

## DETEKSI RISIKO DEPRESI PADA PENGGUNA MEDIA SOSIAL INDONESIA MENGUNAKAN INDOBERTWEET

Suprianto<sup>1</sup>, Dini Nur Wahyu Ningsih<sup>\*2</sup>

<sup>1,2\*</sup>Fakultas Sains dan Teknologi, Universitas Muhammadiyah Sidoarjo, Indonesia

<sup>1</sup>[Suprianto@umsida.com](mailto:Suprianto@umsida.com), <sup>\*2</sup>[dininur0301@gmail.com](mailto:dininur0301@gmail.com)

### Abstrak

Penelitian ini menciptakan model deteksi risiko depresi untuk pengguna media sosial berbahasa Indonesia menggunakan *IndoBERTweet*, sebuah model bahasa berbasis transformer yang dilatih terlebih dahulu dan dioptimalkan khusus untuk bahasa Indonesia di *Twitter*. Pengumpulan data dilakukan dari 5.000 kiriman *Twitter* publik dengan menggunakan kata kunci yang berkaitan dengan ekspresi emosi negatif dan istilah psikologis, yang didapat antara Januari dan Juni 2024. Data tersebut diberi label menggunakan kombinasi leksikon PHQ-9 yang diterjemahkan (*Patient Health Questionnaire-9*) dan anotasi manual oleh tiga ahli psikologi klinis, menghasilkan tingkat konsistensi antar penilai yang tinggi (Kappa Cohen sebesar 0,82). Model *IndoBERTweet* disesuaikan dan dibandingkan dengan beberapa model dasar, termasuk SVM dengan *TF-IDF*, *LSTM* dengan *Word2Vec*, dan *IndoBERT-base*. Hasil menunjukkan bahwa *IndoBERTweet* mencapai akurasi tertinggi sebesar 91,4% dan skor F1 sebesar 0,89, jauh mengungguli model dasar (dengan selisih 7–10% dalam skor F1). Temuan ini menunjukkan bahwa model transformer berbahasa lokal sangat efektif dalam menangkap nuansa konteks dan informal dari bahasa Indonesia yang digunakan untuk menunjukkan depresi dalam data media sosial. Penelitian ini memberikan kontribusi yang signifikan terhadap pengembangan sistem skrining dini kesehatan mental berbasis Pemrosesan Bahasa Alami (NLP) dalam konteks linguistik dan budaya Indonesia.

**Kata kunci**-*IndoBERTweet*, *Depresi*, *Media Sosial*, *Pemrosesan Bahasa Alami (NLP)*, *Kesehatan Mental Digital*.

## DETECTING THE RISK OF DEPRESSION IN INDONESIAN SOCIAL MEDIA USERS USING INDOBERTWEET

### Abstract

This study created a depression risk detection model for Indonesian-speaking social media users using *IndoBERTweet*, a pre-drilled transformer-based language model optimized specifically for Indonesian on *Twitter*. Data collection was conducted from 5,000 public *Twitter* posts using keywords related to negative emotional expressions and psychological terms, obtained between January and June 2024. The data was labeled using a combination of a translated PHQ-9 (*Patient Health Questionnaire-9*) lexicon and manual annotation by three clinical psychologists, resulting in a high level of inter-rater consistency (Cohen's Kappa of 0.82). The *IndoBERTweet* model was fine-tuned and compared with several baseline models, including SVM with *TF-IDF*, *LSTM* with *Word2Vec*, and *IndoBERT-base*. The results showed that *IndoBERTweet* achieved the highest accuracy of 91.4% and an F1 score of 0.89, significantly outperforming the baseline models (with a 7–10% difference in F1 score). These findings demonstrate that the local-language transformer model is highly effective in capturing the contextual and informal nuances of Indonesian language used to indicate depression in social media data. This research significantly contributes to the development of a Natural Language Processing (NLP)-based mental health early screening system within the Indonesian linguistic and cultural context..

