tidak hanya akurat secara teknis, tetapi juga sesuai secara nilai dengan karakteristik mahasiswa Muslim di lingkungan pendidikan Islam. Penelitian ini diharapkan dapat menjadi solusi berbasis teknologi untuk mendeteksi kesehatan mental mahasiswa secara akurat dan sesuai dengan nilai-nilai keislaman, sekaligus menjadi referensi dalam pengembangan sistem pendukung keputusan di lingkungan kampus Islam.

2 Tinjauan Literatur

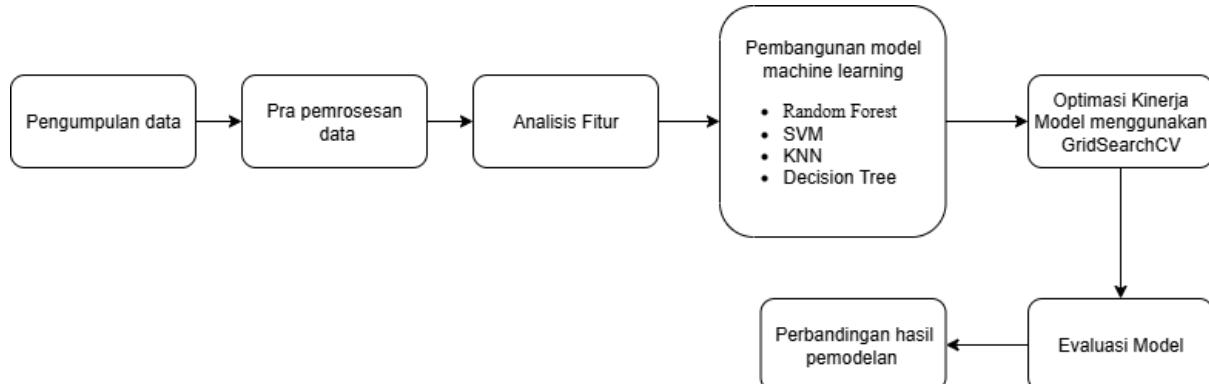
Penelitian terkait deteksi kesehatan mental mahasiswa menggunakan *machine learning* telah banyak dilakukan, namun masih terbatas pada mahasiswa non muslim dan sebagian besar hanya fokus kepada variabel umum yang diteliti seperti tingkat tekanan akademik, kepuasan belajar, durasi tidur, kecemasan dan faktor lainnya yang berkaitan tentang pengalaman spiritual belum banyak diteliti. Penelitian yang dilakukan Najib Nurdiansyah et al.[19] menganalisis kesehatan mahasiswa untuk mencegah gangguan mental dengan membandingkan performa algoritma KNN dan Random Forest. Penelitian ini menunjukkan bahwa kedua algoritma tersebut menghasilkan akurasi tinggi. Namun penelitian tersebut hanya berfokus pada variabel umum untuk mendeteksi apakah mahasiswa mengidap gangguan mental. Penelitian lain yang berkaitan dengan deteksi dini resiko kesehatan

mental di lingkungan pendidikan menggunakan algoritma Stacking Ensemble Learning yang digabungkan dengan 3 algoritma klasifikasi yaitu Logistic Regression, SVM, dan Random Forest. Model yang dibangun dapat menghasilkan akurasi tinggi dalam mendeteksi mahasiswa apakah mengalami depresi atau tidak depresi melalui data riwayat akademik, demografis dan perilaku, tekanan akademik, jam kerja/belajar, kepuasan belajar, durasi tidur, kebiasaan makan, ide bunuh diri, tekanan keuangan, dan riwayat keluarga, penyakit mental. Hasil penelitian menunjukkan bahwa 3 algoritma klasifikasi tersebut dengan kombinasi algoritma Stacking Ensemble Learning yang dibangun mampu mengklasifikasikan mahasiswa mengalami depresi atau tidak sehingga memnghasilkan akurasi sebesar 84%, dengan nilai AUC ROC sebesar 0,93 dan AUC Precision-Recall sebesar 0,91 [20]. Namun dalam penelitian tersebut belum meneliti kegiatan ibadah yang dilakukan dalam sehari-hari. Sementara itu, Algoritma Random Forest juga digunakan untuk prediksi kesehatan mental remaja berdasarkan faktor lingkungan sekolah mampu mencapai akurasi sebesar 80,43%[21]. Namun atribut yang digunakan untuk predisi hanya berkaitan dengan faktor psikologis remaja.

Berdasarkan ketiga penelitian tersebut dapat disimpulkan bahwa Algoritma KNN, Random Forest, SVM mampu menghasilkan model dengan kinerja klasifikasi yang tinggi untuk mendeteksi kesehatan mental remaja dan mahasiswa dalam lingkungan pendidikan menengah dan tinggi. Namun fitur atau atribut yang digunakan hanya berkaitan dengan faktor psikologis dan akademik. Pada penelitian ini bertujuan untuk mendeteksi kesehatan mental mahasiswa melalui faktor psikologis dan menambahkan kegiatan ibadah sebagai atribut yang diteliti. Algoritma Klasifikasi yang digunakan pada penelitian ini adalah SVM, KNN, Random Forest, Decision Tree, dan GridSearch CV untuk mencari kombinasi parameter terbaik.

