



EduMood: Sistem Deteksi Sentimen Berbasis Web Menggunakan Metode Machine Learning untuk Identifikasi Awal Gejala Stres Mahasiswa

M. Riko Anshori Prasetya^{1,*}, Subhannur Rahman², Arif Mudi Priyatno³, Mera¹, Ulfia Wahyuni¹

¹Fakultas Sains dan Teknologi, Sistem Informasi, Universitas Sari Mulia, Banjarmasin

Jl. Pramuka No.2, Pemurus Luar, Kec. Banjarmasin Timur, Kota Banjarmasin, Kalimantan Selatan, Indonesia

²Fakultas Kesehatan, Keperawatan dan Profesi Ners, Universitas Sari Mulia, Banjarmasin

Jl. Pramuka No.2, Pemurus Luar, Kec. Banjarmasin Timur, Kota Banjarmasin, Kalimantan Selatan, Indonesia

³Fakultas Ekonomi dan Bisnis, Bisnis Digital, Universitas Pahlawan Tuanku Tambusai, Riau

Jl. Tuanku Tambusai No.23, Bangkinang, Kec. Bangkinang, Kabupaten Kampar, Riau, Indonesia

Email: ^{1,*}riko.anshori@gmail.com, ²zikrisubhan55@gmail.com, ³arifmudi@universitaspahlawan.ac.id,

⁴mermera0610@gmail.com, ⁵ulfiaafianii@gmail.com

Email Penulis Korespondensi: riko.anshori@gmail.com

Submitted: 24/05/2025; Accepted: 23/07/2025; Published: 31/07/2025

Abstrak—Kesehatan mental mahasiswa menjadi isu penting yang perlu mendapat perhatian serius, terutama di era media sosial yang sarat tekanan psikologis. Penelitian ini bertujuan untuk mengembangkan sistem EduMood, sebuah sistem analisis sentimen berbasis web untuk mengidentifikasi masalah kesehatan mental mahasiswa dengan menganalisis tweet di Twitter. Data tweet dikumpulkan menggunakan kata kunci yang relevan dan melalui tahap preprocessing seperti pembersihan teks, pelabelan awal berbasis leksikon bilingual, dan penyeimbangan jumlah data antar kelas sentimen. Sistem ini menggunakan dua algoritma machine learning, Support Vector Machine (SVM) dan Naive Bayes dengan representasi fitur Term Frequency-Inverse Document Frequency (TF-IDF). Hasil evaluasi menunjukkan bahwa SVM memiliki akurasi lebih tinggi sebesar 99,3% dibandingkan Naive Bayes yang mencapai 96,5% dengan skor f1 untuk semua kelas di atas 0,99 untuk SVM. EduMood diimplementasikan dalam bentuk aplikasi berbasis web menggunakan Flask dan Bootstrap 5, yang menyajikan hasil analisis melalui dashboard interaktif. Dashboard menampilkan distribusi sentimen secara agregat dalam bentuk diagram, wordcloud, tabel monitoring, dan prediksi manual teks. Hasil penelitian ini menunjukkan bahwa EduMood tidak hanya memberikan performa model yang sangat baik, tetapi juga menawarkan solusi praktis bagi pihak kampus untuk memantau kondisi psikologis mahasiswa secara cepat, berbasis data nyata, dan mudah diakses. Sistem ini diharapkan dapat mendukung upaya peningkatan kesehatan mental mahasiswa secara berkelanjutan.

Kata Kunci: Kesehatan Mental; Analisis Sentimen; Machine Learning; SVM; Web-Based Dashboard.

Abstract—Students' mental health is an important issue that needs serious attention, especially in the era of social media which is full of psychological pressure. This research aims to develop EduMood, a web-based sentiment analysis system to monitor college students' mental health issues by analyzing tweets on Twitter. The tweet data is collected using relevant keywords and goes through preprocessing stages such as text cleaning, bilingual lexicon-based initial labeling, and balancing the amount of data between sentiment classes. The system uses two machine learning algorithms, Support Vector Machine (SVM) and Naive Bayes with Term Frequency-Inverse Document Frequency (TF-IDF) feature representation. The evaluation results show that SVM has a higher accuracy of 99.3% compared to Naive Bayes which reaches 96.5% with f1 scores for all classes above 0.99 for SVM. EduMood is implemented as a web-based application using Flask and Bootstrap 5, which presents the analysis results through an interactive dashboard. The dashboard displays the aggregate sentiment distribution in the form of diagrams, wordclouds, monitoring tables, and text manual predictions. The results of this study show that EduMood not only provides excellent model performance, but also offers a practical solution for the campus to monitor the psychological condition of students in a fast, real data-based, and easily accessible manner. This system is expected to support efforts to improve student mental health in a sustainable manner.

Keywords: Mental Health; Sentiment Analysis; Machine Learning; SVM; Web-Based Dashboard

1. PENDAHULUAN

Kesehatan mental mahasiswa telah menjadi salah satu isu penting yang banyak diperhatikan dalam beberapa tahun terakhir. Laporan WHO menyebutkan jika pada kawasan Asia Pasifik (WHO SEARO) kesehatan mental merupakan salah satu penyakit yang belum dapat diatasi seutuhnya baik dalam skala global maupun lokal [1], [2]. Di Indonesia sendiri satu dari duapuluh tiga remaja di Indonesia mengalami gangguan kesehatan jiwa[3]. Mahasiswa berada pada masa transisi menuju ke masa dewasa yang penuh dengan tekanan akademis, sosial, dan juga ekonomi yang secara signifikan akan berpengaruh pada kesehatan mental mereka[4].

Di sisi lain, mahasiswa masa kini merupakan generasi yang sangat aktif dalam memanfaatkan aplikasi digital seperti media sosial[5]. Mahasiswa sendiri sering menggunakan media sosial, khususnya Twitter, yang saat ini menjadi ruang bagi mahasiswa untuk dapat mengekspresikan emosi dan keluh kesah mereka secara terbuka[6], [7]. Ungkapan dan juga diskusi yang muncul di media sosial ini sebenarnya bisa mencerminkan keadaan psikologis mahasiswa [8]. Beberapa penelitian juga menunjukkan jika pola bahasa, frekuensi posting, dan isi emosional dari tweet berkorelasi dengan indikator depresi[9].

Namun, sampai saat ini, proses pemantauan kesehatan mental mahasiswa melalui media sosial masih sulit dilakukan secara manual, karena jumlah data yang luas, tidak terstruktur, dan bersifat dinamis(Nazari et al., 2023).

Selain itu, metode konvensional seperti kuisioner ataupun wawancara memiliki berbagai keterbatasan, selain dari cakupan responden, waktu, serta keterbukaan menghadapi jawaban[11]. Hal ini menegaskan jika diperlukan sebuah sistem otomatis yang berbasis teknologi yang dapat membantu pihak kampus untuk memantau kesehatan mental mahasiswanya secara cepat, akurat, dan juga realtime.

