

Terbit online pada laman : <http://teknosi.fti.unand.ac.id/>

Jurnal Nasional Teknologi dan Sistem Informasi

| ISSN (Print) 2460-3465 | ISSN (Online) 2476-8812 |



Artikel Penelitian

Klasifikasi Hybrid Kecemasan Pengguna X Menggunakan Random Forest, SMOTE, dan Fitur Temporal

Ni Putu Eka Apriyanthi ^{a,*}, I Gede Teguh Satya Dharma ^b, Civica Moehaimin Dhewanty^c

^{a,b,c} Program Studi Manajemen Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Bali, Badung, Bali

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 09 Mei 2026

Revisi Akhir: 18 Agustus 2026

Diterbitkan Online: 23 Agustus 2026

KATA KUNCI

Kecemasan,
Klasifikasi Hybrid,
Random Forest,
SMOTE,
Fitur Temporal

KORESPONDENSI

E-mail: capriyanthi@pnb.ac.id

ABSTRACT

Pengungkapan indikasi kecemasan di media sosial X kerap terselubung dalam bahasa implisit (*covert anxiety*), sehingga pendekatan klasifikasi berbasis konten teks tunggal sering kali gagal menangkap konteks psikologis secara utuh serta rentan mengalami bias akibat ketidakseimbangan kelas data. Penelitian ini bertujuan untuk membangun model klasifikasi *hybrid* yang mengintegrasikan fitur linguistik dan indikator perilaku temporal guna meningkatkan sensitivitas deteksi kecemasan. Metodologi dijalankan secara bertahap mulai dari pra-pemrosesan data, ekstraksi fitur tekstual berbasis TF-IDF, serta pembentukan variabel biner temporal *is_night* (rentang jam 00:00-04:00 WIB). Kedua modalitas fitur digabungkan melalui skema *early fusion (concatenation)* menjadi vektor *hybrid* tunggal, yang kemudian diseimbangkan menggunakan teknik *Synthetic Minority Over-sampling Technique (SMOTE)* sebelum dilatih menggunakan algoritma Random Forest. Hasil eksperimen menunjukkan bahwa arsitektur *hybrid* berhasil mencapai tingkat akurasi sebesar 76,83% dengan performa *Recall* kelas netral sebesar 0,85. Analisis *feature importance* membuktikan bahwa variabel *is_night* secara empiris menjadi salah satu prediktor kunci yang memvalidasi korelasi klinis insomnia digital (skala DASS-21) dengan kecemasan. Kesimpulannya, penggabungan metadata waktu terbukti efektif melengkapi analisis teks dalam memperkuat interpretasi konteks perilaku pada sistem deteksi dini kesehatan mental di ruang digital.

1. PENDAHULUAN

Gangguan kesehatan mental, khususnya kecemasan (*anxiety*), telah menjadi isu global yang krusial, terutama pada individu yang berada dalam masa transisi usia 16 hingga 25 tahun [1]. Kelompok ini, yang mayoritas terdiri dari mahasiswa, seringkali menghadapi tekanan akademik dan adaptasi sosial yang tinggi yang berisiko memicu gangguan psikologis [2]. Namun, keterbatasan akses ke layanan profesional dan stigma sosial menyebabkan banyak individu lebih memilih untuk mengekspresikan kondisi emosional mereka secara anonim melalui media sosial, khususnya platform X [3], [4].

Platform X (sebelumnya Twitter) menyediakan data tekstual yang melimpah yang mencerminkan perasaan dan pikiran

pengguna secara *realtime* [5]. Penelitian sebelumnya telah banyak mengeksplorasi penggunaan *Natural Language Processing (NLP)* untuk mendeteksi indikasi depresi dan kecemasan [6], [7]. Algoritma *Random Forest (RF)* terbukti memiliki performa yang tangguh dalam klasifikasi teks kesehatan mental karena kemampuannya menangani data berdimensi tinggi dengan tingkat akurasi yang kompetitif [8], [9], [10]. Meski demikian, mayoritas penelitian tersebut masih berfokus pada analisis konten tekstual semata, tanpa mempertimbangkan aspek perilaku digital lainnya.

Salah satu inovasi dalam deteksi kesehatan mental adalah penggunaan fitur temporal atau pola waktu pengunggahan konten. Berdasarkan instrumen klinis *Depression Anxiety Stress Scales (DASS-21)*, gangguan pola tidur atau insomnia merupakan salah satu indikator utama kecemasan [1]. Pengguna yang mengunggah konten pada jam-jam tidak wajar seperti jam malam

ataudini hari, secara konsisten menunjukkan korelasi dengan tingkat kecemasan yang lebih tinggi [11]. Namun, integrasi antara fitur tekstual dan fitur perilaku temporal ini masih jarang dilakukan dalam model klasifikasi *hybrid*.

Tantangan lain dalam klasifikasi data kesehatan mental adalah ketidakseimbangan kelas (*imbalanced data*), di mana jumlah unggahan yang menunjukkan indikasi kecemasan jauh lebih sedikit dibandingkan unggahan netral [12]. Hal ini dapat menyebabkan model cenderung bias terhadap kelas mayoritas dan menurunkan nilai *Recall* pada kelas minoritas yang justru lebih krusial untuk dideteksi [13]. Teknik *Synthetic Minority Oversampling Technique* (SMOTE) telah terbukti efektif dalam mengatasi masalah ini dengan menciptakan sampel sintetis pada kelas minoritas, sehingga meningkatkan sensitivitas model klasifikasi [12], [14].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk membangun model klasifikasi *hybrid* yang menggabungkan fitur tekstual berbasis TF-IDF (*Term Frequency-Inverse Document Frequency*) dan fitur temporal berbasis metadata *timestamp*. Eksperimen dilakukan dengan memanfaatkan dataset sekunder publik yang telah terkurasi, sehingga penelitian berfokus pada pengembangan model komputasi dan bukan pada proses akuisisi data primer melalui pengumpulan langsung (*scraping*) di platform X. Penggunaan algoritma *Random Forest* yang dioptimalkan dengan SMOTE diharapkan dapat memberikan hasil skrining dini yang akurat dan tervalidasi secara klinis melalui kaitan indikator dengan instrumen DASS-21.