3 Metode Penelitian

Metode penelitian yang digunakan pada penelitian disusun melalui alur penelitian sebagai berikut:



Gambar 1 Alur penelitian

Berikut penjelasan masing-masing tahapan dari Gambar 1 di atas:

1. Pengumpulan Data

Penelitian ini didasarkan pada data primer yang diperoleh melalui metode survei menggunakan kuesioner yang disebarluaskan kepada 127 mahasiswa dari berbagai program studi di Universitas Muhammadiyah Kudus. Komposisi responden didominasi oleh perempuan (109 orang) dan sisanya adalah laki-laki (18 orang). Instrumen penelitian yang digunakan adalah kuesioner terstruktur dengan skala Likert, yang dirancang untuk mengukur dua konstruk utama: kesehatan mental dan praktik keagamaan. Variabel kesehatan mental diukur melalui serangkaian item pertanyaan yang mengeksplorasi gejala-gejala seperti kecemasan, kehilangan minat, dan perasaan tertekan. Sementara itu, variabel praktik keagamaan mengukur tingkat ketaatan responden dalam menjalankan aktivitas spiritual, seperti keteraturan shalat, membaca Al-Qur'an, berzikir, dan partisipasi dalam kegiatan keagamaan. Berdasarkan respons yang terkumpul, setiap partisipan kemudian diklasifikasikan ke

dalam kategori "Mental Sehat" atau "Mental Bermasalah" untuk keperluan analisis data lebih lanjut guna menguji hubungan antara praktik keagamaan dan kondisi kesehatan mental.

2. Pra pemrosesan data

Setelah eksplorasi data selesai, tahap pra-pemrosesan dilakukan untuk mentransformasi data mentah ke dalam format yang sesuai untuk dianalisis oleh algoritma machine learning. Langkah pertama adalah encoding, di mana variabel-variabel kategorikal seperti 'Jenis Kelamin' dan variabel target 'Kategori Mental' dikonversi menjadi representasi numerik menggunakan LabelEncoder. Proses ini merupakan prasyarat mutlak bagi sebagian besar algoritma klasifikasi. Selanjutnya, dataset dibagi menjadi dua subset: data latih (*training set*) dengan proporsi 80% dan data uji (*testing set*) dengan proporsi 20%. Pembagian ini dilakukan dengan teknik *stratified sampling* untuk memastikan bahwa distribusi kelas yang tidak seimbang pada variabel target tetap terjaga secara proporsional di kedua subset, sehingga mencegah bias dalam evaluasi model. Langkah krusial berikutnya dalam pra-pemrosesan adalah penskalaan fitur (*feature scaling*). Teknik StandardScaler diterapkan pada variabel-variabel prediktor numerik untuk menstandarisasi rentang nilainya, yaitu dengan mengubah distribusinya sehingga memiliki rata-rata 0 dan standar deviasi 1. Penskalaan ini tidak diterapkan pada semua model, melainkan secara spesifik untuk algoritma yang sensitif terhadap skala fitur, yaitu Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN). Algoritma-algoritma ini menggunakan metrik jarak dalam perhitungannya, sehingga fitur dengan rentang nilai yang besar dapat secara tidak proporsional mendominasi proses pembelajaran. Dengan demikian, penskalaan memastikan bahwa setiap fitur memberikan kontribusi yang setara, yang pada akhirnya bertujuan untuk meningkatkan akurasi dan stabilitas kinerja model.

3. Analisis Fitur

Penelitian ini juga bertujuan untuk mendapatkan pemahaman tentang faktor-faktor penentu status kesehatan mental. Untuk itu, dilakukan analisis fitur penting (*feature importance analysis*) dengan memanfaatkan output dari model berbasis pohon (Random Forest dan Decision Tree). Analisis ini mengkuantifikasi kontribusi relatif dari setiap variabel prediktor dalam membuat keputusan klasifikasi. Hasilnya diurutkan untuk mengidentifikasi lima fitur paling berpengaruh, seperti tingkat kekhawatiran, kelelahan, dan praktik spiritual. Wawasan ini sangat berharga karena memberikan bukti empiris mengenai gejala atau perilaku mana yang paling kuat kaitannya dengan kondisi mental. Kombinasi antara model berakurasi tinggi yang telah dioptimalkan dan pemahaman mendalam tentang fitur-fitur prediktif ini menjadi luaran utama dari penelitian, yang menghasilkan rekomendasi model berbasis bukti untuk aplikasi praktis.

4. Pembangunan model *Machine Learning*

Pada tahap pemodelan, empat algoritma klasifikasi yang merepresentasikan paradigma pembelajaran yang berbeda dipilih untuk dilatih dan dievaluasi secara komparatif. Algoritma tersebut meliputi: Random Forest (metode ensemble), Support Vector Machine (SVM) (metode berbasis margin), K-Nearest Neighbors (KNN) (metode berbasis instans), dan Decision Tree (model tunggal). Pemilihan ini bertujuan untuk menguji hipotesis mengenai pendekatan mana yang paling efektif untuk dataset ini. Setiap model dilatih menggunakan data latih yang telah melalui pra-pemrosesan. Untuk SVM dan KNN, data latih yang digunakan adalah data yang telah diskalakan, sementara Random Forest dan Decision Tree menggunakan data latih asli karena keduanya tidak sensitif terhadap skala fitur.

5. Optimasi Kinerja model menggunakan GridSearchCV

Tahap selanjutnya adalah memaksimalkan potensi prediktif dari model-model yang telah dievaluasi. Teknik utama yang digunakan untuk mencapai hasil maksimal adalah optimisasi hiperparameter menggunakan GridSearchCV. Hiperparameter adalah parameter konfigurasi eksternal model yang nilainya tidak dapat dipelajari dari data, seperti jumlah pohon pada Random Forest atau nilai C pada SVM. GridSearchCV secara sistematis membangun dan mengevaluasi model untuk setiap kombinasi hiperparameter yang telah ditentukan dalam sebuah grid, menggunakan validasi silang untuk mengukur kinerja setiap kombinasi. Dengan pendekatan ini, konfigurasi hiperparameter yang paling optimal untuk setiap algoritma dapat diidentifikasi secara objektif.

6. Evaluasi model dan perbandingan hasil pemodelan

Evaluasi kinerja setiap model dilakukan dengan menggunakan dua pendekatan utama untuk memastikan hasil yang komprehensif. Pertama, akurasi prediksi diukur pada data uji, yang merupakan data yang belum pernah dilihat oleh model selama proses pelatihan. Ini memberikan estimasi kinerja

model pada data baru di dunia nyata. Kedua, untuk menguji robustisitas dan generalisasi model, diterapkan teknik validasi silang 5-lipat (*5-fold cross-validation*) pada data latih. Teknik ini membagi data latih menjadi lima bagian, melatih model sebanyak lima kali pada kombinasi yang berbeda, dan menghitung rata-rata kinerjanya. Pendekatan ganda ini tidak hanya mengukur akurasi tetapi juga memberikan indikasi mengenai potensi *overfitting*, yaitu ketika model berkinerja sangat baik pada data latih namun buruk pada data baru. Hasil evaluasi awal ini menjadi dasar untuk menentukan model mana yang paling potensial untuk dioptimalkan lebih lanjut.

