

Analisis Performa Algoritma Machine Learning Untuk Identifikasi Depresi Pada Mahasiswa

Mutia Fadhilla¹, Rizky Wandri^{1*}, Anggi Hanafiah¹, Panji Rachmat Setiawan¹, Yudhi Arta¹, Suandi Daulay²

¹ Program Studi Teknik Informatika, Fakultas Teknik, Universitas Islam Riau, Pekanbaru, Indonesia

² Sistem Informasi, Sekolah Tinggi Teknologi Pekanbaru, Pekanbaru, Indonesia

Email: ¹tiafadhilla@eng.uir.ac.id, ^{2*}rizkywandri@eng.uir.ac.id, ³anggihanafiah@eng.uir.ac.id, ⁴panji.r.setiawan@eng.uir.ac.id,

⁵yudhiarta@eng.uir.ac.id, ⁶suwandidaulay90@gmail.com

Email Penulis Korespondensi: rizkywandri@eng.uir.ac.id

Abstrak—Kesehatan mental, khususnya depresi, menjadi isu penting di kalangan mahasiswa akibat tekanan akademik, sosial, dan penggunaan media sosial. Deteksi depresi menghadapi tantangan seperti stigma, literasi rendah, dan metode konvensional yang kurang efektif. Teknologi machine learning menawarkan solusi dengan algoritma seperti Naive Bayes, SVM, dan Random Forest untuk meningkatkan akurasi deteksi, mendukung intervensi dini, serta memperbaiki sistem kesehatan mental mahasiswa. Kesehatan mental, khususnya depresi, menjadi isu penting di kalangan mahasiswa akibat tekanan akademik, sosial, dan penggunaan media sosial. Deteksi depresi menghadapi tantangan seperti stigma, literasi rendah, dan metode konvensional yang kurang efektif. Teknologi machine learning menawarkan solusi dengan algoritma seperti Naive Bayes, K-Nearest Neighbor, Decision Tree, Logistic Regression, Random Forest, dan Support Vector Machine untuk meningkatkan akurasi deteksi, mendukung intervensi dini, serta memperbaiki sistem kesehatan mental mahasiswa. Berdasarkan hasil analisis performa dari algoritma machine learning, model yang paling efektif dalam memprediksi status depresi pada mahasiswa yaitu Logistic Regression yang memiliki tingkat akurasi sebesar 95,62%. Sebagai langkah strategis, teknologi machine learning dapat diintegrasikan untuk diagnosis awal depresi pada mahasiswa. Sistem ini diharapkan lebih efektif dan efisien, meningkatkan akurasi diagnosis, dan membuka peluang pendekatan baru dalam kesehatan mental yang responsif dan berbasis data.

Kata Kunci: Kesehatan Mental; Depresi; Machine Learning; Deteksi Dini; Akurasi Diagnosis

Abstract—Mental health, especially depression, is a major issue among college students due to academic, social, and social media pressures. Depression detection faces challenges such as stigma, low literacy, and ineffective conventional methods. Machine learning technology offers solutions with algorithms such as Naive Bayes, SVM, and Random Forest to improve detection accuracy, support early intervention, and improve the student mental health system. Mental health, especially depression, is a major issue among college students due to academic, social, and social media pressures. Depression detection faces challenges such as stigma, low literacy, and ineffective conventional methods. Machine learning technology offers solutions with algorithms such as Naive Bayes, K-Nearest Neighbor, Decision Tree, Logistic Regression, Random Forest, and Support Vector Machine to improve detection accuracy, support early intervention, and improve the student mental health system. Based on the results of the performance analysis of the machine learning algorithm, the most effective model in predicting depression status in students is Logistic Regression which has an accuracy rate of 95.62%. As a strategic step, machine learning technology can be integrated for early diagnosis of depression in students. This system is expected to be more effective and efficient, improve diagnostic accuracy, and open up opportunities for new approaches to responsive, data-driven mental health.

Keywords: Mental Health; Depression; Machine Learning; Early Detection; Diagnostic Accuracy

1. PENDAHULUAN

Aspek krusial saat berada di lingkungan perkuliahan yaitu kesehatan mental khususnya depresi yang sudah mulai diperhatikan. Tidak bisa dikhianati, mahasiswa modern saat ini menghadapi tantangan yang begitu kompleks. Mengacu pada data yang dikeluarkan oleh WHO, angka penderita depresi global berada di eskalasi dengan total akumulatif mencapai 300 juta jiwa dan dominasi pencatatan kasus ini oleh kaum remaja dan dewasa [1]. Penelitian menunjukkan bahwa sekitar 46% remaja mengalami beberapa bentuk penyakit mental setiap tahunnya, dan dari jumlah tersebut, sebagian besar tidak menerima perawatan kesehatan yang memadai karena kurangnya kesadaran mengenai kesehatan mental [2]. Mahasiswa salah satu kelompok yang rentan terhadap tekanan yang dapat memicu depresi, hal ini disebabkan oleh tekanan akademik di dunia pendidikan, masalah keuangan serta interaksi sosial yang tidak sehat, terutama yang berkaitan dengan penggunaan media sosial [3]. Banyak mahasiswa merasa tertekan dan terasing karena berpikiran negatif dan membandingkan diri mereka dengan orang lain dan yang dapat memperburuk keadaan mereka salah satunya penggunaan media sosial yang sering kali berlebihan. Edukasi kesadaran mengenai kesehatan mental sangat penting di kalangan mahasiswa. Program psikoedukasi yang bertujuan untuk membuat mahasiswa lebih mengenal penyakit depresi dan cara pengobatannya [4], [5]. Berdasarkan penelitian, kegiatan sosialisasi dan seminar tentang kesehatan mental dapat meningkatkan tingkat kesadaran dan pengetahuan mahasiswa mengenai isu ini, sehingga mereka lebih siap untuk menghadapi tantangan yang ada [6].