Tujuan utama dari penelitian ini adalah untuk membangun sebuah model klasifikasi *hybrid* yang mampu mengidentifikasi tingkat kecemasan dengan mengintegrasikan fitur tekstual dan fitur karakteristik perilaku digital, khususnya pola waktu pengunggahan konten (*temporal features*). Melalui pendekatan ini, penelitian bertujuan untuk menganalisis kontribusi fitur perilaku, seperti kecenderungan aktivitas pada jam malam yang merepresentasikan gejala insomnia, dalam meningkatkan performa deteksi dibandingkan dengan model konvensional yang

hanya berbasis teks [6], [15]. Selain itu, optimalisasi model dilakukan melalui implementasi teknik *Synthetic Minority Oversampling Technique* (SMOTE) guna mengatasi tantangan ketidakseimbangan data yang sering ditemukan pada dataset kesehatan mental di media sosial [12], [14]. Hasil akhir dari riset ini diharapkan dapat menyediakan standar analisis prediktif yang tervalidasi dengan indikator klinis instrumen DASS-21 sebagai alat skrining dini bagi kelompok usia transisi [8].

Untuk menjaga fokus dan kedalaman analisis, penelitian ini dilaksanakan dengan beberapa batasan teknis dan substansial. Data yang diolah sepenuhnya bersumber dari dataset sekunder publik (*Mental Health Corpus*) yang diperoleh melalui repositori data terbuka yang mencakup penggunaan bahasa gaul (*slang*) dan singkatan kontekstual remaja [4], [16]. Fokus subjek penelitian dibatasi pada pengguna dalam rentang usia transisi (16-25 tahun) yang diidentifikasi melalui ekstraksi kata kunci spesifik seperti "maba", "skripsi", atau "kuliah" guna menangkap fenomena stres akademik [6], [13]. Secara metodologis, eksperimen dijalankan menggunakan algoritma *Random Forest* dan teknik penyeimbangan data SMOTE di lingkungan *cloud computing* Google Colab. Luaran dari penelitian ini difokuskan pada laporan analisis performa model (seperti akurasi, F1-score, dan *feature importance*) dan tidak menghasilkan aplikasi mandiri (*prototype*). Klasifikasi yang dihasilkan hanya bersifat sebagai indikator awal atau alat skrining dan tidak ditujukan untuk menggantikan diagnosis klinis resmi dari tenaga medis profesional seperti psikolog atau psikiater.

2. METODE

Bagian ini menguraikan secara sistematis mengenai desain eksperimen, arsitektur model *hybrid*, karakteristik dataset, serta prosedur validasi yang diterapkan dalam penelitian ini. Fokus utama metodologi ini adalah pada integrasi analisis linguistik berbasis teks dan analisis perilaku berbasis pola temporal untuk mendeteksi indikasi kecemasan pada kelompok usia transisi. Seluruh tahapan penelitian dijalankan secara komprehensif mengikuti diagram alir yang digambarkan pada Gambar 1.



Gambar 1. Alur Penelitian


Proses diawali dengan penyiapan lingkungan komputasi di Google Colab dan pengumpulan data sekunder yang diunduh melalui repositori Kaggle (*Mental Health Corpus*), diikuti dengan tahap pra-pemrosesan teks yang intensif guna menangani

karakteristik bahasa nonformal [6], [16]. Tahapan krusial berikutnya adalah ekstraksi fitur *hybrid* yang menggabungkan pembobotan TF-IDF ekstraksi fitur temporal biner (*is_night*) berdasarkan metadata *timestamp* pengunggahan [11], [2]. Untuk

mengatasi ketidakseimbangan kelas yang umum ditemukan pada data kesehatan mental, dataset dibagi menjadi data latih dan data uji, kemudian teknik *Synthetic Minority Over-sampling Technique* (SMOTE) diterapkan pada data latih sebelum tahap klasifikasi menggunakan algoritma *Random Forest* [15], [14]. Rangkaian eksperimen diakhiri dengan evaluasi performa model dan analisis korelasi fitur terhadap indikator klinis DASS-21 melalui interpretasi nilai *feature importance*.

2.1. Arsitektur Model

Arsitektur model yang diusulkan dalam penelitian ini menerapkan pendekatan ensemble learning melalui algoritma *Random Forest* dengan skema masukan *hybrid*. Struktur model terdiri dari tiga lapisan utama: *Input Layer* (Vektor fitur hybrid), *Processing Layer* (Ensemble Trees), dan *Output Layer* (Prediksi Kelas), sebagaimana diilustrasikan pada Gambar 2.



Gambar 2. Arsitektur Model

Model ini didesain secara *hybrid* untuk menangani heterogenitas data media sosial. Fitur tekstual hasil pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF) merepresentasikan konten emosional pengguna, sementara fitur perilaku temporal hasil ekstraksi metadata waktu memberikan konteks perilaku digital. Integrasi kedua fitur ini (X_{hybrid}) dirumuskan pada persamaan (1):

$$X_{hybr} = w_{tf}, w_{tfidf2}, \dots, w_{tfidfN}, f_{is_night} \quad (1)$$

Di mana w_{tfidf} adalah bobot kata dan f_{is_night} adalah variabel biner perilaku. Penggabungan ini bertujuan untuk meningkatkan sensitivitas model terhadap pola perilaku digital (seperti gejala insomnia) yang secara klinis sering menyertai ekspresi kecemasan di media sosial [1], [17]. Untuk memberikan gambaran operasional mengenai bagaimana arsitektur model ini bekerja, Tabel 1 menyajikan rincian komponen masukan dan mekanisme pengolahan pada arsitektur yang diusulkan.

Tabel 1. Komponen Arsitektur Model *Hybrid*

Komponen Arsitektur	Deskripsi Teknis	Tujuan
Input Content (X1)	Vektor TF-IDF (dimensi n-kata)	Mengekstraksi fitur linguistik dan tanda emosional dalam teks.
Input Behavior (X2)	Fitur Temporal (is_night)	Mengidentifikasi indikator insomnia berdasarkan jam posting (00:00-04:00).
Feature Fusion	Early Fusion (Concatenation)	Menggabungkan fitur teks dan waktu menjadi satu ruang fitur terpadu.

