



Early Detection Model Development of Adolescent Mental Health Using Support Vector Machine Based on Text Analysis

Pengembangan Model Deteksi Dini Kesehatan Mental Remaja Menggunakan Support Vector Machine Berbasis Analisis Teks

Rima Ruktiari^{1*}, Hamid Wijaya², Muhammad Rizal³

^{1,2}Jurusan Ilmu Komputer, Universitas Sembilanbelas November Kolaka, Indonesia

³Jurusan Teknik Komputer dan Jaringan, Politeknik Negeri Ujung Pandang, Indonesia

E-Mail: ¹rimaruktiarii@gmail.com, ²hamidwijaya35@gmail.com, ³muhammad.rizal@poliupg.ac.id

Received Oct 24th 2025; Revised Dec 28th 2025; Accepted Jan 25th 2026; Available Online Jan 31th 2026

Corresponding Author: Rima Ruktiari

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Adolescent mental health is a critical global issue, driven by the increasing prevalence of depression, anxiety, and personality disorders during the productive age. Conventional evaluation methods, such as clinical interviews and questionnaires, are often subjective, time-consuming, and limited in scope, thereby delaying early intervention. This study aims to develop an early detection model for adolescent mental health using text analysis based on the Support Vector Machine (SVM) algorithm. The dataset comprises approximately 4,000 text entries collected from Reddit forums and categorized into five classes: stress, depression, bipolar disorder, personality disorder, and anxiety. After resampling, each class contained approximately 200 samples. Text preprocessing included cleaning, tokenization, stopword removal, and stemming. Feature representation was performed using a combination of word-level and character-level Term Frequency-Inverse Document Frequency (TF-IDF), resulting in 28,456 features. Two models—Linear SVC and SVC with a Radial Basis Function (RBF) kernel—were evaluated using grid search. Experimental results indicate that the SVC (RBF) model achieved the best performance, with an accuracy of 63.3% and a macro-F1 score of 0.635 on the test set. Further analysis shows that class 0 (stress) achieved the most stable performance ($F1 = 0.730$), while class 1 (depression) remained the most challenging to classify ($F1 = 0.545$). The Precision-Recall curve further indicates that class 0 achieved the highest average precision (0.844), whereas class 4 (anxiety) obtained the lowest (0.638). These findings demonstrate the potential of SVM-based text analysis for early detection of adolescent mental health conditions, while highlighting the need for further optimization, particularly in handling classes with subtle linguistic patterns.

Keywords: Adolescent Mental Health, Early Detection, Support Vector Machine, Text Analysis

Abstrak

Kesehatan mental remaja merupakan aspek fundamental dalam pembangunan generasi muda. Peningkatan prevalensi depresi, kecemasan, dan gangguan kepribadian di kalangan remaja menimbulkan dampak serius terhadap kesejahteraan individu dan masyarakat. Evaluasi tradisional melalui wawancara atau kuesioner bersifat subjektif dan memerlukan waktu lama, sehingga sering terlambat dalam memberikan intervensi dini. Penelitian ini bertujuan mengembangkan model deteksi dini kesehatan mental remaja berbasis analisis teks menggunakan algoritma *Support Vector Machine* (SVM). Dataset terdiri dari ±4000 entri teks dari forum Reddit dengan lima kategori: stress, depresi, bipolar, gangguan kepribadian, dan anxiety. Setelah dilakukan resampling, setiap kelas memiliki sekitar 200 data. Teks diproses melalui *cleaning*, tokenisasi, penghapusan *stopwords*, dan stemming. Representasi fitur dilakukan dengan gabungan *word-level* dan *char-level* TF-IDF, menghasilkan 28.456 fitur. Dua model diuji, yaitu Linear SVC dan SVC dengan kernel RBF, melalui grid search. Hasil terbaik diperoleh SVC (RBF) dengan akurasi 63.3% dan macro-F1 0.635 pada data uji. Analisis menunjukkan kelas 0 (stress) paling stabil ($F1=0.730$), sedangkan kelas 1 (depresi) masih sulit dideteksi ($F1=0.545$). PR Curve memperlihatkan AP tertinggi pada kelas 0 (0.844) dan terendah pada kelas 4 (0.638). Hasil ini menunjukkan bahwa SVM mampu memberikan baseline yang menjanjikan untuk deteksi dini kesehatan mental berbasis teks, meskipun optimasi lanjutan tetap diperlukan.