Mendeteksi depresi di kalangan mahasiswa merupakan tantangan yang signifikan, terutama karena kesulitan mereka dalam menyadari dan mengakui gejala yang muncul. Mahasiswa sering kali mengalami tekanan akademik yang tinggi, yang dapat memicu atau memperburuk kondisi depresi. Penelitian menunjukkan bahwa mahasiswa kedokteran memiliki prevalensi depresi yang lebih tinggi dibandingkan dengan mahasiswa dari jurusan lain dengan angka mencapai 34,9% [7]. Stressor akademik, seperti tuntutan belajar yang berat dan transisi dari sekolah menengah ke perguruan tinggi, berkontribusi besar terhadap munculnya gejala depresi [8].

Salah satu faktor yang memperumit deteksi depresi adalah stigma yang melekat pada gangguan kesehatan mental. Banyak mahasiswa merasa malu atau takut untuk mengakui bahwa mereka mengalami masalah emosional, yang dapat menghalangi mereka untuk mencari bantuan. Penelitian menunjukkan bahwa mahasiswa sering kali tidak menyadari gejala depresi yang mereka alami, seperti perasaan sedih yang berkepanjangan, putus asa, dan rendah diri [9]. Hal ini diperparah oleh kurangnya literasi kesehatan mental di kalangan mahasiswa, yang dapat menghambat kemampuan mereka untuk mengenali dan memahami kondisi mereka sendiri [10].

Penelitian menunjukkan bahwa pembelajaran daring juga berkontribusi pada peningkatan tingkat stres dan kecemasan, yang selanjutnya dapat memicu gejala depresi [11], [12]. Secara keseluruhan, tantangan dalam mendeteksi depresi di kalangan mahasiswa sangat kompleks dan melibatkan berbagai faktor, termasuk stigma, literasi kesehatan mental, dukungan sosial, dan tekanan akademik. Upaya untuk meningkatkan kesadaran dan pemahaman tentang kesehatan mental di kalangan mahasiswa.

Deteksi depresi merupakan tantangan signifikan dalam bidang kesehatan mental, terutama ketika mempertimbangkan keterbatasan metode konvensional yang sering digunakan. Metode konvensional, seperti wawancara klinis dan kuesioner standar, sering kali tidak cukup untuk menangkap kompleksitas dan variasi gejala depresi yang dialami individu. Penelitian menunjukkan bahwa banyak kasus depresi, terutama pada pasien dengan kondisi medis tertentu seperti stroke, tidak terdeteksi karena kurangnya perhatian dari *caregiver* atau tenaga kesehatan [13]. Hal ini menunjukkan bahwa metode konvensional sering kali tidak sensitif terhadap gejala awal yang mungkin muncul, sehingga mengakibatkan diagnosis yang terlambat dan perawatan yang tidak memadai.

Deteksi depresi merupakan tantangan signifikan dalam bidang kesehatan mental, terutama ketika mempertimbangkan keterbatasan metode konvensional yang sering digunakan. Metode konvensional, seperti wawancara klinis dan kuesioner standar, sering kali tidak cukup untuk menangkap kompleksitas dan variasi gejala depresi yang dialami individu. Penelitian menunjukkan bahwa banyak kasus depresi, terutama pada pasien dengan kondisi medis tertentu seperti stroke, tidak terdeteksi karena kurangnya perhatian dari *caregiver* atau tenaga kesehatan [13]. Hal ini menunjukkan bahwa metode konvensional sering kali tidak sensitif terhadap gejala awal yang mungkin muncul, sehingga mengakibatkan diagnosis yang terlambat dan perawatan yang tidak memadai.

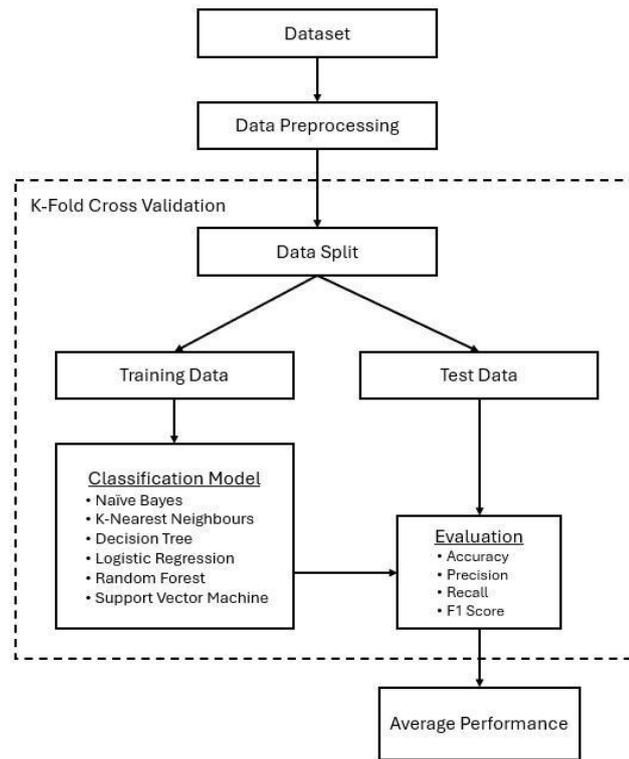
Penggunaan teknologi dalam diagnosis depresi, seperti sistem pakar dan metode berbasis *machine learning*, menunjukkan potensi yang menjanjikan untuk mengatasi keterbatasan metode konvensional. Sebagai contoh, metode *Certainty Factor* dan *Support Vector Machine* (SVM) telah diusulkan sebagai alternatif untuk meningkatkan akurasi dan efisiensi dalam mendeteksi depresi [14]. Metode ini tidak hanya dapat mengurangi kesalahan manusia dalam diagnosis tetapi juga mempercepat proses identifikasi gejala, sehingga memungkinkan intervensi yang lebih cepat dan tepat [15]. Dengan demikian, integrasi teknologi dalam diagnosis depresi dapat menjadi langkah penting untuk meningkatkan deteksi dan perawatan kesehatan mental.