Sebagai solusi dari permasalahan tersebut, penelitian ini melakukan pengembangan sistem berbasis web bernama EduMood, dimana sistem ini mampu untuk mendeteksi sentimen mahasiswa dari cuitan mereka di media sosial, mengklasifikasikan sentimen menjadi positif, negatif, dan netral, serta menyajikan hasil analisis dalam bentuk dashboard interaktif yang mudah dipahami. EduMood mengintegrasikan teknik pembelajaran mesin (machine learning) untuk melakukan analisis sentimen dan visualisasi data sehingga pihak kampus dapat lebih cepat mendeteksi kondisi psikologis mahasiswa dan mengambil langkah intervensi bila diperlukan.

Beberapa penelitian sejenis telah memanfaatkan media sosial sebagai sumber data dalam melakukan analisis psikologis masyarakat. Beberapa penelitian sebelumnya telah memanfaatkan media sosial untuk melakukan deteksi gangguan psikologis khususnya depresi. Misalnya penelitian [12] yang menggunakan machine learning untuk mendeteksi tanda-tanda depresi melalui analisis tweet namun fokusnya hanya pada klasifikasinya. Demikian pula dengan penelitian [13] yang melakukan klasifikasi multi kelas sentimen untuk mendeteksi depresi namun tidak mengembangkan sistem yang dapat digunakan secara praktis.

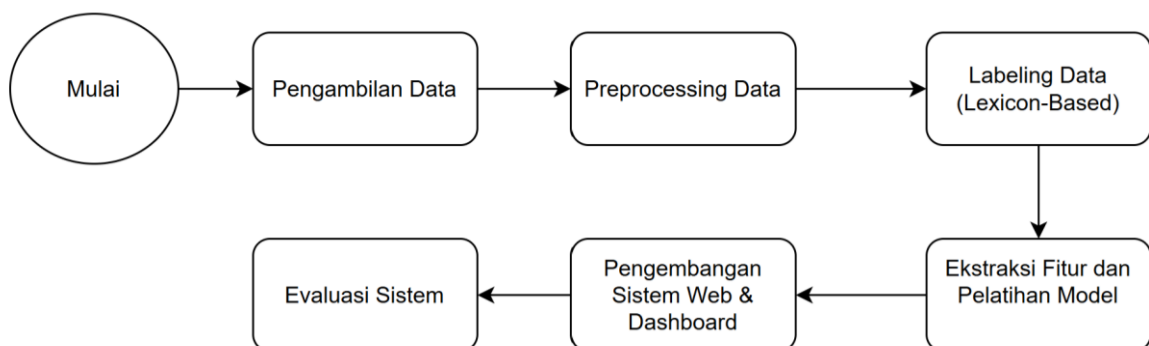
Penelitian oleh (Obagbuwa et al., 2023) membandingkan model supervised learning dalam melakukan deteksi sentimen teks, namun hasilnya bersifat teoritis tanpa integrasi dalam sistem pemantauan yang terstruktur. [15]juga mengusulkan sebuah sistem manajemen kesehatan yang menggunakan analisis sentimen namun tidak memiliki sebuah dashboard interaktif, sedangkan [16] yang mengembangkan metode depresi melalui pendekatan AI, tapi lebih fokus ke pengujian performa daripada menggunakannya untuk konteks nyata seperti lingkungan universitas.

Berdasarkan penelitian-penelitian tersebut, terdapat beberapa gap yang ingin diisi oleh penelitian ini. Pertama, sebagian besar penelitian hanya fokus pada pembangunan model klasifikasi sentimen tanpa integrasi dengan sistem berbasis web. Kedua, sebagian besar studi belum menyediakan dashboard interaktif yang menyajikan hasil analisis dalam berbagai bentuk visualisasi yang informatif seperti wordcloud, tren harian, dan tabel monitoring. Ketiga, masih sedikit penelitian yang secara khusus memfokuskan diri pada konteks kesehatan mental mahasiswa, padahal kelompok ini sangat rentan terhadap masalah psikologis dan membutuhkan perhatian khusus.

Oleh karena itu, penelitian ini bertujuan untuk mengembangkan EduMood, sebuah sistem berbasis web untuk pemantauan kesehatan mental mahasiswa melalui analisis sentimen cuitan di media sosial. EduMood dirancang untuk dapat mengklasifikasikan sentimen mahasiswa secara otomatis, menyajikan hasil analisis dalam bentuk dashboard interaktif, dan mendukung monitoring real-time sehingga pihak kampus dapat memperoleh informasi yang relevan untuk merancang intervensi yang tepat. Diharapkan, EduMood dapat membantu pihak kampus atau pihak terkait lainnya dalam memahami kondisi psikologis mahasiswa secara lebih baik, cepat, dan berbasis data nyata, serta dapat menjadi dasar pengembangan sistem serupa di masa mendatang.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan metode pengembangan sistem berbasis web dengan pendekatan machine learning untuk analisis sentimen. Tahapan metodologi meliputi pengumpulan data, preprocessing teks, pelatihan model klasifikasi sentimen, pengembangan dashboard visualisasi, dan pengujian sistem. Gambar 1 menyajikan alur kerja sistem secara keseluruhan.



Gambar 1. Alur Kerja Sistem

2.1 Tahapan Penelitian

Sistem EduMood dirancang untuk membantu pihak kampus dalam memantau kondisi kesehatan mental mahasiswa melalui cuitan yang dipublikasikan di media sosial Twitter. Sistem terdiri dari empat tahapan utama:

1. Pengumpulan data tweet.
2. Preprocessing data yang terdiri dari pembersihan data dan melabeli data dengan Lexicon Based.
3. Pelatihan model klasifikasi dengan machine learning
4. Implementasi sistem berbasis web dengan dashboard visualisasi hasil.

2.2 Dataset

Dataset penelitian ini diperoleh dengan mengumpulkan cuitan berbahasa Indonesia dari Twitter yang mengandung kata kunci relevan seperti mahasiswa, kampus, stres, capek, depresi, dan kuliah. Data dikumpulkan menggunakan Twitter selama periode 2023-2025 dan terdiri dari 102935 cuitan. Dataset kemudian diberi label sentimen secara manual oleh tiga annotator sebagai positif, negatif, atau netral. Contoh dataset dapat dilihat pada Gambar 2.

conversation_id_str	created_at	favorite_count	full_text	id_str
1944424268621920000	Sun Jul 13 15:50:45 +0000 2	869	People should stop taking SSRIs for anxiety and depression. These 10 specific supplements can actually reset your nervous system by targeting GABA serotonin and stress hormones (naturally). 1)	1944424268621920000
1941417022161810000	Sat Jul 05 08:41:02 +0000 2	417	Saffron https://t.co/dpGvkEGVQF i m tired i m stress i m hurt but i m fine	1941417022161810000
1941861134144830000	Sun Jul 06 14:05:47 +0000 2	629	Aspirin = strong anti-hairloss properties. -anti-stress -anti-inflammatory -pro-metabolic -pro-thyroid (T3) Aspirin also shifts the mitochondria from the state of oxidizing fats into oxidizing glucose which is favorable for thyroid hormone (T3) & hair health. https://t.co/00DQGzES8t	1941861134144830000
1943914719674270000	Sat Jul 12 06:06:00 +0000 2	4458	Dua for removing difficulties and stress. https://t.co/rQB4GIR37Q my favorite game is to guess if my headache is due to dehydration	1943914719674270000
1941446610418090000	Sat Jul 05 10:38:36 +0000 2	125394	migraine malnutrition stress lack of sleep poor position or a brain tumor.	1941446610418090000

