

# Perbandingan Kinerja Algoritma Machine Learning Dalam Prediksi Kesehatan Mental Dan Burnout Mahasiswa

Jose Julian Hidayat\*<sup>1)</sup>, Fajri Fauzan Azhari<sup>2)</sup>, Tsania Manzilatul Husna<sup>3)</sup>,  
Aulia Nufaila Fahmayani<sup>4)</sup>, Novant Nanda Pradana<sup>5)</sup>, Cindy Setyowati<sup>6)</sup>

1. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Bekasi, Indonesia
2. Program Studi Psikologi, Fakultas Psikologi, Universitas Islam Indonesia, D.I. Yogyakarta, Indonesia
3. Program Studi Psikologi, Fakultas Psikologi, Universitas Negeri Surabaya, Surabaya, Indonesia
4. Program Studi Psikologi, Fakultas Psikologi, Universitas Negeri Surabaya, Surabaya, Indonesia
5. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Bekasi, Indonesia
6. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Bekasi, Indonesia

## Article Info

### Kata Kunci:

*Machine Learning;*  
*Mental Health Prediction;*  
*Student Burnout;*  
*Classification Algorithms;*  
*Imbalanced Data*

### Keywords:

*Machine Learning;*  
*Mental Health Prediction;*  
*Student Burnout;*  
*Classification Algorithms;*  
*Imbalanced Data*

### Article history:

Received : 3 April 2026  
Revised : 4 April 2026  
Accepted : 5 April 2026  
Available online : 1 Mei 2026

### DOI :

[10.48144/suryainformatika.v16i1.2420](https://doi.org/10.48144/suryainformatika.v16i1.2420)

\* Corresponding author.

Jose Julian Hidayat

E-mail address:

[josejulianhidayat@gmail.com](mailto:josejulianhidayat@gmail.com)

## ABSTRAK

Penelitian ini bertujuan untuk membandingkan kinerja beberapa algoritma *machine learning* dalam memprediksi tingkat kesehatan mental dan *burnout* mahasiswa, yang diklasifikasikan ke dalam tiga kategori, yaitu *Low*, *Medium*, dan *High*. Algoritma yang diuji meliputi *Decision Tree*, *Logistic Regression*, *Naive Bayes*, *Support Vector Machine (SVM)*, dan *Random Forest*. Evaluasi dilakukan menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* pada dataset berjumlah 200.000 data. Hasil penelitian menunjukkan bahwa *Logistic Regression* memiliki performa terbaik secara keseluruhan dengan nilai akurasi sebesar 0,8720 dan *F1-Score* sebesar 0,8677, diikuti oleh *Random Forest* dengan akurasi 0,8708. *Decision Tree* dan *SVM* juga menunjukkan performa yang kompetitif dengan akurasi masing-masing sebesar 0,8646 dan 0,8684, sementara *Naive Bayes* memiliki performa terendah dengan akurasi 0,8503. Namun demikian, seluruh model mengalami kesulitan dalam memprediksi kelas *High*, yang ditunjukkan oleh nilai *recall* yang relatif rendah, terutama pada *SVM* yang gagal mendeteksi kelas tersebut. Hal ini mengindikasikan adanya ketidakseimbangan data yang signifikan, di mana kelas *Low* mendominasi dataset. Secara keseluruhan, *Logistic Regression* dan *Random Forest* dapat direkomendasikan sebagai model terbaik untuk prediksi kesehatan mental mahasiswa dalam studi ini. Namun, diperlukan strategi penanganan data tidak seimbang, seperti *resampling* atau *cost-sensitive learning*, untuk meningkatkan performa prediksi pada kelas minoritas, khususnya kategori *High*.

## ABSTRACT

*This study aims to compare the performance of several machine learning algorithms in predicting students' mental health and burnout levels, which are classified into three categories: Low, Medium, and High. The evaluated algorithms include Decision Tree, Logistic Regression, Naive Bayes, Support Vector Machine (SVM), and Random Forest. The evaluation was conducted using Accuracy, Precision, Recall, and F1-Score metrics on a dataset consisting of 200,000 samples. The results indicate that Logistic Regression achieved the best overall performance, with an accuracy of 0.8720 and an F1-Score of 0.8677, followed closely by Random Forest with an*

accuracy of 0.8708. Decision Tree and SVM also demonstrated competitive performance, with accuracies of 0.8646 and 0.8684, respectively, while Naive Bayes showed the lowest performance with an accuracy of 0.8503. However, all models struggled to accurately predict the High class, as reflected by relatively low recall values, particularly in the SVM model, which failed to identify this class. This issue suggests a significant class imbalance in the dataset, where the Low category dominates. In conclusion, Logistic Regression and Random Forest are recommended as the most effective models for predicting students' mental health and burnout in this study. Nevertheless, further improvements are required to address class imbalance, such as applying resampling techniques or cost-sensitive learning, to enhance prediction performance for minority classes, especially the High category.

## 1. PENDAHULUAN

Kesehatan mental mahasiswa merupakan aspek penting yang mempengaruhi keberhasilan akademik dan kualitas hidup secara keseluruhan [1]. Dalam lingkungan pendidikan tinggi, mahasiswa menghadapi berbagai tekanan, baik dari tuntutan akademik, interaksi sosial, maupun ekspektasi pribadi dan keluarga [2]. Kondisi ini menjadikan mahasiswa sebagai kelompok yang rentan mengalami gangguan kesehatan mental

Kesehatan mental mahasiswa dalam beberapa tahun terakhir menjadi isu yang semakin krusial, terutama dengan meningkatnya kompleksitas tuntutan akademik dan dinamika kehidupan kampus [3]. Berbagai studi empiris menunjukkan adanya peningkatan signifikan pada tingkat stres dan kelelahan psikologis mahasiswa, yang secara langsung berdampak pada penurunan performa akademik dan kualitas hidup [4].

Fenomena *burnout* menjadi salah satu indikator utama yang merepresentasikan kondisi kesehatan mental mahasiswa [5]. *Burnout* tidak hanya muncul sebagai respon terhadap beban akademik yang tinggi, tetapi juga dipengaruhi oleh tekanan sosial, ekspektasi keluarga, serta ketidakmampuan dalam mengelola waktu dan emosi secara efektif [6]. Kondisi ini semakin diperparah dalam lingkungan pendidikan yang kompetitif.

Penelitian-penelitian sebelumnya menunjukkan bahwa mahasiswa dengan tingkat *burnout* tinggi cenderung mengalami disengagement terhadap aktivitas akademik, penurunan produktivitas, serta peningkatan risiko gangguan psikologis yang lebih serius [7]. Hal ini menegaskan bahwa *burnout* bukan sekadar fenomena sementara, melainkan kondisi yang memiliki implikasi jangka panjang.

Meskipun demikian, deteksi terhadap kondisi kesehatan mental mahasiswa masih menghadapi berbagai keterbatasan. Pendekatan yang digunakan umumnya bersifat reaktif dan bergantung pada laporan subjektif, sehingga sering kali gagal mengidentifikasi kondisi risiko tinggi secara dini [8]. Akibatnya, intervensi yang diberikan menjadi kurang optimal.

Beberapa studi telah mencoba mengidentifikasi faktor-faktor yang berkontribusi terhadap *burnout*, seperti beban akademik, kualitas tidur, dan dukungan social [9]. Namun, sebagian besar penelitian tersebut berfokus pada analisis deskriptif atau korelasional, sehingga belum mampu memberikan solusi prediktif yang dapat digunakan secara praktis.