Machine learning (ML) telah muncul sebagai alat yang menjanjikan untuk mendeteksi depresi di kalangan mahasiswa, memanfaatkan berbagai algoritma untuk meningkatkan kecepatan dan akurasi deteksi. Penerapan ML dalam konteks ini sangat relevan mengingat semakin tingginya prevalensi masalah kesehatan mental di kalangan mahasiswa, yang dapat berdampak signifikan pada kinerja akademis dan kesejahteraan mereka secara keseluruhan [16], [17], [18]. Beberapa penelitian telah menunjukkan efektivitas berbagai algoritma pembelajaran mesin dalam mengidentifikasi gejala depresi. Misalnya, penerapan metode pembelajaran mesin *ensemble* terbukti meningkatkan kemampuan deteksi dengan menggabungkan beberapa algoritma untuk meningkatkan kinerja secara keseluruhan [19]. Hasil dari penelitian ini menunjukkan bahwa ML dapat memberikan penilaian depresi yang tepat waktu dan akurat, yang penting untuk intervensi dini dan dukungan bagi siswa yang berisiko [20]. Integrasi pembelajaran mesin dalam mendeteksi depresi di kalangan mahasiswa menghadirkan kemajuan signifikan dalam penilaian kesehatan mental. Kombinasi berbagai algoritma, termasuk metode ML tradisional dan teknik pembelajaran mendalam modern, bersama dengan data dari media sosial dan perangkat yang dapat dikenakan, menawarkan kerangka kerja yang komprehensif untuk deteksi gejala depresi yang tepat waktu dan akurat.

Fokus penelitian ini untuk menganalisis dan evaluasi performa enam algoritma *machine learning* yaitu Naive Bayes, *K-Nearest Neighbor*, *Decision Tree*, *Logistic Regression*, *Random Forest*, dan *Support Vector Machine*. Penelitian ini bertujuan untuk mengevaluasi performa algoritma *machine learning* dalam mendeteksi depresi pada mahasiswa, membandingkan akurasi, presisi, *recall*, dan metrik lainnya untuk menentukan algoritma terbaik serta memberikan rekomendasi untuk penerapan *machine learning* dalam deteksi depresi. Manfaat penelitian ini untuk memberikan wawasan baru mengenai performa algoritma *machine learning* dalam bidang kesehatan mental dan membantu institusi pendidikan atau profesional kesehatan dalam mengembangkan sistem deteksi dini depresi yang efektif.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif untuk mengevaluasi performa enam algoritma *machine learning* (Naive Bayes, *K-Nearest Neighbor*, *Decision Tree*, *Logistic Regression*, *Random Forest*, dan *Support Vector Machine*) dalam klasifikasi tingkat depresi mahasiswa. Analisis dilakukan dengan membandingkan akurasi, presisi, *recall*, dan nilai F1 dari setiap algoritma. *Dataset* yang digunakan dalam penelitian ini adalah data tingkat depresi mahasiswa. Gambar 1 merupakan langkah-langkah penelitian meliputi:



Gambar 1. Alur Penelitian

- a. Persiapan Data
Mengumpulkan dan memahami *dataset*.
- b. Preprocessing Data
Mengatasi nilai yang hilang atau tidak *valid*, normalisasi atau standarisasi data jika diperlukan.
- c. Split Data
Teknik mendasar dalam analisis data dan pembelajaran mesin, yang digunakan untuk mengevaluasi kinerja model prediktif.
- d. Implementasi Algoritma
Menerapkan setiap algoritma menggunakan *pipeline* pemrosesan. Algoritma terdiri dari:

1. Naïve Bayes

Naïve Bayes merupakan model pembelajaran mesin *probabilistik* yang didasarkan pada Teorema Bayes. Model ini digunakan untuk melakukan tugas klasifikasi, yaitu pengelompokan atau pengkategorian data berdasarkan pada ciri-ciri atau pola-pola tertentu pada data. Teorema Bayes menyediakan mekanisme untuk memperbarui estimasi probabilitas untuk suatu kelas berdasarkan bukti baru menggunakan formula:

$$p(x) = \frac{p(C_k) \cdot p(x|C_k)}{p(x)} \tag{1}$$

di mana $p(x)$ merepresentasikan peluang posterior dari kelas C_k yang diberikan input fitur x , $p(C_k)$ merupakan peluang prior dari kelas C_k , $p(x|C_k)$ adalah kemungkinan fitur x pada kelas C_k , dan $p(x)$ adalah kemungkinan munculnya fitur x pada data. Model klasifikasi ini memprediksi kategori atau kelas berdasarkan hasil pengolahan dari setiap peluang posterior variabel pada setiap kelas yang ada dan mengambil nilai tertinggi.

