

Deteksi Dini Gangguan Kesehatan Mental berdasarkan Sentimen menggunakan Metode *Stacking*

Early Detection of Mental Health Disorders based on Sentiment using Stacking Method

¹Naufal Maldini*, ²Danang Wahyu Utomo, ³Rahmadika Putri Tresyani

^{1,2,3}Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro
^{1,2,3}Jl. Imam Bonjol No.207, Pendrikan Kidul, Kec. Semarang Tengah, Kota Semarang, Jawa Tengah, Indonesia

*e-mail: 111202113247@mhs.dinus.ac.id

(*received*: 22 November 2024, *revised*: 17 January 2025, *accepted*: 20 January 2025)

Abstrak

Gangguan kesehatan mental merupakan masalah serius yang semakin meningkat secara global, termasuk di Indonesia. Penelitian ini bertujuan untuk memprediksi gangguan mental melalui analisis sentimen dengan menggunakan pendekatan *Stacking Classifier*, yang menggabungkan algoritma *Random Forest*, *Gradient Boosting Classifier*, dan *Logistic Regression*. Dataset yang digunakan berasal dari berbagai platform media sosial, dengan data teks yang diklasifikasikan ke dalam tujuh kategori kesehatan mental, seperti depresi, kecemasan, dan gangguan kepribadian. Data diproses melalui tahap prapemrosesan, termasuk pembersihan, penyeimbangan, dan reduksi kata menggunakan algoritma TF-IDF. Hasil penelitian menunjukkan bahwa metode *Stacking Classifier* mampu mencapai akurasi sebesar 95,66%, dengan *precision* 95,63%, *recall* 95,66%, dan *F1-Score* 95,64%. Hasil ini lebih unggul dibandingkan algoritma individual yang diuji dalam penelitian. Temuan ini menunjukkan potensi besar analisis sentimen berbasis machine learning dalam membantu deteksi dini gangguan mental, sehingga dapat digunakan sebagai alat pendukung untuk meningkatkan diagnosis dan intervensi kesehatan mental secara lebih efektif.

Kata kunci: kesehatan mental, analisis sentimen, stacking classifier, machine learning, prediksi kesehatan mental.

Abstract

Mental health disorders are a serious and growing global concern, including in Indonesia. This study aims to predict mental health disorders through sentiment analysis using the Stacking Classifier approach, which combines Random Forest, Gradient Boosting Classifier, and Logistic Regression algorithms. The dataset was sourced from various social media platforms, consisting of textual data classified into seven mental health categories, such as depression, anxiety, and personality disorders. The data underwent preprocessing steps, including cleaning, balancing, and dimensionality reduction using the TF-IDF algorithm. The study results indicate that the Stacking Classifier method achieved an accuracy of 95.66%, with a precision of 95.63%, recall of 95.66%, and F1-Score of 95.64%. These results outperform the individual algorithms tested in the research. The findings demonstrate the significant potential of sentiment analysis powered by machine learning for early detection of mental health disorders, making it a valuable tool to enhance diagnosis and intervention in mental health care more effectively.

Keywords: mental health, sentiment analysis, stacking classifier, machine learning, mental health prediction.

1 Pendahuluan

Salah satu aspek terpenting dalam kehidupan adalah kesehatan mental, dengan prevalensi gangguan mental yang terus meningkat secara global. Menurut data WHO pada tahun 2019, sebanyak 970 juta jiwa di dunia mengalami gangguan kesehatan mental, termasuk depresi dan kecemasan. Dampak ekonomi dari kondisi ini diperkirakan mencapai USD 16 triliun pada 2030, menjadikannya

sebagai prioritas kesehatan masyarakat [1], [2]. Selain itu, pandemi *COVID-19* memperburuk situasi ini, dengan peningkatan prevalensi gangguan mental hingga 25% [1].

Menurut survei yang dilakukan oleh *I-NAMHS (Indonesia National Adolescent Mental Health Survey)* 1 dari 20 remaja di Indonesia memiliki masalah kesehatan mental. Hal ini diakibatkan karena efek pembatasan kontak sosial selama pandemi *COVID-19* yang lalu [3]. Sebagian remaja memiliki resiko lebih besar terhadap masalah kesehatan mental karena lingkungan tinggal, stigma, diskriminasi atau pengucilan, serta keterbatasan akses terhadap dukungan dan layanan berkualitas [4].

Kesehatan mental mencakup kesejahteraan emosional, psikologi, dan sosial, yang berpengaruh terhadap cara berpikir seseorang, merasakan, dan juga berperilaku seseorang. Kesehatan mental yang baik penting untuk mengelola stres, membangun hubungan, dan membuat keputusan yang tepat. Gangguan kesehatan mental mencakup berbagai kondisi yang mengganggu pikiran, emosi, dan perilaku, sering kali menyebabkan tekanan dan kesulitan dalam menjalani aktivitas harian. Kondisi ini beragram dan dapat memengaruhi individu dari berbagai usia, latar belakang, dan profesi [5].