Selain itu, penelitian terdahulu cenderung tidak mengintegrasikan pendekatan kuantitatif berbasis data dalam skala besar. Hal ini menyebabkan keterbatasan dalam memahami pola kompleks yang mendasari kondisi kesehatan mental mahasiswa, terutama dalam konteks variasi individu dan lingkungan.

Kesenjangan lain yang ditemukan adalah kurangnya pendekatan yang mampu mengklasifikasikan tingkat kesehatan mental secara terstruktur ke dalam beberapa kategori risiko. Padahal, klasifikasi seperti Low, Medium, dan High sangat penting untuk menentukan prioritas intervensi yang tepat.

Berdasarkan kondisi tersebut, diperlukan pendekatan yang tidak hanya mampu menganalisis kondisi kesehatan mental secara deskriptif, tetapi juga mampu melakukan prediksi secara sistematis dan berbasis data. Hal inilah yang menjadi dasar utama dilakukannya penelitian ini.

Perkembangan teknologi informasi, khususnya dalam bidang machine learning, memberikan peluang signifikan dalam pengembangan sistem prediksi berbasis data. Dalam beberapa tahun terakhir, *machine learning* telah banyak digunakan untuk menyelesaikan permasalahan klasifikasi dalam berbagai domain, termasuk kesehatan mental [10].

Sejumlah penelitian sebelumnya menunjukkan bahwa algoritma seperti *Logistic Regression*, *Support Vector Machine*, dan *Random Forest* mampu menghasilkan performa yang cukup baik dalam memprediksi kondisi mental. Namun, hasil yang diperoleh sering kali tidak konsisten antar studi karena perbedaan karakteristik dataset dan pendekatan evaluasi [11].

Selain itu, sebagian besar penelitian hanya membandingkan sejumlah kecil algoritma, sehingga belum memberikan gambaran komprehensif mengenai performa berbagai metode dalam satu kerangka evaluasi yang sama. Hal ini menyulitkan dalam menentukan algoritma yang paling optimal untuk kasus tertentu.

Permasalahan lain yang sering muncul dalam klasifikasi kesehatan mental adalah ketidakseimbangan data (*class imbalance*). Dalam banyak kasus, data didominasi oleh kelas dengan risiko rendah, sementara kelas dengan risiko tinggi memiliki jumlah yang jauh lebih sedikit. Kondisi ini menyebabkan model cenderung bias terhadap kelas mayoritas.

Metrik akurasi sebagai indikator utama performa model [12]. Padahal, dalam konteks data tidak seimbang, akurasi tidak cukup untuk menggambarkan kemampuan model dalam mendeteksi kelas minoritas yang justru memiliki tingkat urgensi tinggi [13].

Dengan demikian, terdapat *research gap* yang jelas, yaitu kurangnya studi komparatif yang menguji berbagai algoritma *machine learning* pada dataset berskala besar dengan distribusi kelas tidak seimbang, serta minimnya analisis performa model pada masing-masing kelas.

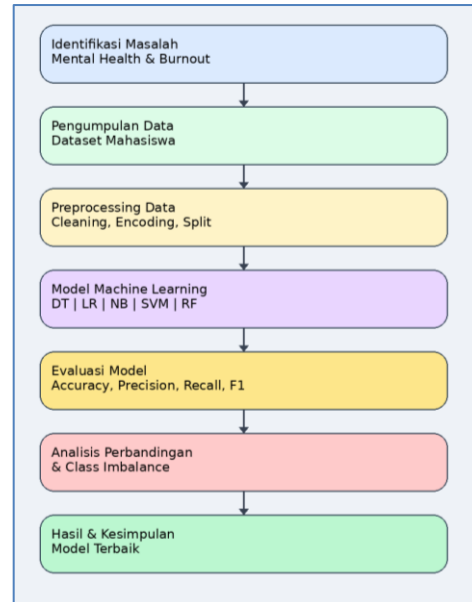
*State of the art* dalam penelitian ini terletak pada pendekatan evaluasi yang lebih komprehensif, yaitu dengan membandingkan lima algoritma machine learning (*Decision Tree, Logistic Regression, Naive Bayes, SVM, dan Random Forest*) menggunakan berbagai metrik evaluasi, termasuk *precision, recall, dan F1-score* untuk setiap kelas.

Adapun *novelty* dari penelitian ini adalah analisis komparatif multi-algoritma dalam konteks prediksi kesehatan mental mahasiswa dengan fokus pada permasalahan *class imbalance* serta evaluasi performa pada tiga kategori klasifikasi (*Low, Medium, High*). Berdasarkan hal tersebut, pertanyaan penelitian yang diajukan adalah: algoritma machine learning mana yang memiliki kinerja terbaik dalam memprediksi tingkat kesehatan mental dan burnout mahasiswa pada kondisi data yang tidak seimbang, serta bagaimana performa masing-masing model dalam mendeteksi kelas risiko tinggi.

## 2. METODE PENELITIAN

Metodologi penelitian tersebut menggambarkan alur sistematis penelitian dimulai dari identifikasi permasalahan terkait kesehatan mental dan burnout mahasiswa, kemudian dilanjutkan dengan proses pengumpulan dataset yang relevan. Data yang diperoleh selanjutnya melalui tahap *preprocessing* seperti pembersihan, *encoding*, dan pembagian data latih serta uji. Setelah itu, dilakukan pemodelan menggunakan beberapa algoritma *machine learning* (*Decision Tree, Logistic Regression, Naive Bayes, SVM, dan Random Forest*). Kinerja model dievaluasi menggunakan metrik *accuracy, precision, recall, dan F1-score*, kemudian

dianalisis untuk membandingkan performa serta mengidentifikasi pengaruh *class imbalance*. Tahap akhir menghasilkan kesimpulan berupa model terbaik yang paling efektif dalam memprediksi kesehatan mental mahasiswa.



Gambar 1. Alur dan Desain Penelitian

### 2.1 Data Collection

Data pada dataset *Student Mental Health and Burnout* dikumpulkan dalam bentuk data sintesis yang dirancang untuk merepresentasikan kondisi nyata mahasiswa terkait kesehatan mental dan *burnout*. Dataset ini dibuat untuk keperluan analisis data dan *machine learning*, dengan menggabungkan berbagai variabel yang umum digunakan dalam studi kesehatan mental mahasiswa seperti faktor akademik, psikologis, dan gaya hidup. Meskipun bukan hasil survei langsung, data ini dibangun menggunakan distribusi yang realistis sehingga tetap mampu mencerminkan hubungan antar variabel yang relevan dalam dunia pendidikan tinggi. Dataset dapat diakses melalui *Kaggle* pada tautan berikut: <https://www.kaggle.com/datasets/sharmajicoder/student-mental-health-and-burnout>

Tabel 1. Deskripsi Dataset

No	Nama Kolom	Tipe Data	Deskripsi
1	age	Numerik	Usia mahasiswa
2	gender	Kategorikal	Jenis kelamin mahasiswa
3	academic_year	Kategorikal	Tahun akademik (semester/tahun studi)
4	study_hours_per_day	Numerik	Rata-rata jam belajar per hari
5	exam_pressure	Numerik	Tingkat tekanan saat ujian