Kata Kunci: Analisis Teks, Deteksi Dini, Kesehatan Mental Remaja, Support Vector Machine

1. PENDAHULUAN

Kesehatan mental merupakan aspek krusial dalam perkembangan remaja, di mana gangguan mental yang muncul pada usia dini dapat memberikan dampak jangka panjang terhadap kesejahteraan individu dan masyarakat[1]. Tekanan akademik, intensitas penggunaan media sosial, serta dinamika lingkungan keluarga dan pertemanan sering kali berkontribusi terhadap meningkatnya kasus stres, depresi, dan gangguan kepribadian pada kelompok usia remaja. Sejumlah survei internasional dan nasional juga melaporkan peningkatan prevalensi gangguan kesehatan mental pada kelompok usia 15–24 tahun. Kondisi ini menunjukkan bahwa gejala awal gangguan mental sering berkembang pada fase remaja, namun tidak selalu teridentifikasi secara tepat waktu. Akibatnya, intervensi kerap dilakukan pada tahap yang lebih lanjut, ketika dampak negatif telah meluas, seperti penurunan prestasi akademik, kecenderungan penyalahgunaan zat, hingga meningkatnya risiko bunuh diri. Oleh sebab itu, pendekatan yang mampu mengenali indikasi awal gangguan kesehatan mental secara lebih cepat dan objektif menjadi semakin relevan untuk dikembangkan.


Metode tradisional dalam mendeteksi kesehatan mental, seperti wawancara psikologis dan kuesioner, masih banyak digunakan[2]. Namun, metode ini memiliki keterbatasan karena bergantung pada subjektivitas responden dan keterampilan tenaga kesehatan. Selain itu, cakupan metode ini terbatas sehingga sulit menjangkau populasi remaja yang lebih luas. Seiring dengan pesatnya perkembangan teknologi digital, media sosial telah menjadi ruang utama bagi remaja untuk mengekspresikan perasaan, pengalaman pribadi, serta kondisi emosional mereka secara spontan dan berkelanjutan. Konten tekstual yang dihasilkan, seperti cerita personal, keluhan emosional, maupun ekspresi psikologis sehari-hari, mengandung informasi linguistik yang berpotensi mencerminkan kondisi kesehatan mental individu. Sejumlah penelitian menunjukkan bahwa pendekatan berbasis kecerdasan buatan, khususnya machine learning dan deep learning, mampu mengekstraksi pola-pola kompleks dari data teks dalam skala besar secara lebih objektif dan konsisten dibandingkan pendekatan manual[3][4]. Pemanfaatan teknik analisis teks berbasis ML juga telah terbukti efektif dalam mendukung proses identifikasi dini gejala gangguan kesehatan mental, serta memungkinkan pengembangan sistem pemantauan yang cepat, adaptif, dan dapat diterapkan pada populasi yang luas[5][6].

Berbagai penelitian telah menyoroti pentingnya evaluasi dan pemantauan kesehatan mental pada lingkungan pendidikan, mengingat tingginya tekanan dan tantangan yang dihadapi oleh pelajar[7]. Studi literatur menyimpulkan bahwa pemanfaatan teknik machine learning dapat memberikan kontribusi signifikan dalam mendeteksi gejala awal gangguan kesehatan mental melalui analisis data yang bersifat objektif[8]. Pendekatan multimodal telah terbukti efektif dalam mendeteksi serta mengklasifikasikan tanda-tanda awal masalah kesehatan mental[9]. Penggunaan algoritma Support Vector Machine (SVM) dalam analisis teks dapat menangani data dengan dimensi tinggi dan menghasilkan klasifikasi yang akurat[10][11]. Model prediktif yang dikembangkan dengan menggunakan classifiers telah meningkatkan akurasi dalam mendeteksi gangguan mental, sehingga mendukung strategi intervensi dini yang lebih efektif[12][13]. Penelitian terkini menunjukkan bahwa SVM, jika diintegrasikan dengan analisis teks, dapat meningkatkan akurasi dan efektivitas dalam mengidentifikasi potensi masalah kesehatan mental, sehingga memungkinkan intervensi yang lebih cepat dan tepat[14].

Meskipun berbagai penelitian terdahulu telah menunjukkan efektivitas pendekatan machine learning, khususnya Support Vector Machine, dalam mendeteksi gangguan kesehatan mental berbasis teks, sebagian besar studi masih berfokus pada klasifikasi biner, dataset dengan distribusi kelas yang tidak seimbang, atau penggunaan representasi fitur tunggal. Selain itu, evaluasi performa sering kali terbatas pada satu konfigurasi model tanpa analisis perbandingan yang komprehensif. Berangkat dari celah tersebut, penelitian ini menghadirkan pendekatan yang mengombinasikan representasi fitur word-level dan character-level TF-IDF untuk menangkap variasi linguistik yang lebih halus pada teks media sosial. Selain itu, penelitian ini melakukan evaluasi komparatif antara Linear SVC dan SVC dengan kernel Radial Basis Function (RBF) pada skenario multi-kelas yang mencakup lima kategori kesehatan mental. Dengan demikian, kontribusi utama penelitian ini terletak pada penyediaan baseline yang terstruktur dan terukur untuk deteksi dini kesehatan mental remaja berbasis analisis teks, sekaligus memberikan pemahaman yang lebih mendalam mengenai tantangan klasifikasi pada kelas-kelas dengan pola linguistik yang saling tumpang tindih.