4 Hasil dan Pembahasan

Pada bagian ini, akan dipaparkan hasil dari proses deteksi kesehatan mental mahasiswa performance menggunakan algoritma machine learning berdasarkan faktor psikologis dan kegiatan ibadah. Proses analisis dimulai dengan tahapan pra pemrosesan data, pembagian data menjadi *subset* pelatihan model dan pengujian, optimasi model hingga evaluasi performa model.

4.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah sebanyak 127 data mahasiswa dari berbagai prodi yang ada di Universitas Muhammadiyah Kudus dengan rincian jumlah data mahasiswa laki-laki sebanyak 18 orang dan mahasiswa perempuan sebanyak 109. Berikut contoh dataset yang digunakan dapat dilihat pada Tabel 1 di bawah ini.

Tabel 1 Contoh dataset

Jenis_kelamin	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Kategori Mental
Laki-laki	1	1	1	1	1	1	5	4	4	2	Mental
Laki-laki	1	1	2	3	3	3	3	3	3	3	Bermasalah
Perempuan	1	1	2	2	2	1	5	1	1	2	Mental
Perempuan	3	3	3	3	3	3	4	3	4	3	Bermasalah
Perempuan	2	2	3	3	2	3	4	4	3	2	Mental
Perempuan											Sehat

Berikut adalah penjelasan dari tabel 1 di atas:

1. Jenis_kelamin: jenis kelamin mahasiswa: Laki-laki, perempuan
2. Q1: Saya merasa cemas atau khawatir tanpa sebab yang jelas: Skala 1-5 (1:Tidak pernah, 5:Sangat sering)
3. Q2: Saya khawatir berlebihan tentang hal-hal kecil hingga sulit mengendalikannya: Skala 1-5 (1:Tidak pernah, 5:Sangat sering)
4. Q3: Saya kehilangan minat atau kesenangan dalam aktivitas yang biasa saya sukai: Skala 1-5(1:Tidak pernah, 5:Sangat sering)
5. Q4: Saya merasa mudah lelah atau kurang energi meski cukup istirahat: Skala 1-5 (1:Tidak pernah, 5:Sangat sering)
6. Q5: Saya sulit berkonsentrasi ketika belajar atau menghadiri kuliah: :Skala 1-5(1:Tidak pernah, 5:Sangat sering)
7. Q6: Saya sering merasa sedih, putus asa, atau tertekan: Skala 1-5(1:Tidak pernah, 5:Sangat sering)
8. Q7: Saya melaksanakan shalat lima waktu tepat pada waktunya: Skala 1-5(1:Tidak pernah, 5:Sangat sering)
9. Q8:Saya rutin membaca Al-Qur'an atau mempelajari tafsirnya: Skala 1-5(1:Tidak pernah, 5:Sangat sering)
10. Q9:Saya berzikir atau membaca doa pagi/sore secara teratur: :Skala 1-5(1:Tidak pernah, 5:Sangat sering)

11. Q10: Saya aktif menghadiri kajian, majelis taklim di kampus atau rumah: Skala 1-5 (1:Tidak pernah, 5:Sangat sering)
12. Kategori mental: Mental Bermasalah, Mental Sehat

4.2 Pra pemrosesan data

Pra pemrosesan pada penelitian ini melalui tahapan-tahapan sebagai berikut:

1. Pengkodean variabel kategorikal

Data kategorikal seperti jenis kelamin dan kategori mental diubah telebih dahulu menjadi angka biner yaitu 0 atau 1. Sebagai contoh, jenis kelamin Laki-laki dikodekan menjadi 0 dan perempuan menjadi 1.

2. Pengecekan *missing value*

Pada tahapan ini data dicek terlebih dahulu untuk memastikan kelengkapan dan kualitasnya. Langkah yang kami lakukan adalah pengecekan nilai yang hilang (*missing value*) pada setiap atribut. Hasil pengecekan menunjukkan bahwa dataset tidak ditemukan *missing value* sehingga data dapat langsung digunakan pada tahap selanjutnya tanpa proses imputasi maupun penghapusan data.

3. Memisahkan fitur dan target

Fitur (X): kolom yang dijadikan fitur antara lain: jenis kelamin dan Q1-Q10.

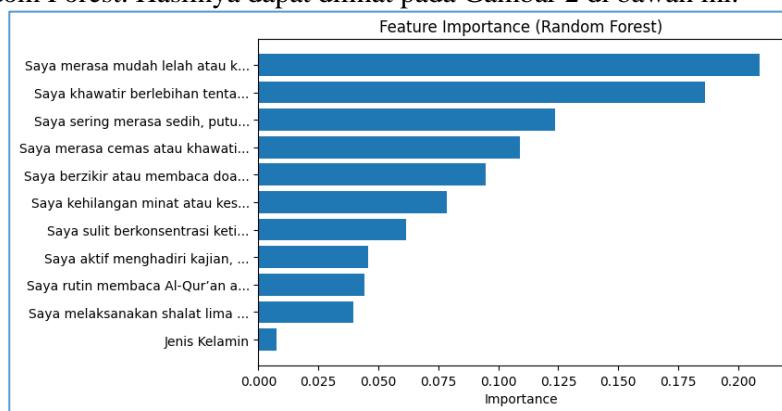
Target(Y): kolom target yang akan diprediksi yaitu Kategori mental. Pada penelitian ini data kategori mental diubah menjadi angka biner. Mental Bermasalah diubah menjadi 0 dan Mental Sehat diubah menjadi 1 menggunakan *Label Encoder*.