No	Nama Kolom	Tipe Data	Deskripsi
6	academic_performance	Numerik	Performa akademik mahasiswa
7	stress_level	Numerik	Tingkat stres
8	anxiety_score	Numerik	Skor kecemasan
9	depression_score	Numerik	Skor depresi
10	sleep_hours	Numerik	Rata-rata jam tidur
11	physical_activity	Numerik	Tingkat aktivitas fisik
12	social_support	Numerik	Tingkat dukungan sosial
13	screen_time	Numerik	Waktu penggunaan layar per hari
14	internet_usage	Numerik	Intensitas penggunaan internet
15	financial_stress	Numerik	Tingkat tekanan finansial
16	family_expectation	Numerik	Tingkat ekspektasi keluarga
17	burnout_score	Numerik	Skor tingkat burnout
18	mental_health_index	Numerik	Indeks kesehatan mental secara keseluruhan
19	risk_level	Kategorikal	Kategori risiko (Low, Medium, High)
20	dropout_risk	Kategorikal	Risiko mahasiswa untuk dropout

## 2.2 Data Preprocessing

Pada *data preprocessing* menjelaskan bagaimana data mentah dipersiapkan sebelum dianalisis. Biasanya mencakup pembersihan data, penanganan missing value, encoding data kategorikal, normalisasi atau standarisasi, serta seleksi fitur jika diperlukan [14]. Walaupun dataset kamu sudah bersih, tetap perlu dijelaskan proses verifikasi kualitas data.

## 2.3 Model Algoritma Machine Learning

*Decision Tree* adalah algoritma klasifikasi yang bekerja dengan membentuk struktur pohon keputusan berdasarkan fitur-fitur dalam data [15]. Setiap node dalam pohon merepresentasikan suatu kondisi atau aturan, sedangkan cabang menunjukkan hasil dari kondisi tersebut, dan daun (*leaf*) menunjukkan hasil akhir atau kelas prediksi [16]. Algoritma ini memilih fitur yang paling berpengaruh dengan menggunakan kriteria seperti *Gini Index* atau *Information Gain* [17]. Kelebihan utama *Decision Tree* adalah mudah dipahami dan diinterpretasikan, namun kelemahannya adalah rentan terhadap *overfitting* jika pohon terlalu kompleks [18].

*Random Forest* merupakan pengembangan dari *Decision Tree* yang menggunakan banyak pohon

keputusan (*ensemble method*) [19]. Setiap pohon dibangun dari subset data yang berbeda secara acak (*bootstrap sampling*) dan hasil prediksi ditentukan berdasarkan voting dari seluruh pohon [20]. Metode ini mampu meningkatkan akurasi dan mengurangi *overfitting* yang sering terjadi pada *Decision Tree* tunggal. Selain itu, *Random Forest* juga lebih stabil terhadap variasi data, meskipun interpretasinya lebih kompleks dibandingkan *Decision Tree* [21].

*Logistic Regression* adalah algoritma klasifikasi yang digunakan untuk memodelkan probabilitas suatu data masuk ke dalam kelas tertentu berdasarkan hubungan antara variabel independen dan dependen [22]. Algoritma ini menggunakan fungsi sigmoid untuk mengubah nilai output menjadi probabilitas antara 0 dan 1. *Logistic Regression* memiliki keunggulan dalam interpretasi model dan efisiensi komputasi, serta cocok digunakan untuk dataset dengan hubungan linear, namun memiliki keterbatasan dalam menangani pola non-linear yang kompleks [23].

*Naive Bayes* merupakan algoritma klasifikasi berbasis probabilitas yang menggunakan Teorema Bayes dengan asumsi bahwa setiap fitur bersifat independen satu sama lain [24]. Meskipun asumsi ini jarang terpenuhi secara nyata, *Naive Bayes* tetap mampu memberikan performa yang baik, terutama pada dataset dengan dimensi tinggi. Algoritma ini memiliki keunggulan dalam kecepatan komputasi dan efisiensi, namun performanya dapat menurun jika terdapat korelasi yang kuat antar fitur [25].

*Support Vector Machine* adalah algoritma klasifikasi yang bekerja dengan mencari *hyperplane* optimal yang mampu memisahkan data ke dalam kelas yang berbeda dengan margin maksimum [26]. *SVM* efektif dalam menangani data dengan dimensi tinggi dan dapat menggunakan kernel *trick* untuk menangani data non-linear [27]. Meskipun memiliki akurasi yang tinggi, *SVM* membutuhkan waktu komputasi yang lebih besar dan sensitif terhadap pemilihan parameter seperti kernel dan *regularization* [28].

## 2.4 Evaluasi dan Visualisasi Model

Evaluasi model dalam penelitian ini dilakukan untuk mengukur kinerja masing-masing algoritma *machine learning* dalam memprediksi tingkat kesehatan mental dan *burnout* mahasiswa. Proses evaluasi menggunakan beberapa metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score* [29]. *Accuracy* digunakan untuk mengukur proporsi prediksi yang benar dari seluruh data, sedangkan *precision* menunjukkan tingkat ketepatan model dalam memprediksi suatu kelas [30]. *Recall* digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh data yang sebenarnya termasuk dalam suatu kelas, dan *F1-score* merupakan rata-rata harmonis antara *precision* dan *recall* yang memberikan gambaran keseimbangan kinerja model [31].

Tabel 2. Dataset Penelitian

<https://www.kaggle.com/datasets/sharmajicoder/student-mental-health-and-burnout>

a	gen	aca-	stress_	burn-	...	drop-
g	der	demic_per-	level	out_sco	.	out_ris
e		formance		re		k
2	Mal	68.4111	4.116	2.0373	...	1.7466
3	e		9			
0	Mal	67.6822	0.349	0.0	...	0.0
2	Mal	58.3724	3.476	0.0	...	0.6969
9	e		2			
2	Mal	68.9257	6.778	7.2277	...	5.3806
7	e		8			
2	Mal	69.1419	1.854	0.0	...	0.0
4	e		6			
2	Fe-	68.3322	5.464	1.4729	...	2.7311
9	mal		8			
2	Fe-	75.1808	2.989	1.7983	...	0.8687
1	mal		9			
e						
...	...	...	...	...	...	...
2	Mal	69.4144	6.306	4.3220	...	2.6422
7	e		4			

Selain itu, evaluasi juga dilakukan menggunakan classification report untuk melihat performa model pada masing-masing kelas, yaitu *Low*, *Medium*, dan *High*. Pendekatan ini penting karena dataset yang digunakan memiliki distribusi yang tidak seimbang (*class imbalance*), sehingga evaluasi tidak hanya berfokus pada performa keseluruhan, tetapi juga pada kemampuan model dalam mendeteksi kelas minoritas, khususnya kategori *High* yang memiliki tingkat risiko lebih tinggi.

Dalam proses evaluasi, setiap algoritma diuji menggunakan data uji (*test set*) yang telah dipisahkan sebelumnya dari data latihan [32]. Hasil prediksi kemudian dibandingkan dengan label sebenarnya untuk menghitung nilai metrik evaluasi. Perbandingan antar algoritma dilakukan secara komprehensif untuk menentukan model dengan performa terbaik berdasarkan kombinasi metrik yang digunakan.

$$recall = \frac{TP}{TP + FN} \tag{1}$$

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

$$F1 - score = 2 \times \frac{precision \times recall}{precision + recall} \tag{3}$$

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \tag{5}$$

Visualisasi digunakan untuk memperjelas hasil evaluasi dan memudahkan interpretasi perbandingan kinerja antar model. Bentuk visualisasi yang digunakan antara lain grafik perbandingan nilai *accuracy*, *precision*, *recall*, dan *F1-score* untuk masing-masing algoritma, serta diagram batang untuk membandingkan performa antar kelas. Selain itu, *confusion matrix* juga dapat digunakan untuk menggambarkan distribusi prediksi benar dan salah pada setiap kelas.