2. K-Nearest Neighbor

Algoritma *k-Nearest Neighbors* (K-NN) merupakan salah satu metode fundamental pada *machine learning* yang bersifat non-parametrik. Algoritma ini dapat digunakan untuk melakukan tugas klasifikasi maupun *regresi* pada *machine learning*. KNN bekerja dengan prinsip bahwa klasifikasi dari suatu titik data dapat diambil berdasarkan kelas mayoritas antara k tetangga terdekat dari titik data tersebut. Adapun tahapan pada algoritma ini yaitu:

- a) Mencari jarak dari titik data yang ingin diklasifikasi dengan titik data yang ada pada semua data latih, di mana pada penelitian ini jarak dihitung menggunakan rumus jarak *Euclidean*:

$$D_{i,j} = \sqrt{\sum_{k=1}^n (X_{ik} - X_{jk})^2} \tag{2}$$

- b) Menentukan k tetangga yang terdekat dari titik data, di mana pada penelitian ini menggunakan beberapa nilai k sebagai pengujian yaitu 3, 5, 7, dan 9.

- c) Melakukan voting dengan menetapkan label kelas yang paling sering muncul di antara k tetangga terdekat.
3. Decision Tree
Decision Tree merupakan salah satu model sederhana pada *supervised machine learning*, yang digunakan untuk melakukan tugas klasifikasi. Selama proses pelatihan, model ini akan membangun sebuah struktur pohon keputusan yang digunakan untuk mendapatkan hasil klasifikasi. Pembuatan pohon keputusan melibatkan pemisahan data secara rekursif berdasarkan nilai fitur untuk memaksimalkan pemisahan kelas. Proses ini berlanjut hingga kriteria penghentian terpenuhi, seperti mencapai kedalaman pohon yang telah ditentukan sebelumnya atau mencapai tingkat kemurnian tertentu di simpul daun. Tujuan utamanya adalah untuk membuat model yang memprediksi nilai variabel target berdasarkan beberapa variabel input. Pada penelitian ini, algoritma yang digunakan pada *Decision Tree* untuk membangun struktur pohon yaitu Iterative Dichotomiser 3 (ID3). Algoritma ini membuat percabangan pohon Keputusan berdasarkan nilai *Information Gain* yang dimiliki oleh setiap atribut pada data.
4. Logistic Regression
Logistic Regression merupakan salah satu model probabilistik pada *Machine Learning*, seperti model Naïve Bayes. Model ini biasanya digunakan untuk klasifikasi biner dengan memprediksi probabilitas suatu hasil yang hanya memiliki dua kemungkinan (ya atau tidak, benar atau salah, dan lainnya). Pada *Logistic Regression*, menerapkan fungsi logistik berbentuk 'S' yang memprediksi dua nilai maksimum yaitu antara 0 atau 1. Pada penelitian ini fungsi *logistic* yang digunakan adalah fungsi sigmoid. Adapun input dari fungsi *logistic* tersebut merupakan variabel independen dari *dataset* yang berupa:
- $$v = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n \quad (3)$$
- Di mana v merupakan variabel independen yang terdiri dari bias β dan atribut fitur (x) dari dataset.
5. Random Forest
Random Forest merupakan salah satu metode *Ensemble Machine Learning* yang digunakan untuk klasifikasi dengan menggabungkan beberapa pohon Keputusan. Pendekatan model ini digunakan untuk mengurangi *overfitting* dan meningkatkan generalisasi pada proses pelatihan. *Random Forest* bekerja dengan membangun banyak pohon Keputusan selama pelatihan dan mengeluarkan hasil model klasifikasi atau prediksi regresi dari masing-masing pohon keputusan. Setelah setiap pohon membuat prediksinya, *Random Forest* akan menggabungkan prediksi tersebut. Untuk klasifikasi, kelas dengan suara terbanyak di semua pohon akan dipilih sebagai hasil prediksi akhir.
6. Support Vector Machine
Support Vector Machine (SVM) adalah salah satu model *Supervised Machine Learning* yang digunakan untuk klasifikasi atau regresi. Model ini bekerja dengan mengidentifikasi *hyperplane* optimal yang dapat memisahkan data dari kelas yang berbeda dengan margin terbesar. Tujuan utama SVM adalah menemukan *hyperplane* yang secara jelas mengklasifikasikan titik data dalam ruang berdimensi-N. *Hyperplane* yang optimal dapat memaksimalkan margin, yang didefinisikan sebagai jarak antara *hyperplane* dan titik data terdekat dari salah satu kelas, yang dikenal sebagai vektor pendukung. Pemaksimalan ini memastikan bahwa model mencapai pemisahan terbaik antara kelas, sehingga mengurangi kesalahan klasifikasi. Adapun fungsi kernel, yang menentukan bagaimana model ini memetakan data input ke ruang berdimensi-N sehingga dapat dipisah oleh *hyperplane*, pada penelitian ini menggunakan *Radial Basis Function* (RBF) Kernel.
- e. Evaluasi Kinerja
 Mengukur performa algoritma berdasarkan metrik akurasi, presisi, *recall*, dan nilai F1 dan membandingkan hasil untuk menentukan algoritma dengan performa terbaik menggunakan *confusion matrix*.
- f. Average Performance
 Menginterpretasikan hasil evaluasi untuk menjawab tujuan penelitian.

3. HASIL DAN PEMBAHASAN

Temuan penelitian ini diharapkan dapat membantu memberikan wawasan baru mengenai performa algoritma *machine learning* dalam bidang kesehatan mental dan membantu institusi pendidikan atau profesional kesehatan dalam mengembangkan sistem deteksi dini depresi yang efektif. Selanjutnya menerapkan setiap algoritma yang digunakan untuk mengukur performa algoritma berdasarkan metrik akurasi, presisi, *recall*, dan nilai F1 dan membandingkan hasil untuk menentukan algoritma dengan performa terbaik.