4. Membagi data *Training* dan *testing*

Setelah dataset dipisahkan fitur dan targetnya, selanjutnya data dibagi menjadi data *training* dan data *testing* menggunakan teknik train-test split. Pembagian data *training* dan *testing* yaitu: 80% untuk data *training* dan 20% untuk data *testing* dengan parameter *random_state* = 42. Pembagian ini dilakukan dengan teknik stratified sampling untuk memastikan bahwa distribusi kelas yang tidak seimbang pada variabel target tetap terjaga secara proporsional di kedua subset, sehingga mencegah bias dalam evaluasi model.

4.3 Analisis Fitur

Untuk mengidentifikasi faktor utama yang mempengaruhi kesehatan mental mahasiswa di Universitas Muhammadiyah Kudus, dilakukan analisis fitur dilihat dari *feature importance* menggunakan Random Forest. Hasilnya dapat dilihat pada Gambar 2 di bawah ini.



Gambar 2 Analisis fitur dalam deteksi kesehatan mental

Berdasarkan hasil analisis *feature importance* dalam deteksi kesehatan mental menggunakan algoritma Random Forest, fitur "Saya merasa mudah lelah atau kurang energi meski cukup istirahat" memiliki nilai kontribusi teringgi terhadap hasil prediksi dengan nilai *importance* sebesar 0,21. Hal ini menunjukkan bahwa kondisi kelelahan atau kurang energi merupakan indikator utama yang paling berpengaruh dalam model. Selanjutnya, fitur "Saya khawatir berlebihan tentang hal-hal kecil hingga sulit mengendalikannya" juga memiliki pengaruh yang tinggi dengan nilai *importance* sebesar 0,19, yang mengindikasikan bahwa rasa khawatir berlebihan turut menjadi faktor penting dalam penentuan prediksi. Selain itu, fitur "Saya sering merasa sedih, putus asa, atau tertekan", " Saya merasa cemas

atau khawatir tanpa sebab yang jelas”, dan “Saya berzikir atau membaca doa pagi/sore secara teratur” juga memberikan kontribusi signifikan dengan nilai *importance* yang berkisar antara 0,10 hingga 0,12.

Sementara itu, fitur dengan nilai *importance* rendah, seperti “Jenis Kelamin”, “Saya melaksanakan shalat lima waktu tepat pada waktunya”, dan “Saya rutin membaca Al-Qur'an atau mempelajari tafsirnya” menunjukkan kontribusi yang relatif kecil terhadap hasil prediksi. Hal ini mengindikasikan bahwa faktor demografis maupun aktivitas ibadah tidak terlalu berpengaruh dalam model dibandingkan dengan faktor psikologis. Dengan demikian, dapat disimpulkan bahwa variabel-variabel psikologis, seperti kelelahan, kekhawatiran, dan perasaan sedih, dan salah satu aktivitas ibadah seperti berdzikir atau membaca do'a pagi/sore memiliki pengaruh yang lebih besar dalam membangun model prediksi dibandingkan faktor lainnya.

4.4 Pembangunan model *machine learning*

Pada penelitian ini dalam membangun model *machine learning* untuk deteksi kesehatan mental mahasiswa di Universitas Muhammadiyah Kudus menggunakan 4 algoritma yaitu Random Forest, SVM, KNN, dan Decision Tree. Setiap algoritma menggunakan *library* scikit-learn dengan tidak melakukan penyetelan parameter(*default*). Hasil evaluasi awal pada data uji menunjukkan kinerja yang beragam, sebagaimana dapat dilihat pada Tabel 2.

Tabel 2 Kinerja 4 model yang dibangun

No	Model	Akurasi	Precision	Recall	F1-Score
1.	Random Forest	84,62%	85%	85%	85%
2.	SVM	88,46%	88%	88%	88%
3.	KNN	88,46%	88%	88%	88%
4.	Decision Tree	73,08%	81%	73%	75%

Berdasarkan hasil kinerja model yang dibangun, model SVM dan KNN memberikan performa terbaik dengan nilai akurasi sebesar 88,46%, *precision* 88%, *recall* 88%, serta *f1-score* 88%. Hal ini menandakan bahwa kedua model tersebut memiliki kemampuan yang konsisten dalam melakukan prediksi. Model Random Forest juga menunjukkan performa yang cukup baik dengan akurasi sebesar 84,62%, *precision* 85%, *recall* 85%, dan *f1-score* 85%. Meskipun sedikit lebih rendah dibandingkan SVM dan KNN, model ini masih tergolong efektif dalam melakukan klasifikasi. Sementara itu, model Decision Tree menghasilkan performa paling rendah dibandingkan tiga model lainnya, dengan akurasi hanya sebesar 73%, *precision* 81%, *recall* 73%, dan *f1-score* 75%. Hal ini menunjukkan bahwa Decision Tree kurang optimal dalam memprediksi data pada penelitian ini.

4.5 Optimasi kinerja model menggunakan GridSearchCV

Untuk meningkatkan kinerja model, dilakukan proses optimasi hiperparameter menggunakan GridSearchCV dan dievaluasi menggunakan *stratified 5-fold cross validation* pada masing-masing model. Proses ini bertujuan untuk mencari kombinasi parameter terbaik yang dapat menghasilkan performa optimal pada data *testing*. Hasil perbandingan optimasi kinerja setiap model dapat dilihat pada Gambar 3.

```
==== Hyperparameter Optimization (Grid Search) ====\n\nOptimizing Random Forest...\nBest parameters: {'max_depth': 5, 'min_samples_split': 2, 'n_estimators': 100}\nBest CV score: 0.9014\n\nOptimizing SVM...\nBest parameters: {'C': 1, 'gamma': 'scale', 'kernel': 'linear'}\nBest CV score: 0.9405\n\nOptimizing KNN...\nBest parameters: {'metric': 'manhattan', 'n_neighbors': 3, 'weights': 'uniform'}\nBest CV score: 0.9019\n\nOptimizing Decision Tree...\nBest parameters: {'max_depth': 5, 'min_samples_leaf': 1, 'min_samples_split': 2}\nBest CV score: 0.9024
```