Sentimen analisis memungkinkan untuk mengabstraksi informasi subjektif dalam bentuk data teks. Hal ini menjadi alat penting dalam memahami opini publik dan mendeteksi masalah kesehatan mental yang mungkin tersembunyi dalam opini atau komentar masyarakat [6]. Sentimen yang terkandung dalam teks dapat memberikan indikasi awal mengenai kondisi mental, seperti depresi atau kecemasan, sehingga memungkinkan pengambilan langkah intervensi lebih awal.

Dalam upaya meningkatkan diagnosis dini dan akurat, metode pembelajaran mesin (*ML*) telah banyak digunakan. Salah satu pendekatan efektif adalah *ensemble learning*, khususnya metode *stacking*, yang menggabungkan beberapa algoritma untuk menghasilkan model prediksi yang lebih kuat. Dua algoritma yang sering digunakan dalam pendekatan ini adalah *Random Forest (RF)* dan *Gradient Boosting Classifier (GBC)*. *RF* terkenal karena kemampuannya menangani data yang tidak seimbang dan kompleks, sedangkan *GBC* unggul dalam memodelkan hubungan non-linear secara efisien

2 Tinjauan Literatur

Dalam sepuluh tahun terakhir, penerapan *machine learning* telah berkembang signifikan untuk menganalisis data teks terkait kesehatan mental. Dan dalam kurun waktu lima tahun terakhir, perkembangan dalam prediksi dan klasifikasi penyakit mental melalui analisis sentimen telah mengalami kemajuan yang signifikan. Penyebab utamanya disebabkan oleh peningkatan jumlah data teks yang berasal dari media sosial, forum, dan platform digital lainnya. Kini, analisis sentimen digunakan untuk mendeteksi perasaan, emosi, dan pola bahasa yang berkaitan dengan gangguan mental. Dalam konteks ini, metode *ensemble* seperti *stacking* semakin populer karena kelebihanannya dalam menggabungkan beberapa model *machine learning*, yang dapat meningkatkan akurasi prediksi, terutama untuk data teks yang sangat bervariasi.

Priyono et al [6] mengusulkan penggunaan metode *Random Forest (RF)* dalam mendiagnosis gangguan mental, termasuk depresi dan bipolar. Studi ini menggunakan dataset berisi 120 data pasien dengan 17 atribut, di mana proses tuning parameter dan *K-Fold Cross Validation* berhasil mencapai akurasi sebesar 90,83%, presisi 93,25%, dan recall 90,83%. Penelitian ini menekankan keunggulan *RF* dalam menghasilkan klasifikasi yang akurat, khususnya dengan parameter terbaik seperti *n-estimator* sebanyak 30 dan *maximum depth* sebesar 4. Hasil penelitian ini menunjukkan bahwa metode *RF* berpotensi diimplementasikan dalam sistem diagnosis klinis untuk mempercepat deteksi dini gangguan mental.

Anastasia et al [7] dalam penelitiannya menggunakan metode *machine learning* untuk menilai data mengenai depresi dan kesehatan mental. Berbagai algoritma klasifikasi, seperti *K-Nearest Neighbor (KNN)*, *Naïve Bayes*, *Decision Tree*, *Support Vector Machine (SVM)*, dan *AdaBoost* diuji dalam penelitian ini. Hasil analisis menunjukkan bahwa model *KNN* memiliki akurasi tertinggi dengan nilai *Area Under Curve (AUC)* sebesar 79.6%, menjadi yang paling efektif dalam klasifikasi data kesehatan mental serta prediksi tingkat depresi. Penelitian ini juga menemukan bahwa faktor usia, jenis kelamin, dan pekerjaan memiliki pengaruh signifikan terhadap tingkat depresi, terutama pada kelompok usia 25-30 tahun. Temuan ini menggarisbawahi potensi *KNN* sebagai model yang andal untuk analisis data kesehatan mental dan menunjukkan bahwa karakteristik demografis merupakan indikator penting dalam kesehatan mental.

Chung et al [8] membahas evaluasi beberapa *machine learning* untuk memprediksi masalah kesehatan mental. Penelitian ini mengeksplorasi beberapa model, baik dengan pendekatan tunggal maupun *ensemble*. Model yang diuji antara lain *LogisticRegression*, *Gradient Boosting*, *Neural Network*, *K-Nearest Neighbors (KNN)*, dan *Support Vectore Machine (SVM)*. Metode *ensemble* seperti *Voting Classifier*, *Extreme Gradient Boosting*, dan *Deep Neural Network* juga diuji pada penelitian ini. Hasil menunjukkan bahwa *Gradient Boosting* mencapai akurasi tertinggi sebesar 88.80%, diikuti oleh *Neural Networks* dengan akurasi 88.00%. Sedangkan model *ensemble voting classifier* mencatat akurasi sebesar 85.60%, metode lain seperti *Logistic Regression* dan *SVM* mencapai akurasi antara 82.40% hingga 84.00%. Hasil ini menunjukkan bahwa *Gradient Boosting* adalah model terbaik untuk klasifikasi biner kesehatan mental pada penelitian ini.