Ensemble Engine	Random Forest (n-trees)	Melakukan klasifikasi melalui agregasi keputusan dari berbagai sub-pohon.
Decision Logic	Majority Voting	Menentukan prediksi akhir kelas 'Cemas' atau 'Netral'.

Algoritma *Random Forest* dalam model *hybrid* ini bekerja melalui tahapan *Bootstrap Aggregating* (Bagging). Algoritma akan membentuk N buah *decision tree* independen, di mana setiap pohon dilatih menggunakan sub-sampel acak dari vektor fitur hybrid (X_{hyb}) yang telah dihasilkan. Pada setiap titik percabangan (node) dalam *decision tree*, algoritma mengevaluasi fitur teks (TF-IDF) dan fitur temporal (f_{is_night}) menggunakan metrik *Gini Impurity* untuk menentukan pemisahan (split) data yang paling optimal. Nilai *Gini Impurity* dihitung menggunakan persamaan (2):

$$Gini(p) = 1 - \sum_{i=1}^c (p_i)^2 \quad (2)$$

Di mana c adalah jumlah kelas (2 kelas: Cemas dan Netral) dan p_i adalah probabilitas kemunculan kelas i pada node tersebut. Pohon akan terus bercabang hingga mencapai *leaf node* murni atau batas kedalaman maksimum terpenuhi.

Setelah seluruh N pohon terbentuk, tahap klasifikasi akhir dilakukan menggunakan mekanisme *Majority Voting*. Jika $h_k(x)$ adalah prediksi dari *decision tree* ke- k , maka prediksi final $\hat{y}$ untuk sampel pengguna didefinisikan pada persamaan (3):

$$\hat{y} = \underset{y \in \{0,1\}}{\operatorname{argmax}} \sum_{k=1}^N I(h_k(x) = y) \quad (3)$$

Mekanisme ini memastikan bahwa fitur temporal yang mendeteksi indikasi insomnia (f_{is_night}) akan diagregasi secara terukur bersama fitur tekstual dominan, sehingga mereduksi varians dan mencegah terjadinya overfitting pada klasifikasi teks media sosial yang bising (*noisy*).

2.2. Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset sekunder publik bertajuk *Mental Health Corpus* yang bersumber dari repositori Kaggle. Data primer yang diolah tersimpan dalam file *tweet_train.xlsx* yang mencakup riwayat unggahan pengguna platform X beserta metadata waktu pengunggahan (*timestamp*). Dataset ini dipilih karena memiliki cakupan label yang luas terkait kondisi kesehatan mental emosional di media sosial.

Untuk menjaga relevansi dengan tujuan penelitian, yaitu deteksi kecemasan pada kelompok usia transisi, dilakukan prosedur pemfilteran data secara spesifik. Dataset difilter untuk menangkap fenomena stres akademik yang dialami oleh individu dalam rentang usia 16 hingga 25 tahun. Proses identifikasi subjek dilakukan melalui ekstraksi kata kunci yang mencerminkan beban kognitif dan tekanan sosial mahasiswa, seperti "maba", "skripsi", "kuliah", "tugas", dan "IPK" [18], [5].

Statistik distribusi kelas dalam dataset sebelum dilakukan proses penyeimbangan data (oversampling) disajikan pada Tabel 2.

Tabel 2. Distribusi Kelas pada Dataset Awal

Label	Deskripsi Indikator	Jumlah Unggahan	Persentase
Cemas (1)	Mencakup indikasi gangguan perilaku, kecemasan, dan kegagalan penyesuaian sosial.	2.148	53,7%
Netral (0)	Unggahan bersifat umum atau non-antisosial.	1.852	46,3%
Total		4.000	100%

Data ini kemudian diproses lebih lanjut menggunakan fitur temporal yang diekstraksi dari kolom *created_at* (*timestamp*) untuk mengidentifikasi pola perilaku digital pengguna pada jam-jam kritis. Penggunaan dataset ini memungkinkan penelitian untuk memiliki landasan data yang besar guna menjamin stabilitas model *Random Forest* yang dikembangkan.

2.3. Lingkungan Pengembangan

Eksperimen dalam penelitian ini dijalankan pada lingkungan *cloud computing* menggunakan platform Google Colab. Infrastruktur ini dipilih karena kemampuannya dalam menyediakan sumber daya komputasi yang stabil serta kemudahan integrasi dengan ekosistem Google lainnya. Proses pengembangan dilakukan menggunakan bahasa pemrograman Python 3.10. Untuk menjaga persistensi data dan efisiensi akses terhadap dataset berukuran besar, dilakukan prosedur mounting pada Google Drive yang terhubung langsung ke direktori kerja penelitian.

2.4. Preprocessing dan Anotasi Data

Data tekstual yang bersumber dari platform X memiliki karakteristik *noise* yang signifikan, ditandai dengan penggunaan bahasa non-formal, simbol, dan struktur sintaksis yang tidak baku. Tahapan pra-pemrosesan diimplementasikan melalui urutan prosedur sebagai berikut: urutan data secara sistematis menggunakan pustaka *Regular Expression (re)* dan *Pandas*.

Tahapan pra-pemrosesan diimplementasikan melalui urutan prosedur sebagai berikut:

- Text Cleansing:** Menghapus entitas yang tidak memiliki nilai semantik bagi model klasifikasi, mencakup *Uniform Resource Locator (URL)*, *username* (karakter @), *hashtag* (#), angka, serta redundansi tanda baca.
- Case Folding:** Mentransformasi seluruh karakter teks menjadi huruf kecil (*lowercase*) guna menyeragamkan representasi data dan mereduksi dimensionalitas fitur yang diakibatkan oleh variasi kapitalisasi.
- Slang Normalization:** Mengonversi kosakata non-standar dan singkatan (seperti "maba", "skripsweet", "ga", "kn") ke dalam bentuk leksikal standar bahasa Indonesia. Hal ini krusial untuk menjaga konsistensi semantik pada saat proses vektorisasi fitur tekstual dilakukan [16].
- Stopword Removal:** Menghilangkan kata-kata fungsional dengan frekuensi kemunculan tinggi namun

memiliki bobot informasi rendah terhadap deteksi kondisi emosional (seperti "yang", "di", "ke", "dan").