Melalui visualisasi tersebut, pola performa model dapat diamati secara lebih jelas, termasuk kecenderungan model dalam memprediksi kelas mayoritas dan kesulitan dalam mendeteksi kelas minoritas [33]. Hal ini membantu dalam mengidentifikasi kelemahan masing-masing algoritma serta memberikan dasar dalam menentukan model yang paling sesuai untuk digunakan.

### 3. HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan pengujian terhadap lima algoritma machine learning, yaitu *Decision Tree*, *Logistic Regression*, *Naive Bayes*, *Support Vector Machine (SVM)*, dan *Random Forest* untuk memprediksi tingkat kesehatan mental dan burnout mahasiswa. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* pada dataset berjumlah 200.000 data.

#### 3.1. Hasil

Berdasarkan hasil pengujian, *Logistic Regression* menunjukkan performa terbaik dengan nilai *accuracy* sebesar 0,8720, *precision* 0,8666, *recall* 0,8720, dan *F1-score* 0,8677. Hasil ini menunjukkan bahwa *Logistic Regression* mampu memberikan keseimbangan yang baik antara ketepatan dan kemampuan deteksi model.

*Random Forest* menempati posisi kedua dengan *accuracy* sebesar 0,8708 dan *F1-score* sebesar 0,8655. Model ini menunjukkan performa yang stabil dan mampu menangani variasi data dengan baik, terutama karena pendekatan ensemble yang digunakan.

Sementara itu, *Support Vector Machine (SVM)* memiliki *accuracy* sebesar 0,8684, namun menunjukkan kelemahan signifikan dalam mendeteksi kelas *High*, dengan nilai *recall* yang sangat rendah (0,00). Hal ini mengindikasikan bahwa *SVM* gagal mengenali kelas minoritas dalam dataset.

*Decision Tree* menghasilkan *accuracy* sebesar 0,8646 dengan performa yang cukup baik secara keseluruhan, namun masih mengalami keterbatasan dalam mendeteksi kelas *High* dengan *recall* yang rendah (0,31). Hal ini menunjukkan adanya kecenderungan bias terhadap kelas mayoritas.

*Naive Bayes* memiliki performa terendah dengan *accuracy* sebesar 0,8503, meskipun masih menunjukkan kemampuan yang cukup baik dalam mendeteksi kelas *Medium*. Namun, model ini kurang optimal dalam menangani distribusi data yang kompleks

#### 3.2. Pembahasan

Secara umum, seluruh model menunjukkan performa yang tinggi pada kelas *Low*, yang merupakan kelas

mayoritas dalam dataset. Hal ini terlihat dari nilai *precision* dan *recall* yang konsisten di atas 0,80 untuk hampir semua algoritma.

Tabel 3. Hasil Prediksi dan Klasifikasi Semua Algoritma

Algoritma	Accuracy	Precision	Recall	F1-Score
Decision Tree	0.8646	0.8586	0.8646	0.8601
Logistic Regression	0.8720	0.8666	0.8720	0.8677
Naive Bayes	0.8503	0.8579	0.8503	0.8534
SVM	0.8684	0.8493	0.8684	0.8571
Random Forest	0.8708	0.8655	0.8708	0.8655

Namun, performa model menurun secara signifikan pada kelas Medium dan terutama pada kelas High. Kelas High memiliki jumlah data paling sedikit, sehingga menjadi tantangan utama dalam proses klasifikasi. *Logistic Regression* dan *Random Forest* relatif lebih baik dibandingkan model lain dalam menangani kelas ini, meskipun nilai *recall* masih tergolong rendah.

Tabel 4. Classification Report dari Algoritma Decision Tree

Kelas	Precision	Recall	F1-Score	Support
High	0.65	0.31	0.42	3016
Low	0.91	0.94	0.92	153329
Medium	0.71	0.64	0.67	43655
Accuracy			0.86	200000
Macro Avg	0.75	0.63	0.67	200000
Weighted Avg	0.86	0.86	0.86	200000

Tabel 5. Classification Report dari Algoritma Logistic Regression

Kelas	Precision	Recall	F1-Score	Support
High	0.70	0.33	0.45	3016
Low	0.91	0.94	0.93	153329
Medium	0.73	0.66	0.69	43655
Accuracy			0.87	200000
Macro Avg	0.78	0.64	0.69	200000
Weighted Avg	0.87	0.87	0.87	200000

Tabel 6. Classification Report dari Algoritma Naive Bayes

Kelas	Precision	Recall	F1-Score	Support
High	0.51	0.50	0.50	3016

Kelas	Precision	Recall	F1-Score	Support
Low	0.93	0.89	0.91	153329
Medium	0.64	0.72	0.68	43655
Accuracy			0.85	200000
Macro Avg	0.69	0.70	0.70	200000
Weighted Avg	0.86	0.85	0.85	200000

Tabel 7. Classification Report dari Algoritma Support Vector Machine

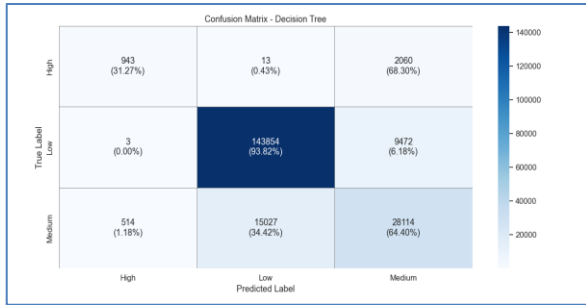
Kelas	Precision	Recall	F1-Score	Support
High	0.00	0.00	0.00	3016
Low	0.90	0.96	0.93	153329
Medium	0.74	0.62	0.67	43655
Accuracy			0.87	200000
Macro Avg	0.54	0.53	0.53	200000
Weighted Avg	0.85	0.87	0.86	200000

Tabel 8. Classification Report dari Algoritma Random Forest

Kelas	Precision	Recall	F1-Score	Support
High	0.00	0.00	0.00	3016
Low	0.90	0.96	0.93	153329
Medium	0.74	0.62	0.67	43655
Accuracy			0.87	200000
Macro Avg	0.54	0.53	0.53	200000
Weighted Avg	0.85	0.87	0.86	200000


*SVM* menunjukkan performa paling buruk dalam mendeteksi kelas *High*, yang mengindikasikan bahwa model ini sangat sensitif terhadap ketidakseimbangan data. Hal ini juga tercermin pada nilai *macro average* yang lebih rendah dibandingkan *weighted average*.

Perbedaan antara *macro average* dan *weighted average* pada seluruh model menunjukkan adanya ketidakseimbangan distribusi data (*class imbalance*). *Weighted average* yang tinggi menandakan dominasi kelas mayoritas, sedangkan *macro average* yang lebih rendah menunjukkan bahwa performa pada kelas minoritas belum optimal.



