

KLASIFIKASI RISIKO KESEHATAN MENTAL GENERASI Z BERDASARKAN PENGGUNAAN MEDIA SOSIAL MENGGUNAKAN METODE NAÏVE BAYES

Laila Syafira¹, Zahwa Aura Mutiara Hsb², Roberto Kaban³

^{1,2}Program Studi Sistem Informasi, Fakultas Sains dan Teknologi, Institut Teknologi dan Bisnis Indonesia, Deli Serdang, Indonesia

³Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Institut Teknologi dan Bisnis Indonesia, Deli Serdang, Indonesia

Email: lailasyafira37@gmail.com, zhwaurahsb@gmail.com, roberto.kaban@yahoo.com

*Penulis Korespondensi
(Laila Syafira)

Abstrak

Kesehatan mental Generasi Z menjadi perhatian penting karena intensitas penggunaan media sosial yang tinggi berpotensi memengaruhi kondisi psikologis, seperti kecemasan, depresi, dan gangguan tidur. Penelitian ini bertujuan mengklasifikasikan risiko kesehatan mental Generasi Z berdasarkan pola penggunaan media sosial menggunakan algoritma Naïve Bayes. Dataset *Social Media and Mental Health* dari Kaggle digunakan sebanyak 481 data responden, kemudian difilter pada rentang usia 18–27 tahun sehingga diperoleh 356 data. Tahap praproses meliputi pelabelan, penanganan *missing value*, penyeimbangan data, transformasi data, normalisasi, dan seleksi fitur sehingga diperoleh 312 data final dengan 10 atribut terpilih. Data dibagi menjadi 70% data latih dan 30% data uji. Hasil pengujian menunjukkan akurasi sebesar 92,55%, presisi 91,67%, dan recall 93,62%. Hasil ini menunjukkan bahwa pola penggunaan media sosial berpotensi digunakan sebagai indikator awal dalam deteksi risiko kesehatan mental Generasi Z.

Kata kunci: kesehatan mental, generasi z, media sosial, naïve bayes, klasifikasi

MENTAL HEALTH RISK CLASSIFICATION OF GENERATION Z BASED ON SOCIAL MEDIA USAGE USING THE NAÏVE BAYES METHOD

Abstract

The mental health of Generation Z is a significant concern because their high social media usage intensity can potentially impact psychological conditions, such as anxiety, depression, and sleep disorders. This study aims to classify Generation Z's mental health risks based on their social media usage patterns using the Naïve Bayes algorithm. The Social Media and Mental Health dataset from Kaggle used 481 respondents' data, then filtered by the age range of 18–27 years to obtain 356 data points. The preprocessing stage included labeling, handling missing values, data balancing, data transformation, normalization, and feature selection to obtain 312 final data points with 10 selected attributes. The data were divided into 70% training data and 30% test data. The test results showed an accuracy of 92.55%, a precision of 91.67%, and a recall of 93.62%. These results indicate that social media usage patterns have the potential to be used as an early indicator in detecting Generation Z's mental health risks.

Keywords: mental health, generation z, social media, naïve bayes, classification

1. PENDAHULUAN

Penggunaan media sosial yang tinggi pada Generasi Z dapat memengaruhi kondisi psikologis, terutama melalui munculnya kecemasan, depresi, gangguan tidur, dan kesulitan berkonsentrasi. Kondisi ini menjadi perhatian karena Generasi Z merupakan kelompok yang tumbuh dalam lingkungan digital dan sangat akrab dengan platform media sosial. Di sisi lain, peningkatan tekanan sosial, perbandingan diri,

serta paparan informasi yang terus-menerus dapat memperburuk kerentanan psikologis pada kelompok usia ini. Temuan tersebut sejalan dengan penelitian (Valkenburg et al., 2022) yang menyatakan bahwa penggunaan media sosial memiliki hubungan yang kompleks dengan kesehatan mental remaja dan dipengaruhi oleh karakteristik individu serta pola penggunaan media sosial. Selain itu, (Shannon et al., 2022) menemukan bahwa penggunaan media sosial