Gambar 2. Contoh Dataset Mentah dengan Excel

2.3 Preprocessing Data

Data cuitan yang diperoleh dari Twitter pada umumnya bersifat tidak terstruktur, mengandung banyak elemen yang tidak relevan, dan bervariasi dalam penulisan. Oleh karena itu, diperlukan tahapan preprocessing untuk membersihkan, menormalkan, dan mempersiapkan data sehingga lebih representatif untuk pelatihan model machine learning dan prediksi [17]. Preprocessing dilakukan pada data pelatihan yang kemudian dikerjakan menjadi beberapa tahapan. Tahapan preprocessing pada penelitian ini mencakup beberapa langkah berikut:

1. Lowercasing.
Lowercasing preprocessing adalah salah satu langkah dalam preprocessing data yang berguna untuk melakukan transformasi data teks dari huruf besar menjadi huruf kecil. Lowercasing memastikan jika semua teks dibuat sama, contoh "Data" dan "data" yang berguna untuk mengurangi kompleksitas dari dataset[18]. Contoh dari lowercasing:
Teks Asli: Aku CAPEK dengan semua tugas kampus!
Setelah Lowercasing: aku capek dengan semua tugas kampus!
2. Pembersihan URL, Mention, dan Hashtag.
Pembersihan URL, Mention, dan Hastag adalah langkah penting dalam preprocessing dalam text mining terutama untuk data yang bersifat media sosial. Proses ini berguna sebagai suatu langkah untuk meningkatkan kualitas data dengan menghilangkan berbagai elemen yang tidak relevan sehingga dapat menghambat proses analisis[19]. Contoh dari langkah ini adalah:
Teks asli:
"Checkout tugas @Kalkulus di <http://kampusku.ac.id> sekarang!"
Setelah pembersihan URL, mention, dan hashtag:
"checkout tugas di sekarang!"
3. Penghapusan Angka dan Tanda Baca.
Proses penghapusan angka dan tanda baca adalah sebuah proses dalam teks data untuk melakukan proses cleaning dan juga normalisasi data. Proses ini melibatkan transformasi data mentah yang memiliki karakter yang tidak diinginkan seperti angka dan tanda baca, yang memastikan konsistensi disetiap kumpulan data[20]. Adapun contoh dari penghapusan angka dan tanda baca dapat dilihat pada contoh berikut:
Teks asli:
"hari ini aku mengerjakan 3 tugas sekaligus!!!"
Setelah hapus angka dan tanda baca:
"hari ini aku mengerjakan tugas sekaligus"
4. Penghapusan Space berlebih.
Proses ini adalah membersihkan spasi berlebih yang muncul akibat penghapusan elemen-elemen sebelumnya yang dibersihkan[21]. Contoh penghapusan ini dapat dilihat pada contoh berikut:
Teks setelah beberapa pembersihan:



"terima kasih "

Setelah hapus spasi berlebih:

"terima kasih"

5. Labeling dengan Lexicon

Lexicon labelling merupakan sebuah proses untuk memberikan label sentimen (misalnya: positif, negatif, atau netral) pada sebuah teks dengan cara mencocokkan kata-kata dalam teks dengan daftar kata (lexicon) yang sudah diberi skor sentimen sebelumnya. Lexicon disini adalah semacam kamus yang berisi kata seperti baik, buruk, senang, marah maka nilai sentimennya bisa bernilai +1 (Positif), -1 (negatif), 0 (netral)[22]. Contoh lexicon labelling dapat dilihat pada Tabel 1:

Tabel 1. Contoh Lexicon kecil

Kata	Skor
Senang	1
Bahagia	1
Semangat	1
Stress	-1
Biasa	0

Teks: "Hari ini aku senang tapi stress karena kuliah ku sangat lama"

Cek kata dengan lexicon:

a. Senang = +1

b. Stress = -1

Maka jumlah skornya: +1 + (-1) = 0, maka kata ini kemungkinan akan digolongkan sebagai netral.

2.4 Pemodelan Sentimen Analisis dengan Algoritma Naive Bayes dan SVM TF-IDF

Setelah data melalui tahapan preprocessing, dilakukan pemodelan untuk membangun sistem klasifikasi sentimen. Dalam penelitian ini, digunakan dua algoritma machine learning populer, yaitu Naive Bayes dan Support Vector Machine (SVM) dengan representasi fitur TF-IDF. Tahapan pemodelan sistem dijelaskan sebagai berikut:

1. Algoritma Naive Bayes.

Naive Bayes (NB) merupakan salah satu algoritma klasifikasi berbasis probabilitas yang sederhana namun efektif. Algoritma ini didasarkan pada teorema Bayes, dengan asumsi bahwa setiap fitur (atribut) dalam data bersifat kondisional independen terhadap fitur lainnya, mengingat kelas target tertentu. Asumsi ini memungkinkan perhitungan probabilitas menjadi lebih sederhana dan efisien, meskipun pada kenyataannya seringkali tidak sepenuhnya terpenuhi pada data nyata[23]. Secara matematis, tujuan Naive Bayes sendiri adalah mencari kelas Y untuk memaksimalkan probabilitas posterior P(Y|X), yang dapat dihitung dengan (1):

$$P(Y|X) \propto P(Y) \prod_{i=1}^n P(X_i|Y) \tag{1}$$

Dalam konteks ini, simbol P(Y) merepresentasikan probabilitas awal (prior probability) dari kelas Y, yaitu seberapa besar kemungkinan sebuah data termasuk ke kelas tersebut sebelum mempertimbangkan fitur-fitur yang dimilikinya. Sementara itu P(X_i|Y) menggambarkan probabilitas kemunculan fitur X_i dengan syarat bahwa data tersebut berasal dari kelas Y. Dengan kata lain, ini menunjukkan seberapa sering fitur tertentu muncul dalam data yang diketahui berasal dari kelas tersebut. Seluruh fitur yang digunakan dalam proses klasifikasi diwakili oleh vektor X = (X₁, X₂, ..., X_N) dimana X₁ hingga X_N merupakan kumpulan fitur yang diperoleh dari data input seperti kata-kata dalam tweet yang telah diolah sebelumnya. Model Naive Bayes kemudian menghitung probabilitas posterior untuk masing-masing kelas dan memilih kelas dengan nilai probabilitas tertinggi sebagai hasil prediksi [23]. Naive bayes dikenal sebagai sebuah algoritma yang cepat, mudah digunakan, dan bekerja dengan cukup baik pada dataset yang ada. Keunggulan lainnya adalah kemampuan dari algoritma ini yang relatif baik untuk menghadapi data dengan missing values dan ketahannya terhadap overfitting [24]. Pada penelitian ini Algoritma Naive Bayes yang digunakan untuk data teks. Data teks yang telah melalui tahap preprocessing kemudian diubah menjadi vektor fitur dengan TF-IDF (pada penjelasan SVM) sebelum dilatih menggunakan Naive Bayes. Model ini dilatih dengan dataset berlabel hasil lexicon dan diuji pada data uji dengan proporsi 80:20.