Gambar 3 Optimasi model menggunakan GridSearchCV

Berdasarkan hasil pencarian parameter terbaik menggunakan Grid SearchCV diperoleh hasil yaitu pada model Random Forest, parameter terbaik diperoleh dengan *max_depth* = 5, *min_samples_split* = 2, dan *n_estimators* = 100. Hasil optimasi menghasilkan nilai *cross validation score* sebesar 0,9014. Model SVM menunjukkan kinerja yang lebih baik dengan parameter optimal berupa *C* = 1, *gamma* = scale, dan *kernel* = linear. Model ini menghasilkan *cross validation score* tertinggi yaitu 0,9405, sehingga model ini sebagai salah satu model paling unggul. Model KNN juga mengalami peningkatan kinerja setelah optimasi dengan parameter terbaik *metric* = manhattan, *n_neighbors* = 3, dan *weights* = uniform. Hasilnya menunjukkan *cross validation score* sebesar 0,9019. Sementara itu, model Decision Tree memperoleh parameter terbaik pada *max_depth*=5, *min_samples_leaf* = 1, dan *min_samples_split* = 2. Model ini menghasilkan cross validation score sebesar 0,9024. Meskipun terdapat sedikit peningkatan dari sisi validasi, performa uji tetap lebih rendah dibandingkan model lainnya. Secara keseluruhan, hasil optimasi menunjukkan bahwa algoritma SVM dan KNN memberikan performa terbaik, diikuti oleh Random Forest dan Decision Tree masih yang menunjukkan performa sama. Hal ini mengindikasikan bahwa pemilihan parameter yang tepat melalui GridSearchCV mampu meningkatkan kinerja model, meskipun efektivitas peningkatan berbeda-beda pada setiap model.

4.6 Evaluasi model dan perbandingan hasilnya

Pada tahap pemodelan, empat algoritma klasifikasi yang merepresentasikan paradigma pembelajaran yang berbeda dipilih untuk dilatih dan dievaluasi secara komparatif. Algoritma tersebut meliputi: Random Forest, SVM, KNN, dan Decision Tree. Pemilihan ini bertujuan untuk menguji hipotesis mengenai pendekatan mana yang paling efektif untuk dataset ini. Setiap model dilatih menggunakan data latih yang telah melalui pra-pemrosesan. Untuk SVM dan KNN, data latih yang digunakan adalah data yang telah diskalakan, sementara Random Forest dan Decision Tree menggunakan data latih asli karena keduanya tidak sensitif terhadap skala fitur. Evaluasi kinerja setiap model dilakukan dengan menggunakan dua pendekatan utama untuk memastikan hasil yang komprehensif. Pertama, akurasi prediksi diukur pada data uji, yang merupakan data yang belum pernah dilihat oleh model selama proses pelatihan. Ini memberikan estimasi kinerja model pada data baru di dunia nyata. Kedua, untuk menguji robustisitas dan generalisasi model, diterapkan teknik validasi silang 5-lipat (*5-fold cross-validation*) pada data latih. Teknik ini membagi data latih menjadi lima bagian, melatih model sebanyak lima kali pada kombinasi yang berbeda, dan menghitung rata-rata kinerjanya. Hasil evaluasi dan perbandingan modelnya dapat dilihat pada Tabel 3.

Tabel 3 Perbandingan kinerja model sebelum dan setelah dioptimasi

No	Model	Akurasi	Precision	Recall	F1-Score
1.	Random Forest	84,62%	85%	85%	85%
2.	SVM	88,46%	88%	88%	88%

3.	KNN	88,46%	88%	88%	88%
4.	Decision Tree	73,08%	81%	73%	75%
5.	Random Forest				
6.	GridSearchCV	90,14%	92,24%	94,67%	89,94%
	SVM				
6.	GridSearchCV	94,05%	94,67%	100%	93,91%
7.	KNN GridSearchCV	90,19%	90,28%	100%	89,59%
	Decision Tree				
8.	GridSearchCV	90,24%	91,25%	96%	89,90%

Tabel 3 menggambarkan hasil perbandingan kinerja empat algoritma klasifikasi yaitu Random Forest, Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Decision Tree dengan kondisi sebelum dan sesudah dilakukan optimasi menggunakan GridSearchCV dengan *stratified 5-fold cross validation*. Secara umum, optimasi hiperparameter terbukti mampu meningkatkan kinerja algoritma lebih optimal, baik kinerja akurasi maupun metrik evaluasi lainnya. Pada model Random Forest, akurasi meningkat dari 84,62 % menjadi 90,14 %, *precision* dari 85 % menjadi 92,24 %, *recall* dari 85 % menjadi 94,67 %, dan *f1-score* dari 85 % menjadi 89,94 %. Hal ini menunjukkan bahwa optimasi parameter memperbaiki sensitivitas model terhadap kelas minoritas, yaitu mahasiswa dengan potensi mental yang bermasalah. Model SVM menunjukkan performa paling optimal setelah dilakukan optimasi. Akurasi meningkat dari 88,46 % menjadi 94,05 %, dengan *precision* 94,67 %, *recall* 100 %, dan *f1-score* 93,91 %. *Recall* sempurna ini menandakan bahwa seluruh kasus mahasiswa dengan potensi mental yang bermasalah berhasil terdeteksi tanpa ada yang terlewat (*minim false negative*). Hasil ini sejalan dengan penelitian E.M Arias et al. [22] yang menunjukkan bahwa SVM mampu menghasilkan akurasi tinggi dalam mendekripsi stres mahasiswa. Model KNN juga mengalami peningkatan performa, meskipun tidak sebesar SVM. Akurasi meningkat dari 88,46 % menjadi 90,19 %, dengan *precision* 90,28 %, *recall* 100 %, dan *f1-score* 89,59 %. Hasil ini menunjukkan bahwa KNN mampu mengenali seluruh kasus pada kelas positif, meskipun nilai *f1-score* masih lebih rendah dibandingkan SVM.