3 Metode Penelitian

Penelitian ini bertujuan untuk menganalisis sentimen berdasarkan kategori yang ada, sehingga dapat memberikan hasil deteksi gangguan kesehatan mental. Untuk mencapai tujuan permasalahan penelitian yang terjadi dapat dilakukan pembuatan sistem deteksi dini gangguan kesehatan mental menggunakan metode *stacking*. Metode ini menggunakan algoritma TF-IDF untuk menghitung bobot pada *statement* dan *stemming* untuk menemukan bentuk dasar dari sebuah kata turunan. Penelitian yang dilakukan mencakup beberapa tahapan, yaitu prapemrosesan data, implementasi *stemming*, implementasi TF-IDF, kemudian mengevaluasi model.

Dataset

Eksperimen ini menggunakan mental health dataset sebagai uji kategori penyakit mental. Penulis menggunakan data dari website <https://www.kaggle.com/datasets/suchintikasarkar/sentiment-analysis-for-mental-health/data>.

Dataset ini merupakan data untuk klasifikasi berdasarkan status penyakit mental, yang terdiri dari 7 kategori, yaitu "Normal", "Depression", "Suicidal", "Anxiety", "Stress", "Bi-Polar", dan "Personality Disorder". Dataset ini disajikan dalam bentuk ".csv" dengan kolom pertama adalah unique key, kolom kedua adalah pernyataan dan kolom ketiga adalah status penyakit mental yang diderita. Pengaturan atribut adalah *statement* dan status.

Pengaturan dataset menggunakan tools *Google Colaboratory*. Pada kolom *statement* merupakan kolom pernyataan dari seseorang tentang apa yang sedang dirasakan oleh dirinya. Kolom status sebagai kolom dari status penyakit mental, berisi status dari penyakit mental yang diderita.

TF – IDF

TF-IDF adalah algoritma numerik statistik yang menghasilkan bobot untuk setiap kata dalam teks. Algoritma ini bertujuan untuk menilai seberapa penting suatu kata dalam kumpulan dokumen dengan cara menghitung tingkat kepentingannya berdasarkan frekuensi kemunculannya [9]. Semakin sering sebuah kata muncul dalam suatu dokumen, maka semakin tinggi bobot yang diberikan. Untuk menghitung *Term Frequency* suatu dokumen dapat dihitung dengan persamaan (1) sebagai berikut.

$$TF_{ij} = \frac{f_{ij}}{\sum^k f_{ij}} \quad (1)$$

Tf mengukur frekuensi kemunculan suatu kata dalam sebuah dokumen, sementara *Invers Document Frequency (IDF)* menghitung sebaran kata tersebut di seluruh dokumen. *IDF* dapat dihitung dengan menggunakan persamaan (2).

$$IDF_i = \log\left(\frac{N}{n_i}\right) + 1 \quad (2)$$

N merupakan total jumlah dokumen dalam kumpulan dokumen tersebut. Setelah nilai *TF* dan *IDF* diperoleh, langkah selanjutnya menghitung nilai *TF-IDF* dengan mengalikan kedua nilai tersebut. Dengan demikian, nilai *TF-IDF* dapat dihitung menggunakan persamaan (3)

$$TFIDF_{ij} = TF_{ij} \times IDF_i \quad (3)$$

Algoritma Gradient Boosting

Gradient Boosting Classifier adalah metode yang kuat yang digunakan dalam pengembangan model klasifikasi dan regresi, yang secara khusus dioptimalkan untuk proses pembelajaran pada model yang menunjukkan karakteristik non-linear [10]. Biasanya, teknik ini dikaitkan dengan pohon keputusan atau regresi, di mana metode ini membangun serangkaian model prediksi lemah, seperti pohon keputusan regresi, secara bertahap dan berurutan [11].

Setiap pembelajar baru ditambahkan secara bertahap ke dalam model, memperbaiki kemampuan prediksi ensemble secara keseluruhan. Node dan daun dalam pohon yang dibangun berkontribusi pada proses pengambilan keputusan, menghasilkan prediksi berdasarkan node keputusan tersebut. Meskipun setiap pohon regresi memiliki kekuatan prediksi yang lemah secara individual, kekuatan kolektif mereka sebagai ensemble secara signifikan meningkatkan akurasi prediksi. Konstruksi ensemble yang bertahap dan berurutan ini memungkinkan perbaikan terhadap kesalahan dalam ensemble sebelumnya, sehingga meningkatkan kekokohan model secara keseluruhan [12].

Adaptive Boosting

Adaptive Boosting (AdaBoost) adalah algoritma klasifikasi yang membentuk komite dari beberapa klasifikator lemah dan meningkatkan kinerja algoritma pembelajaran mesin dengan menggabungkannya menjadi satu klasifikator yang kuat. Tujuan utama dari algoritma ini adalah meningkatkan bobot pada data yang belum terklasifikasi dan mengurangi bobot pada data yang sudah terklasifikasi dengan benar. Beberapa keunggulan dari AdaBoost adalah kemudahan penggunaannya dan tingkat akurasi klasifikator lemahnya. Namun, algoritma ini juga memiliki kelemahan, seperti kebutuhan akan data berkualitas tinggi dan pengoptimalan hiperparameter. Pohon keputusan yang dihasilkan sering disebut sebagai *Decision Stump* [13], dan model akan terus dilatih hingga mencapai tingkat kesalahan yang lebih rendah [14].