2. METODOLOGI PENELITIAN

Alur metodologi penelitian dimulai dari tahap pengumpulan Dataset (lihat Gambar 1). Data mentah tersebut selanjutnya melalui proses *preprocessing* untuk membersihkan dan menormalisasi teks. Hasil *praproses* kemudian dikonversi ke dalam bentuk numerik melalui ekstraksi fitur dengan metode TF-IDF, baik pada level kata maupun karakter. Representasi fitur ini menjadi dasar bagi tahap pelatihan model menggunakan algoritma Support Vector Machine (SVM). Setelah model terbentuk, dilakukan *hyperparameter tuning* melalui grid search dan validasi silang untuk memperoleh konfigurasi terbaik. Tahap akhir adalah evaluasi model dengan berbagai metrik performa seperti akurasi, presisi, recall, F1-score, serta visualisasi berupa *Confusion Matrix* dan *Precision-Recall Curve*.



Gambar 1. Metodologi Penelitian

2.1. Dataset

Dataset penelitian terdiri dari ± 4000 entri teks Reddit dengan lima kategori kesehatan mental. Setelah resampling, distribusi menjadi relatif seimbang: kelas 1 (200), kelas 4 (191), kelas 2 (184), kelas 0 (183), dan kelas 3 (182). Mayoritas teks berisi kurang dari 300 kata yang dapat dilihat pada Tabel 1 dan cuplikan data pada Gambar 2.

Tabel 1. Distribusi label data

Kelas	Jumlah
1	200
4	191
2	184
0	183
3	182

text	title	target
"Hi there!!"	Trying to write an Email while Manic like:	2
I have been suspecting about having AvPD for quite some time. Knowing that my inability to have close relationships and function in society wasn't just my fault but is due to a condition	Resentment	3
Hello everyone, lurker for a small while now. I'm 24M.	Hello, new here	3
NOW, FOR many this is a reminder... If you want something natural and holistic, free, self driven...etc this may be for you. I share my thoughts here:	3 practices I use to alleviate my social anxiety QUICKLY.	3
I know!	Anticipated	2
And I know this wont work but idk what else to do. I just genuinely hate myself and I hope that maybe if I hit my goal weight I can finally have the confidence to talk to people and not feel so	I'm trying to solve an internal issue externally	3
Hello everyone, I am writing this because I've been reading posts on this sub for the past week, since I've learned about AvPD from my new therapist and researching about this	Looking for some good vibes	3
I've been on lithium and olanzapine for a few months, and I've developed bad acne and spots on my cheeks that I'm really self-conscious about. I used to have such clear skin. I use a	Acne help?	2
I found out that in times where my social anxiety was really bad this would also heavily influence my own self confidence and self worth. I would beat myself up for everything I did	Does your anxiety affects your self confidence?	4
I'm a software developer and work long hours sometimes. When I get a complex problem to solve I'm getting nervous and eventually had tension headaches lasting for the entire day. At	IT and anxiety	0

Gambar 2. Cuplikan dataset

2.2. Pra-pemrosesan

Tahap pra-pemrosesan bertujuan untuk membersihkan dan menormalkan data teks agar representasi fitur yang dihasilkan lebih konsisten serta relevan untuk proses klasifikasi. Proses ini dimulai dengan *case folding* untuk mengonversi seluruh teks menjadi huruf kecil, sehingga variasi penulisan tidak memengaruhi pembentukan fitur. Selanjutnya dilakukan tokenisasi untuk memecah teks menjadi unit kata, diikuti dengan penghapusan *stopwords* guna menghilangkan kata-kata umum yang tidak memiliki kontribusi semantik signifikan terhadap klasifikasi. Proses *stemming* kemudian diterapkan untuk mengembalikan kata ke bentuk dasarnya, sehingga variasi morfologis dapat diminimalkan. Selain itu, dilakukan penyaringan karakter khusus dan simbol yang tidak relevan dengan analisis linguistik. Setelah seluruh tahapan pra-pemrosesan diterapkan, dataset dibagi menjadi dua bagian, yaitu 752 entri untuk data pelatihan dan 188 entri untuk data pengujian, dengan menjaga proporsi kelas pada masing-masing subset agar distribusi label tetap seimbang. Pembagian

ini bertujuan untuk memastikan evaluasi performa model mencerminkan kemampuan generalisasi yang adil terhadap seluruh kelas.