yang bermasalah (*problematic social media use*) berhubungan dengan meningkatnya risiko depresi, kecemasan, dan gangguan kesehatan mental pada remaja maupun dewasa muda. Kesehatan mental tidak hanya berkaitan dengan ada atau tidaknya gangguan jiwa, tetapi juga kemampuan individu untuk berfungsi secara optimal dalam kehidupan sehari-hari. Menurut World Health Organization, kesehatan mental yang baik tercermin dari kemampuan individu menghadapi tekanan, bekerja produktif, dan berkontribusi terhadap lingkungannya. Di Indonesia, isu kesehatan mental pada usia muda juga masih menjadi perhatian, sebagaimana ditunjukkan oleh Riskesdas 2018 yang melaporkan adanya gangguan mental emosional pada sebagian penduduk usia produktif. Berbagai penelitian sebelumnya telah memanfaatkan data mining untuk klasifikasi kesehatan mental, termasuk penggunaan algoritma Naïve Bayes, seperti pada analisis kesehatan mental mahasiswa (Maulana & Rismayani, 2023)(Suitela et al., 2026). Penelitian terkait Generasi Z dan Media Sosial juga telah dilakukan, baik dari sisi dampak jam kerja terhadap kesehatan mental (Al Fahreza et al., 2024). Maupun Pengaruh penggunaan ponsel terhadap kecemasan dan insomnia (Tsania et al., 2026). Maupun potensi konten media sosial dalam memicu gejala depresi (Dina et al., 2025).

Selain itu, banyak dataset yang tersedia belum memiliki label klinis sehingga diperlukan pendekatan klasifikasi berbasis label operasional yang dijelaskan secara transparan, sebagaimana juga di terapkan pada penelitian klasifikasi kesehatan mental siswa (Habibah et al., 2025). Berdasarkan hal tersebut, penelitian ini bertujuan membangun model klasifikasi risiko kesehatan mental Generasi Z berdasarkan pola penggunaan media sosial menggunakan algoritma Naïve Bayes. Penelitian ini diharapkan dapat memberikan gambaran awal mengenai indikator perilaku digital yang berhubungan dengan risiko kesehatan mental serta menjadi dasar bagi pengembangan deteksi dini yang lebih terjangkau dan praktis.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan klasifikasi dalam data mining untuk mengidentifikasi risiko kesehatan mental Generasi Z berdasarkan pola penggunaan media sosial. Proses penelitian meliputi pengumpulan data, praproses data, seleksi fitur, pembagian data, klasifikasi menggunakan Naïve Bayes, dan evaluasi model. Seluruh tahapan diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan library *pandas*, *numpy*, dan *scikit-learn* melalui platform Google Colaboratory. Alur penelitian dapat dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Data

Data bersumber dari dataset *Social Media and Mental Health* di platform Kaggle berikut link nya: <https://www.kaggle.com/datasets/souvikahmed071/social-media-and-mental-health> yang memuat 481 data responden dengan 20 atribut mencakup informasi demografis, kebiasaan penggunaan media sosial, dan indikator psikologis. Data difilter pada rentang usia 18–27 tahun sesuai definisi Generasi Z, menghasilkan 356 data yang relevan. Meskipun dataset bersifat internasional, relevansinya terhadap konteks Indonesia tetap terjaga karena dampak media sosial terhadap kesehatan mental merupakan isu global yang juga dialami generasi muda Indonesia, sebagaimana didukung data Riskesdas. Seluruh proses pengolahan data dan implementasi model pada penelitian ini didokumentasikan secara terbuka dan dapat diakses melalui notebook Goggle Colab berikut:

https://colab.research.google.com/drive/1OZnV6SetNc-VjlcJMdUiCqCVYB_-YABH?usp=sharing