Setelah proses normalisasi teks, dilakukan tahap Anotasi Data untuk memvalidasi validitas label pada dataset. Dataset *Mental Health Corpus* memiliki struktur pelabelan awal yang kemudian dikonversi menjadi kategori biner untuk memenuhi kebutuhan arsitektur klasifikasi yang diusulkan. Proses anotasi dan pemetaan ulang (*mapping*) ini merujuk pada indikator klinis yang tercantum dalam instrumen *Depression Anxiety Stress Scales (DASS-21)*, di mana variabel perilaku digital dipetakan untuk mengidentifikasi gejala kecemasan [1, 8].

Berdasarkan struktur kolom *idClass* pada file *tweet_train.xlsx*, kategori diklasifikasikan sebagai berikut:

- Kelas 1 (Cemas): Merepresentasikan unggahan yang mengindikasikan gangguan perilaku, kegelisahan otonom, dan hambatan adaptasi sosial yang relevan dengan simptom kecemasan menurut skala DASS-21 [4, 6].
- Kelas 0 (Netral): Merepresentasikan kategori *Non-Antisocial* atau umum yang tidak menunjukkan deviasi perilaku maupun indikasi gangguan kesehatan mental secara klinis.

Hasil dari tahap ini merupakan *clean dataset* yang menjadi basis input bagi proses rekayasa fitur hybrid pada tahapan eksperimen selanjutnya.

2.4.1. Rekayasa Fitur Hybrid

Tahap rekayasa fitur bertujuan untuk mentransformasi data yang telah diproses menjadi representasi numerik yang dapat diinterpretasikan oleh algoritma machine learning. Penelitian ini mengusulkan skema hybrid feature engineering yang menggabungkan dimensi konten tekstual dengan dimensi perilaku temporal guna menangkap indikasi kecemasan secara lebih komprehensif [19]. Proses pembentukan fitur *hybrid* dilakukan melalui dua jalur ekstraksi utama:

- Ekstraksi Fitur Tekstual (X_1): Menggunakan metode pembobotan TF-IDF. Teknik ini dipilih untuk mengukur signifikansi suatu kata terhadap dokumen dalam korpus, sehingga kata-kata kunci yang merepresentasikan gangguan emosional dapat diberikan bobot yang lebih tinggi dibandingkan kata umum lainnya [20].
- Ekstraksi Fitur Temporal (X_2): Mengekstraksi metadata *timestamp* dari kolom *created_at* pada dataset untuk membentuk fitur biner *is_night*. Fitur ini memberikan nilai '1' jika waktu pengunggahan berada pada interval kritis (00:00 – 04:00 WIB) dan nilai '0' untuk waktu di luar interval tersebut. Pendekatan ini didasarkan pada temuan bahwa pola aktivitas media sosial di malam hari sering kali berkaitan dengan gangguan tidur atau insomnia, yang merupakan salah satu indikator fisik dalam gangguan kesehatan mental [21].

Kedua fitur tersebut kemudian digabungkan melalui mekanisme *feature fusion* menjadi satu vektor fitur tunggal (X_{hy}). Integrasi ini memungkinkan model untuk tidak hanya menganalisis apa yang diungkapkan oleh pengguna (aspek linguistik), tetapi juga bagaimana pola waktu pengungkapannya (aspek perilaku) [22]. Strategi penggabungan fitur ini diharapkan dapat meminimalisir *false positives* pada proses klasifikasi

dengan memberikan konteks tambahan bagi algoritma *Random Forest* dalam mengenali pola risiko kecemasan pada mahasiswa [20].


2.4.2. Penanganan Class Imbalance (SMOTE)

Dataset ini memiliki tantangan berupa ketidakseimbangan kelas (*class imbalance*) yang signifikan, di mana data kategori netral jauh lebih dominan dibandingkan kategori indikasi kecemasan. Ketidakseimbangan ini berisiko menyebabkan model mengalami bias dan mengabaikan karakteristik kelas minoritas yang krusial untuk dideteksi [23].

Untuk mengatasinya, diterapkan teknik *Synthetic Minority Over-sampling Technique* (SMOTE). Berbeda dengan *random oversampling* biasa yang sekadar menduplikasi data, SMOTE bekerja dengan cara menyintesis sampel baru pada kelas minoritas (Cemas) melalui interpolasi linear ruang fitur [12]. Kedua, sampel buatan baru (x_{new}) dikalkulasi dengan memilih tetangga acak x_{zi} dan menskalakan selisih jaraknya menggunakan faktor acak λ antara 0 dan 1, sebagaimana ditunjukkan pada persamaan (4):

$$x_{new} = x_i + \lambda \times (x_{zi} - x_i) \quad (4)$$

Prosedur penyeimbangan ini dijalankan secara eksklusif pada *training set* guna mencegah terjadinya fenomena kebocoran data (*data leakage*). Implementasi SMOTE ini secara signifikan menggeser *decision boundary* dari algoritma *Random Forest* untuk lebih sensitif terhadap kelas minoritas, sehingga metrik *Recall* dalam mengenali pola risiko kesehatan mental implisit dapat dioptimalkan [23].



Gambar 3. Distribusi Kepadatan Waktu Posting

Berdasarkan Gambar 3, terlihat perbedaan densitas yang mencolok pada jam dini hari. Kelompok "Cemas/Risiko" memiliki kepadatan aktivitas yang jauh lebih tinggi pada pukul 00:00 hingga 04:00 WIB dibandingkan kelompok "Normal". Hal ini membuktikan secara visual adanya fenomena insomnia digital yang menjadi landasan penggunaan fitur *is_night*.

3.1.2. Analisis Postingan Jam Malam

Berdasarkan data aktivitas pada rentang waktu kritis tersebut, dilakukan kategorisasi perilaku untuk melihat muatan konten yang dihasilkan pengguna.