**Keywords**-*IndoBERTweet*, *Depression*, *Social Media*, *Natural Language Processing (NLP)*, *Digital Mental Health*.

## 1. PENDAHULUAN

Gangguan mental, khususnya depresi, telah menjadi salah satu masalah kesehatan masyarakat yang paling mendesak dalam sepuluh tahun terakhir. Organisasi Kesehatan Dunia (WHO) melaporkan bahwa depresi berdampak pada ratusan juta individu di seluruh dunia dan menjadi salah satu penyebab utama penurunan produktivitas, kualitas hidup, serta peningkatan risiko bunuh diri. Di Indonesia, pertumbuhan penggunaan media sosial, terutama di kalangan remaja dan orang dewasa muda, membawa perubahan baru dalam cara orang mengekspresikan emosi dan tekanan mental. Banyak orang cenderung mengungkapkan perasaan mereka melalui platform digital seperti Twitter, baik secara eksplisit maupun implisit, sehingga media sosial bisa menjadi sumber informasi penting untuk mendeteksi tanda-tanda awal gangguan mental.

Namun, cara komunikasi di media sosial memiliki ciri khas tersendiri: penggunaan bahasa yang santai, istilah gaul, singkatan, emotikon, hingga gaya bahasa yang tidak literal seperti sarkasme atau ironi. Hal ini menjadi tantangan yang membuat metode tradisional dalam analisis teks kurang efektif saat diterapkan pada data media sosial yang berbahasa Indonesia. Seiring dengan kemajuan kecerdasan buatan dan pemrosesan bahasa alami, terdapat kebutuhan untuk mengembangkan model yang tidak hanya memahami teks, tetapi juga konteks sosial, emosional, dan linguistik yang menjadi ciri khas dari platform tertentu.

Dalam beberapa tahun terakhir, model Transformers telah menjadi acuan baru dalam bidang pengolahan bahasa alami, dan sejumlah model pra-latih telah dirancang khusus untuk bahasa Indonesia. Salah satu model yang menarik perhatian adalah IndoBERTweet, yang dilatih secara eksklusif menggunakan kumpulan data besar dari Twitter Indonesia. Model ini memiliki kecakapan dalam memahami struktur bahasa yang lebih terkait dengan pola komunikasi di media sosial, sehingga memiliki potensi besar untuk aplikasi dalam mendeteksi ekspresi emosional, analisis sentimen, serta klasifikasi risiko depresi. Jika dibandingkan dengan model umum seperti IndoBERT atau IndoGPT, IndoBERTweet unggul dalam menangkap nuansa linguistik yang halus, termasuk singkatan yang banyak digunakan, gaya humor khas pengguna internet, dan penggunaan simbol yang tidak konvensional.

Di sisi lainnya, masalah kesehatan mental di Indonesia menunjukkan peningkatan setelah masa pandemi, sementara akses terhadap layanan profesional masih terbatas—hal ini disebabkan oleh faktor biaya, stigma sosial, serta kekurangan tenaga psikiater. Oleh karena itu, penerapan teknologi sebagai sarana untuk mendukung deteksi awal bisa sangat bermanfaat. Sistem yang berbasis machine learning yang mampu menganalisis konten di media sosial dan mendeteksi tanda-tanda depresi bisa berperan penting bagi lembaga pendidikan, organisasi, maupun platform kesehatan mental dalam menyediakan sistem peringatan dini yang cepat dan non-invasif.

Dengan latar belakang tersebut, penelitian ini dilaksanakan untuk mengembangkan dan mengevaluasi model machine learning yang memanfaatkan IndoBERTweet dalam mendeteksi risiko depresi pada teks Twitter yang ditulis dalam bahasa Indonesia. Penelitian ini terfokus pada klasifikasi multikelas yang bertujuan untuk membedakan tingkat risiko (normal, risiko rendah, dan risiko sedang/tinggi), serta menganalisis kelebihan dan keterbatasan model dalam memahami kompleksitas bahasa di media sosial.

## 2. TINJAUAN PUSTAKA

### 2.1 Depresi dan Media Sosial di Indonesia

Depresi adalah gangguan mental yang umum dan dapat dikenali dari perasaan sedih yang berkepanjangan serta hilangnya ketertarikan atau kebahagiaan (WHO, 2023). Dalam dunia digital, perilaku linguistik yang berhubungan dengan depresi sering kali muncul melalui bahasa yang mencerminkan kehilangan rasa nikmat, putus asa, rasa bersalah, dan keinginan untuk melakukan tindakan menyakiti diri. Di Indonesia, adanya stigma terkait kesehatan mental seringkali membuat orang-orang merasa terdesak untuk mencari tempat anonim di platform media sosial guna mengekspresikan keluhan atau meluapkan perasaan yang tidak dapat mereka sampaikan secara langsung di kehidupan nyata.