2. Algoritma SVM (Support Vector Machine) dan TF- IDF (Term Frequency - Inverse Document Frequency).

TF – IDF adalah metode representasi teks menjadi vektor numerik yang memperhitungkan pentingnya sebuah kata di sebuah dokumen relatif terhadap seluruh koleksi dokumen. TF (Term Frequency) merupakan frekuensi kemunculan kata di suatu dokumen sedangkan IDF (Inverse Document Frequency) yaitu ukuran seberapa jarang sebuah kata muncul di seluruh dokumen, sehingga kata yang umum (seperti "dan", "di") akan mendapatkan bobot kecil. TF-IDF efektif untuk menonjolkan kata-kata yang relevan untuk suatu dokumen[25]. Sedangkan SVM (Support Vector Machine) adalah algoritma pembelajaran mesin berbasis margin yang digunakan untuk klasifikasi. Prinsip dasarnya adalah mencari hyperplane yang memisahkan dua kelas data dengan margin maksimum[26]. Rumus dari TF-IDF dan juga SVM dapat dilihat pada persamaan (2,3).



tfidf(t, d) = tf(t, d) x idf(t) (2)

y=sign(wTx+b) (3)

Dalam penelitian ini, digunakan kernel linear dengan parameter class_weight disetel menjadi balanced untuk mengatasi distribusi kelas yang tidak seimbang. Fitur teks direpresentasikan dengan metode Term Frequency-Inverse Document Frequency (TF-IDF), yang menghitung bobot setiap kata pada dokumen relatif terhadap frekuensinya di seluruh dokumen. Pada penelitian ini, digunakan TF-IDF dengan maksimal 10.000 fitur dan ngram_range (1,2) untuk mempertimbangkan unigram dan bigram.

3. Evaluasi Model.

Dalam penelitian ini, evaluasi kinerja model klasifikasi dilakukan terlebih dahulu menggunakan confusion matrix. Kinerja kedua model penelitian ini dievaluasi menggunakan data uji. Metrik evaluasi yang digunakan adalah akurasi, presisi, recall, dan F1-score. Selain itu, performa model divisualisasikan dalam bentuk confusion matrix untuk menunjukkan jumlah prediksi benar dan salah pada masing-masing kelas (positif, netral, negatif). Confusion matrix divisualisasikan dengan menggunakan heatmap sehingga lebih mudah dipahami[27]. Evaluasi dilakukan untuk membandingkan performa kedua model sehingga dapat menentukan model yang paling optimal untuk diterapkan pada sistem EduMood. Bentuk dari confusion matrix sendiri dapat dilihat pada Tabel 2 berikut:

Tabel 2. Confusion Matrix

Table with 3 columns: Nama, Nomor, Field. Rows: Actual Positif, Actual Negatif.

Dalam evaluasi performa model klasifikasi, confusion matrix merupakan alat analisis yang digunakan untuk mengukur akurasi prediksi terhadap kelas-kelas target. Matriks ini menyajikan perbandingan antara label aktual dan hasil prediksi model dalam empat kategori utama. Pertama, True Positive (TP) menunjukkan jumlah data yang sebenarnya termasuk dalam kelas positif dan berhasil diprediksi dengan benar oleh model sebagai positif. Kedua, True Negative (TN) adalah jumlah data yang sebenarnya negatif dan juga berhasil diprediksi negatif oleh model. Ketiga, False Positive (FP) mengacu pada jumlah data yang sebenarnya negatif, tetapi keliru diprediksi sebagai positif oleh model — kesalahan ini dikenal juga sebagai Type I Error. Terakhir, False Negative (FN) menunjukkan jumlah data yang sebenarnya positif, namun diprediksi negatif oleh model, atau dikenal sebagai Type II Error. Dengan memahami keempat komponen ini, peneliti dapat menghitung berbagai metrik evaluasi seperti precision, recall, dan F1-score, yang memberikan gambaran menyeluruh terhadap kinerja model dalam mengklasifikasikan data dengan tepat [28]. Dari confusion matrix, kita dapat menghitung berbagai metrik evaluasi berikut[29]:

a. Akurasi (Accuracy)

Persentase prediksi yang benar (positif ataupun negatif) dari seluruh prediksi yang rumusnya dapat dilihat pada persamaan (4).

Accuracy = (TP+TN) / (TP+TN+FP+FN) (4)

b. Presisi (Precision)

Proporsi prediksi positif yang benar-benar positif. Terlihat presisi pada persamaan (5).

Precision = TP / (TP+FP) (5)

c. Sensitivity/ True Positive Rate (Recall)

Proporsi kasus positif yang berhasil dideteksi sebagai positif. Contoh Recall dapat dilihat pada persamaa (6).

Recall = TP / (TP+ FN) (6)

d. F1-Score

Harmonic mean dari precision dan recall yang berguna ketika dataset tidak seimbang. Rummusnya dapat dilihat pada persamaan (7)

F1 = 2 x (Precision x Recall) / (Precision+ Recal) (7)

2.5 Implementasi Dashboard Web

Sistem EduMood diimplementasikan sebagai aplikasi berbasis web yang dirancang untuk mempermudah akses, penggunaan, dan visualisasi hasil analisis sentimen. Implementasi menggunakan framework Flask dengan bahasa pemrograman Python karena ringan, fleksibel, dan mudah diintegrasikan dengan pustaka pembelajaran mesin. Antarmuka web dikembangkan menggunakan Bootstrap 5 untuk memastikan tampilan yang responsif dan modern.