2.5. Metrik Evaluasi

Efikasi model klasifikasi diukur menggunakan parameter *Confusion Matrix* yang terdiri dari akurasi, *precision*, *F1-score*, dan *recall*. Dalam konteks skrining kesehatan mental, *Recall* ditetapkan sebagai metrik evaluasi utama guna meminimalisir probabilitas *false negative*, yaitu kegagalan sistem dalam mengidentifikasi individu yang sebenarnya memiliki risiko kecemasan [15, 20]. Pengukuran ini krusial untuk memastikan reliabilitas model sebagai instrumen deteksi dini [4].

Selain metrik performa klasifikasi, dilakukan analisis *Gini Importance* untuk mengevaluasi kontribusi relatif dari setiap variabel prediktor dalam algoritma *Random Forest* [10]. Hasil evaluasi ini kemudian disintesis untuk memberikan interpretasi mengenai keterkaitan antara aktivitas digital malam hari dengan indikasi klinis kecemasan sesuai dengan keputusan model [2, 18]. Hasil evaluasi ini kemudian disintesis untuk memberikan interpretasi mengenai keterkaitan antara aktivitas digital malam hari dengan indikasi klinis kecemasan sesuai dengan standar DASS-21 [1].


3. HASIL

3.1. Analisis Ekplorasi Data

Tahap pertama adalah melakukan analisis terhadap karakteristik dataset mentah untuk memvalidasi hipotesis awal mengenai fitur temporal.

3.1.1. Pola Aktivitas Digital

Analisis waktu posting dilakukan untuk membandingkan perilaku pengguna Normal dengan pengguna yang memiliki risiko kecemasan.



Gambar 4. Pola Waktu Posting

Hasil pada Gambar 4 menunjukkan bahwa mayoritas postingan bersifat umum (113 data). Namun, terdapat frekuensi yang cukup signifikan pada kategori perilaku iritabilitas dan agresivitas (21 data) serta ketidakmampuan menyesuaikan diri dengan norma (16 data). Data ini mengonfirmasi bahwa aktivitas malam hari tidak hanya soal kuantitas waktu, tetapi juga berkaitan dengan kualitas konten yang bersifat emosional.

3.2. Implementasi Fitur dan Pemodelan

Setelah pola temporal tervalidasi pada tahap EDA, data diproses melalui tahap rekayasa fitur hybrid dan penyeimbangan kelas.

Integrasi Fitur Hybrid


Data teks ditransformasi menggunakan TF-IDF dan dikonkatensikan dengan fitur biner *is_night*. Proses ini menghasilkan vektor fitur hybrid yang merepresentasikan dimensi konten (tekstual) dan dimensi perilaku (temporal).

3.2.1. SMOTE

Untuk mengatasi ketidakseimbangan kelas (Label 1: 2.148; Label 0: 1.852), teknik SMOTE diterapkan pada data latih. Hal ini bertujuan agar model *Random Forest* dapat mengenali karakteristik kedua kelas secara objektif tanpa terpengaruh oleh dominasi jumlah salah satu kelas.

3.3. Evaluasi Performa Model Hybrid

Model dievaluasi menggunakan *Confusion Matrix* untuk mengukur ketepatan prediksi pada data uji.



Gambar 5. *Confusion Matrix*: Deteksi Kecemasan

Berdasarkan Gambar 5, model mencapai tingkat Akurasi sebesar 76.83%. Rincian metrik evaluasi disajikan pada Tabel 3.


Tabel 3. Laporan Klasifikasi Model *Hybrid*.

Kelas	Precision	Recall	F1-Score	Support
0.0 (Netral)	0.8	0.85	0.83	159
1.0 (Cemas)	0.69	0.62	0.65	87
Rata-rata (Weighted)	0.76	0.77	0.77	246

Model menunjukkan stabilitas yang baik dengan akurasi 76.83%. Nilai *Precision* kelas cemas sebesar 0.69 menunjukkan kemampuan model dalam meminimalisir kesalahan deteksi pada data yang bersifat kompleks.

3.4. Fitur Importance

Tahap akhir adalah mengukur kontribusi masing-masing fitur terhadap keputusan klasifikasi model menggunakan metode *Gini Importance*.



Gambar 6. 10 Fitur Paling Berpengaruh dalam Deteksi Cemas

Berdasarkan Gambar 6, ditemukan bahwa fitur tekstual seperti kata "bodo", "suka", dan "bikin" menjadi prediktor utama. Terkait fitur temporal, hasil log program menunjukkan bahwa: Fitur Temporal memberikan kontribusi, namun kata-kata tertentu masih lebih dominan.

Meskipun fitur tekstual mendominasi, kehadiran *is_night* dalam proses pelatihan memberikan dimensi tambahan bagi model untuk membedakan konteks emosional yang muncul di waktu-waktu yang tidak lazim.

4. PEMBAHASAN

Bab ini membahas implikasi dari temuan eksperimen, menginterpretasikan makna di balik fitur-fitur dominan, dan menganalisis efektivitas pendekatan hybrid dalam konteks deteksi dini gangguan kecemasan pada media sosial.

4.1. Efektifitas Arsitektur Hybrid

Penelitian ini mengusulkan penggabungan fitur tekstual (TF-IDF) dan fitur temporal (*is_night*) untuk melatih model *Random Forest*. Hasil pengujian menunjukkan model mampu mencapai akurasi sebesar 76.83%. Dalam konteks pemrosesan bahasa alami (NLP) pada media sosial, angka ini merupakan capaian yang kompetitif mengingat karakteristik teks media sosial yang sangat *noisy*, implisit, dan tidak terstruktur.

Meskipun model menunjukkan performa yang sangat baik dalam mengenali kelas netral (*Recall* 0.85), terdapat tantangan pada deteksi kelas cemas (*Recall* 0.62). Hal ini mengindikasikan fenomena *covert anxiety* (kecemasan tersembunyi), di mana sebagian pengguna yang mengalami tekanan psikologis cenderung menyamarkan keluhannya menggunakan bahasa keseharian atau sarkasme, sehingga batas (*decision boundary*) antara teks netral dan cemas menjadi bias jika hanya dilihat dari susunan katanya saja. Di sinilah peran fitur temporal masuk sebagai konteks tambahan.