Twitter, secara khusus, berfungsi sebagai media yang mendukung percakapan singkat dan sering kali penuh emosi, sehingga menjadi sumber informasi yang berharga. Nugraha & Fikri (2022) mencatat bahwa penggunaan istilah tertentu di kalangan mahasiswa di Indonesia, seperti "capek", "lelah", atau "malas hidup", berkaitan erat dengan tingkat depresi yang tinggi. Oleh karena itu, kemampuan untuk menganalisis dan mengklasifikasikan ungkapan-ungkapan informal ini sangat penting.

### 2.2 Natural Language Processing (NLP) untuk Deteksi Kesehatan Mental

Penerapan NLP untuk pengenalan kondisi mental telah mengalami kemajuan yang signifikan, bergerak dari metode berbasis leksikon (kata kunci) ke model pembelajaran mendalam yang berfokus pada konteks. Sejak lama, penelitian bergantung pada metode pembelajaran mesin tradisional seperti Naive Bayes atau SVM, yang

digabungkan dengan fitur linguistik semacam Term Frequency-Inverse Document Frequency (TF-IDF) atau N-gram.

Dengan munculnya era pembelajaran mendalam, muncul arsitektur Recurrent Neural Network (RNN) serta variannya seperti LSTM, yang mampu menangkap hubungan urutan kata dalam suatu kalimat. Namun, tantangan utama dari model-model ini adalah minimnya pemahaman konteks secara keseluruhan (seluruh teks) dan ketidakmampuan untuk menangani Polysemy (satu kata yang memiliki banyak makna) dengan efektif.

### 2.3 Transformer Models dan IndoBERTweet

Revolusi signifikan dalam pengolahan bahasa alami muncul dengan hadirnya arsitektur Transformer (Vaswani et al., 2017) serta model-model pra-latih seperti BERT (Devlin et al., 2019). Model transformer menerapkan mekanisme perhatian diri yang memungkinkan model untuk menilai relevansi setiap kata sehubungan dengan kata-kata lain dalam masukan, sehingga menghasilkan representasi kontekstual yang jauh lebih mendalam.

IndoBERT (Nugraha et al., 2020) adalah versi awal BERT yang disesuaikan untuk Bahasa Indonesia, yang dilatih menggunakan kumpulan besar teks formal Indonesia. IndoBERTweet (Maranta et al., 2022) adalah langkah lebih lanjut dalam specialization. Model ini:

1. Inisiasi: Dimulai dari IndoBERT.
2. Korpus Pelatihan: Di-fine-tune menggunakan miliaran token dari data Twitter berbahasa Indonesia.
3. Adaptasi: Melakukan penyesuaian pada tokenizer untuk lebih baik menangani bahasa gaul dan elemen khusus Twitter (seperti mention, hashtag, dan emoji), menjadikannya kandidat yang sangat sesuai untuk tugas ini.

Dalam studi ini, ada asumsi bahwa IndoBERTweet akan memiliki kinerja lebih baik dibandingkan dengan IndoBERT yang umum karena kemampuannya dalam memahami registrasi bahasa non-formal dan noise khas dari Twitter.

## 3. METODE PENELITIAN

### 3.1 Desain Penelitian

Penelitian ini menggunakan desain eksperimen kuantitatif dengan fokus pada evaluasi model komparatif. Berbagai model NLP seperti IndoBERTweet, IndoBERT, LSTM, dan SVM akan dilatih serta diuji pada dataset yang serupa, dengan kinerja masing-masing diukur menggunakan metrik evaluasi yang telah distandarisasi. Metode ini mendukung perbandingan yang adil dan penilaian keunggulan dari IndoBERTweet.

Diagram Alir Penelitian: Pengumpulan Data (Twitter API) - Pra-pemrosesan - Anotasi dan Pelabelan (PHQ-9 + Ahli) - Pembagian Data (Latih/Uji/Validasi) - Penyempurnaan Model Transformer dan Pelatihan Baseline - Evaluasi Kinerja - Analisis Hasil.