Aplikasi web ini terdiri dari tiga halaman utama yang dapat diakses melalui menu navigasi: Dashboard, Prediksi Sentimen, dan Monitoring Tweet.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Preprocessing Data

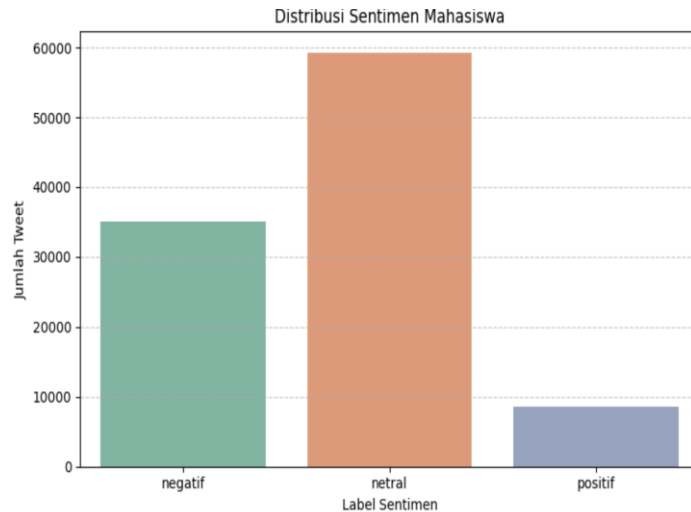
Tahapan preprocessing menghasilkan sebuah dataset yang lebih bersih dan konsisten untuk melakukan pelatihan pada model. Dari data awal yang berhasil dikumpulkan, dilakukan beberapa kali perbaikan seperti yang dijelaskan pada bagian metodologi yaitu lowercasing, menghapus URL, mention, dan hashtag, angka, tanda baca, dan juga menghapus space akibat beberapa langkah sebelumnya. Selain itu, data diberikan label sentimen secara otomatis dengan menggunakan metode bilingual (Indonesia – Inggris) untuk membentuk dataset pelatihan. Contoh hasilnya dari preprocessing data dapat dilihat pada Gambar 3.

Contoh Data Sebelum & Sesudah Preprocessing:

	full_text	clean_text	sentiment
29532	Stress Management https://t.co/EwMd01WVWA	stress management	netral
55815	when you're in a public place take a moment to...	when youre in a public place take a moment to ...	netral
78866	INFINIT Labs is building a smart way to use De...	infinet labs is building a smart way to use de...	netral
61308	ATTENTION STUDENTS Deadline for application fo...	attention students deadline for application fo...	netral
40217	Capek Ya Allah	capek ya allah	negatif

Gambar 3. Hasil Preprocessing Data

Distribusi data yang didapatkan dari hasil sentimennya adalah 35.028 data cuitan negatif, netral sebanyak 59312 data, dan positif 8595 data seperti yang terlihat pada Gambar 4.



Gambar 4. Distribusi Data Setelah Pelabelan Sentimen

Sebelum melatih model, dilakukan pemeriksaan distribusi label sentimen pada dataset. Terlihat jika jumlah data awal tidak seimbang. Ketidakseimbangan ini dapat menyebabkan bias pada model, dimana model akan cenderung memprediksi kelas dengan jumlah yang lebih besar yaitu netral. Oleh sebab itu, penelitian ini akan dilakukan penyeimbangan dataset dengan cara mengambil jumlah sampel terkecil dari salah satu kelas, kemudian akan diacak dan disamakan jumlah data untuk setiap kelas. Hal ini memastikan model menerima jumlah data yang sama untuk tiap kelas saat pelatihan, sehingga hasil prediksi tidak berat sebelah. Distribusi data setelah dilakukan balancing terlihat pada Tabel 3.

Tabel 3. Distribusi Data

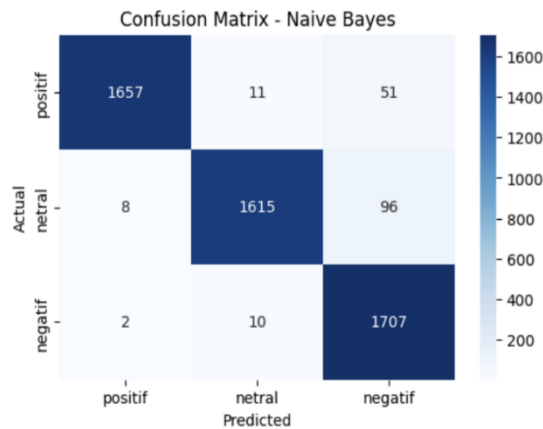
Sentimen	Jumlah Data
Positif	8592
Negatif	8592
Netral	8592

3.2 Pelatihan dengan Algoritma Naive Bayes dan SVM TF-IDF dan Evaluasi Model

Penelitian ini menggunakan dua algoritma sebagai penggunaan modelnya yaitu Algoritma SVM dan Algoritma Naive Bayes dengan menggunakan fitur TF-IDF. Data nya sendiri dibagi menjadi 80% untuk data pelatihan dan 20% untuk data pengujian. Model dilatih menggunakan pipeline dari Scikit-Learn yang mengintegrasikan preprocessing, TF-IDF, dan classifier dalam satu alur. Evaluasi model sendiri akan digunakan confusion matrix dengan precision, recall, F1-score, dan akurasi yang akan secara rinci dijelaskan pada penjelasan (1) dan (2).

1. Naive Bayes

Hasil detail heatmap confusion matrix dengan menggunakan Algoritma Naive Bayes yang dapat dilihat pada Gambar 5 menunjukkan jika prediksi kelas positif dan netral masih bercampur dengan kelas lain. Model Naive Bayes yang terlihat pada Tabel 3 menunjukkan hasil yang sangat baik dengan akurasi yang mencapai 96%. F1-score pada naive bayes tercatat pada kelas positif mencapai 0,979, sedangkan pada kelas negatif relatif lebih rendah yaitu 0.955.



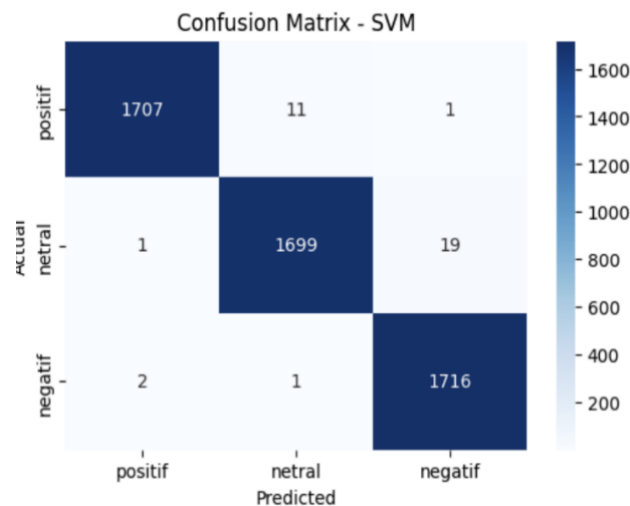
Gambar 5. Heatmap Algoritma Naive Bayes

Tabel 3. Hasil Evaluasi Naive Bayes

Sentimen	Precision	Recall	F1-score	Support
Positif	0,690278	0,669444	0,679861	1719
Netral	0,685417	0,652083	0,66875	1719
Negatif	0,639583	0,689583	0,663194	1719
Akurasi			0,670139	5157

2. SVM

Hasil detail yang memperlihatkan distribusi prediksi dengan warna intens pada diagonal dapat dilihat pada Gambar 6 heatmap confusion matrix SVM. Model SVM yang terlihat pada Tabel 4 menunjukkan kinerja yang sangat baik dengan akurasi yang sangat tinggi mencapai 99.3% lebih tinggi dari pada menggunakan model Naive Bayes, serta f1-score yang tinggi di semua kelas (positif: 0.996, netral 0.991, negatif 0.993). Confusion matrix SVM menunjukkan bahwa sebagian besar prediksi berada pada diagonal matriks, menandakan prediksi benar sangat dominan pada semua kelas.