Random Forest

Algoritma ini menggunakan teknik *ensemble learning* yang biasa digunakan untuk masalah klasifikasi. Setiap *tree* akan dilatih menggunakan *subset* sampel pelatihan yang diambil secara acak (*bootstrapping*) dan subset acak dari fitur *input*. Dengan ini, model dapat belajar dari beragam fitur yang ada dalam data. Jika suatu fitur merupakan prediktor kuat terhadap variabel respon, maka fitur tersebut akan lebih sering dipilih untuk memaksimalkan akurasi klasifikasi [15].

Random Forest (RF) mengatasi keterbatasan algoritma pemisahan dalam proses konstruksi pohon. RF melampaui performa pohon keputusan yang di-bag dengan membatasi penggunaan hanya sebagian kecil atribut input secara acak sebagai kandidat titik pemisah. Selama pohon klasifikasi dibangun, RF hanya mempertimbangkan percabangan berdasarkan subset atribut yang dipilih secara acak, mirip dengan metode *bagging*. Pendekatan ini memanfaatkan "*simultaneously ensembling*" di mana beberapa model pohon keputusan dijalankan secara paralel pada berbagai sub-sampel data, dan hasil akhirnya ditentukan melalui mekanisme voting. Dengan ukuran variabel acak yang telah ditentukan sebelumnya, metode ini mampu mengurangi risiko overfitting dan meningkatkan akurasi prediksi secara terkontrol [16].

Evaluasi Model

Confusion matrix adalah tabel yang berfungsi untuk menyajikan informasi terkait kinerja model, khususnya dalam mengukur efektivitas klasifikasi yang dilakukan. Matriks ini menjadi dasar untuk mengevaluasi performa algoritma klasifikasi pada tahap penilaian model [17].

Tabel 1. Confusion matrix

		<i>Predicted Values</i>	
		Positive (0)	Negative (1)
Actual Value	Postive (0)	TP	FP
	Negative (1)	FN	TN

Tabel 1 menjelaskan baris *Actual Values* menunjukkan nilai sebenarnya (*ground truth*) dari data dan memiliki dua kelas, yaitu *positive* (0) yang menunjukkan data benar benar positif dan *negative* (1) yang menunjukkan data benar benar negatif. Sedangkan kolom *Predicted Values* menunjukkan nilai yang diprediksi oleh model dan memiliki 2 kemungkinan, yaitu *positive* (0) dimana data yang diprediksi sebagai positif dan *negative* (1) dimana data yang diprediksi sebagai negatif.

Confusion Matrix merupakan alat evaluasi yang digunakan untuk menilai kinerja sebuah model. Matriks ini menyajikan informasi berupa nilai TP (True Positive) dan TN (True Negative), yang menggambarkan jumlah prediksi benar yang berhasil dilakukan model. Sebaliknya, nilai FP (False Positive) dan FN (False Negative) menunjukkan jumlah prediksi yang keliru yang dihasilkan oleh model.

Setelah membangun data *training*, tahap pengujian dilakukan untuk mengevaluasi model berdasarkan nilai akurasi dan *F1-Score*. Akurasi mencerminkan proporsi prediksi yang benar, baik

untuk data positif maupun negatif, terhadap total data yang diuji. Sementara itu, *F1-Score* menunjukkan kualitas model dalam menyeimbangkan presisi dan *recall*. Untuk menghitung akurasi, presisi, *recall*, dan *F1-Score*, dapat digunakan *Confusion Matrix* yang mencatat performa model berdasarkan jumlah prediksi benar dan salah [18]. Untuk memperoleh perhitungan kinerja model ini dapat dilakukan dengan menghitung nilai *akurasi*, *precision*, *recall*, dan *F1-Score* berdasarkan rumus yang ada pada persamaan (4), (5), (6), dan (7).

$$\text{Akurasi} = \frac{TP+TN}{TP+FP+TN+FN} \tag{4}$$

$$\text{Precision} = \frac{TP}{TP+FP} \tag{5}$$

$$\text{Recall} = \frac{TP}{TP+FN} \tag{6}$$

$$\text{F1 - Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{7}$$

Logistic Regression

Logistic Regression adalah algoritma pembelajaran mesin yang terkenal dan termasuk dalam pendekatan *supervised learning*. Dalam metode ini, kita memprediksi variabel dependen tertentu dari serangkaian variabel bebas. Regresi logistik digunakan untuk memprediksi keluaran dari variabel-variabel terstruktur tertentu. Hasilnya adalah nilai kategoris atau diskret, seperti 0 atau 1, ya atau tidak, benar atau salah, dan sebagainya. Namun, alih-alih memberikan nilai pasti seperti 0 dan 1, algoritma ini menghasilkan nilai probabilistik yang berkisar antara 0 dan 1 [19].