3.1 Dataset

Peneliti menggunakan *dataset* yang di dapat dari data keggle tentang *Depression Student* yang berjumlah 502 data. Yang terdiri dari (*Gender, Age, Academic Pressure, Study Satisfaction, Sleep Duration, Dietary Habits, Suicidal Thought, Study Hours, Financial Stress, Family History, Depression*).

Tabel 1. *Depression Student Dataset*

No	Gender	Age	Family History of Mental Illness	...	Depression
----	--------	-----	----------------------------------	-----	------------

1	Male	28	Yes	...	No
2	Male	28	Yes	...	No
3	Male	25	No	...	Yes
...
50 0	Female	23	Yes	...	No
50 1	Male	33	Yes	...	No
50 2	Male	18	Yes	...	Yes

3.2 Preprocessing Data

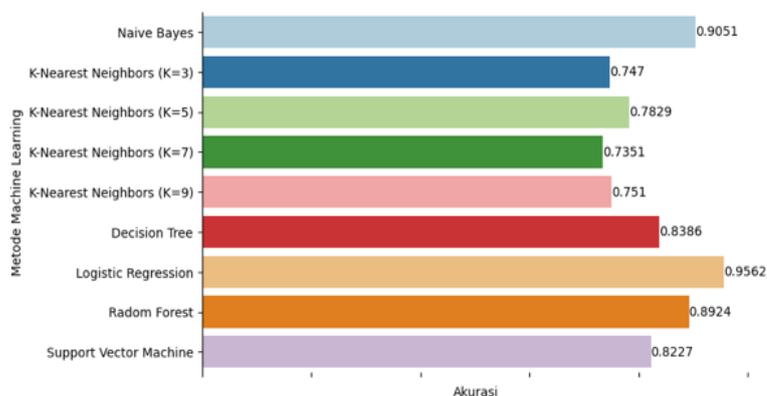
Tabel 2. Hasil Preprocessing Data

Gender	Age	...	Family History of Mental Illness	Depression
1	28	...	1	0
1	28	...	1	0
1	25	...	0	1
1	23	...	1	0
0	31	...	1	0
...

Pre-processing data merupakan tahapan awal yang sangat penting pada proses *Machine Learning*. Tahapan ini digunakan untuk mengubah data mentah menjadi data yang memiliki format sesuai dengan model *Machine Learning* yang akan digunakan. *Pre-processing* data akan memastikan bahwa format data bersih dan konsisten, sehingga dapat diproses secara efektif oleh algoritma *Machine Learning*. Data yang diproses sebelumnya dengan buruk dapat menghasilkan model yang tidak akurat dan hasil yang kurang optimal. Pada penelitian ini, tahapan *preprocessing* yang dilakukan adalah *Label Encoding*, di mana pada proses ini mengubah data kategorik menjadi data numerik sehingga dapat digunakan dalam model pembelajaran mesin, yang terutama bekerja dengan masukan numerik. Sebagai contoh, data jenis kelamin Laki-laki diubah menjadi 0 dan Perempuan menjadi 1. Semua atribut serta label kategori pada *dataset* menggunakan proses ini pada tahapan *pre-processing*.

3.3 Analisis Performa Algoritma

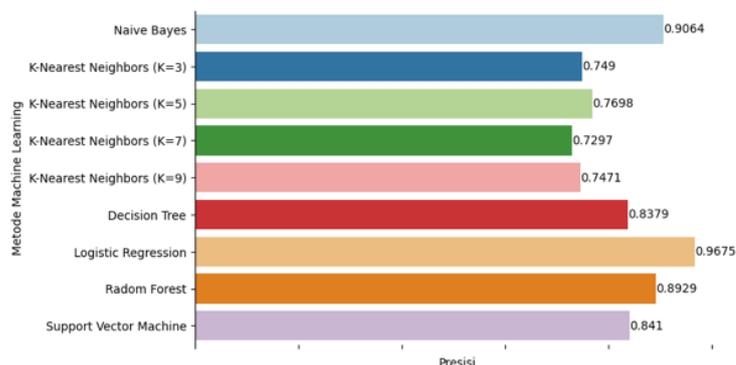
Evaluasi performa model merupakan salah satu tahapan penting dalam membangun model pada *Machine Learning*. Hal ini untuk menentukan seberapa efektif model dalam menerapkan pengetahuan yang didapatkan dari proses pelatihan data terhadap data baru yang belum pernah dikenal sebelumnya. Pada penelitian ini, evaluasi performa model *machine learning* menggunakan bantuan *Confusion Matrix*, yang merepresentasikan secara visual mengenai hasil prediksi dari model *machine learning* dibandingkan dengan yang sebenarnya. Berdasarkan matriks ini, dapat dilakukan perhitungan beberapa metrik untuk mengevaluasi performa model *machine learning*, diantaranya tingkat akurasi, presisi, *recall*, dan skor F1.