Gambar 6. Heatmap Algoritma SVM

Tabel 4. Hasil Evaluasi SVM

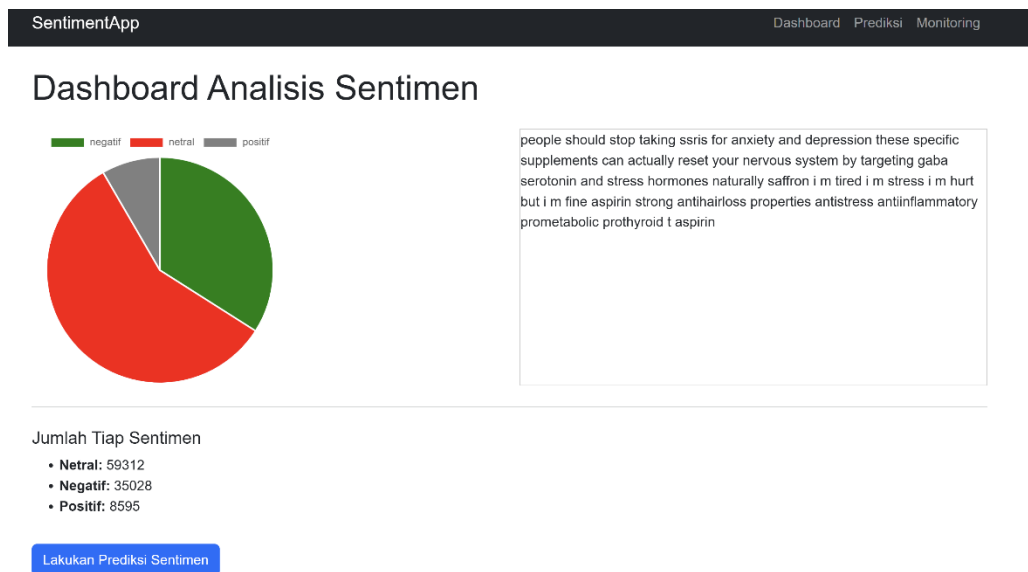
Sentimen	Precision	Recall	F1-score	Support
Positif	0,693056	0,689583	0,691667	1719
Netral	0,689583	0,686111	0,688194	1719
Negatif	0,686111	0,693056	0,689583	1719
Accuracy			0,689583	5157

3.3 Hasil Implementasi Website

Pada penelitian ini, website dinamakan dengan EduMood. Sistem Edumood berhasil mengimplementasikan aplikasi berbasis web dengan menggunakan framework flask menggunakan bahasa pemrograman python dari sisi server dan bootstrap 5 pada sisi tampilan. Tampilan terdiri dari 3 fitur yaitu:

1. Dashboard

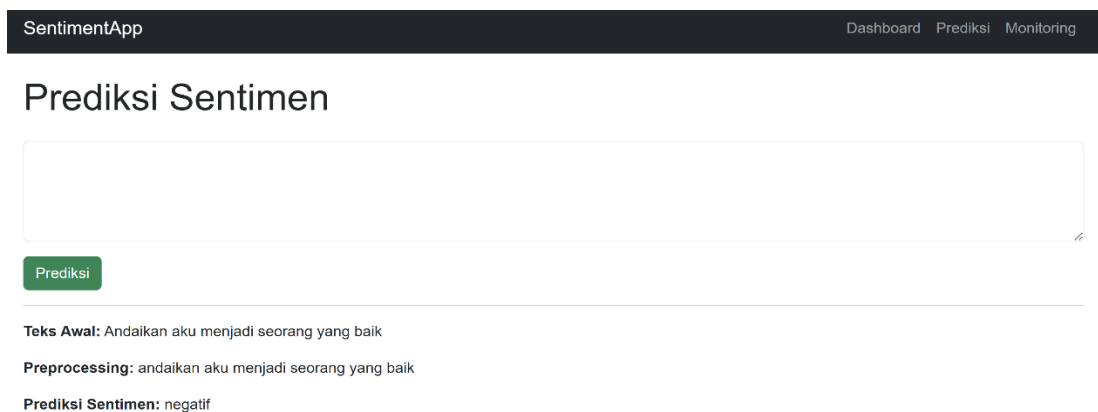
Dashboard sendiri menampilkan distribusi sentiment dalam bentuk piechart, barchart, wordcloud, serta rekap dari masing-masing sentimen. Pada Gambar 7 terlihat tampilan dari dashboard EduMood yang menunjukkan distribusi data.



Gambar 7. Halaman Dashboard Website

2. Prediksi Sentimen Manual


Halaman prediksi sentiment manual adalah halaman untuk melakukan pengujian teks secara manual, misalnya ketika pihak psikologis kampus ingin melakukan pengecekan pada cuitan tertentu. Setelah pengguna memasukan teks dan mengirim, hasil prediksi akan ditampilkan dengan teks awal, teks setelah dilakukan preprocessing, dan juga prediksi sentimennya yang terdiri dari positif, negatif, atau netral. Gambar 8 terlihat halaman dari prediksi sentimen manual ini.



Gambar 8. Halaman Sentimen Website

3. Monitoring Tweet

Halaman untuk memantau data cuitan yang sudah dianalisis berikut prediksi sentimennya dalam bentuk tabel interaktif dengan kemampuan pencarian dan filter. Gambar 9 terlihat halaman dari monittornig Tweet ini.

SentimentApp		Dashboard	Prediksi	Monitoring
 Monitoring Tweet				
Teks	Sentimen			
people should stop taking ssris for anxiety and depression these specific supplements can actually reset your nervous system by targeting gaba serotonin and stress hormones naturally saffron	netral			
i m tired i m stress i m hurt but i m fine	negatif			
aspirin strong antihairloss properties antistress antiinflammatory prometabolic prothyroid t aspirin also shifts the mitochondria from the state of oxidizing fats into oxidizing glucose which is favorable for thyroid hormone t amp hair health	positif			
dua for removing difficulties and stress	netral			
my favorite game is to guess if my headache is due to dehydration migraine malnutrition stress lack of sleep poor position or a brain tumor	netral			
kamu lagi banyak tekanan ya batinmu cape pasti banyak yg kamu pendam amp kamu tumpuk sendiri kan kamu tau ga yg udah kamu pendam sejak lama itu sekarang lagi meluap semua karena udah penuh kapasitas kamu udah overload berhentilah sejenak beristirahatlah amp tenangkan dirimu	netral			
no one is coming to save you hii statement hunipea stress ajab	netral			
dua for removing difficulties and stress	netral			

Gambar 9. Halaman Monitoring Website

3.4 Pembahasan

Hasil penelitian ini menunjukkan bahwa sistem EduMood berhasil mendeteksi sentimen mahasiswa dengan akurasi tinggi, khususnya dengan model SVM yang mencapai akurasi 99,3%, lebih unggul dibandingkan Naive Bayes dengan akurasi 96,5%. Tingginya performa SVM ini dapat dijelaskan oleh kemampuannya dalam membentuk hyperplane optimal yang memisahkan kelas-kelas sentimen dengan margin maksimum pada data teks berdimensi tinggi, yang memang merupakan karakteristik data teks pada umumnya. Hal ini konsisten dengan temuan-temuan sebelumnya [26], [29], dimana SVM seringkali dilaporkan sebagai salah satu algoritma yang unggul untuk klasifikasi teks, termasuk untuk analisis sentimen.