Pendekatan Ensemble Stacking

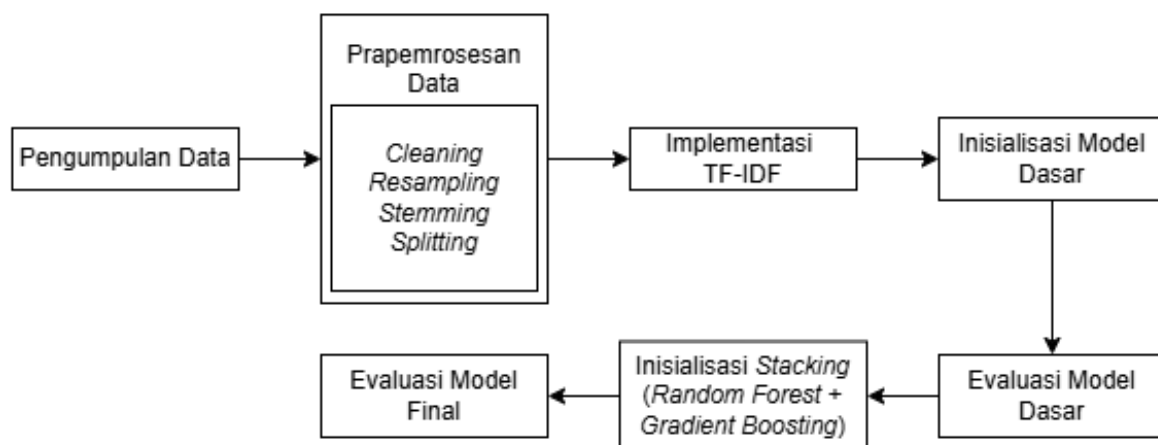
Ensemble learning merupakan kombinasi dari beberapa algoritma *machine learning* (ML) yang digunakan untuk meningkatkan akurasi sehingga hasil prediksi menjadi lebih tepat dibandingkan algoritma tunggal [20]. Metode ini mencakup beberapa model pembelajaran mesin yang biasa disebut sebagai model pembelajar dasar atau *base learners* [21]. Terdapat 3 (tiga) teknik *ensemble* yaitu: *bagging*, *boosting*, dan *stacking* [22].

Pendekatan *stacking* merupakan salah satu metode yang memiliki tujuan untuk meningkatkan prediksi dengan menggabungkan beberapa model (*base models*) menjadi satu yang lebih kuat. Pada metode ini, beberapa model dasar dilatih secara paralel, dan hasil prediksi dari setiap model ini digabungkan. Hasil prediksi ini akan digunakan sebagai input untuk model meta (*meta-learner*), kemudian model meta akan dilatih untuk membuat prediksi akhir [20].

4 Hasil dan Pembahasan

Hasil menggunakan metode *stacking* dalam deteksi dini gangguan mental berbasis sentimen didapatkan dengan beberapa tahapan sebagai berikut:

Eksperimen



Gambar 1. Tahapan eksperimen

Tahapan eksperimen seperti yang ada di Gambar 1 dimulai dari pengumpulan data. Setelah data terkumpul akan dilakukan tahap prapemrosesan data, dimana data akan di *cleaning* kemudian akan di *resampling*. Selanjutnya data akan dilakukan proses *stemming* dan yang terakhir data akan dibagi

(*splitting*) menjadi data uji dan data latih. Setelah selesai pada tahap prapemrosesan data, data yang sudah siap akan diubah menjadi data vektor numerik menggunakan fitur *TF-IDF* (*Term Frequency-Inverse Document Frequency*). Langkah selanjutnya adalah inisialisasi model dasar, model yang diinisialisasi adalah *Random Forest*, *Gradient Boosting Classifier*, *Adaptive Boosting*, dan *Logistic Regression*. Setelah model dasar diinisialisasi, langkah selanjutnya adalah evaluasi model. Hal ini dilakukan untuk menentukan model mana yang akan dipilih untuk selanjutnya digunakan untuk model *stacking*. Jika model dasar sudah ditentukan, langkah berikutnya adalah insialisasi model *stacking*. Langkah terakhir adalah evaluasi model akhir, langkah ini bertujuan untuk mengetahui berapa akurasi yang didapatkan dari model akhir yang sudah dilatih menggunakan data latih yang sudah ditentukan.

Pengumpulan Data

Data yang digunakan merupakan kumpulan status kesehatan yang dikurasi dengan cermat yang ditandai dari berbagai pernyataan. Kumpulan data ini menggabungkan data mentah dari berbagai sumber. Data tersebut bersumber dari beberapa *platform* termasuk postingan media sosial, *Reddit*, postingan *Twitter*, dan masih banyak lagi. Setiap data ditandai dengan status kesehatan mental tertentu.

Tabel 2 menunjukkan deskripsi dari *dataset* yang digunakan. Penelitian ini menggunakan *Sentiment Analysis for Mental Health dataset* dengan atribut berjumlah 2 (dua) dan memiliki data sebanyak 53043 data berupa data teks.