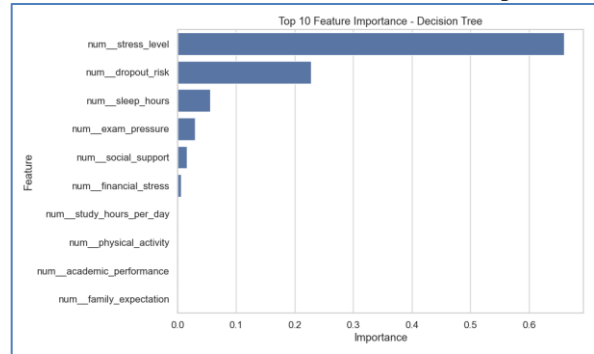
Gambar 2. Confusion Matrix Decision Tree

Berdasarkan *confusion matrix Decision Tree* pada Gambar 2., model menunjukkan performa yang sangat baik pada kelas *Low*, dengan mayoritas data (143.854 atau 93,82%) berhasil diklasifikasikan dengan benar. Namun, performa pada kelas *High* masih rendah, di mana sebagian besar data (68,30%) justru salah diklasifikasikan sebagai *Medium*, sehingga menunjukkan kelemahan model dalam mendeteksi kondisi berisiko tinggi. Pada kelas *Medium*, model cukup baik tetapi masih terjadi kesalahan prediksi ke kelas *Low* sebesar 34,42%. Hal ini mengindikasikan bahwa model cenderung bias terhadap kelas mayoritas (*Low*) dan mengalami kesulitan dalam membedakan kelas minoritas, terutama *High*, akibat adanya ketidakseimbangan data.



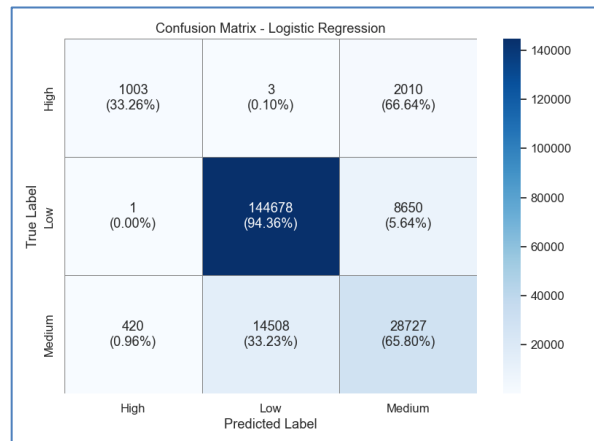
Gambar 3. Learning Curve Algoritma Decision Tree

Berdasarkan grafik distribusi kelas *risk level*, terlihat bahwa data sangat tidak seimbang, di mana kelas *Low* mendominasi dengan jumlah yang jauh lebih besar dibandingkan kelas lainnya, diikuti oleh kelas *Medium*, sementara kelas *High* memiliki jumlah yang sangat sedikit. Ketimpangan distribusi ini menunjukkan adanya *class imbalance* yang signifikan, yang berpotensi menyebabkan model *machine learning* menjadi bias terhadap kelas mayoritas dan kurang mampu mengenali kelas minoritas, khususnya kategori *High* yang justru memiliki tingkat risiko paling tinggi.



Gambar 4. Feature Importance Decision Tree


Berdasarkan grafik *feature importance* pada model *Decision Tree*, terlihat bahwa variabel tingkat stres (*num\_stress\_level*) memiliki pengaruh paling dominan dalam menentukan prediksi kesehatan mental mahasiswa. Diikuti oleh risiko dropout (*num\_dropout\_risk*) sebagai faktor penting kedua, sementara variabel lain seperti jam tidur, tekanan ujian, dan dukungan sosial memiliki kontribusi yang relatif lebih kecil. Hal ini menunjukkan bahwa kondisi stres menjadi faktor utama yang mempengaruhi tingkat burnout mahasiswa, sedangkan faktor lain berperan sebagai pendukung. Dengan demikian, model lebih banyak mengandalkan indikator psikologis dibandingkan faktor gaya hidup atau akademik lainnya dalam proses prediksi.



Gambar 5. Confusion Matrix Logistic Regression

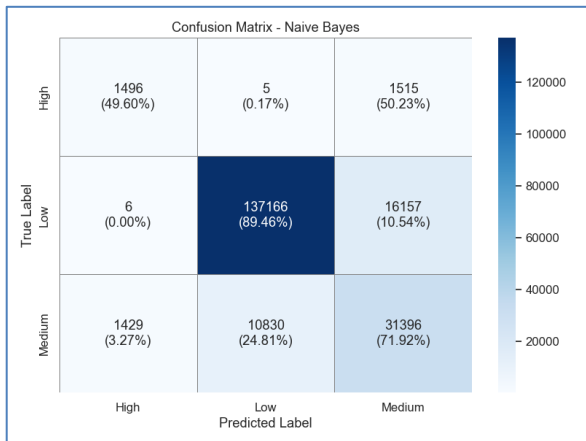
Berdasarkan *confusion matrix Logistic Regression*, model menunjukkan performa yang sangat baik pada kelas *Low*, dengan sebagian besar data (144.678 atau 94,36%) berhasil diklasifikasikan dengan benar. Pada kelas *Medium*, model juga cukup baik dengan tingkat prediksi benar sebesar 65,80%, meskipun masih terdapat kesalahan klasifikasi ke kelas *Low*. Namun, pada kelas *High*, performa model masih terbatas, di mana sebagian besar data (66,64%) salah diklasifikasikan sebagai *Medium*. Hal ini menunjukkan bahwa meskipun *Logistic Regression* memiliki akurasi tinggi secara keseluruhan, model masih mengalami kesulitan dalam membedakan kelas

berisiko tinggi akibat ketidakseimbangan distribusi data.



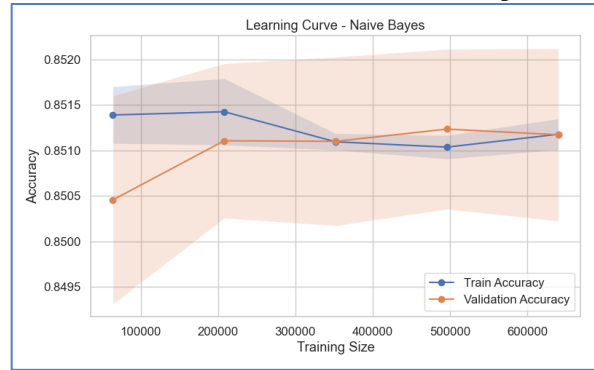
Gambar 6. Training Curve Logistic Regression

Berdasarkan grafik *learning curve Logistic Regression*, terlihat bahwa nilai akurasi *training* dan validasi sangat dekat dan cenderung stabil seiring bertambahnya jumlah data. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* maupun *underfitting* yang signifikan. Selain itu, kurva yang relatif datar mengindikasikan bahwa penambahan data tidak memberikan peningkatan performa yang berarti, sehingga model sudah mencapai performa optimal dengan konfigurasi saat ini.



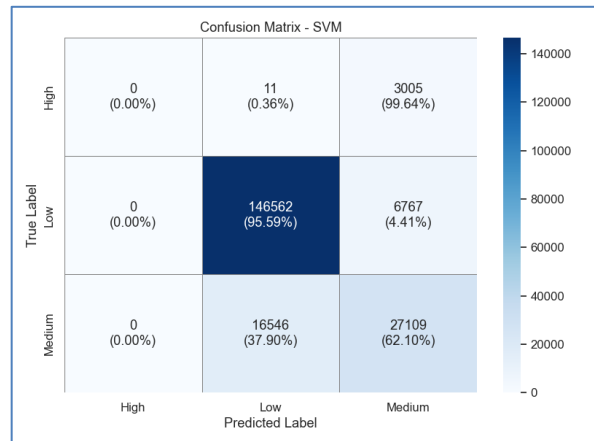
Gambar 7. Confusion Matrix Naive Bayes

Berdasarkan *confusion matrix Naive Bayes*, model menunjukkan performa yang cukup baik pada kelas *Low* dengan tingkat prediksi benar sebesar 89,46%, meskipun lebih rendah dibandingkan model lain. Pada kelas *Medium*, model mampu mengklasifikasikan dengan cukup baik (71,92%), namun masih terdapat kesalahan prediksi ke kelas *Low*. Sementara itu, pada kelas *High*, performa model relatif seimbang antara prediksi benar (49,60%) dan kesalahan ke kelas *Medium* (50,23%), yang menunjukkan kemampuan deteksi yang lebih baik dibanding beberapa model lain. Secara keseluruhan, *Naive Bayes* lebih mampu mengenali kelas minoritas dibanding *SVM* atau *Decision Tree*, namun tetap dipengaruhi oleh ketidakseimbangan data.