Decision Tree yang sebelumnya memiliki performa terendah dengan akurasi 73,08 % menunjukkan peningkatan lebih baik setelah dilakukan optimasi, yaitu mencapai 90,24 %. *Precision* meningkat dari 81 % menjadi 91,25 %, *recall* dari 73 % menjadi 96 %, dan *f1-score* dari 75 % menjadi 89,90 %. Hal ini memperlihatkan bahwa kelemahan *overfitting* pada Decision Tree dapat diminimalkan melalui optimasi parameter, sebagaimana juga disampaikan oleh Desi Anggraeni et al. [23]. Dengan demikian, hasil penelitian ini membuktikan bahwa GridSearchCV efektif dalam meningkatkan performa model klasifikasi. Selain peningkatan kinerja, penelitian ini juga menghadapi tantangan berupa ketidakseimbangan data (*imbalanced data*). Jumlah mahasiswa dengan kondisi mental sehat lebih dominan dibandingkan dengan mahasiswa yang memiliki potensi mental yang bermasalah. Distribusi data yang tidak seimbang ini dapat menimbulkan bias pada model, terutama apabila evaluasi hanya mengandalkan akurasi. Oleh karena itu, penggunaan metrik lain seperti *precision*, *recall*, dan *f1-score* menjadi penting untuk memberikan gambaran yang lebih komprehensif terhadap kinerja model. Hal ini berkaitan dengan penelitian mengenai penanganan data medis yang tidak seimbang, yang menegaskan perlunya evaluasi berbasis multi-metrik agar model tidak bias terhadap kelas mayoritas [24]. Dalam konteks penelitian ini, *recall* menjadi metrik yang sangat krusial karena dapat meminimalkan kemungkinan terlewatnya mahasiswa yang benar-benar berada dalam kondisi berisiko, meskipun dengan konsekuensi meningkatnya *false positive*.

Secara keseluruhan, hasil penelitian menunjukkan bahwa optimasi melalui GridSearchCV tidak hanya meningkatkan performa model tetapi juga memberikan keandalan yang lebih baik dalam konteks deteksi kesehatan mental mahasiswa. Model SVM GridSearchCV menjadi model terbaik dengan akurasi 94,05 % dan *recall* sempurna 100 %, sehingga model ini lebih optimal dalam mendekripsi mahasiswa dengan potensi masalah kesehatan mental.

4.7 Relevansi Temuan dengan Nilai-nilai Islam

Temuan penelitian ini tidak hanya signifikan dalam konteks teknis penerapan algoritma machine learning, tetapi juga sangat relevan dalam memperkuat integrasi antara teknologi dan nilai-nilai Islam dalam dunia pendidikan tinggi. Integrasi nilai-nilai ini dalam sistem deteksi kesehatan mental berbasis machine learning menandai suatu pendekatan inovatif dan kontekstual yang menjawab kesenjangan riset antara aspek spiritualitas dan teknologi. Dalam konteks ini, sistem deteksi dini yang dibangun bukan hanya bertujuan meningkatkan efisiensi administratif kampus atau sekadar mengotomatisasi proses evaluasi psikologis, tetapi berfungsi untuk memfasilitasi kesejahteraan mahasiswa Muslim secara utuh, mencakup aspek mental, emosional, dan spiritual. Dengan mengintegrasikan nilai-nilai Islam dalam fitur-fitur input maupun interpretasi hasil model, teknologi *machine learning* tidak lagi bersifat netral atau sekadar algoritmik, melainkan menjadi instrumen yang human-centered, sesuai dengan karakteristik lembaga pendidikan Islam seperti Universitas Muhammadiyah Kudus.

4.8 Keterbatasan dataset

Penelitian ini memiliki beberapa keterbatasan pada aspek dataset yang perlu diakui secara terbuka untuk memberikan konteks terhadap hasil dan generalisasi model. Pertama, ukuran sampel yang digunakan relatif kecil, yaitu hanya 127 responden. Jumlah ini tergolong terbatas untuk penelitian berbasis *machine learning*, sehingga kemampuan model dalam melakukan generalisasi terhadap populasi mahasiswa yang lebih luas masih perlu diuji pada dataset dengan skala lebih besar dan beragam.

Kedua, terdapat ketidakseimbangan demografis yang cukup signifikan, dengan 109 responden laki-laki dan hanya 18 responden perempuan. Ketimpangan ini berpotensi menyebabkan model cenderung belajar lebih banyak dari pola yang merepresentasikan mahasiswa laki-laki, sehingga performanya tidak optimal ketika diaplikasikan pada populasi dengan proporsi mahasiswa perempuan. Penelitian lanjutan disarankan untuk menyeimbangkan distribusi gender agar hasil model lebih representatif.

Ketiga, jumlah kelas antara mental bermasalah sebanyak 34 dengan mental sehat sebanyak 93 menunjukkan bahwa tidak seimbang sehingga menyebabkan model lebih banyak memprediksi kelas mental sehat. Oleh karena itu, pada penelitian selanjutnya disarankan untuk menyeimbangkan jumlah kelas agar hasil prediksi lebih baik.

Keempat, sumber data hanya berasal dari satu institusi, yaitu Universitas Muhammadiyah Kudus. Hal ini dapat membatasi validitas eksternal temuan, karena karakteristik sosial, akademik, dan religius mahasiswa di universitas lain mungkin berbeda. Oleh karena itu, penelitian berikutnya diharapkan dapat memperluas cakupan ke beberapa perguruan tinggi Islam di wilayah berbeda guna memperoleh model yang lebih *general* dan *robust*.

Keterbatasan-keterbatasan ini penting untuk dipertimbangkan dalam interpretasi hasil. Meskipun model SVM menunjukkan kinerja tinggi dengan akurasi 94,05% dan recall sempurna, performa tersebut mungkin bersifat spesifik terhadap karakteristik dataset penelitian ini. Pengumpulan data dengan sampel yang lebih besar, seimbang, dan multi-institusi di masa mendatang akan memperkuat reliabilitas dan generalisasi temuan serta memungkinkan pengujian ulang terhadap konsistensi model pada konteks demografis yang berbeda.