4.2. Implementasi Fitur Temporal

Salah satu temuan paling signifikan dalam penelitian ini adalah tervalidasinya hipotesis mengenai aktivitas malam hari. Berdasarkan analisis *Kernel Density Estimate* (Gambar 3), kelompok berisiko kecemasan memiliki lonjakan aktivitas digital pada rentang pukul 00:00 hingga 04:00 WIB.

Secara klinis, pola ini beririsan langsung dengan indikator DASS-21, di mana gangguan tidur (*insomnia*) merupakan salah satu

manifestasi somatik dari kecemasan (*anxiety*) dan stres berlebih. Individu yang mengalami *overthinking* atau *hyperarousal* (kewaspadaan berlebih) di malam hari cenderung mengalihkan kecemasannya melalui media sosial.

Lebih lanjut, analisis kategori perilaku (Gambar 4) pada jam malam menunjukkan munculnya aktivitas Iritabilitas dan Agresivitas serta Ketidakmampuan menyesuaikan diri dengan norma. Kondisi ini dapat dijelaskan melalui konsep *ego depletion* (penurunan energi mental).

4.3. Analisis Fitur Tekstual

Berdasarkan analisis *Feature Importance* (Gambar 6), model mengandalkan kata-kata spesifik untuk melakukan klasifikasi. Temuan ini memberikan wawasan psikologis yang menarik.

- Proyeksi Emosi Negatif ("brensek", "bikin"): Munculnya kata umpatan atau keluhan reaktif menempati bobot tinggi. Ini sejalan dengan temuan pada jam malam (iritabilitas). Pengguna dengan tingkat kecemasan tinggi cenderung lebih sensitif terhadap stimulus eksternal dan mengekspresikan rasa frustrasinya secara agresif di ruang digital.
- Sikap Apatis sebagai Defense Mechanism ("bodo"): Kata "bodo" (bodo amat/tidak peduli) muncul sebagai fitur paling berpengaruh. Dalam psikologi klinis, sikap apatis atau emotional blunting sering kali bukan berarti benar-benar tidak peduli, melainkan sebuah mekanisme koping (*defense mechanism*) untuk melindungi diri dari tekanan mental atau ekspektasi yang memicu kecemasan (misalnya stres akademik atau ekspektasi sosial).

4.4. Keunggulan dan Keterbatasan

Integrasi fitur *is_night* ke dalam 10 fitur teratas membuktikan bahwa arsitektur *hybrid* berhasil memberikan konteks yang tidak bisa ditangkap oleh TF-IDF saja. Teks "bodo amat" yang diunggah pada pukul 12 siang mungkin hanya sekadar gurauan, namun teks yang sama jika diunggah pada pukul 03:00 pagi memiliki probabilitas tinggi sebagai ekspresi keputusan atau *anxiety attack*.

Untuk menguji efikasi dan kontribusi keilmuan dari arsitektur *hybrid* yang diusulkan, hasil pengujian pada penelitian ini disandingkan dengan beberapa penelitian terdahulu yang berfokus pada deteksi kesehatan mental berbasis media sosial. Perbandingan performa dan pendekatan metodologi disajikan pada Tabel 4.

Berdasarkan hasil komparasi pada Tabel 4, model *hybrid* yang menggabungkan fitur tekstual dan fitur temporal biner *is_night* berhasil mengungguli performa penelitian-penelitian terdahulu yang hanya mengandalkan satu modalitas data. Penelitian Darmawan dkk. dan Siswandi & Susilo yang memanfaatkan algoritma pembacaan teks konvensional menghasilkan akurasi masing-masing sebesar 73,40% dan 75,20% [3, 6]. Capaian penelitian ini sebesar 76,83% membuktikan secara empiris bahwa penambahan parameter perilaku *is_night* (waktu pengunggahan pukul 00:00–04:00 WIB) mampu memberikan penguatan konteks psikologis yang signifikan, melengkapi keterbatasan analisis linguistik yang sering kali terkendala oleh sarkasme atau bahasa implisit penggunaannya.

Tabel 4. Perbandingan Hasil Eksperimental dengan Penelitian Terdahulu.

Studi & Metode	Detail Fitur & Performa
Darmawan dkk. (2023) [3] <i>Support Vector Machine</i> , Tanpa SMOTE	Tekstual TF-IDF (Twitter) Akurasi: 73,40%
Rahayu dkk. (2023) [4] Naive Bayes & RF, <i>Random Oversampling</i>	Tekstual Word2Vec (Depresi) Akurasi: 74,50%
Siswandi & Susilo (2026) [6] <i>Random Forest</i> , Tanpa SMOTE	Tekstual TF-IDF (Platform X) Akurasi: 75,20%
Maldini dkk. (2025) [15] <i>Stacking Ensemble</i> , SMOTE	Sentimen Tekstual (Multimodel) Akurasi: 76,10%
Penelitian saat ini <i>Random Forest</i> , SMOTE	Hybrid (TF-IDF + <i>is_night</i>) Akurasi: 76,83% (<i>Recall</i> Netral: 0,85)

Kebaharuan utama dari penelitian ini terletak pada integrasi dua modalitas fitur yang saling melengkapi (*hybrid features*), yaitu ekstraksi fitur tekstual (TF-IDF) dan indikator perilaku digital temporal (*f_{is_night}*), yang diformulasikan khusus untuk mendeteksi gangguan kecemasan pada pengguna media sosial berbahasa Indonesia. Berbeda dengan penelitian terdahulu yang mayoritas berfokus tunggal pada pembacaan konten teks (LSA, Word2Vec, atau TF-IDF semata), penelitian ini membuktikan secara eksplisit bahwa variabel waktu pengunggahan pada rentang jam biologis kritis (00:00–04:00 WIB) berfungsi sebagai *anchor point* kontekstual yang signifikan. Integrasi fitur temporal biner ini terbukti secara empiris meningkatkan sensitivitas model klasifikasi Random Forest dan menggeser *decision boundary* secara efektif setelah dikombinasikan dengan teknik SMOTE, sehingga mampu menghasilkan akurasi sebesar 76,83% yang melampaui pendekatan berbasis teks tunggal.