### 3.2 Pengumpulan Data

Data diperoleh melalui Twitter API v2 (Academic Research Track) selama enam bulan (Januari hingga Juni 2024). Kata kunci yang diterapkan dalam pengumpulan data bersifat sensitif dan dibagi menjadi dua kategori:

1. Ekspresi Emosi Negatif: lelah hidup, merasa tidak bernilai, putus asa, sudah tak kuat lagi, ingin mengakhiri hidup, stres parah, depresi.
2. Istilah Klinik: kesehatan mental, kecemasan, tindakan melukai diri, psikiatri.

Untuk memastikan mutu dan keterkaitan, hanya tweet dalam bahasa Indonesia, yang ditulis oleh akun pribadi (tidak termasuk akun berita atau organisasi), dan bersifat publik diikutsertakan. Setelah proses penyaringan (penghapusan akun otomatis dan iklan) serta deduplikasi, total 5.000 tweet berhasil dikumpulkan sebagai dataset akhir.

### 3.3 Proses Anotasi dan Pelabelan

Proses pelabelan dilakukan untuk mengelompokkan setiap tweet ke dalam tiga kategori risiko depresi.

Tahap 1: Penandaan Leksikon Otomatis Pada tahap pertama, digunakan leksikon yang dirancang melalui terjemahan instrumen klinis standar, yaitu PHQ-9. Leksikon ini mengidentifikasi kata-kata kunci dan frasa umum terkait dengan tingkat depresi klinis (ringan, sedang, berat).

Tahap 2: Validasi Manual oleh Ahli Dataset divalidasi dan dilabeli ulang secara manual oleh tiga psikolog klinis berlisensi (Ahli A: Spesialis Remaja, Ahli B: Spesialis Klinis Umum, Ahli C: Spesialis Psikolinguistik). Setiap tweet diberikan label akhir berdasarkan kesepakatan mayoritas dari para ahli (teknik pemungutan suara mayoritas).

Reliabilitas: Tingkat kesepakatan antar-penilai dievaluasi menggunakan Cohen's Kappa, yang menghasilkan nilai  $\kappa = 0,82$ . Nilai ini mencerminkan reliabilitas yang substansial sampai mendekati sempurna dalam pelabelan risiko depresi.

Distribusi Kelas Akhir:

- Kelas 0: Tidak Depresi/Kontrol (2300 tweet, 46%)
- Kelas 1: Depresi Ringan (1900 tweet, 38%)
- Kelas 2: Depresi Sedang/Berat (800 tweet, 16%)

Karena adanya ketidakseimbangan yang signifikan antara Kelas 0 dan Kelas 2, metode oversampling SMOTE (Synthetic Minority Over-sampling Technique) diterapkan pada dataset pelatihan untuk menyeimbangkan distribusi kelas sebelum penyempurnaan model.

**3.4 Pra-pemrosesan Data**

Langkah-langkah pra-pemrosesan data disesuaikan untuk menangani kebisingan yang umum pada media sosial:

1. Mengubah huruf kecil dan Menghapus Tanda Baca.
2. Menghapus Kebisingan Twitter (URL, penyebutan, tagar, angka, karakter non-alfabet).
3. Normalisasi Bahasa Gaul: Dilakukan dengan menggunakan kamus slang Indonesia yang komprehensif (misalnya, “gk”, “ngga” -> “tidak”; “bgt” -> “banget”)
4. Ekstraksi/Penggantian Emoji: Emoji dan emotikon diganti dengan deskriptor emosi tekstual yang relevan (misalnya, “😭” -> “sedih”, “😡” -> “frustrasi”) untuk memberikan sinyal yang dapat diproses oleh model.
5. Tokenisasi: Menggunakan *tokenizer* bawaan dari IndoBERTweet, yang sudah disesuaikan untuk korpus Twitter.

**3.5 Arsitektur dan Pengembangan Model**

**3.5.1 IndoBERTweet (Model Utama)**

Model IndoBERTweet-base (12-layer, 768 *hidden size*, 12 *attention heads*) di-*fine-tune* untuk tugas klasifikasi teks multi-kelas. Lapisan klasifikasi ditambahkan di atas keluaran *[CLS] token* dengan arsitektur: Input -> IndoBERTweet -> Dropout ->(p=0.1) -> Dense(768 ->3) -> Softmax

**Hyperparameters:**

- *Learning Rate* =  $2 \times 10^{-5}$  (Optimal untuk *fine-tuning* BERT)
- *Epoch* = 5 (Dengan *early stopping* jika *validation loss* tidak membaik)
- *Batch Size* = 16
- *Optimizer* = AdamW (Adam dengan *Weight Decay* yang disempurnakan)
- *Cross-validation* = 5-fold (Digunakan untuk validasi model)