2.3. Representasi Fitur

Representasi fitur dilakukan menggunakan pendekatan Term Frequency–Inverse Document Frequency (TF-IDF), yang bertujuan untuk mengukur tingkat kepentingan suatu istilah dalam sebuah dokumen relatif terhadap seluruh dokumen dalam korpus. Pada penelitian ini, digunakan kombinasi TF-IDF pada level kata (*word-level*) dengan *n-gram* 1–2 dan level karakter (*character-level*) dengan *n-gram* 3–5. Pendekatan gabungan ini dirancang untuk menangkap baik informasi semantik dari kata maupun variasi linguistik halus seperti kesalahan penulisan, singkatan, dan ekspresi informal yang umum ditemukan pada teks media sosial. Secara matematis, TF-IDF didefinisikan pada persamaan 1 dan Hasil transformasi dapat dilihat pada persamaan 2.

$$TF-IDF(t, d) = TF(t, d) \times \log DF(t)N \quad (1)$$

$$X_{train} \in R^{752 \times 28456}, X_{test} \in R^{188 \times 28456} \quad (2)$$

2.4. Pemodelan

Tahap pemodelan dilakukan menggunakan algoritma Support Vector Machine (SVM) karena kemampuannya dalam menangani data berdimensi tinggi serta performanya yang stabil pada tugas klasifikasi teks. Dua varian model diuji, yaitu Linear Support Vector Classifier (Linear SVC) dan SVC dengan kernel Radial Basis Function (RBF). Linear SVC digunakan sebagai baseline karena efisiensinya pada data teks, sementara kernel RBF dipilih untuk mengeksplorasi kemampuan model dalam menangkap pola non-linear yang mungkin muncul pada data linguistik yang kompleks.

Tabel 2. Grid Research

Model	Parameter Terbaik	CV f1_Macro
Linear SVC	C=0.5	0.654
SVC (RBF)	C=2, gamma=scale	0.669

Hasil grid search yang ditampilkan pada Tabel 2 memperlihatkan bahwa kedua algoritma yang diuji Linear SVC, SVC dengan kernel RBF menunjukkan kinerja yang cukup kompetitif dengan skor macro-F1 berkisar antara 0.654 hingga 0.669. Linear SVC dengan parameter terbaik C = 0.5 menghasilkan skor macro-F1 sebesar 0.654. Nilai ini menunjukkan kemampuan cukup baik dalam mengklasifikasikan seluruh kelas, namun margin pemisah linear kurang mampu menangkap kompleksitas pola linguistik pada data teks. SVC dengan kernel RBF memberikan perbaikan performa dengan skor macro-F1 0.669 pada konfigurasi C = 2 dan $\gamma = \text{scale}$.

2.5. Evaluasi

Evaluasi performa model dilakukan menggunakan beberapa metrik klasifikasi, yaitu akurasi, precision, recall, dan F1-score, untuk memberikan gambaran yang komprehensif mengenai kemampuan model. Penggunaan metrik macro-F1 dipilih karena setiap kelas memiliki tingkat kepentingan yang sama dalam konteks deteksi kesehatan mental. F1-score didefinisikan sebagai harmonisasi antara precision dan recall, yang dirumuskan pada persamaan 3.

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

Selain metrik numerik, evaluasi juga dilengkapi dengan Confusion Matrix untuk menganalisis kesalahan klasifikasi antar kelas, serta Precision–Recall Curve untuk menilai keseimbangan antara ketepatan dan kelengkapan prediksi pada masing-masing kelas. Pendekatan evaluasi ini memungkinkan analisis performa model secara lebih mendalam, khususnya pada kelas-kelas yang memiliki kemiripan pola linguistik.

2.6. Literature Review

Pemanfaatan data digital untuk analisis kesehatan mental telah menjadi fokus utama dalam penelitian terkini, terutama dengan meningkatnya penggunaan media sosial sebagai sarana ekspresi emosional individu. Sejumlah studi menunjukkan bahwa teks yang dihasilkan pengguna mengandung pola linguistik dan emosional yang dapat merefleksikan kondisi psikologis secara tidak langsung, sehingga berpotensi digunakan sebagai indikator awal gangguan kesehatan mental [15][16][17]. Pendekatan berbasis machine learning