4.9 Implikasi Praktis dan Akademik

Penelitian ini memberikan kontribusi yang signifikan tidak hanya dalam tataran teoritis, tetapi juga dalam ranah praktis dan akademik yang saling menguatkan. Secara praktis, model deteksi dini kesehatan mental yang dikembangkan melalui pendekatan *machine learning* ini dapat diterapkan sebagai sistem peringatan dini di lingkungan kampus, khususnya pada perguruan tinggi berbasis nilai-nilai Islam seperti Universitas Muhammadiyah Kudus. Sistem ini berpotensi membantu lembaga pendidikan dalam mengidentifikasi mahasiswa yang berisiko mengalami gangguan kesehatan mental secara cepat dan akurat, bahkan sebelum gejala yang serius muncul. Dengan memanfaatkan data survei dan indikator perilaku keagamaan, sistem ini dapat memfasilitasi pendekatan preventif yang lebih responsif dan terukur, sehingga intervensi psikologis dan spiritual dapat diberikan secara tepat waktu dan kontekstual. Dengan landasan metodologis yang kuat dan validasi empiris yang mendalam, hasil penelitian ini diharapkan dapat menjadi rujukan bagi penelitian-penelitian lanjutan, serta

mendorong kolaborasi lintas bidang keilmuan dalam pengembangan sistem teknologi yang bermanfaat secara sosial dan relevan secara spiritual.

5 Kesimpulan

Penelitian ini berhasil merancang model deteksi kesehatan mental mahasiswa berbasis *machine learning* dengan menggunakan algoritma Random Forest, SVM, KNN, dan Decision Tree yang dibandingkan kinerjanya antara sebelum dan sesudah optimasi. Hasil pengujian menunjukkan bahwa kinerja model yang dioptimasi dengan GridSearchCV mampu meningkatkan performa seluruh model yang dibangun, model terbaik diperoleh SVM yang menghasilkan akurasi tertinggi sebesar 94,05 %, *precision* sebesar 94,67%, *recall* sebesar 100 %, dan *f1-score* sebesar 93,91%, sehingga lebih optimal untuk mendeteksi mahasiswa dengan potensi masalah kesehatan mental. Namun penelitian ini masih memiliki keterbatasan pada data yang tidak seimbang antara kelas mental bermasalah dan sehat sehingga mempengaruhi kemampuan model dalam mendeteksi kelas minoritas yaitu:mental bermasalah. Oleh karena itu, penelitian selanjutnya disarankan menggunakan teknik penyeimbangan data seperti SMOTE sehingga hasil model dalam deteksi kesehatan mental menghasilkan kinerja yang lebih baik.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia melalui Direktorat Penelitian dan Pengabdian kepada Masyarakat (DPPM) yang telah memberikan dukungan pendanaan dalam penelitian ini dengan skema Penelitian Dosen Pemula Tahun Anggaran 2025 dengan nomer kontrak 046/LL6/PL/AL.04/2025. Dukungan ini sangat membantu dalam proses pelaksanaan penelitian hingga penyusunan artikel ilmiah.

Referensi

- [1] M. Arif, S. Irfan, M. M. Rhaman Shaoan, and W. Ali, “AI and Machine Learning in Islamic Guidance: Opportunities, Ethical Considerations, and Future Directions,” *Guidance*, Vol. 21, No. 02, pp. 429–451, 2025, DOI: 10.34005/guidance.v21i02.4449.
- [2] Muhammadu Ibrahim Nasrin, “The Influence of Islamic Spiritual Values on Students’ Mental Health: A Special Focus on Tawakkul (توكل), Sabr (صبر) and Shukr(شکر),” *Lect. J. Islam. Educ. Stud.*, Vol. 4, No. 2, pp. 260–272, 2025, DOI: 10.58355/lectures.v4i2.150.
- [3] M. I. Siraji, A. A. Rahman, M. M. Nishat, M. A. Mamun, F. Faisal, L. I. Khalid, and A. Ahmed, *Impact of Mobile Connectivity on Students’ Wellbeing: Detecting Learners’ Depression using Machine Learning Algorithms*, Vol. 18, No. 11 November. 2023. DOI: 10.1371/journal.pone.0294803.
- [4] M. Razavi, S. Ziyadidegan, A. Mahmoudzadeh, S. Kazeminasab, E. Baharlouei, V. Janfaza, R. Jahromi, and F. Sasangohar, “Machine Learning, Deep Learning, and Data Preprocessing Techniques for Detecting, Predicting, and Monitoring Stress and Stress-Related Mental Disorders: Scoping Review,” *JMIR Ment. Heal.*, Vol. 11, 2024, DOI: 10.2196/53714.
- [5] A. Algumaei, N. M. Yaacob, M. Doheir, M. N. Al-Andoli, and M. Algumaei, “Symmetric Therapeutic Frameworks and Ethical Dimensions in AI-based Mental Health Chatbots (2020–2025): A Systematic Review of Design Patterns, Cultural Balance, and Structural Symmetry,” *Symmetry (Basel.)*, Vol. 17, No. 7, 2025, DOI: 10.3390/sym17071082.
- [6] N. F. A. Mazzuki, N. S. ssir Sukeri, M. I. Abdullah, U. Jaffer, N. Mohd Kadri, and C. M. N. Che Mohd Nassir, “Spirituality, Spiritual Coping and Mental Well-Being among Malaysian Medical and Health Sciences Students,” *Int. J. Educ. Psychol. Couns.*, Vol. 9, No. 56, pp. 897–910, 2024, DOI: 10.35631/ijepc.956055.
- [7] E. Oksanda and E. Zulaifah, “Religiosity, Resilience and Psychological Well-Being among University Students in Indonesia,” *Int. J. Islam. Psychol.*, Vol. 8, No. 1, pp. 64–5, 2025, [Online]. Available: <https://eur-lex.europa.eu/legal-content/PT/TXT/PDF/?uri=CELEX:32016R0679&from=PT%0Ahttp://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=CELEX:52012PC0011:pt:NOT>
- [8] M. Çınaroglu, “Islamically Modified Cognitive Behavioral Therapy,” *Din ve İnsan Derg.*, Vol.