Tabel 2. Deskripsi dataset

Dataset	Jumlah Atribut	Jumlah Data
Sentiment Analysis for Mental Health	2	53043

Prapemrosesan Data

Prapemrosesan data merupakan salah satu langkah untuk proses klasifikasi teks [23]. Hal ini merupakan langkah penting dalam mempersiapkan data teks sebelum digunakan untuk melatih model ML. Tujuannya untuk membersihkan dan mentransformasi data agar lebih mudah diproses oleh model. Tahap pertama yang dilakukan adalah pembersihan data dengan cara menghapus karakter khusus, menghapus kolom yang tidak digunakan, dan menghapus atau mengubah teks menjadi huruf kecil. Pada Tabel 3, kolom "*Unnamed : 0*" akan dihilangkan karena kolom tersebut tidak digunakan.

Tabel 3. Data yang belum dibersihkan

Unnamed : 0	statement	status
0.	Oh my gosh	Anxiety
1.	Trouble sleeping, confused mind....	Anxiety
2.	I feel generally fine except thoughts.....	Depression
3.	I have no idea, all of sudden i heard your.....	Normal
4.	How to hurt peoples feelings, i think....	Personality Disorder

Setelah data dibersihkan seperti pada Tabel 4, tahap selanjutnya adalah menyeimbangkan data. hal ini dilakukan agar data dari kelas minoritas jumlahnya sama dengan kelas mayoritas.

Tabel 4. Data yang sudah dibersihkan

statement	status
Oh my gosh	Anxiety
Trouble sleeping, confused mind....	Anxiety
I feel generally fine except thoughts.....	Depression
I have no idea, all of sudden i heard your.....	Normal

How to hurt peoples feelings, i think....	Personality Disorder
---	----------------------

Pada Tabel 5 jumlah data per status masih tidak seimbang, maka dari itu digunakanlah fungsi *resmpl* untuk menyeimbangkan jumlah sampel di setiap kelas pada dataset dengan cara *resampling*. Sehingga setiap kelas memiliki jumlah sampel yang sama dengan kelas yang memiliki jumla sampel terbanyak. *Resampling* ini berguna dalam menangani ketidakseimbangan kelas (*class imbalance*) pada dataset.

Tabel 5. Jumlah data yang belum seimbang

Status	Jumlah Data
Normal	16351
Depresion	15404
Suicidal	10653
Anxiety	3888
Bipolar	2877
Stress	2669
Personality Disorder	1201

Setelah data sudah seimbang seperti pada Tabel 6, data kemudian direduksi ke dalam bentuk dasarnya (*stemming*). *Stemming* merupakan proses menemukan bentuk dasar dari sebuah kata turunan dengan cara menghapus imbuhan sehingga menjadi kata dasar [24]. Contoh, kata “*running*”, “*runs*”, dan “*ran*” akan direduksi mennjadi “*run*”. Kata “*carring*”, “*cared*”, “*cares*” akan menjadi “*care*”.

Tabel 6. Jumlah data yang sudah seimbang

Status	Jumlah Data
Normal	16351
Depresion	16351
Suicidal	16351
Anxiety	16351
Bipolar	16351
Stress	16351
Personality Disorder	16351

Input: This is a test sentence with some punctuation!
 Output: thi is a test sentenc with some punctuat

Gambar 2. Contoh proses reduksi (*stemming*)

Data yang sudah seimbang dan sudah direduksi seperti Gambar 2 akan dibagi menjadi 20% data uji (*testing*) dan 80% data uji (*training*). Data uji akan digunakan untuk mengevaluasi performa model yang telah dilatih menggunakan data latih. Ini memberikan gambaran tentang bagaimana model akan berperforma pada data yang belum pernah diliat sebelumnya.

Implementasi TF-IDF

Data yang sudah melewatokan prapemrosesan akan diberikan bobot disetiap kata yang akan digunakan [23] dan diubah menjadi representasi numerik menggunakan *TF-IDF Vectorizer* dan menghasilkan matriks yang merepresentasikan teks dalam bentuk numerik menggunakan algoritma

TF-IDF sesuai Pers. (3). Hasil yang diperoleh dari fitur ini adalah vektor numerik seperti pada Tabel 7.

Tabel 7. Hasil implementasi fitur *TF-IDF*

nomor_dokumen	nomor_fitur	bobot_tfidf
0	3398	0.05035397878771241
0	8703	0.07320941464219106
0	3719	0.04945296482499577
22880	6668	0.15062105504545975
22880	6711	0.12467277606058141
22880	7381	0.20725901340832076
22880	7393	0.3932160072953328

Inisialisasi Model Dasar

Setelah semua proses prapemrosesan selesai, langkah selanjutnya adalah inisialisasi model. *Random Forest*, *Gradient Boosting Classifier*, *AdaBoost* dan *Logistic Regression* dijadikan sebagai model yang akan dilatih terlebih dahulu dengan menggunakan data latih yang sudah disiapkan.

Evaluasi Model Dasar

Model dasar yang sudah dilatih menghasilkan hasil yang ada pada Tabel 8. Dari hasil ini *Random Forest*, *Gradient Boosting Classifier*, dan *Logistic Regression* dipilih karena memiliki hasil evaluasi yang cukup tinggi.