memungkinkan proses analisis dilakukan secara objektif dan berskala besar, melampaui keterbatasan metode konvensional yang bergantung pada wawancara dan kuesioner manual [18] [19]. Review komprehensif yang dilakukan oleh Deshmukh [3] dan Saleem [4] menegaskan bahwa teknik ML dan AI telah menunjukkan kinerja yang menjanjikan dalam mendeteksi depresi, kecemasan, dan stres melalui analisis teks media sosial. Berbagai algoritma machine learning telah diterapkan dalam konteks deteksi kesehatan mental, termasuk Logistic Regression, Naïve Bayes, Random Forest, dan Support Vector Machine (SVM). Di antara metode tersebut, SVM sering dilaporkan memiliki performa yang stabil pada klasifikasi teks berdimensi tinggi, khususnya ketika dikombinasikan dengan representasi fitur berbasis TF-IDF. Chauhan [20] dan Pritam [21] menunjukkan bahwa SVM mampu menghasilkan akurasi yang kompetitif dalam mendeteksi gangguan mental pada pelajar, sementara Sharma [22] dan Kaushik [23] menekankan efektivitas penggunaan classifier dalam mendukung strategi deteksi dini. Temuan ini mengindikasikan bahwa SVM masih relevan digunakan sebagai baseline yang kuat dalam penelitian klasifikasi kesehatan mental berbasis teks.

Beberapa penelitian juga mengeksplorasi penggunaan deep learning dan pendekatan multimodal untuk meningkatkan akurasi deteksi gangguan mental. Kogilathota [24] menunjukkan bahwa integrasi berbagai sumber data dapat memperkaya representasi kondisi psikologis individu, sementara studi lain menyoroti potensi deep learning dalam menangkap pola non-linear yang kompleks [25]. Namun demikian, pendekatan tersebut umumnya memerlukan dataset berukuran besar serta sumber daya komputasi yang tinggi, sehingga tidak selalu praktis untuk skenario penelitian dengan data terbatas. Oleh karena itu, penggunaan SVM dengan kombinasi representasi fitur linguistik yang tepat tetap menjadi pendekatan yang relevan, terutama untuk membangun baseline yang terukur dan dapat direplikasi dalam konteks deteksi dini kesehatan mental remaja berbasis teks.

3. RESULTS AND DISCUSSION

3.1. Hasil Grid Search

Linear SVC ($C=0.5$) mencapai $f1_macro=0.654$, sedangkan SVC RBF ($C=2$, $\gamma=scale$) mencapai $f1_macro=0.669$. Hal ini menunjukkan bahwa kernel non-linear lebih mampu menangkap pola kompleks dalam data

3.2. Evaluasi pada Data uji

Model SVC ber-kernel RBF yang telah dipilih melalui proses validasi silang dievaluasi pada data uji terpisah untuk menilai kemampuan generalisasi di luar data pelatihan. Penilaian dilakukan menggunakan metrik standar klasifikasi—precision, recall, dan F1-score per kelas—serta support (jumlah sampel per kelas). Pelaporan per kelas diperlukan karena performa model pada tugas multi-kelas sering tidak merata. Ringkasan hasil pengukuran pada data uji disajikan pada Tabel 3, yang menampilkan metrik untuk masing-masing kelas bersama nilai agregat yang akan dibahas setelah tabel.

Table 3. Metrik Evaluasi

Kelas	Precision	Recall	F1-score	Support
0	0.730	0.730	0.730	37
1	0.500	0.600	0.545	40
2	0.818	0.486	0.610	37
3	0.643	0.750	0.692	36
4	0.590	0.605	0.597	38

Akurasi keseluruhan 0.633, dengan macro-F1 0.635. Kelas 0 paling stabil, kelas 2 memiliki precision tinggi namun recall rendah, dan kelas 1 merupakan yang terlemah.

3.3. Confusion Matrix


Confusion Matrix menunjukkan bahwa kelas 1 dan 4 sering tertukar, mengindikasikan adanya kemiripan linguistik pada gejala depresi dan kecemasan (lihat Gambar 3).

3.4. Precision-Recall Curve


PR Curve menunjukkan AP tertinggi pada kelas 0 (0.844), sedangkan kelas 1 dan 4 lebih rendah (0.684 dan 0.638). Hal ini menegaskan tantangan dalam membedakan gejala depresi dan anxiety.

Gambar 4 memperlihatkan keseimbangan antara precision dan recall untuk tiap kelas pada model SVC dengan kernel RBF. Kelas 0 memiliki performa terbaik dengan Average Precision (AP) = 0.844, menandakan model sangat konsisten mendeteksi kelas ini dengan sedikit kesalahan. Kelas 2 (AP = 0.785) dan kelas 3 (AP = 0.780) menunjukkan performa menengah, di mana precision masih relatif tinggi meski recall menurun di beberapa titik. Kelas 1 (AP = 0.684) dan kelas 4 (AP = 0.638) memiliki kurva paling rendah, yang berarti model lebih sulit menyeimbangkan ketepatan dan kelengkapan pada dua kelas ini.