2.2 Pre-processing Data

Tahap praproses dilakukan untuk meningkatkan kualitas data sebelum proses klasifikasi. Langkah yang dilakukan meliputi pelabelan, penanganan *missing value*, penyeimbangan data, penyeimbangan data, transformasi data, dan normalisasi. Alur penelitian dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Pre-processing

a. Pembuatan Label Klasifikasi

Pembuatan label klasifikasi dilakukan untuk membentuk kategori "Ya" dan "Tidak" berdasarkan rata-rata skor lima gejala psikologis, yaitu kecemasan, depresi, gangguan tidur, kesulitan berkonsentrasi, dan kemudahan terdistraksi. Ambang batas 3,5 ditentukan secara manual oleh peneliti sebagai batas pemisah kedua kategori tersebut. Label ini digunakan sebagai label operasional dalam penelitian karena dataset tidak menyediakan diagnosis klinis sebagai acuan.

b. Penyeimbangan Data

Distribusi kelas tidak seimbang dengan 200 data "Ya" dan 156 data "Tidak", sehingga diterapkan teknik undersampling menghasilkan 312 data seimbang (156:156) (Apriliyani & Salim, 2022).

c. Transformasi Data

Atribut kategorikal dikonversi ke bentuk numerik menggunakan Label Encoding.

d. Normalisasi Data

Seluruh atribut dinormalisasi menggunakan metode *Min-Max Normalization* ke skala 0–1.

2.3 Seleksi Fitur

Dilakukan seleksi fitur berbasis uji statistik untuk memilih 10 atribut paling relevan dari 20 atribut yang tersedia meliputi kebiasaan penggunaan media sosial tanpa tujuan, distraksi akibat media sosial, kegelisahan tanpa media sosial, kemudahan terdistraksi, kecemasan, kesulitan berkonsentrasi, perbandingan diri, depresi, fluktuasi minat, dan gangguan tidur, sebagaimana pendekatan seleksi fitur serupa juga diterapkan pada penelitian klasifikasi berbasis Naïve Bayes lainnya (Amali et al., 2024).

2.4 Pembagian Data

Data dibagi dengan perbandingan 70:30 menghasilkan 218 data latih dan 94 data uji secara terstratifikasi, mengacu pada (Putra et al., 2023).

2.5 Naïve Bayes

Naïve Bayes adalah algoritma klasifikasi berbasis probabilitas yang diperkenalkan oleh Thomas Bayes. Algoritma ini mengasumsikan setiap atribut bersifat independen satu sama lain dan terbukti efektif dalam klasifikasi data kesehatan mental (Butar Butar & Purnomo, 2025). Teorema Bayes dinyatakan pada Persamaan (1).

$$P(B|A) = \frac{P(A|B) \times P(B)}{P(A)} \quad (1)$$

Dari teorema tersebut diturunkan persamaan Naïve Bayes pada Persamaan (2).

$$P(a_i|v_j) = \frac{n_c + mp}{n + m} \quad (2)$$

Keterangan rumus tersebut adalah sebagai berikut. Nilai n_c menunjukkan jumlah data latih pada kelas tertentu yang sesuai dengan atribut yang diamati. Nilai p merupakan probabilitas awal yang diperoleh dari pembagian angka satu dengan jumlah kelas yang ada. Nilai m adalah jumlah atribut dalam dataset, sedangkan nilai n adalah jumlah seluruh data latih pada kelas yang bersangkutan.

2.6 Klasifikasi Naïve Bayes

Proses klasifikasi dilakukan menggunakan algoritma Naïve Bayes yang bekerja berdasarkan teorema Bayes dengan asumsi bahwa setiap atribut dalam data bersifat independen satu sama lain. Algoritma ini dipilih karena terbukti efektif dalam mengklasifikasikan data kesehatan mental dengan kebutuhan komputasi yang ringan dan tidak membutuhkan jumlah data yang sangat besar. Perhitungan probabilitas posterior pada setiap kelas dilakukan menggunakan persamaan berikut.

$$P(Y|X) = P(Y) \prod_{i=1}^n P(X_i|Y) \quad (3)$$

Di mana $P(Y)$ merupakan probabilitas awal kelas Y , dan $P(X_i|Y)$ adalah probabilitas kemunculan atribut X_i pada kelas Y .