5. KESIMPULAN

Berdasarkan hasil eksperimen dan pembahasan yang telah dilakukan, penelitian ini menyimpulkan bahwa integrasi fitur tekstual dan fitur temporal terbukti efektif dalam mendeteksi indikasi kecemasan pada pengguna platform X. Kebaharuan utama penelitian ini terletak pada pemanfaatan variabel temporal *is_night* sebagai penanda perilaku digital malam hari yang berhasil melengkapi keterbatasan analisis linguistik tunggal. Arsitektur *hybrid* menggunakan algoritma Random Forest yang dikombinasikan dengan teknik penyeimbangan SMOTE berhasil mencapai tingkat akurasi sebesar 76.83%.

Temuan kunci dalam penelitian ini menunjukkan bahwa variabel temporal *is_night* (aktivitas pengunggahan pukul 00:00–04:00 WIB) merupakan prediktor yang valid dan signifikan secara statistik. Meskipun fitur tekstual (seperti kata-kata "bodo", "brensek", dan "bikin") masih menjadi prediktor dominan, kehadiran fitur temporal memberikan dimensi kontekstual tambahan yang memperkuat interpretasi perilaku pengguna. Model ini memiliki performa yang sangat stabil dalam mengenali kelompok netral (*Recall* 0.85), namun masih menghadapi tantangan dalam mendeteksi ekspresi kecemasan yang bersifat implisit (*covert anxiety*).

Untuk pengembangan penelitian di masa mendatang, terdapat beberapa saran yang dapat dipertimbangkan ekstraksi semantik yang lebih dalam. Mengingat adanya keterbatasan fitur TF-IDF dalam menangkap konteks kalimat yang sarkas atau implisit, penggunaan metode Deep Learning seperti BERT disarankan untuk menangkap makna semantik yang lebih kompleks. Dsamping itu penambahan fitur metadata seperti selain waktu posting, fitur lain seperti frekuensi interaksi, jumlah reposts, dan analisis sentimen terhadap komentar balasan dapat diintegrasikan untuk memperkaya profil perilaku pengguna serta variasi dataset. Penelitian selanjutnya dapat memperluas cakupan dataset tidak hanya terbatas pada satu korpus, guna menguji konsistensi fitur `is_night` pada kelompok demografis yang berbeda (misalnya pekerja shift malam vs mahasiswa).

DAFTAR PUSTAKA

- [1] W. Febriani, S. Eka Prastya, B. Sabella, and F. Dona Marleny, "Analysis of the Impact of Violent Content on Social Media on Adolescent Cyberpsychology Using Support Vector Machine and Random Forest," 2026. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [2] A. A. Sari and H. Permatasari, "Seminar Nasional Amikom Surakarta (Semnasa) 2025 Prediksi Risiko Kesehatan Mental Berdasarkan Pola Penggunaan Perangkat Digital Menggunakan Algoritma Logistic Regression".
- [3] F. Darmawan, M. Joe, Y. I. Kurniawan, and L. Afuan, "Analisis Sentimen Kemungkinan Depresi dan Kecemasan pada Twitter Menggunakan Support Vector Machine," *Jurnal Eksplorasi Informatika*, vol. 13, no. 1, pp. 24–36, Sep. 2023, doi: [10.30864/eksplorasi.v13i1.854](https://doi.org/10.30864/eksplorasi.v13i1.854).
- [4] K. Rahayu, V. Fitria, D. Septhya, R. Rahmadden, and L. Efrizoni, "Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, pp. 108–114, Sep. 2023, doi: [10.57152/malcom.v3i2.780](https://doi.org/10.57152/malcom.v3i2.780).
- [5] C. H. Shwetha and K. Pushpalatha, "A Deep Learning Framework for Depression and Major Depressive Disorder Detection from Social Media Text Using MentalBERT and Multilayer Perceptron," *International Journal of Intelligent Engineering and Systems*, vol. 18, no. 8, pp. 253–268, Sep. 2025, doi: [10.22266/ijies2025.0930.16](https://doi.org/10.22266/ijies2025.0930.16).
- [6] A. Siswandi and A. Susilo, "Bulletin Of Computer Science Research Identifikasi Indikasi Risiko Depresi pada Unggahan Media Sosial X Menggunakan Natural Language Processing dan Algoritma Random Forest," *Media Online*, vol. 6, no. 2, pp. 813–822, 2026, doi: [10.47065/bulletincsr.v6i2.1026](https://doi.org/10.47065/bulletincsr.v6i2.1026).
- [7] O. Ojo, I. Adewuyi, O. Oni, O. Oyinloye, I. Gbolade, and A. Ojo, "An Intelligent-Based System for Detecting Depression on Social Media Platform," May 24, 2023, doi: [10.21203/rs.3.rs-2931653/v1](https://doi.org/10.21203/rs.3.rs-2931653/v1).
- [8] M. J. Faisti, R. Hadapiningradja Kusumodestoni, G. Wahyu, and N. Wibowo, "Mental Health Classification Using Naïve Bayes and Random Forest Algorithms," 2025. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [9] N. P. E. Apriyanthi, C. M. Dhewanty, P. D. W. Ayu, I. M. R. A. Nugroho, and I. W. R. Wijaya, "Analisis Performa Komparatif Algoritma Machine Learning untuk Deteksi Fraud dalam Transaksi Blockchain," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 8, no. 1, pp. 8–15, Jan. 2026, doi: [10.47233/jteksis.v8i1.2285](https://doi.org/10.47233/jteksis.v8i1.2285).
- [10] L. Breiman, "Random Forests," 2001.
- [11] K. K. Putri and E. B. Setiawan, "Depression Detection in Indonesian X Social Media Text using Convolutional Neural Networks and Long Short-Term Memory with TF- IDF and FastText Methods," *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 2, pp. 557–574, Apr. 2025, doi: [10.52436/1.jutif.2025.6.2.4206](https://doi.org/10.52436/1.jutif.2025.6.2.4206).
- [12] V. Wijaya and N. Rachmat, "Penerapan SMOTE dan Regresi Logistik Pada Website Skrining Awal Kesehatan Mental Mahasiswa," *Jurnal Algoritme*, vol. 5, no. 2, pp. 121–130, Apr. 2025, doi: [10.35957/algoritme.v5i2.9046](https://doi.org/10.35957/algoritme.v5i2.9046).
- [13] I. D. Ishak, F. Tupamahu, and Y. Rahman, "Early Detection of Mental Health Risk Indicators in Children Using Machine Learning Based on Teacher Questionnaires in Islamic Early Childhood Education in Gorontalo.," *Al-Ulum*, vol. 24, no. 2, pp. 284–304, Dec. 2024, doi: [10.30603/au.v24i2.6439](https://doi.org/10.30603/au.v24i2.6439).
- [14] A. F. Anjani, D. Anggraeni, and I. M. Tirta, "Implementasi Random Forest Menggunakan SMOTE untuk Analisis Sentimen Ulasan Aplikasi Sister for Students UNEJ," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 9, no. 2, pp. 163–172, Sep. 2023, doi: [10.25077/teknosi.v9i2.2023.163-172](https://doi.org/10.25077/teknosi.v9i2.2023.163-172).
- [15] N. Maldini *et al.*, "Sistemasi: Jurnal Sistem Informasi Deteksi Dini Gangguan Kesehatan Mental berdasarkan Sentimen menggunakan Metode Stacking Early Detection of Mental Health Disorders based on Sentiment using Stacking Method," 2025. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [16] D. Suharjanto and S. Sumarsono, "Optimalisasi DoRA untuk Deteksi Ujaran Kebencian Berbahasa Indonesia Berbasis Transformer," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 11, no. 3, pp. 341–349, Jan. 2026, doi: [10.25077/teknosi.v11i3.2025.341-349](https://doi.org/10.25077/teknosi.v11i3.2025.341-349).
- [17] M. D. Purbolaksono, M. I. Tantowi, A. I. Hidayat, and Adiwijaya, "Perbandingan Support Vector Machine dan Modified Balanced Random Forest dalam Deteksi Pasien Penyakit Diabetes," *Jurnal RESTI*, vol. 5, no. 2, pp. 393–399, Apr. 2021, doi: [10.29207/resti.v5i2.3008](https://doi.org/10.29207/resti.v5i2.3008).
- [18] N. D. Kurniawan, P. R. Ferdian, and N. Hidayati, "Analisis Sentimen Algoritma Naïve Bayes, Support Vector Machine, dan Random Forest Pada Ulasan Aplikasi Ajaib," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 11, no. 1, pp. 87–97, May 2025, doi: [10.25077/teknosi.v11i1.2025.87-97](https://doi.org/10.25077/teknosi.v11i1.2025.87-97).
- [19] J. Angskun, S. Tipprasert, and T. Angskun, "Big data analytics on social networks for real-time depression detection," *J. Big Data*, vol. 9, no. 1, Dec. 2022, doi: [10.1186/s40537-022-00622-2](https://doi.org/10.1186/s40537-022-00622-2).