Gambar 2. Hasil Evaluasi *Machine Learning* (Akurasi)

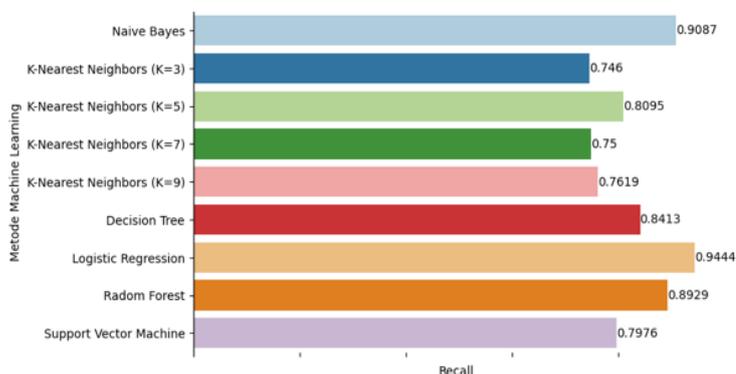
Tingkat akurasi setiap model *machine learning* yang digunakan pada penelitian ini dapat dilihat pada gambar di atas. Pada Gambar 2, berdasarkan hasil evaluasi dengan menggunakan metrik akurasi, *Logistic Regression* memiliki tingkat akurasi paling tinggi dibandingkan dengan model-model lainnya, yaitu 95,62%. Hal ini menunjukkan bahwa model ini adalah model yang paling efektif melakukan prediksi depresi pada mahasiswa berdasarkan tingkat akurasi, diikuti oleh model *Naive Bayes* dan *Random Forest* dengan performa yang sangat baik. Adapun *Decision Tree* dan *Support Vector Machine* menunjukkan akurasi yang lebih rendah dibandingkan *Naive Bayes* dan *Random Forest*, tetapi

masih cukup baik yaitu 83,86% dan 82,27%. Sedangkan model *K-Nearest Neighbors* memiliki tingkat akurasi paling rendah dibandingkan model lainnya, dengan tingkat akurasi terbaik pada nilai, yaitu 78,29% dengan menggunakan nilai $K=5$.



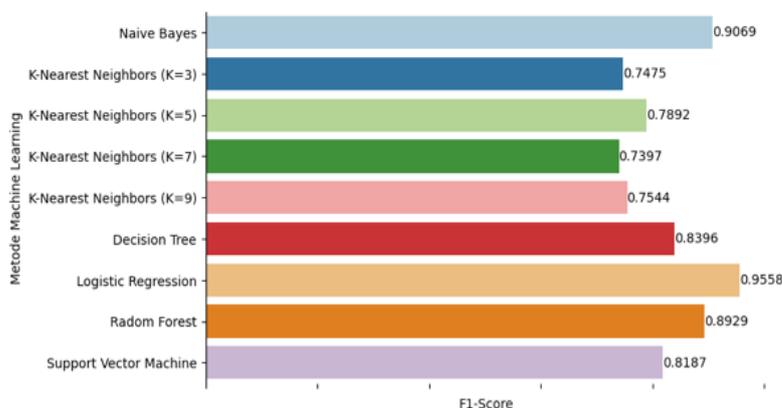
Gambar 3. Hasil Evaluasi Machine Learning (Presisi)

Hasil evaluasi model *Machine Learning* menggunakan metrik presisi dapat dilihat pada grafik di atas. Pada Gambar 3, model terbaik berdasarkan skor metrik presisi sama dengan model terbaik berdasarkan tingkat akurasi, yaitu *Logistic Regression*. Model ini memiliki skor presisi yaitu 96,75%. Hal ini menunjukkan bahwa model ini tidak hanya memiliki tingkat akurasi tinggi dalam memprediksi status depresi mahasiswa, tetapi juga mampu dalam memprediksi kelas positif dengan sangat baik. Selain model ini, *Naive Bayes* dan *Random Forest* juga memiliki skor presisi yang tinggi yaitu 90,64% dan 89,29%. Sedangkan model yang memiliki skor presisi paling rendah yaitu model *K-Nearest Neighbors* dengan nilai $K=7$.



Gambar 4. Hasil Evaluasi Machine Learning (Recall)

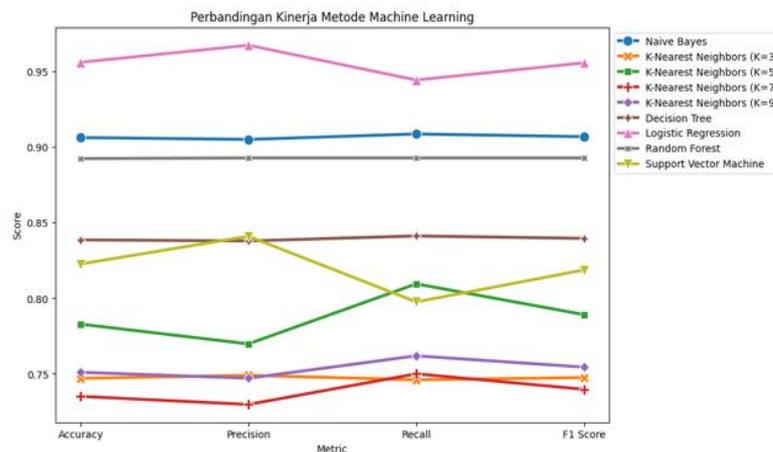
Metrik selanjutnya yang digunakan dalam mengevaluasi performa model *machine learning* yaitu skor *Recall*. Hasil dari evaluasi menggunakan metrik ini dapat dilihat pada gambar di atas. Pada Gambar 4, berdasarkan hasil evaluasi *recall*, *Logistic Regression* juga merupakan model yang terbaik dengan miliki skor *Recall* yaitu 94,4%, sama dengan hasil evaluasi presisi dan akurasi. Hal ini menunjukkan bahwa model ini juga mampu mengidentifikasi sebanyak mungkin data positif dari keseluruhan data yang tersedia. Selanjutnya, model *Naive Bayes* juga memiliki kinerja yang sangat baik berdasarkan skor *recall* yaitu 90,87%, diikuti juga oleh model *Random Forest* dan *Decision Tree*. Sedangkan model yang memiliki skor presisi paling rendah yaitu model *K-Nearest Neighbors* dengan nilai $K=3$.