SVC (RBF) mampu meningkatkan deteksi pada kelas dominan (kelas 0) dibanding model linear, tetapi masih terdapat gap besar antar kelas, terutama pada kelas 1 dan 4.



Gambar 3. Confusion Matrix



Gambar 4. Precision-Recall Curve per kelas

3.5. Diskusi

Hasil penelitian menunjukkan bahwa model Support Vector Machine dengan kernel Radial Basis Function (SVM RBF) mampu memberikan performa yang lebih baik dibandingkan model linear, yang tercermin dari peningkatan nilai macro-F1 dan stabilitas prediksi pada beberapa kelas. Keunggulan ini dapat dijelaskan oleh kemampuan kernel RBF dalam memetakan data ke ruang berdimensi lebih tinggi, sehingga pola linguistik non-linear yang muncul dalam teks media sosial dapat dipisahkan dengan lebih efektif. Karakteristik bahasa pada unggahan remaja, yang sering bersifat informal, ambigu, dan emosional, menyebabkan hubungan antar fitur tidak selalu linear, sehingga pendekatan non-linear menjadi lebih sesuai untuk menangkap kompleksitas tersebut. Hal ini juga menjelaskan mengapa kelas stres menunjukkan performa paling stabil, karena ekspresi linguistik pada kelas ini cenderung lebih eksplisit dan konsisten dibandingkan kelas lainnya. Ketimpangan performa antar kelas, khususnya pada kelas depresi dan kecemasan, mengindikasikan adanya tumpang tindih pola linguistik yang cukup tinggi. Ekspresi emosional pada kedua kondisi tersebut sering kali menggunakan kosakata dan struktur kalimat yang serupa, sehingga menyulitkan model untuk membedakannya secara tegas. Temuan ini sejalan dengan penelitian terdahulu yang melaporkan bahwa klasifikasi gangguan mental berbasis teks multi-kelas memiliki tingkat kesulitan yang lebih tinggi dibandingkan klasifikasi biner, terutama ketika kelas-kelas yang dianalisis memiliki karakteristik linguistik yang berdekatan. Dibandingkan dengan studi sebelumnya yang menggunakan SVM dan representasi TF-IDF, performa yang diperoleh dalam penelitian ini berada pada kisaran yang sebanding, sehingga memperkuat peran SVM sebagai baseline yang reliabel dalam deteksi kesehatan mental berbasis teks. Dari sisi implikasi, hasil penelitian ini menunjukkan bahwa pendekatan berbasis analisis teks dan machine learning berpotensi mendukung sistem deteksi dini kesehatan mental remaja secara otomatis dan berskala besar. Namun demikian, beberapa keterbatasan masih perlu diperhatikan. Dataset yang digunakan bersumber dari platform media sosial berbahasa Inggris, sehingga generalisasi ke konteks bahasa dan budaya

lain, termasuk bahasa Indonesia, masih terbatas. Selain itu, meskipun distribusi kelas telah diseimbangkan melalui resampling, variasi linguistik alami antar kelas tetap menjadi tantangan utama. Oleh karena itu, pengembangan selanjutnya dapat diarahkan pada integrasi data primer berbahasa Indonesia, penerapan teknik penyesuaian bobot kelas untuk meningkatkan sensitivitas terhadap kelas minor, serta eksplorasi representasi berbasis embedding semantik seperti Word2Vec atau BERT guna menangkap konteks makna yang lebih dalam. Pendekatan tersebut diharapkan mampu meningkatkan performa model, khususnya pada kelas-kelas dengan pola linguistik yang saling tumpang tindih.

4. CONCLUSION

Penelitian ini menunjukkan bahwa pendekatan deteksi dini kesehatan mental remaja berbasis analisis teks menggunakan Support Vector Machine (SVM) mampu mengidentifikasi pola linguistik yang berkaitan dengan kondisi psikologis secara cukup efektif. Model yang dikembangkan mencapai akurasi sebesar 63.3% dan nilai macro-F1 sebesar 0.635, dengan performa paling stabil pada kelas stres. Hasil ini mengindikasikan bahwa pemanfaatan SVM sebagai baseline dalam klasifikasi multi-kelas kesehatan mental berbasis teks dapat memberikan kontribusi yang relevan dalam mendukung upaya deteksi dini, khususnya pada skenario dengan keterbatasan data dan sumber daya komputasi. Meskipun demikian, performa model yang belum merata antar kelas, terutama pada kelas depresi dan kecemasan, menunjukkan adanya keterbatasan dalam membedakan kondisi mental dengan pola linguistik yang saling tumpang tindih. Selain itu, penggunaan dataset berbahasa Inggris dari media sosial membatasi generalisasi hasil ke konteks bahasa dan budaya lain. Pengembangan selanjutnya dapat diarahkan pada perluasan dataset yang lebih beragam, penerapan strategi penyesuaian bobot kelas, serta eksplorasi representasi fitur berbasis embedding semantik seperti Word2Vec atau model berbasis transformer seperti BERT, guna meningkatkan kemampuan model dalam menangkap konteks dan nuansa bahasa secara lebih mendalam.