- 4, No. 7, pp. 60–85, 2024, DOI: 10.69515/dinveinsan.1437013.
- [9] M. N. Hossain, N. Fahad, R. Ahmed, A. Sen, M. S. Al Huda, and M. I. Hossen, “*Preventing Student’s Mental Health Problems with the Help of Data Mining*,” *Int. J. Comput.*, Vol. 23, No. 1, pp. 101–108, 2024, DOI: 10.47839/ijc.23.1.3441.
- [10] M. Huda and S. Slamet, “*Mental Health Concept in Islamic Education*,” *Int. J. Educ. Elem. Psychol.*, Vol. 1, No. 3, pp. 169–179, 2024, DOI: 10.70177/ijep.v1i3.1092.
- [11] D. Deprizon, R. Refika, S. Sahlam, U. R. Nursyam, A. Lestari, and A. Widyanthi, “Peran Edukasi Digital Islami dalam Menyikapi Kesehatan Mental (Stres) Mahasiswa Program Studi Pendidikan Guru Madrasah Ibtidaiyah (PGMI),” *kependidikan MI*, Vol. 02, pp. 127–140, 2024, [Online]. Available: <https://doi.org/10.46963/mpgmi/v10i1.1668>
- [12] S. Musabiq and I. Karimah, “Gambaran Stress dan Dampaknya pada Mahasiswa,” *Insight SCI. J. Psychol.*, Vol. 20, No. 2, p. 74, 2018, DOI: 10.26486/psikologi.v20i2.240.
- [13] T. Chen, “*Investigating the Mental Health of University Students during the COVID-19 Pandemic in a UK University: A Machine Learning Approach using Feature Permutation Importance*,” *Brain Informatics*, Vol. 10, No. 1, 2023, DOI: 10.1186/s40708-023-00205-8.
- [14] Lina Eta Safitri and Ovi Soviya, “Kesehatan Mental dan Pendidikan Agama Islam Mahasiswa di STIKES Griya Husada Sumbawa,” *J. Anestesi*, Vol. 3, No. 1, pp. 45–50, 2024, DOI: 10.59680/anestesi.v3i1.1584.
- [15] Anis Sintya and Ike Utia Ningsih, “Peran Sholat dalam mengurangi Stres dan Kecemasan,” *J. Psychol. Soc. SCI.*, Vol. 3, No. 2, pp. 62–70, 2025, DOI: 10.61994/jpss.v3i2.1059.
- [16] O. Iparraguirre-, “*Machine Learning Models to Classify and Predict Depression in College Students*,” Vol. 18, No. 14, pp. 148–163, 2024, DOI: 10.3991/ijim.v18i14.48669.
- [17] J. Qiu, L. Cheng, and J. Huang, “*Charting the Landscape of Artificial Intelligence Ethics: A Bibliometric Analysis*,” *Int. J. Digit. Law Gov.*, Vol. 2, No. 1, pp. 135–167, 2025, DOI: 10.1515/ijdlg-2025-0007.
- [18] C. El Morr, M. Jammal, I. Bou-Hamad, S. Hijazi, D. Ayna, M. Romani, and R. Hoteit, “*Predictive Machine Learning Models for Assessing Lebanese University Students’ Depression, Anxiety, and Stress During COVID-19*,” *J. Prim. Care Community Heal.*, Vol. 15, 2024, DOI: 10.1177/21501319241235588.
- [19] N. Nurdiansyah, F. S. Febriyan, Z. Gesit, and D. Amanta, “*Mental Health Analysis to Prevent Mental Disorders in Students using the K-Nearest Neighbor (K-NN) Algorithm and Random Forest Algorithm* Analisis Kesehatan Mental untuk mencegah Gangguan Mental pada Mahasiswa menggunakan Algoritma K-Nearest Neighbor (K),” *MALCOM Indones. J. Mach. Learn. Comput. SCI.*, Vol. 5, No. January, pp. 1–9, 2025, DOI: 10.57152/malcom.v5i1.1537.
- [20] L. Umbari Putri, R. Yesputra, S. Y. Prayogi, N. Marpaung, and J. Hutahean, “*Stacking Ensemble Model Machine Learning* Deteksi Dini Risiko Kesehatan Mental di Lingkungan Pendidikan,” Vol. 4307, No. August, pp. 4256–4266, 2024, DOI: 10.54314/jssr.v8i3.4147.
- [21] M. Rahma, M. Fikry, and Y. Afrillia, “*Prediksi Kesehatan Mental Remaja berdasarkan Faktor Lingkungan Sekolah menggunakan Machine Learning*,” *J. Inform. J. Pengemb. IT*, Vol. 10, No. 2, pp. 382–390, 2025, DOI: 10.30591/jpit.v10i2.8556.
- [22] E. M. Arias, J. Parraga-Alava, and D. Z. Montenegro, “*Stress Detection among Higher Education Students: A Comprehensive Systematic Review of Machine Learning Approaches*,” *Int. Conf. eDemocracy eGovernment, ICEDEG*, No. 2024, pp. 1–8, 2024, DOI: 10.1109/ICEDEG61611.2024.10702055.
- [23] D. Anggreani, Hamdani, and Nurmisba, “*Grid Search Hyperparameter Analysis in Optimizing the Decision Tree Method for Diabetes Prediction*,” *Indones. J. Data SCI.*, Vol. 5, No. 3, pp. 190–197, 2024, DOI: 10.56705/ijodas.v5i3.190.
- [24] M. Salmi, D. Atif, D. Oliva, A. Abraham, and S. Ventura, *Handling Imbalanced Medical Datasets: Review of a Decade of Research*, Vol. 57, No. 10. Springer Netherlands, 2024. DOI: 10.1007/s10462-024-10884-2.