- [20] A. Murarka, B. Radhakrishnan, and S. Ravichandran, "Classification of mental illnesses on social media using RoBERTa," 2021. [Online]. Available: <https://afsp.org>
- [21] J. Robinson, M. Rodrigues, S. Fisher, E. Bailey, and H. Herrman, "Social media and suicide prevention: findings from a stakeholder survey," *Shanghai Arch. Psychiatry*, vol. 27, no. 1, pp. 27–35, 2015, doi: [10.11919/j.issn.1002-0829.214133](https://doi.org/10.11919/j.issn.1002-0829.214133).
- [22] F. B. Adi Nugroho, W. Ghazi, and F. Adi Rafrastara, "A Comparative Analysis of P-Value and Mutual Information Feature Selection Methods for Random Forest-Based Phishing Detection," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 11, no. 3, pp. 377–386, Jan. 2026, doi: [10.25077/teknosi.v11i3.2025.377-386](https://doi.org/10.25077/teknosi.v11i3.2025.377-386).
- [23] M. Arif, I. Ameer, N. Bölücü, G. Sidorov, A. Gelbukh, and V. Elangovan, "Mental Illness Classification on Social Media Texts Using Deep Learning and Transfer Learning," *Computacion y Sistemas*, vol. 28, no. 2, pp. 451–464, 2024, doi: [10.13053/CyS-28-2-4873](https://doi.org/10.13053/CyS-28-2-4873).

BIODATA PENULIS



Ni Putu Eka Apriyanthi

Staf pengajar pada Program Studi Manajemen Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Bali. Fokus penelitian ditekankan pada bidang *Human-Computer Interaction* (HCI), desain UI/UX, *Financial Technology* (Fintech), serta implementasi *Machine Learning* untuk analisis sistem. Pengembangan metodologi perancangan antarmuka yang berpusat pada pengguna dan optimasi efisiensi sistem informasi menjadi bagian utama dalam aktivitas akademik yang dilakukan.



I Gede Teguh Satya Dharma

Staf pengajar pada Program Studi Manajemen Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Bali. Peminatan riset difokuskan pada bidang *Digital Image Processing*, *Computer Vision*, dan pengembangan sistem cerdas berbasis *Artificial Intelligence*. Penelitian yang dilakukan mencakup optimasi algoritma untuk pengenalan pola serta penguatan keamanan sistem berbasis biometrik.



Civica Moeahimin Dhewanty

Staf pengajar pada Program Studi Manajemen Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Bali. Bidang keahlian dan peminatan riset meliputi analisis aspek teknologi media sosial, perilaku pengguna digital, serta mitigasi risiko keamanan siber (*cyberbullying*). Integrasi metode *Human-Centered Design* (HCD) dalam pengembangan purwarupa sistem informasi menjadi konsentrasi dalam berbagai publikasi ilmiah yang dihasilkan.