ACKNOWLEDGMENTS

Penulis mengucapkan terima kasih kepada DRTPM Kemendikisaintek atas pendanaan melalui hibah penelitian BIMA tahun 2025, serta kepada tim peneliti dan mahasiswa yang telah membantu pengumpulan dan pengolahan data.

REFERENCES

- [1] S. Kataru, K. King, and L. Fernando, "Machine Learning-Based Early Detection and Intervention for Mental Health Issues in Children," in *2024 IEEE 48th Annual Computers, Software, and Applications Conference (COMPSAC)*, 2024, pp. 2001–2007. doi: 10.1109/COMPSAC61105.2024.00320.
- [2] B. Li and Y. Xu, "Research on evaluation model of College Students' mental health," in *2021 International Conference on Health Big Data and Smart Sports (HBDSS)*, 2021, pp. 114–117. doi: 10.1109/HBDSS54392.2021.00031.
- [3] H. K. Deshmukh, S. J. Parekh, S. S. Sapkal, and P. Kamble, "MindMap: A Review on Mental Health Analysis using ML," in *2023 6th International Conference on Advances in Science and Technology (ICAST)*, 2023, pp. 325–329. doi: 10.1109/ICAST59062.2023.10454965.
- [4] M. Saleem and H. Afzal, "A Review of Mental Health Analysis Through Social Media Using Machine Learning and Deep Learning Approaches," in *2024 International Conference on Engineering & Computing Technologies (ICECT)*, 2024, pp. 1–7. doi: 10.1109/ICECT61618.2024.10581373.
- [5] Y. Ibrahimov, T. Anwar, and T. Yuan, "Explainable AI for Mental Disorder Detection via Social Media: A survey and outlook," Jun. 2024, [Online]. Available: <http://arxiv.org/abs/2406.05984>
- [6] K. D. Kannan, S. Kumar Jagatheesaperumal, R. N. V. P. S. Kandala, M. Lotfaliany, R. Alizadehsani, and M. Mohebbi, "Advancements in Machine Learning and Deep Learning for Early Detection and Management of Mental Health Disorder A R T I C L E I N F O."
- [7] B. Li and Y. Xu, "Research on evaluation model of College Students' mental health," in *2021 International Conference on Health Big Data and Smart Sports (HBDSS)*, 2021, pp. 114–117. doi: 10.1109/HBDSS54392.2021.00031.
- [8] H. K. Deshmukh, S. J. Parekh, S. S. Sapkal, and P. Kamble, "MindMap: A Review on Mental Health Analysis using ML," in *2023 6th International Conference on Advances in Science and Technology (ICAST)*, 2023, pp. 325–329. doi: 10.1109/ICAST59062.2023.10454965.
- [9] V. Kogilathota, "iPonder: A Novel Approach to Multimodal Mental Health Diagnosis and Therapy for Teens via Deep Transfer Learning and Computer Vision," in *2021 IEEE International Conference on Artificial Intelligence, Robotics, and Communication (ICAIRC)*, 2021, pp. 20–24. doi: 10.1109/ICAIRC52191.2021.9545055.
- [10] S. Chauhan, M. Mittal, H. Singh, S. Kumar, P. Goel, and S. Gupta, "Predictive Analysis on Student's Mental Health Towards Online Mobile Games Using Machine Learning," in *2023 IEEE 15th International Conference on Computational Intelligence and Communication Networks (CICN)*, 2023, pp. 321–324. doi: 10.1109/CICN59264.2023.10402317.