Gambar 8. Learning Curve Naive Bayes

Berdasarkan grafik *learning curve Naive Bayes*, terlihat bahwa nilai akurasi *training* dan validasi berada sangat dekat dan cenderung *konvergen* seiring bertambahnya jumlah data. Hal ini menunjukkan bahwa model memiliki generalisasi yang baik dan tidak mengalami *overfitting*. Selain itu, kurva yang relatif stabil mengindikasikan bahwa performa model tidak banyak berubah dengan penambahan data, sehingga model telah mencapai batas optimalnya, meskipun tingkat akurasi keseluruhan masih lebih rendah dibandingkan algoritma lain.




Gambar 9. Confusion Matrix SVM

Berdasarkan *confusion matrix SVM*, model menunjukkan performa yang sangat baik pada kelas *Low*, dengan tingkat prediksi benar mencapai 95,59%. Namun, model gagal sepenuhnya dalam mendeteksi kelas *High*, di mana seluruh data (99,64%) salah diklasifikasikan sebagai *Medium*. Pada kelas *Medium*, performa model cukup baik dengan prediksi benar sebesar 62,10%, meskipun masih banyak kesalahan ke kelas *Low*. Hal ini menunjukkan bahwa *SVM* sangat bias terhadap kelas mayoritas dan tidak mampu mengenali kelas minoritas (*High*), yang mengindikasikan pengaruh kuat dari ketidakseimbangan data terhadap kinerja model.




Gambar 10. Learning Curve SVM



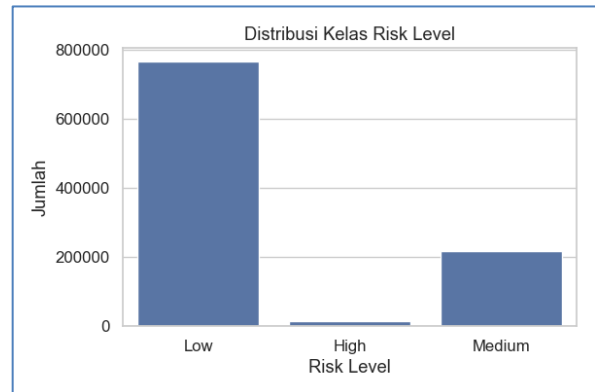
Gambar 12. Learning Curve Random Forest

Berdasarkan grafik *learning curve SVM*, terlihat bahwa nilai akurasi training dan validasi sangat berdekatan dan cenderung meningkat secara stabil seiring bertambahnya jumlah data. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting*. Namun, meskipun performa terlihat stabil dan cukup tinggi, hasil ini perlu dikaji bersama *confusion matrix* yang menunjukkan bahwa model gagal mendeteksi kelas *High*, sehingga akurasi yang tinggi lebih disebabkan oleh dominasi kelas mayoritas (*Low*) dalam dataset.

Berdasarkan grafik *learning curve Random Forest*, terlihat bahwa akurasi training menurun seiring bertambahnya jumlah data, sementara akurasi validasi sedikit meningkat dan kemudian stabil. Jarak antara keduanya masih cukup terlihat, yang menunjukkan adanya sedikit *overfitting* pada model. Namun, karena akurasi validasi relatif stabil di sekitar nilai yang tinggi, model tetap memiliki kemampuan generalisasi yang baik meskipun masih dapat ditingkatkan.



Gambar 11. Confusion Matrix Random Forest



Berdasarkan *confusion matrix Random Forest*, model menunjukkan performa yang sangat baik pada kelas *Low*, dengan sebagian besar data (144.788 atau 94,43%) berhasil diklasifikasikan dengan benar. Pada kelas *Medium*, model juga cukup baik dengan tingkat prediksi benar sebesar 65,57%, meskipun masih terdapat kesalahan klasifikasi ke kelas *Low*. Namun, pada kelas *High*, performa model masih rendah, di mana sebagian besar data (75,00%) salah diklasifikasikan sebagai *Medium*. Hal ini menunjukkan bahwa meskipun *Random Forest* memiliki akurasi tinggi secara keseluruhan, model masih kesulitan dalam mendeteksi kelas risiko tinggi akibat ketidakseimbangan distribusi data.

Berdasarkan grafik distribusi kelas risk level, terlihat bahwa data sangat tidak seimbang, di mana kelas *Low* mendominasi dengan jumlah yang jauh lebih besar dibandingkan kelas lainnya, diikuti oleh kelas *Medium*, sementara kelas *High* memiliki jumlah yang sangat sedikit. Ketimpangan distribusi ini menunjukkan adanya *class imbalance* yang signifikan, yang berpotensi menyebabkan model machine learning menjadi bias terhadap kelas mayoritas dan kurang mampu mengenali kelas minoritas, khususnya kategori *High* yang justru memiliki tingkat risiko paling tinggi.

#### 4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa algoritma machine learning mampu digunakan untuk memprediksi tingkat kesehatan mental dan burnout mahasiswa dengan performa yang cukup baik. Dari lima algoritma yang diuji, yaitu *Decision Tree*, *Logistic Regression*, *Naive Bayes*, *Support Vector Machine (SVM)*, dan *Random Forest*, diperoleh hasil bahwa *Logistic Regression* memiliki performa terbaik dengan nilai *accuracy*

sebesar 0,8720 dan F1-score sebesar 0,8677, diikuti oleh *Random Forest* yang juga menunjukkan performa yang kompetitif. Secara umum, seluruh model menunjukkan performa yang sangat baik dalam memprediksi kelas Low sebagai kelas mayoritas. Namun, performa model menurun secara signifikan pada kelas Medium dan terutama pada kelas High. Hal ini disebabkan oleh adanya ketidakseimbangan data (*class imbalance*) yang membuat model cenderung bias terhadap kelas mayoritas dan kurang mampu mendeteksi kelas minoritas. Model SVM menunjukkan kelemahan paling signifikan karena gagal mendeteksi kelas High sama sekali, meskipun memiliki akurasi yang cukup tinggi. Sementara itu, *Naive Bayes* menunjukkan kemampuan yang relatif lebih baik dalam mendeteksi kelas High dibandingkan beberapa model lain, meskipun performanya keseluruhannya lebih rendah. Hasil analisis juga menunjukkan bahwa metrik *accuracy* saja tidak cukup untuk mengevaluasi performa model dalam kasus data tidak seimbang. Oleh karena itu, penggunaan *precision*, *recall*, dan F1-score sangat penting untuk memberikan gambaran yang lebih komprehensif, terutama dalam menilai kemampuan model dalam mendeteksi kelas berisiko tinggi. Dengan demikian, *Logistic Regression* dan *Random Forest* dapat direkomendasikan sebagai model terbaik dalam penelitian ini, namun masih diperlukan peningkatan performa, khususnya dalam mendeteksi kelas High yang memiliki tingkat risiko paling tinggi.