Proses balancing data yang dilakukan sebelum pelatihan juga berkontribusi besar terhadap kualitas hasil yang diperoleh. Dengan membuat distribusi data positif, netral, dan negatif menjadi seimbang, model tidak lagi bias terhadap kelas mayoritas. Hasil confusion matrix memperlihatkan bahwa prediksi lebih merata pada semua kelas, dengan sedikit sekali salah prediksi. Ini menunjukkan bahwa pendekatan balancing sederhana seperti undersampling yang diterapkan sudah cukup efektif untuk mengatasi masalah class imbalance pada dataset ini.

Ketika dibandingkan dengan penelitian [9], [13], [15], terlihat bahwa EduMood mengadopsi prinsip-prinsip dasar dari penelitian sebelumnya, seperti memanfaatkan data teks dari media sosial untuk mendeteksi kondisi psikologis pengguna. Namun, pendekatan EduMood yang berbasis machine learning dan memanfaatkan pembelajaran dari data terbukti mampu mengenali pola yang lebih kompleks dibandingkan pendekatan berbasis leksikon sederhana. Hal ini didukung oleh hasil evaluasi kuantitatif pada EduMood yang menunjukkan metrik akurasi dan f1-score yang tinggi.

Dari hasil ini dapat disimpulkan bahwa kombinasi metode preprocessing yang tepat, balancing dataset, pemilihan algoritma yang sesuai, serta penyajian hasil yang informatif berperan penting dalam menghasilkan sistem yang tidak hanya akurat secara teknis tetapi juga relevan secara praktis. Pihak kampus dapat memanfaatkan EduMood sebagai alat bantu untuk memantau kondisi psikologis mahasiswa secara cepat dan terukur, serta untuk mengidentifikasi tren sentimen yang dapat menjadi indikator awal adanya masalah kesehatan mental di lingkungan kampus.

4. KESIMPULAN

Penelitian ini bertujuan untuk mengembangkan EduMood, sebuah sistem website deteksi sentimen berbasis web untuk mendukung pemantauan kesehatan mental mahasiswa melalui analisis cuitan di media sosial. Sistem ini dirancang untuk membantu pihak kampus dalam memperoleh informasi mengenai kondisi psikologis mahasiswa secara lebih cepat, akurat, dan berbasis data nyata. EduMood mengintegrasikan teknologi machine learning dengan antarmuka web yang interaktif, sehingga hasil analisis dapat diakses dengan mudah dan divisualisasikan dalam bentuk yang informatif. Proses pengembangan sistem dimulai dengan tahapan pengumpulan data cuitan mahasiswa dari media sosial Twitter menggunakan kata kunci relevan seperti mahasiswa, kampus, stres, dan depresi. Data yang diperoleh kemudian melalui proses preprocessing untuk membersihkan teks dari elemen-elemen yang tidak relevan seperti lowercasing kata, menghilangkan URL, mention, hashtag, angka, tanda baca, dan menghilangkan space dari langkah sebelumnya. Hasil dari tahapan ini disimpan sebagai teks yang lebih bersih dan konsisten, siap untuk dianalisis lebih lanjut. Pelabelan awal dilakukan secara otomatis menggunakan lexicon bilingual (Bahasa Indonesia dan Bahasa Inggris) untuk menentukan apakah cuitan bersentimen positif, negatif,



atau netral. Sistem ini menggabungkan metode machine learning berbasis SVM dengan representasi TF-IDF, yang menunjukkan akurasi tinggi mencapai 99,3%, lebih baik dibandingkan dengan Naive Bayes yang mencapai 96,5%. Data yang digunakan telah melalui tahap preprocessing dan balancing sehingga distribusi sentimen positif, netral, dan negatif menjadi seimbang. EduMood menyajikan hasil analisis secara praktis melalui web dashboard interaktif yang menampilkan distribusi sentimen, wordcloud, tabel monitoring, serta prediksi manual. Dengan demikian, EduMood dapat menjadi alat bantu yang efektif bagi pihak kampus untuk memantau kondisi psikologis mahasiswa secara cepat, berbasis data nyata, dan mudah diakses.

UCAPAN TERIMAKASIH

Terima kasih disampaikan kepada pihak-pihak yang telah mendukung penelitian ini terutama untuk Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi serta Universitas Sari mulia yang sudah membantu dalam pendanaan dan pengarahan penelitian melalui program hibah untuk dosen.