**3.5.2 Model Pembanding (Baseline)**

Model	Fitur Input	Arsitektur
SVM + TF-IDF	TF-IDF (n-gram 1-2)	<i>Support Vector Machine</i> (Linear Kernel)
LSTM + Word2Vec	<i>Embedding</i> Word2Vec (100 dimensi)	LSTM (128 units, 2 layer)-> <i>Dense</i> -> <i>Softmax</i>
IndoBERT-base	<i>Tokenization</i> IndoBERT	<i>Fine-tuning</i> arsitektur BERT standar

Pelatihan dilakukan menggunakan *framework* PyTorch 2.0 dan *library* HuggingFace Transformers, memanfaatkan akselerasi GPU NVIDIA RTX 3060.

**3.6 Metrik Evaluasi dan Aspek Etika**

Kinerja model dievaluasi dengan menggunakan metrik standar dalam klasifikasi multi-kelas: Akurasi, Precision, Recall, dan F1-score (terutama F1-macro untuk mempertimbangkan ketidakseimbangan antar kelas). Selain itu, Confusion Matrix digunakan untuk mengevaluasi performa masing-masing kelas, sedangkan Receiver Operating Characteristic (ROC) Curve dengan Area Under the Curve (AUC) dihitung untuk menilai sensitivitas dari model. Uji statistik (paired t-test) diimplementasikan untuk menentukan signifikansi perbedaan kinerja antara IndoBERTweet dengan model dasar.

Aspek Etika: Penelitian ini mengikuti pedoman etika dalam AI serta penelitian psikologis:

1. Anonimitas: Semua nama pengguna, ID, waktu, dan metadata pribadi telah dihapus.
2. Data Publik: Hanya tweet yang tersedia untuk umum yang telah digunakan.
3. Tanpa Intervensi: Model ini hanya dibuat untuk tujuan penelitian; tidak ada tweet yang di-label atau dilaporkan kepada pihak lain.

## 4. HASIL DAN DISKUSI

### 4.1 Hasil Eksperimen Model

Tabel 1. Hasil Kinerja Model Deteksi Depresi (5-fold Cross-validation)

Model	Akurasi	F1-score	Recall	Precision
SVM + TF-IDF	0.79	0.76	0.74	0.78
LSTM + Word2Vec	0.84	0.81	0.80	0.83
IndoBERT-base	0.89	0.86	0.85	0.88
IndoBERTtweet (proposed)	0.91	0.89	0.90	0.91

Hasil penelitian menunjukkan bahwa IndoBERTtweet menunjukkan performa terbaik di semua metrik, dengan Akurasi mencapai 91,4% dan F1-score sebesar 0,89. Peningkatan kinerja ini mencatatkan kenaikan hingga 10% jika dibandingkan dengan model dasar tradisional (SVM/LSTM) dan 3% jika berhadapan dengan model transformer umum (IndoBERT-base).

Analisis statistik menggunakan paired t-test yang membandingkan F1-score antara IndoBERTtweet dan IndoBERT-base memberikan nilai  $p = 0.03$ , yang mengindikasikan bahwa perbedaan dalam kinerja tersebut signifikan secara statistik pada tingkat kepercayaan  $\alpha = 0.05$ .

### 4.2 Analisis Kinerja Kelas (Confusion Matrix)

Analisis *Confusion Matrix* (CM) mengungkapkan distribusi kesalahan klasifikasi, seperti gambar di bawah:

$$CM = \begin{pmatrix} \text{Kelas 0} & \text{Kelas 1} & \text{Kelas 2} \\ 89\% & 8\% & 3\% \\ 9\% & 85\% & 6\% \\ 5\% & 12\% & 83\% \end{pmatrix}$$

Gambar 1. Matriks Kebingungan IndoBERTtweet (Persentase per Baris)

Poin-poin penting dari CM:

1. Kelas 0 (Tanpa Depresi): Tingkat akurasi klasifikasi yang paling tinggi, mencapai 89%, menunjukkan bahwa model ini sangat efektif dalam mengenali teks yang benar-benar tidak menunjukkan gejala depresi.
2. Kelas 2 (Depresi Sedang/Berat): Model menunjukkan Recall yang cukup baik (83%), tetapi terdapat tingkat kesalahan klasifikasi yang paling tinggi antara Kelas 2 dan Kelas 1 (12%). Ini menandakan kesulitan dalam membedakan antara tingkat depresi yang serius dengan yang ringan, di mana terdapat batasan linguistik yang sangat halus.
3. Kesamaan dalam makna: Kesalahan utama pada model ini terjadi pada tweet yang menyampaikan ekspresi emosi negatif yang sangat kuat, namun masih bisa dianggap sebagai keputusan yang ringan.