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat diberikan untuk pengembangan penelitian selanjutnya. Pertama, perlu dilakukan penanganan terhadap ketidakseimbangan data (*class imbalance*) dengan menggunakan teknik seperti *oversampling*, *undersampling*, atau metode *Synthetic Minority Over-sampling Technique* (SMOTE) untuk meningkatkan kemampuan model dalam mendeteksi kelas minoritas.

Kedua, penelitian selanjutnya dapat mengeksplorasi penggunaan algoritma lain yang lebih kompleks, seperti *Gradient Boosting*, *XGBoost*, atau *deep learning*, yang berpotensi memberikan performa yang lebih baik dalam menangani data dengan distribusi yang tidak seimbang.

Ketiga, perlu dilakukan tuning parameter (*hyperparameter tuning*) pada masing-masing algoritma untuk mendapatkan performa yang optimal, karena dalam penelitian ini kemungkinan masih terdapat parameter yang belum dioptimalkan secara maksimal.

Keempat, pengembangan sistem prediksi kesehatan mental dapat ditingkatkan dengan menambahkan lebih banyak fitur yang relevan, seperti faktor psikologis, sosial, dan lingkungan, sehingga model dapat menangkap pola yang lebih kompleks.

Kelima, visualisasi dan interpretasi model juga perlu ditingkatkan agar hasil prediksi dapat lebih mudah dipahami dan digunakan sebagai dasar pengambilan

keputusan oleh pihak terkait, seperti institusi pendidikan atau konselor.

Dengan adanya pengembangan lebih lanjut, diharapkan sistem prediksi kesehatan mental berbasis machine learning dapat menjadi alat yang efektif dalam mendeteksi dan mencegah burnout pada mahasiswa secara lebih dini.

## REFERENSI

- [1] H. A. Harefa, "Ketika Pelayanan Menjadi Rutinitas: Menyelami Kebosanan Mahasiswa Teologi Dalam Menghadapi Tantangan Spiritual," *LOKO KADA TUO J. Teol. Kontekt. dan oikumenis*, vol. 2, no. 1, pp. 29–41, Mar. 2025, doi: 10.70418/4xen4b29.
- [2] V. Agustin, "Kompetensi Lulusan Sarjana St rata 1 (S1) Psikologi dalam Menghadapi Dunia Kerja Pada Mahasiswa Perguruan Tinggi 'X,'" *Calypra J. Ilm. Mhs. Univ. Surabaya*, vol. 1, no. 1, pp. 1–34, 2012, [Online]. Available: <https://journal.ubaya.ac.id/index.php/jimus/article/view/41/24>
- [3] T. Meriana, "Fenomena Kesehatan Mental Mahasiswa Di Tahun 2025: Urgensi Help-Seeking Behavior Sebagai Strategi Adaptif," *Syntax Idea*, vol. 7, no. 9, pp. 1102–1112, Sep. 2025, doi: 10.46799/syntaxidea.v7i9.13548.
- [4] I. Yusran, S. Selviani, and S. Kahar, "PENGARUH FAKTOR-FAKTOR EKSTERNAL BURNOUT AKADEMIK ATAU INTENSITAS MEDIA SOSIAL," *Al-Isyraq J. Bimbingan, Penyuluhan, dan Konseling Islam*, vol. 8, no. 3, pp. 1127–1146, 2025, doi: <https://doi.org/10.59027/alisyraq.v8i3.1204>.
- [5] G. Tri Prayogo Yusuf, *Psikologi Kesehatan Mental Teori dan Aplikasi untuk Mahasiswa Indonesia*, Pertama. Sumatera Barat: PT. Serasi Media Teknologi, 2026. [Online]. Available: [https://www.researchgate.net/profile/Gilang-Tri-Prayogo-Yusuf/publication/400225614\\_Psikologi\\_Kesehatan\\_Mental\\_Teori\\_dan\\_Aplikasi\\_untuk\\_Mahasiswa\\_Indonesia\\_2026/links/69b51cb9a5bf176ab54ff2d1/Psikologi-Kesehatan-Mental-Teori-dan-Aplikasi-untuk-Mahasiswa-I](https://www.researchgate.net/profile/Gilang-Tri-Prayogo-Yusuf/publication/400225614_Psikologi_Kesehatan_Mental_Teori_dan_Aplikasi_untuk_Mahasiswa_Indonesia_2026/links/69b51cb9a5bf176ab54ff2d1/Psikologi-Kesehatan-Mental-Teori-dan-Aplikasi-untuk-Mahasiswa-I)
- [6] Dian Zahwa Oktaviani and Marsofiyati Marsofiyati, "Pengaruh Beban Tugas Akademik dan Dukungan Sosial Terhadap Tingkat Burnout Mahasiswa Pendidikan Administrasi Perkantoran," *Harmon. Pendidik. J. Ilmu Pendidik.*, vol. 2, no. 1, pp. 322–336, Dec. 2024, doi: 10.62383/hardik.v2i1.1102.
- [7] P. Abel Andreas, S. Fajar Firmansyah, and H. Hendra Pradana, "Studi Fenomenologi Burnout pada Mahasiswa yang Kuliah dan Bekerja," *Psycho Aksara J. Penelit. Psikol.*, vol. 3, no. 2, pp. 154–178, 2025, doi: 10.28926/pyschoaksara.v3i2.1726.
- [8] M. Ali, S. Ali, Q. Abbas, Z. Abbas, and S. W. Lee, "Artificial intelligence for mental health: A narrative review of applications, challenges, and future directions in digital health," *Digit. Heal.*, vol. 11, May 2025, doi: 10.1177/20552076251395548.
- [9] M. N. Makki, *Hubungan Antara Academic Burnout Dengan Kualitas Tidur Pada Mahasiswa Di Program Studi Pendidikan Dokter Uin Maulana Malik Ibrahim*, vol. 2, no. 11. 2023.
- [10] J. Parhusip, J. Feranita, M. P. Mentari, T. Apriliani, and A. M. Jessend, "Implementasi Algoritma K-Means Clustering Untuk Segmentasi Tingkat Kesehatan Mental Mahasiswa Berdasarkan Faktor Stress dan Akademik," *J. Media Inform.*, vol. 7, no. 1 SE-, pp. 449–458, Feb. 2026, doi: 10.55338/jumin.v7i1.7856.
- [11] A. Arum Sari and H. Permatasari, "Prediksi Risiko Kesehatan Mental Berdasarkan Pola Penggunaan Perangkat Digital Menggunakan Algoritma *Logistic*