Gambar 5. Hasil Evaluasi Machine Learning (F1-Score)

Skor F1 merupakan metrik yang digunakan untuk mengukur seberapa efektif model *machine learning* klasifikasi, terutama dalam keadaan di mana data distribusi kelas tidak seimbang. Skor ini adalah hasil rata-rata harmonis dari skor presisi dan *recall* dengan memberikan skor tunggal untuk menyeimbangkan kedua metrik ini. Hasil evaluasi menggunakan skor F1 dapat dilihat pada Gambar 5 grafik di atas. Mirip dengan hasil evaluasi sebelumnya, menggunakan metrik akurasi, presisi, dan *recall*, dapat dilihat bahwa *Logistic Regression* memiliki skor F1 paling tertinggi dibandingkan dengan model klasifikasi lainnya, yaitu 95,58%. Hal ini menunjukkan model ini dapat bekerja secara efektif dalam memprediksi status depresi pada mahasiswa. Selanjutnya, model Naive Bayes memiliki skor F1 cukup tinggi setelah *Logistic Regression*, yang menunjukkan bahwa model ini memiliki tingkat efektivitas yang cukup tinggi. Sedangkan model yang memiliki skor F1 paling rendah yaitu model *K-Nearest Neighbors* dengan nilai $K=7$.

3.4 Penarikan Kesimpulan



Gambar 6. Perbandingan Hasil Evaluasi

Pada Gambar 6, berdasarkan hasil evaluasi performa model *machine learning* secara keseluruhan, dapat disimpulkan bahwa model klasifikasi yang terbaik dan paling efektif dalam memprediksi status depresi pada mahasiswa yaitu *Logistic Regression*, diikuti oleh model Naive Bayes dan *Random Forest*. Hal ini berdasarkan dari perbandingan semua hasil skor metrik yang digunakan untuk mengevaluasi performa model-model klasifikasi yang digunakan pada penelitian ini. Model lainnya yaitu *Decision Tree* dan *Support Vector Machine* juga memberikan hasil evaluasi performa yang baik, tetapi mungkin masih memerlukan *tuning hyperparameter* lebih lanjut untuk meningkatkan performa model. Perbandingan hasil evaluasi performa model-model klasifikasi yang digunakan pada penelitian ini secara keseluruhan dapat dilihat pada gambar grafik di atas.

4. KESIMPULAN

Dalam konteks penelitian ini, dapat disimpulkan bahwa penggunaan algoritma *machine learning* dapat meningkatkan kemampuan dalam deteksi dini terhadap status depresi pada mahasiswa secara signifikan. Hal ini merupakan salah satu langkah penting untuk menjaga kesehatan mental pada lingkungan akademik. Penelitian ini mengevaluasi performa beberapa algoritma klasifikasi pada *machine learning*, diantaranya Naive Bayes, *K-Nearest Neighbor*, *Decision Tree*, *Logistic Regression*, *Random Forest*, dan *Support Vector Machine*. Berdasarkan hasil analisis performa dari algoritma *machine learning*, model yang paling efektif dalam memprediksi status depresi pada mahasiswa yaitu *Logistic Regression* yang memiliki tingkat akurasi sebesar 95,62%. Selain itu, model ini juga menunjukkan skor presisi dan *recall* yang relatif tinggi yaitu 96,75% dan 94,4%, serta skor F1 tertinggi dibandingkan model-model *machine learning* lainnya, yaitu sebesar 95,58%. Sebagai tambahan, dengan mempertimbangkan hasil penelitian ini, salah satu langkah strategis yang dapat dilakukan yaitu mengintegrasikan teknologi *machine learning* dalam melakukan diagnosis awal dalam mengidentifikasi status depresi pada mahasiswa, di mana sistem diagnosa dini ini diharapkan dapat bekerja dengan lebih efektif dan efisien. Integrasi *machine learning* dalam konteks ini tidak hanya meningkatkan akurasi dalam diagnosis awal, tetapi juga sebagai pembuka jalan bagi pendekatan baru dalam bidang kesehatan mental sehingga memiliki intervensi yang lebih responsif dan berbasis data.

REFERENCES

- [1] M. Maulana and N. Yulianti, "Representasi Visual Kesehatan Mental Pada Film Dear David," *Bandung Conference Series Communication Management*, vol. 3, no. 2, pp. 595–601, 2023, doi: 10.29313/bcscm.v3i2.7593.
- [2] N. Infanti Wisnu Wardani *et al.*, "Psikoedukasi Peningkatan Kesadaran Kesehatan Mental Pada Masyarakat Desa Kedung Baya Kelurahan Kalitimbang Cilegon," *Jurnal Pengabdian Masyarakat Bangsa*, vol. 1, no. 7, pp. 1020–1025, 2023, doi: 10.59837/jpmba.v1i7.301.