Tabel 8. Hasil evaluasi model dasar

Algoritma	Accuracy	Precision	Recall	F1-Score
<i>Random Forest</i>	95.32%	95.29%	95.32%	95.30%
<i>Gradient Boosting Classifier</i>	79.31%	79.55%	79.31%	79.15%
<i>AdaBoost</i>	65.98%	66.65%	65.98%	65.90%
<i>Logistic Regression</i>	87.49%	87.25%	87.49%	87.28%

Inisialisasi Model Stacking

Langkah selanjutnya adalah inisialisasi model *Stacking Classifier*. *Random Forest* dan *Gradient Boosting Classifier* akan digunakan sebagai model dasar, sedangkan *Logistic Regression* akan digunakan sebagai *meta learner*. Ketiga model tadi digabungkan menjadi satu, lalu dilatih kembali menggunakan data latih yang sudah disiapkan.

Evaluasi Model Akhir

Setelah model akhir dilatih, akan mendapatkan hasil seperti pada Tabel 9. Hasil akhir model *stacking* memiliki akurasi sebesar 95.66%, *precision* sebesar 95.63%, *recall* sebesar 95.66%, dan *F1-Score* sebesar 95.64%. Hal ini mejadikan model *ensemble stacking* lebih baik dari model tunggal dalam hal deteksi gangguan mental health berbasis sentimen.

Tabel 9. Hasil evaluasi model *stacking*

Accuracy	Precision	Recall	F1-Score
95.66%	95.63%	95.66	95.64%

Tahap terakhir dalam eksperimen ini adalah melakukan *testing* menggunakan model *stacking* yang sudah dilatih menggunakan data latih. Dari tahap ini menghasilkan hasil test yang ada di Tabel 10.

Tabel 10. Hasil test model *stacking*

Input	Output
<i>I can't sleep</i>	<i>Normal</i>

<i>Can't sleep, just worried about assignment</i>	<i>Anxiety</i>
<i>Do we notice things more than others? Why do the smallest things affect us so much.</i>	<i>Bipolar</i>

5 Kesimpulan

Penelitian ini berhasil menunjukkan bahwa pendekatan *Stacking Classifier*, yang menggabungkan *Random Forest* dan *Gradient Boosting Classifier* sebagai model dasar serta *Logistic Regression* sebagai *meta-learner*, mampu menghasilkan performa terbaik dalam memprediksi gangguan kesehatan mental berdasarkan analisis sentimen. Dengan akurasi sebesar 95,66%, *precision* 95,63%, *recall* 95,66%, dan *F1-Score* 95,64%, metode ini membuktikan keunggulannya dibandingkan algoritma individual seperti *Random Forest*, *Gradient Boosting*, *AdaBoost*, dan *Logistic Regression*. Hal ini menegaskan bahwa kombinasi model melalui ensemble learning dapat meningkatkan kekuatan prediksi secara signifikan.

Referensi

- [1] L. S. Khoo, M. K. Lim, C. Y. Chong, and R. McNaney, "Machine Learning for Multimodal Mental Health Detection: A Systematic Review of Passive Sensing Approaches," *Sensors*, vol. 24, no. 2, p. 348, Jan. 2024, doi: 10.3390/s24020348.
- [2] B. Saylam and Ö. D. İncel, "Multitask Learning for Mental Health: Depression, Anxiety, Stress (DAS) Using Wearables," *Diagnostics*, vol. 14, no. 5, p. 501, Feb. 2024, doi: 10.3390/diagnostics14050501.
- [3] Universitas Gadjah Mada, "Hasil Survei I-NAMHS: Satu dari Tiga Remaja Indonesia Memiliki Masalah Kesehatan Mental." Accessed: Nov. 07, 2024. [Online]. Available: <https://ugm.ac.id/id/berita/23086-hasil-survei-i-namhs-satu-dari-tiga-remaja-indonesia-memiliki-masalah-kesehatan-mental/>
- [4] World Health Organization, "Mental Health of adolescents." Accessed: Nov. 07, 2024. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/adolescent-mental-health>
- [5] R. Verma, Nipun, N. Rana, and Dr. R. K. Arora, "Mental Health Prediction using Sentimental Analysis," *Int J Res Appl Sci Eng Technol*, vol. 11, no. 12, pp. 1131–1135, Dec. 2023, doi: 10.22214/ijraset.2023.57534.
- [6] A. Priyono, M. Shodiq, D. P. Alvinsyah, and S. A. Hidayah, "Metode Random Forest untuk memudahkan Klasifikasi Diagnosis Penyakit Mental," *Jurnal Informatika Medis (J-INFORMED)*, vol. 2, no. 1, pp. 1–4, Jun. 2024, doi: 10.52060/im.v2i1.2119.
- [7] M. Anastasia and V. S. Maulivia, "Metode Pembelajaran Mesin untuk Menilai Data Depresi dan Kesehatan Mental *Machine Learning Methods for Assessing Depression and Mental Health Data*," *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 7, no. 3, 2024.
- [8] J. Chung and J. Teo, "single Classifier vs. Ensemble Machine Learning Approaches for Mental Health Prediction," *Brain Inform*, vol. 10, no. 1, p. 1, Dec. 2023, doi: 10.1186/s40708-022-00180-6.
- [9] H. Ogura, Y. Hanada, H. Amano, and M. Kondo, "A Stochastic Model Of Word Occurrences in Hierarchically Structured Written Texts," *SN Appl Sci*, vol. 4, no. 3, p. 77, Mar. 2022, doi: 10.1007/s42452-022-04953-w.
- [10] R. Suhendra et al., "Evaluation of Gradient Boosted Classifier in Atopic Dermatitis Severity Score Classification," *Heca Journal of Applied Sciences*, vol. 1, no. 2, pp. 54–61, Sep. 2023, doi: 10.60084/hjas.v1i2.85.
- [11] Abdullah-All-Tanvir, I. A. Khandokar, A. K. M. M. Islam, S. Islam, and S. Shatabda, "A Gradient Boosting Classifier for Purchase Intention Prediction of Online Shoppers," *Heliyon*, vol. 9, no. 4, p. e15163, Apr. 2023, doi: 10.1016/j.heliyon.2023.e15163.
- [12] T. R. Noviandy et al., "Integrating Genetic Algorithm and LightGBM for QSAR Modeling of Acetylcholinesterase Inhibitors in Alzheimer's Disease Drug Discovery," *Malacca Pharmaceutics*, vol. 1, no. 2, pp. 48–54, Jul. 2023, doi: 10.60084/mp.v1i2.60.