- Regression*,” *Pros. SEMNANA*, vol. 3, pp. 151–161, 2026, [Online]. Available: <https://ojs.amikomsolo.ac.id/index.php/semnana/article/view/999/314>
- [12] H. A. Nabila and Endang Wahyu Pamungkas, “PERBANDINGAN ALGORITMA MACHINE LEARNING: SVM, RANDOM FOREST, DAN XGBOOST UNTUK PREDIKSI STROKE,” *Rabit J. Teknol. dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 1098–1110, Jul. 2025, doi: 10.36341/rabit.v10i2.6444.
- [13] A. Miftahusalam, A. F. Nuraini, A. A. Khoirunisa, and H. Pratiwi, “Perbandingan Algoritma Random Forest, Naïve Bayes, dan Support Vector Machine Pada Analisis Sentimen Twitter Mengenai Opini Masyarakat Terhadap Penghapusan Tenaga Honorar,” *Semin. Nas. Off. Stat.*, vol. 2022, no. 1, pp. 563–572, Nov. 2022, doi: 10.34123/semnasoffstat.v2022i1.1410.
- [14] J. J. Hidayat, C. Setyowati, M. D. I. Amin, K. Bimasakti, and A. P. Werdana, “Deep Learning-based Sentiment Analysis of Public Comments on Military Education Using RoBERTa Algorithm and Rule-Based Hybrid Parameters,” *J. Media Comput. Sci.*, vol. 4, no. 2 SE-Articles, Jul. 2025, doi: 10.37676/jmcs.v4i2.8769.
- [15] J. R. Quinlan, “Learning Decision Tree classifiers,” *ACM Comput. Surv.*, vol. 28, no. 1, pp. 71–72, Mar. 1996, doi: 10.1145/234313.234346.
- [16] B. de Ville, “Decision Trees,” *WIREs Comput. Stat.*, vol. 5, no. 6, pp. 448–455, Nov. 2013, doi: 10.1002/wics.1278.
- [17] A. H. Anshor and A. T. Zy, “Implementasi Metode Decision Tree pada Sistem Prediksi Status Kualitas Produk Minuman A,” *J. Ilm. Inform. Glob.*, vol. 15, no. 1, pp. 17–22, Apr. 2024, doi: 10.36982/jiig.v15i1.3778.
- [18] K. N. Syahputri and M. S. Hasibuan, “OPTIMASI KLASIFIKASI DECISION TREE DENGAN TEKNIK PRUNING UNTUK MENGURANGI OVERFITTING,” *JSiI (Jurnal Sist. Informasi)*, vol. 11, no. 2, pp. 87–96, Sep. 2024, doi: 10.30656/jsii.v11i2.9161.
- [19] A. Riansah, O. Nurdianan, and R. Herdiana, “PENERAPAN ALGORITMA RANDOM FOREST DAN DECISION TREE UNTUK MENINGKATKAN AKURASI KLASIFIKASI PENJUALAN PADA TOKO BANGUNAN,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 3, pp. 4242–4249, May 2025, doi: 10.36040/jati.v9i3.13622.
- [20] A. Putra Argadinata, D. Abdul Fatah, and H. Sukri, “KLASIFIKASI KUALITAS BUAH APEL MENGGUNAKAN METODE RANDOM FOREST,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 2016–2022, Mar. 2025, doi: 10.36040/jati.v9i2.12854.
- [21] E. Rilvani, R. Hidayat, and F. Rizaldi, “LITERATURE REVIEW: PERBANDINGAN ALGORITMA ID3 DAN CART DALAM DATA MINING,” *Kohesi J. Sains dan Teknol.*, vol. 10, no. 1 SE-Articles, pp. 1–10, 2025, doi: 10.2238/bd21vh46.
- [22] A. Ermillian and K. Nugroho, “Perancangan Model Deteksi Potensi Siswa Patus Sekolah Menggunakan Metode Logistic Regression Dan Decision Tree,” *J. Inform. J. Pengemb. IT*, vol. 9, no. 3, pp. 281–295, Dec. 2024, doi: 10.30591/jpit.v9i3.8007.
- [23] E. Y. Boateng and D. A. Abaye, “A Review of the Logistic Regression Model with Emphasis on Medical Research,” *J. Data Anal. Inf. Process.*, vol. 07, no. 04, pp. 190–207, 2019, doi: 10.4236/jdaip.2019.74012.
- [24] M. Afriansyah, Joni Saputra, V. Y. P. Ardhana, and Yuan Sa’adati, “ALGORITMA NAIVE BAYES YANG EFISIEN UNTUK KLASIFIKASI BUAH PISANG RAJA BERDASARKAN FITUR WARNA,” *J. Inf. Syst. Manag. Digit. Bus.*, vol. 1, no. 2, pp. 236–248, Jan. 2024, doi: 10.59407/jismdb.v1i2.438.
- [25] I. Rafi Alfiandi, Gunawan, M. Rizki Fadhil, and R. Samsinar, “Analisis Performa Convolutional Neural Network (CNN) dan Naive Bayes dalam Face Recognition: Akurasi dan Kompleksitas,” *Pros. Semin. Nas. Hukum, Bisnis, Sains dan Teknol.*, vol. 5, no. 1 SE-Articles, pp. 284–294, [Online]. Available: <https://www.ojs.uib.ac.id/HUBISINTEK/article/view/4758>
- [26] J. Rusman, B. Z. Haryati, and A. Michael, “Optimisasi Hiperparameter Tuning pada Metode Support Vector Machine untuk Klasifikasi Tingkat Kematangan Buah Kopi,” *J. Komput. dan Inform.*, vol. 11, no. 2, pp. 195–202, Oct. 2023, doi: 10.35508/jicon.v11i2.12571.
- [27] M. R. Saputra and P. Parjito, “ANALISIS SENTIMEN TWITTER TERHADAP KONFLIK DI PAPUA MENGGUNAKAN PERBANDINGAN NAIVE BAYES DAN SVM,” *JiPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.)*, vol. 10, no. 2, pp. 1197–1208, Mar. 2025, doi: 10.29100/jipi.v10i2.6180.
- [28] C. V. Angkoso, K. Asror, A. Kusumaningsih, and A. K. Nugroho, “Optimasi Algoritma Support Vector Machine Berbasis Kernel Radial Basis Function (RBF) Menggunakan Metode Particle Swarm Optimization Untuk Analisis Sentimen,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 12, no. 3, pp. 705–718, Jun. 2025, doi: 10.25126/jtiik.2025129317.
- [29] J. J. Hidayat, C. Setyowati, and A. P. Werdana, “Perancangan Sistem Prediksi Penyakit pada Tanaman Padi Berbasis Image Processing Menggunakan Algoritma VGG-16 Transfer Learning dan K-Means Segmentation,” *J. Pract. Comput. Sci.*, vol. 5, no. 1, pp. 1–15, May 2025, doi: 10.37366/jpcs.v5i1.5759.
- [30] M. D. I. Amin, J. J. Hidayat, C. Setyowati, E. K. Fitri, A. N. Anggraini, and A. P. Werdana, “Implementasi Model LSTM Untuk Peramalan Curah Hujan Di Bekasi Dengan Pemanfaatan Data Cuaca BMKG,” *J. Teknol. Inf. Digit.*, vol. 1, no. 2, pp. 90–99, [Online]. Available: <https://jurnal.ipdig.id/index.php/jtid/article/view/200>
- [31] Muhamad Febiansyah, J. Jondri, and Indwiarti, “Prediksi Retweet Berdasarkan Konten Dan Pengguna Dengan Metode Classifier Selection,” *Log. J. Penelit. Inform.*, vol. 3, no. 1, Sep. 2025, doi: 10.25124/logic.v3i1.9744.
- [32] M. A. Rahman Wahid, A. Nugroho, and A. Halim Anshor, “Prediksi Penyakit Kanker Paru-Paru Dengan Algoritma Regresi Linier,” *Bull. Inf. Technol.*, vol. 4, no. 1, pp. 63–74, Mar. 2023, doi: 10.47065/bit.v4i1.501.
- [33] A. T. Sasongko and M. Ivan Fanany, “Indonesia Toll Road Vehicle Classification Using Transfer Learning with Pre-trained Resnet Models,” in *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2019, pp. 373–378. doi: 10.1109/ISRITI48646.2019.9034590.