2.7 Evaluasi Model

Kinerja model dievaluasi menggunakan *Confusion Matrix* untuk mengukur nilai akurasi, presisi, dan *recall* sebagaimana diterapkan oleh (Putra et al., 2023). Rumus perhitungan masing-masing metrik evaluasi adalah sebagai berikut.

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (4)$$

$$Presisi = \frac{TP}{TP+FP} \times 100\% \quad (5)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (6)$$

Di mana TP (True Positive) adalah data positif yang diprediksi benar, TN (True Negative) adalah data negatif yang diprediksi benar, FP (False Positive) adalah data negatif yang diprediksi positif, dan FN (False Negative) adalah data positif yang diprediksi negatif.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pre-processing Data

Berdasarkan implementasi yang telah dijalankan, dataset awal yang berjumlah 481 data setelah difilter pada rentang usia 18–27 tahun menghasilkan 356 data. Setelah dilakukan pelabelan, diperoleh 200 data berkelas "Ya" dan 156 data berkelas "Tidak". Ketidakseimbangan ini kemudian diatasi melalui teknik undersampling sehingga diperoleh 312 data dengan distribusi seimbang seperti pada Tabel 1.

Kelas	Jumlah	Persentase
Ya	156	50%
Tidak	156	50%
Total	312	100%

Tabel 1. Distribusi Data Setelah Pre-processing

Setelah melalui tahap transformasi dan normalisasi *Min-Max*, seluruh nilai atribut berada pada rentang 0 hingga 1 seperti contoh pada Tabel 2.

Usia	Kece m.	Distrak.	Depr e.	Tidur	Label
0,333	1,000	0,750	0,750	0,500	Tidak
0,222	1,000	1,000	1,000	1,000	Ya
0,444	0,750	0,750	0,750	0,750	Ya

Tabel 2. Contoh Hasil Normalisasi Data

3.2 Hasil Klasifikasi Naïve Bayes

Setelah melalui tahap seleksi fitur yang menghasilkan 10 atribut terpilih sebagaimana ditampilkan pada Tabel 3, data kemudian dibagi menjadi 218 data latih (70%) dan 94 data uji (30%).

No	Atribut
1	Penggunaan media sosial tanpa tujuan

2	Distraksi akibat media sosial saat sibuk
3	Kegelisahan tanpa media sosial
4	Kemudahan terdistraksi
5	Tingkat kecemasan
6	Kesulitan berkonsentrasi
7	Perbandingan diri dengan orang lain
8	Tingkat depresi
9	Fluktuasi minat pada aktivitas harian
10	Gangguan pola tidur

Tabel 3. Atribut Terpilih Hasil Seleksi

Model Naïve Bayes yang telah dilatih kemudian diuji terhadap 94 data uji, dan hasilnya ditampilkan dalam bentuk Confusion Matrix pada Tabel 4.

	Pred. Ya	Pred. Tidak	Precision
Aktual Ya	44 (TP)	3 (FN)	93,62%
Aktual Tidak	4 (FP)	43 (TN)	91,49%
Recall	91,67%	93,47%	
Accuracy			92,55%

Tabel 4. Confusion Matrix Hasil Klasifikasi

Berdasarkan Tabel 4, model berhasil mengklasifikasikan 44 data berkelas "Ya" dan 43 data berkelas "Tidak" dengan tepat. Sementara itu, terdapat 3 data berkelas "Ya" yang salah diprediksi sebagai "Tidak" dan 4 data berkelas "Tidak" yang salah diprediksi sebagai "Ya". Nilai akurasi, presisi, dan recall secara lengkap disajikan pada Tabel 5.