- [3] S. Budury and A. Fitriasari, "Penggunaan media sosial terhadap kejadian depresi, kecemasan dan stres pada mahasiswa: use of social media on events of depression, anxiety and stress among university students," *Bali Medika Jurnal*, vol. 6, no. 2, pp. 205–208, 2019.
- [4] E. D. Farisandy, A. Asihputri, and J. S. Pontoh, "Peningkatan Pengetahuan Dan Kesadaran Masyarakat Mengenai Kesehatan Mental," *Diseminasi Jurnal Pengabdian Kepada Masyarakat*, vol. 5, no. 1, pp. 81–90, 2023, doi: 10.33830/diseminasiabdimas.v5i1.5037.
- [5] S. A. Mardhiyah, "Inisiasi Mental Health Awareness Melalui Screening Dan Promosi Kesehatan Mental Pada Mahasiswa Universitas Sriwijaya," *Jurnal Pengabdian Sriwijaya*, vol. 7, no. 4, pp. 906–914, 2019, doi: 10.37061/jps.v7i4.12359.
- [6] N. Ima Fitri Sholichah, N. Laily, and F. Zahra, "Pentingnya Kesehatan Mental Bagi Remaja Karang Taruna Di Desa Cemer Lor Kabupaten Gresik," *Room of Civil Society Development*, vol. 2, no. 5, pp. 194–201, 2023, doi: 10.59110/rcsd.213.
- [7] A. F. Ratrin, W. Wilson, and M. I. Ilmiawan, "Hubungan Antara Chronotype Dengan Tingkat Gejala Depresi Pada Mahasiswa Kedokteran Tingkat Pertama Di Fakultas Kedokteran Universitas Tanjungpura," *Jurnal Cerebellum*, vol. 6, no. 3, p. 66, 2021, doi: 10.26418/jc.v6i3.45311.
- [8] V. Isella, A. Chris, and L. Valdo, "Pencapaian Akademik Mempengaruhi Depresi Pada Mahasiswa Tahun Pertama Di Fakultas Kedokteran," *Jurnal Muara Medika Dan Psikologi Klinis*, vol. 2, no. 2, pp. 97–103, 2022, doi: 10.24912/jmmpk.v2i2.22658.
- [9] N. H. Ma'rufa, A. N. Rumaisha, and F. Nashori, "Pengaruh Terapi Zikir Istigfar Terhadap Depresi Pada Mahasiswa," *Psychopolytan Jurnal Psikologi*, vol. 7, no. 1, pp. 52–61, 2023, doi: 10.36341/psi.v7i1.3319.
- [10] D. Nazira, M. Mawarpury, A. Afriani, and I. D. Kumala, "Literasi Kesehatan Mental Pada Mahasiswa Di Banda Aceh," *Seurune Jurnal Psikologi Unsyiah*, vol. 5, no. 1, pp. 23–39, 2022, doi: 10.24815/s-jpu.v5i1.25102.
- [11] M. P. Yanti and N. R. Nurwulan, "Pengaruh Pembelajaran Daring Pada Depresi, Stres, Dan Kecemasan Mahasiswa," *Jurnal Muara Pendidikan*, vol. 6, no. 1, pp. 58–63, 2021, doi: 10.52060/mp.v6i1.520.
- [12] I. B. Al Basith and L. S. Budiarmo, "Pengaruh Pembelajaran Jarak Jauh (Pjj) Terhadap Kesehatan Mental Pada Mahasiswa Fakultas Kedokteran Universitas Tarumanagara Angkatan X," *Jurnal Muara Medika Dan Psikologi Klinis*, vol. 2, no. 2, pp. 149–158, 2022, doi: 10.24912/jmmpk.v2i2.24595.
- [13] E. Y. Harahap, Y. Septianingrum, L. Wijayanti, U. Sholeha, and S. N. Hasina, "Depresi Pasca Stroke (PSD): A Systematic Review," *Jurnal Keperawatan*, vol. 15, no. 2, pp. 859–866, 2023, doi: 10.32583/keperawatan.v15i2.1026.
- [14] S. Abimanyu, N. Bahtiar, and E. Adi Sarwoko, "Implementasi Metode Support Vector Machine (SVM) Dan T-Distributed Stochastic Neighbor Embedding (T-Sne) Untuk Klasifikasi Depresi," *Jurnal Masyarakat Informatika*, vol. 14, no. 2, pp. 146–158, 2023, doi: 10.14710/jmasif.14.2.59513.
- [15] S. R. Hernawan, H. A. Nugroho, and I. Hidayah, "Penerapan Metode Certainty Factor Dalam Diagnosis Gangguan Depresi," *Journal of Computer System and Informatics (Josyc)*, vol. 3, no. 2, pp. 65–72, 2022, doi: 10.47065/josyc.v3i2.643.
- [16] D. Shin *et al.*, "Detection of Minor and Major Depression Through Voice as a Biomarker Using Machine Learning," *J Clin Med*, vol. 10, no. 14, p. 3046, 2021, doi: 10.3390/jcm10143046.
- [17] S. Nuarini, N. Siti Fauziah, N. A. Mayangky, and R. Nurfalah, "Comparison Algorithm on Machine Learning for Student Mental Health Data," *Journal Medical Informatics Technology*, pp. 81–85, 2023, doi: 10.37034/medinftech.v1i3.18.
- [18] S. Masrom, N. F. Jamaludin, F. Abdol Razak, and N. R. Paujah @ Ismail, "Machine Learning Approach to Classify Students' Mental Health During the COVID-19 Pandemic: A Web-Based Interactive Dashboard," *International Journal of Academic Research in Business and Social Sciences*, vol. 13, no. 7, 2023, doi: 10.6007/ijarbs/v13-i7/17124.
- [19] N. Jagtap, H. Shukla, V. Shinde, S. Desai, and V. Kulkarni, "Use of Ensemble Machine Learning to Detect Depression in Social Media Posts," pp. 1396–1400, 2021, doi: 10.1109/icesc51422.2021.9532838.
- [20] J. Wilson A R. and S. K. K., "Early Detection of Anxiety, Depression and Stress Among Potential Patients Using Machine Learning and Deep Learning Models," 2023, doi: 10.1109/icccsc56913.2023.10143026.