- [11] N. Pritam, K. S. Gill, M. Kumar, R. Rawat, and D. Banerjee, "Classification of Student Mental Health Analysis using Logistic Regression and other classification techniques through Machine Learning Methods," in *2024 3rd International Conference for Innovation in Technology (INOCON)*, 2024, pp. 1–5. doi: 10.1109/INOCON60754.2024.10512216.
- [12] N. Sharma, I. S. Patel, N. K. Singh, and B. K. Mishra, "Predictive Modelling of Mental Health Disorders Using Machine Learning Classifiers," in *2024 International Conference on Artificial Intelligence and Quantum Computation-Based Sensor Application (ICAIQSA)*, 2024, pp. 1–6. doi: 10.1109/ICAIQSA64000.2024.10882408.
- [13] P. Kaushik, E. Jain, K. S. Gill, D. Upadhyay, and S. Devliyal, "Optimizing Mental Health Prediction by Fine-Tuning Decision Classifier Parameters for Enhanced Accuracy," in *2024 2nd International Conference on Sustainable Computing and Smart Systems (ICSCSS)*, 2024, pp. 935–939. doi: 10.1109/ICSCSS60660.2024.10625480.
- [14] S. Jage, S. Chaudhari, M. Jatte, A. Mhatre, and V. Mane, "Predicting Mental Health Illness using Machine Learning," in *2023 3rd Asian Conference on Innovation in Technology (ASIANCON)*, 2023, pp. 1–5. doi: 10.1109/ASIANCON58793.2023.10270445.
- [15] J. Singh, M. Wazid, D. P. Singh, and S. Pundir, "An embedded LSTM based scheme for depression detection and analysis," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 166–175. doi: 10.1016/j.procs.2022.12.019.
- [16] H. K. Marrapu, B. Maram, and P. Reddi, "New Analytic Framework of Public Mental Health Prediction Using Data Science," in *2022 International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)*, 2022, pp. 1–6. doi: 10.1109/ICSTSN53084.2022.9761324.
- [17] Y. Koh, C. Lee, Y. Ku, and U. Lee, "Data Visualization for Mental Health Monitoring in Smart Home Environment: A Case Study," in *2023 Workshop on Visual Analytics in Healthcare (VAHC)*, 2023, pp. 53–55. doi: 10.1109/VAHC60858.2023.00017.
- [18] P. Nagaraj, M. A. Kumar, E. S. Kumar, S. I. Lakshmi, R. Aishwarya, and M. Neyashree, "Comparative Analysis for Prediction and Classification of Mental Health Issues and Challenges Using Hybrid Learning Techniques," in *2023 International Conference on Computer Communication and Informatics (ICCCI)*, 2023, pp. 1–7. doi: 10.1109/ICCCI56745.2023.10128356.
- [19] J. Cherian, B. Loftness, J. Cohen, J. Halvorson-Phelan, E. W. McGinnis, and R. S. McGinnis, "Multimodal Markers of Transdiagnostic Childhood Mental Health Impairment," in *2024 IEEE 20th International Conference on Body Sensor Networks (BSN)*, 2024, pp. 1–4. doi: 10.1109/BSN63547.2024.10780528.
- [20] S. Chauhan, M. Mittal, H. Singh, S. Kumar, P. Goel, and S. Gupta, "Predictive Analysis on Student's Mental Health Towards Online Mobile Games Using Machine Learning," in *2023 IEEE 15th International Conference on Computational Intelligence and Communication Networks (CICN)*, 2023, pp. 321–324. doi: 10.1109/CICN59264.2023.10402317.
- [21] N. Pritam, K. S. Gill, M. Kumar, R. Rawat, and D. Banerjee, "Classification of Student Mental Health Analysis using Logistic Regression and other classification techniques through Machine Learning Methods," in *2024 3rd International Conference for Innovation in Technology (INOCON)*, 2024, pp. 1–5. doi: 10.1109/INOCON60754.2024.10512216.
- [22] N. Sharma, I. S. Patel, N. K. Singh, and B. K. Mishra, "Predictive Modelling of Mental Health Disorders Using Machine Learning Classifiers," in *2024 International Conference on Artificial Intelligence and Quantum Computation-Based Sensor Application (ICAIQSA)*, 2024, pp. 1–6. doi: 10.1109/ICAIQSA64000.2024.10882408.
- [23] P. Kaushik, E. Jain, K. S. Gill, D. Upadhyay, and S. Devliyal, "Optimizing Mental Health Prediction by Fine-Tuning Decision Classifier Parameters for Enhanced Accuracy," in *2024 2nd International Conference on Sustainable Computing and Smart Systems (ICSCSS)*, 2024, pp. 935–939. doi: 10.1109/ICSCSS60660.2024.10625480.
- [24] V. Kogilathota, "iPonder: A Novel Approach to Multimodal Mental Health Diagnosis and Therapy for Teens via Deep Transfer Learning and Computer Vision," in *2021 IEEE International Conference on Artificial Intelligence, Robotics, and Communication (ICAIRC)*, 2021, pp. 20–24. doi: 10.1109/ICAIRC52191.2021.9545055.
- [25] M. K. I. Zim and U. Kaur, "Mental health detection and anticipation analysis using Deep Learning," in *2023 International Conference on Computer Communication and Informatics (ICCCI)*, 2023, pp. 1–6. doi: 10.1109/ICCCI56745.2023.10128581.