Metrik	Nilai
Akurasi	92,55%
Presisi	91,67%
Recall	93,62%

Tabel 5. Hasil Evaluasi Model Naïve Bayes

3.3 Pembahasan

Hasil pengujian menunjukkan bahwa model Naïve Bayes mampu mengklasifikasikan risiko kesehatan mental Generasi Z berdasarkan pola penggunaan media sosial dengan akurasi sebesar 92,55%. Hasil ini lebih tinggi dibandingkan (Putra et al., 2023) sebesar 86,87% pada klasifikasi kesehatan mental mahasiswa menggunakan algoritma yang sama, dan mendekati akurasi 97,6% yang dicapai oleh Butar Butar dan Purnomo (2025) pada sistem diagnosa gangguan kepribadian Gen Z.

Fitur-fitur hasil seleksi menunjukkan bahwa hampir seluruh indikator perilaku penggunaan media sosial, seperti distraksi, kegelisahan tanpa media sosial, dan kebiasaan membandingkan diri, berkorelasi kuat

dengan gejala psikologis seperti kecemasan, depresi, dan gangguan tidur. Temuan ini sejalan dengan pernyataan Butar Butar dan Purnomo (2025) bahwa intensitas penggunaan teknologi dan media sosial berpotensi memengaruhi kondisi psikologis individu pada Generasi Z.

Penelitian ini memiliki keterbatasan dalam hal jumlah data yang digunakan yakni 312 data setelah pre-processing dan penyeimbangan. Meskipun demikian, jumlah tersebut masih wajar untuk klasifikasi berbasis Naïve Bayes karena algoritma ini tidak membutuhkan dataset dalam jumlah sangat besar. Penelitian lanjutan disarankan mempertimbangkan perbandingan dengan algoritma lain seperti Support Vector Machine atau Random Forest, serta melibatkan data lokal Indonesia untuk meningkatkan generalisasi model.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan beberapa hal sebagai berikut.

Pertama, penelitian ini berhasil membangun model klasifikasi risiko kesehatan mental pada Generasi Z berdasarkan pola penggunaan media sosial menggunakan algoritma Naïve Bayes. Dataset yang awalnya berjumlah 481 data, setelah difilter pada rentang usia 18–27 tahun dan melalui tahap pre-processing, menghasilkan 312 data dengan distribusi seimbang antara kelas "Ya" dan "Tidak".

Kedua, hasil pengujian menunjukkan bahwa model Naïve Bayes mampu mengklasifikasikan risiko kesehatan mental dengan tingkat akurasi sebesar 92,55%, presisi 91,67%, dan recall 93,62%. Nilai akurasi ini lebih tinggi dibandingkan penelitian Putra dkk. (2023) yang memperoleh akurasi 86,87%, dan mendekati hasil Butar Butar dan Purnomo (2025) sebesar 97,6%.

Ketiga, hasil seleksi fitur menunjukkan bahwa atribut-atribut yang berkaitan dengan perilaku penggunaan media sosial, seperti distraksi, kegelisahan tanpa media sosial, dan kebiasaan membandingkan diri, memiliki korelasi yang kuat dengan gejala psikologis seperti kecemasan, depresi, dan gangguan tidur. Hal ini menunjukkan bahwa pola penggunaan media sosial dapat dijadikan indikator awal yang relevan dalam mendeteksi risiko kesehatan mental pada Generasi Z.

Penelitian ini memiliki beberapa keterbatasan, di antaranya jumlah data yang relatif terbatas yaitu 312 data, penggunaan label klasifikasi yang dibuat secara mandiri karena dataset tidak menyertakan diagnosis klinis, serta penerapan satu algoritma klasifikasi tanpa pembandingan. Untuk penelitian selanjutnya, disarankan menggunakan dataset yang lebih besar dan idealnya berasal dari data lokal Indonesia, melibatkan perbandingan dengan algoritma klasifikasi lain seperti Support Vector Machine atau Random Forest, serta melibatkan validasi dari tenaga

profesional di bidang psikologi untuk meningkatkan keandalan label klasifikasi.