REFERENCES

- [1] D. R. Syarifah, C. Angelina, N. Muhani, and O. Reni, "Determinan Faktor Individu dan Sosial yang Berhubungan dengan Literasi Kesehatan Mental pada Mahasiswa di Universitas Malahayati," *Jurnal Kesehatan*, vol. 16, no. 2, pp. 161–167, Oct. 2023, doi: 10.23917/jk.v16i2.2009.
- [2] L. Ninditya and B. E. Medise, "Laporan Kasus Berbasis Bukti Prevalensi dan Faktor-Faktor yang Berpengaruh Terhadap Masalah Kesehatan Jiwa pada Remaja Selama Pandemi Corona Virus Disease 2019," *Sari Pediatri*, vol. 24, no. 2, pp. 127–133, 2022, doi: <http://dx.doi.org/10.14238/sp24.2.2022>.
- [3] U. Alfu Nahari, "The Relation Between Permissive Parenting and Emotional Intelligence with Adolescent Autonomy," in *Proceeding Conference on Psychology and Behavioral Sciences*, 2024, pp. 647–656. doi: <https://doi.org/10.61994/cpbs.v3i.190>.
- [4] L. Kantam Cletus et al., "Depression, Anxiety and Stress among Tertiary Students in a Low Socio-Economic Settin," *Fortune Journal of Health Sciences*, vol. 7, no. 4, 2024, doi: 10.26502/fjhs.242.
- [5] B. Remaja Millenial Riduan, N. Fauziah, K. Amelia, and U. Islam Negeri Sultan Aji Muhammad Idris Samarinda, "Pemanfaatan Media Sosial sebagai Media Informasi Pendidikan," *Borneo Journal of Islamic Education*, vol. 3, no. 1, pp. 53–64, 2023, doi: <https://doi.org/10.21093/bjie.v3i1.6334>.
- [6] M. Y. Sahan, A. Gual, M. Florencia, and Y. Bello, "Eksplorasi Manajemen Privasi Komunikasi Mahasiswa Melalui Buku Harian Dan Instagram," *WACANA: Jurnal Ilmiah Ilmu Komunikasi*, vol. 24, no. 1, pp. 178–189, 2025, doi: 10.32509/wacana.v24i1.4553.
- [7] F. A. Annabillah and K. M. Boer, "Fitur Close Friends Instagram Sebagai Keterbukaan Diri Mahasiswa Yang Mengalami Kecemasan Bermedia Sosial," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 4, no. 3, pp. 1550–1565, Sep. 2023, doi: 10.35870/jimik.v4i3.379.
- [8] K. Saha, A. Yousuf, R. L. Boyd, J. W. Pennebaker, and M. De Choudhury, "Social Media Discussions Predict Mental Health Consultations on College Campuses," *Sci Rep*, vol. 12, no. 1, p. 123, Jan. 2022, doi: 10.1038/s41598-021-03423-4.
- [9] M. Y. Dhinora and E. Mailoa, "Analisa Tweet Mahasiswa untuk Deteksi Gejala Depresi dengan Penerapan Natural Language Processing," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi (JIMIK)*, vol. 6, no. 2, May 2025, doi: <https://doi.org/10.63447/jimik.v6i2.1405>.
- [10] A. Nazari, M. Hosseinnia, S. Torkian, and G. Garmaroudi, "Social media and mental health in students: a cross-sectional study during the Covid-19 pandemic," *BMC Psychiatry*, vol. 23, no. 1, p. 458, Jun. 2023, doi: 10.1186/s12888-023-04859-w.
- [11] S. Romdona, S. Senja Junista, and A. Gunawan, "Teknik Pengumpulan Data: Observasi, Wawancara, dan Kuisoner," *JISOSEPOL: Jurnal Ilmu Sosial Ekonomi dan Politik*, vol. 3, no. 1, pp. 39–47, 2025, doi: <https://doi.org/10.61787/taceee75>.
- [12] R. Qayyum, H. Afzal, K. Mahmood, and N. Iltaf, "Detection and Analysis of Mental Health Illness using Social Media," in *2023 International Conference on Communication Technologies (ComTech)*, IEEE, Mar. 2023, pp. 34–41. doi: 10.1109/ComTech57708.2023.10165143.
- [13] S. K. S., K. Shanmugavadivel, S. R. V., M. Subramanian, S. R., and S. V. E., "Leveraging multi-class sentiment analysis on social media text for detecting signs of depression," *Applied and Computational Engineering*, vol. 2, no. 1, pp. 242–251, Mar. 2023, doi: 10.54254/2755-2721/2/20220660.
- [14] I. C. Obagbuwa, S. Danster, and O. C. Chibaya, "Supervised machine learning models for depression sentiment analysis," *Front Artif Intell*, vol. 6, Jul. 2023, doi: 10.3389/frai.2023.1230649.
- [15] Prof. P. Kakde, "Sentimental Analysis Using Machine Learning for Mental Healthcare Management System," *Int J Res Appl Sci Eng Technol*, vol. 11, no. 6, pp. 563–570, Jun. 2023, doi: 10.22214/ijraset.2023.53450.
- [16] D. K. Choudhary, A. Gupta, S. Singh, T. Abhinav, and T. Agrawal, "Sentiment Analysis for Depression Detection Using Artificial Intelligence," in *2024 3rd International Conference on Artificial Intelligence For Internet of Things (AIIoT)*, IEEE, May 2024, pp. 1–5. doi: 10.1109/AIIoT58432.2024.10574749.
- [17] M. Arif, maruf Setiawan, A. Dwi Hartono, M. Arif Ma, and ruf Setiawan, "Menggunakan Metode Machine Learning untuk Memprediksi Nilai Mahasiswa dengan Model Prediksi Multiclass," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 10, no. 1, pp. 190–204, 2025, doi: 10.30591/jpit.v9ix.xxx.
- [18] D. Shabira et al., "Deteksi Seksisme Online menggunakan Support Vector Machine dan Naïve Bayes," *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, vol. 8, no. 2, pp. 254–266, 2023, doi: 10.26760/mindjournal.v8i2.254-266.



- [19] T. Rawat and S. Jain, “DPre: Effective preprocessing techniques for social media depressive text,” *Intelligent Decision Technologies*, vol. 16, no. 3, pp. 475–485, Sep. 2022, doi: 10.3233/IDT-210199.
- [20] S. Chrisomalis, “Numerical Notation: A Comparative History,” in *Oxford Classical Dictionary*, Oxford University Press, 2024. doi: 10.1093/acrefore/9780199381135.013.8527.
- [21] C. Y. P. Kiran, and M. P B, “The Novel Method for Data Preprocessing CLI,” *Advances in Intelligent Systems and Technologies*, pp. 117–120, Dec. 2022, doi: 10.53759/aist/978-9914-9946-1-2_21.
- [22] P. Amira Sumitro et al., “Analisis Sentimen Terhadap Vaksin Covid-19 di Indonesia pada Twitter Menggunakan Metode Lexicon Based,” *Jurnal Informatika dan Teknologi Komputer (J-ICOM)*, vol. 2, no. 2, pp. 50–56, 2021, doi: <https://doi.org/10.55377>.
- [23] I. Wickramasinghe and H. Kalutarage, “Naive Bayes: applications, variations and vulnerabilities: a review of literature with code snippets for implementation,” *Soft comput*, vol. 25, no. 3, pp. 2277–2293, Feb. 2021, doi: 10.1007/s00500-020-05297-6.
- [24] Lutfi Muhammad, Surejo Sarif, and Septiana Pinky, “Systematic Literature Review: Penerapan Algoritma Naive Bayes Dalam Sistem Pakar,” *Jurnal Minfo Polgan*, vol. 11, no. 2, pp. 7–13, 2022, doi: 10.33395/jmp.v11i2.11635.
- [25] D. E. Cahyani and I. Patasik, “Performance comparison of tf-idf and word2vec models for emotion text classification,” *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 5, pp. 2780–2788, Oct. 2021, doi: 10.11591/eei.v10i5.3157.
- [26] K. Tri Putra, M. Amin Hariyadi, and C. Crysdiyan, “Perbandingan Feature Extraction TF-IDF Dan Bow Untuk Analisis Sentimen Berbasis SVM,” *Jurnal Cahaya Mandalika*, vol. 3, no. 2, pp. 1449–1463, 2023, doi: <https://doi.org/10.36312/jcm.v5i3>.
- [27] D. Chicco, N. Tötsch, and G. Jurman, “The matthews correlation coefficient (Mcc) is more reliable than balanced accuracy, bookmaker informedness, and markedness in two-class confusion matrix evaluation,” *BioData Min*, vol. 14, pp. 1–22, 2021, doi: 10.1186/s13040-021-00244-z.
- [28] A. R. Hanum et al., “Analisis Kinerja Algoritma Klasifikasi Teks BERT dalam Mendeteksi Berita Hoaks,” *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 11, no. 3, pp. 537–546, 2024, doi: 10.25126/jtiik938093.
- [29] D. Valero-Carreras, J. Alcaraz, and M. Landete, “Comparing two SVM models through different metrics based on the confusion matrix,” *Comput Oper Res*, vol. 152, Apr. 2023, doi: 10.1016/j.cor.2022.106131.