- [13] A. S. Hussein, T. Li, C. W. Yohannese, and K. Bashir, "A-SMOTE: A New Preprocessing Approach for Highly Imbalanced Datasets by Improving SMOTE," *International Journal of Computational Intelligence Systems*, vol. 12, no. 2, p. 1412, 2019, doi: 10.2991/ijcis.d.191114.002.
- [14] P. C. Reddy, R. M. S. Chandra, P. Vadiraj, M. A. Reddy, T. R. Mahesh, and G. Sindhu Madhuri, "Detection of Plant Leaf-based Diseases using Machine Learning Approach," in *2021 IEEE International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)*, IEEE, Dec. 2021, pp. 1–4. doi: 10.1109/CSITSS54238.2021.9683020.
- [15] M. Vedechkina and J. Holmes, "Cognitive Difficulties Following Adversity are not Related to Mental Health: Findings from the ABCD Study," *Dev Psychopathol*, vol. 36, no. 4, pp. 1876–1889, Oct. 2024, doi: 10.1017/S0954579423001220.
- [16] E. S. Mohamed, T. A. Naqishbandi, S. A. C. Bukhari, I. Rauf, V. Sawrikar, and A. Hussain, "A Hybrid Mental Health Prediction Model using Support Vector Machine, Multilayer Perceptron, and Random Forest Algorithms," *Healthcare Analytics*, vol. 3, p. 100185, Nov. 2023, doi: 10.1016/j.health.2023.100185.
- [17] A. F. Hidayatullah, A. A. Fadila, K. P. Juwairi, and R. A. Nayoan, "Identifikasi Konten Kasar pada Tweet Bahasa Indonesia," *Jurnal Linguistik Komputasional (JLK)*, vol. 2, no. 1, p. 1, Mar. 2019, doi: 10.26418/jlk.v2i1.15.
- [18] S. Clara *et al.*, "Implementasi Seleksi Fitur pada Algoritma Klasifikasi *Machine Learning* untuk Prediksi Penghasilan pada *Adult Income Dataset*," *Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya (SENAMIKA) Jakarta-Indonesia*, 2021.
- [19] K. Vaishnavi, U. N. Kamath, B. Ashwath Rao, and N. V Subba Reddy, "Predicting Mental Health Illness using Machine Learning Algorithms," *J Phys Conf Ser*, vol. 2161, no. 1, p. 012021, Jan. 2022, doi: 10.1088/1742-6596/2161/1/012021.
- [20] H. Zhou, Y. Xin, and S. Li, "A Diabetes Prediction Model based on Boruta Feature Selection and Ensemble Learning," *BMC Bioinformatics*, vol. 24, no. 1, p. 224, Jun. 2023, doi: 10.1186/s12859-023-05300-5.
- [21] A. Ghourabi and M. Alohalay, "Enhancing Spam Message Classification and Detection using Transformer-based Embedding and Ensemble Learning," *Sensors*, vol. 23, no. 8, p. 3861, Apr. 2023, doi: 10.3390/s23083861.
- [22] G. D. Sepbriant and D. W. Utomo, "Ensemble Learning pada Kategorisasi Produk *E-Commerce* menggunakan Teknik *Boosting*," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 9, no. 2, pp. 123–133, May 2024, doi: 10.14421/jiska.2024.9.2.123-133.
- [23] A. P. Tirtopangarsa and W. Maharani, "Sentiment Analysis of Depression Detection on Twitter Social Media Users using the *K-Nearest Neighbor Method* Analisis Sentimen Deteksi Depresi pada Pengguna Media Sosial Twitter dengan menggunakan Metode *K-Nearest Neighbor*," pp. 13–2021, 2021.
- [24] F. Astuti and R. Taufan, "Sentiment Analysis of Covid-19 Vaccination on Twitter using Classification Algorithms based on PSO," *SISTEMASI*, vol. 11, no. 2, p. 364, May 2022, doi: 10.32520/stmsi.v11i2.1737.