5. DAFTAR PUSTAKA

- Al Fahreza, M. D., Luthfiarta, A., Rafid, M., Indrawan, M., & Nugraha, A. (2024). Analisis Sentimen: Pengaruh Jam Kerja Terhadap Kesehatan Mental Generasi Z. *Journal of Applied Computer Science and Technology (JACOST)*, 5(1), 16–25. <http://journal.isas.or.id/index.php/JACOST>
- Amali, Maulana, D., Widodo, E., Firmansyah, A., & Danny, M. (2024). Optimizing Sentiment Analysis for Bekasi Flood Management Using SVM and Naive Bayes with Advanced Feature Selection. *Brilliance: Research of Artificial Intelligence*, 4(1). <https://doi.org/10.47709/brilliance.v4i1.4268>
- Apriliyani, E., & Salim, Y. (2022). Analisis performa metode klasifikasi Naïve Bayes Classifier pada Unbalanced Dataset. *Indonesian Journal of Data and Science (IJODAS)*, 3(2), 47–54.
- Butar Butar, F. K., & Purnomo, A. S. (2025). Sistem Pakar Diagnosa Awal Gangguan Kepribadian pada Gen Z Menggunakan Metode Naïve Bayes. *JITET (Jurnal Informatika Dan Teknik Elektro Terapan)*, 13(3). <https://doi.org/10.23960/jitet.v13i3.7126>
- Dina, D. F. M., Haryanti, T., & Haq, M. A. (2025). Analisis Sentimen Terhadap Komentar pada Media Sosial TikTok yang Berpotensi Menyebabkan Depresi Menggunakan Metode Naive Bayes. *Jurnal Ilmiah Computing Insight*, 7(1).
- Habibah, L. S., Van FC, L. L., Putra, P. P., & Saputra, D. (2025). Analisis Pola Kesehatan Mental Siswa Menggunakan Metode Naive Bayes. *Prosiding SEMASTER: Seminar Nasional Teknologi Informasi & Ilmu Komputer*, 4(1), 469–478.
- Maulana, A. I., & Rismayani. (2023). Mental Health Analysis at the University of Dipa Makassar using Naïve Bayes Classifier. *IT Journal Research and Development (ITJRD)*, 8(1), 72. <https://doi.org/10.25299/itjrd.2022.11444>
- Putra, H. D., Khairani, L., & Hastari, D. (2023). Perbandingan Algoritma Naive Bayes Classifier dan Support Vector Machine untuk Klasifikasi Data Kesehatan Mental Mahasiswa. *SENTIMAS: Seminar Nasional Penelitian Dan Pengabdian Masyarakat*, 120–125. <https://journal.irpi.or.id/index.php/sentimas>
- Shannon, H., Bush, K., Villeneuve, P. J., Hellemans, K. G. C., & Guimond, S. (2022). Problematic Social Media Use in Adolescents and Young Adults: Systematic Review and Meta-analysis.

JMIR Mental Health, 9(4 AR-e33450).

<https://doi.org/10.2196/33450>

Suitela, A., Silviana, Bahaluan, F., Tima, M., Nurhayati, I. D., & Zaenuddin. (2026). The Student Mental Health Pattern Using Clustering and Classification Approaches. *JITEEHA: Journal of Information Technology Application in Education, Economy, Health and Agriculture*, 3(2), 49–61.
<https://journal.iteeacademy.org/index.php/jiteeha/>

Tsania, K. N. B., Wardhani, R., & Hanifah, A. I. (2026). Predicting the Impact of Mobile Phone Use on Anxiety and Insomnia Among University of Islam Lamongan Students Through the Naïve Bayes Method. *Jurnal Ilmiah Sistem Informasi (JUISI)*, 5(1), 156–165.
<https://ejurnal.provisi.ac.id/index.php/JUISI/issue/view/169>

Valkenburg, P. M., Meier, A., & Beyens, I. (2022). Social media use and its impact on adolescent mental health: An umbrella review of the evidence. *Current Opinion in Psychology*, 44, 58–68.
<https://doi.org/10.1016/j.copsyc.2021.08.017>