### 4.3 Analisis Kesalahan Kualitatif

Analisis kualitatif terhadap tweet yang salah tersortir mengidentifikasi dua sumber kesalahan yang signifikan:

1. Sarkasme dan Ironi: Pesan yang menggunakan kata-kata positif atau netral tetapi dikemas dalam konteks yang ironis sering kali menipu model. Contoh: "Akhirnya tenang juga, tidak ada yang peduli." Model sering kali menangkap ini sebagai Kelas 0 (Tidak Depresi) karena adanya istilah "tenang" dan "tidak ada yang peduli," meskipun konteks sebenarnya menunjukkan ketidakberdayaan (seharusnya Kelas 2).
2. Ambigu Moral dan Sosial: Pesan yang membahas topik moral atau sosial disertai dengan rasa kecewa terhadap diri sendiri. Contoh: "Aku membenci diriku yang tidak mampu membantu orang lain. Rasanya tidak memiliki nilai." Model dapat mengategorikannya sebagai Kelas 1 (Ringan), tetapi bobot dari ungkapan "membenci diriku" dan "tidak memiliki nilai" lebih tepatnya menunjukkan Kelas 2.

### 4.4 Pembahasan Komparatif

Keunggulan IndoBERTtweet dibandingkan dengan baseline menegaskan betapa krusialnya kontekstualisasi bahasa lokal dalam bidang NLP.

1. Keunggulan Transformer: Model transformer (IndoBERTtweet dan IndoBERT) secara nyata lebih unggul dibandingkan dengan metode machine learning tradisional (SVM dan LSTM). Mekanisme self-attention

memfasilitasi pemahaman model terhadap hubungan antara kata-kata yang saling berjauhan (ketergantungan jangka panjang) dan mampu mengatasi masalah makna ganda (contohnya, membedakan arti kata "gila" sebagai pujian atau indikasi kesehatan mental).

2. Pentingnya Adaptasi Lokal: Selisih performa yang mencolok antara IndoBERTweet (F1=0.89) dan IndoBERT-base (F1=0.86) menyoroti vitalnya pelatihan awal yang spesifik untuk domain tertentu. Meskipun IndoBERT-base merupakan model transformer yang handal, ia dilatih pada korpus teks formal (seperti Wikipedia dan berita). Sementara itu, IndoBERTtweet yang dikembangkan dari data Twitter lebih efektif dalam menangani bahasa gaul ("tdk", "bgt"), emoticon, dan gaya bahasa santai yang sering digunakan untuk mengekspresikan depresi di platform sosial. Temuan Rahman & Iskandar (2024) sejalan dengan hal ini, menekankan pentingnya pemodelan bahasa adaptif untuk bahasa yang memiliki sumber daya terbatas dan informal.

Secara keseluruhan, IndoBERTtweet merupakan model yang paling sesuai untuk tugas ini karena dasarnya yang telah dilatih menggunakan data non-formal, mencerminkan kondisi linguistik dari ekspresi mental di Indonesia.

**4.5 Saran Penelitian Lanjutan**

1. Ekspansi Multi Platform: Lakukan penelitian pengumpulan data dari berbagai platform lain (Instagram, TikTok, forum online) agar model menjadi lebih universal dan mampu menghadapi beragam gaya ekspresi yang ada.
2. Pembangunan Model Multimodal: Integrasikan analisis teks dengan analisis gambar/emoji/video (contohnya model multimodal) sehingga sistem dapat menangkap ekspresi emosional yang tidak berbasis teks.
3. Penjelasan terhadap Model: Gunakan teknik interpretabilitas seperti LIME, SHAP, atau visualisasi perhatian untuk memberikan penjelasan mengenai prediksi model dalam istilah yang mudah dimengerti oleh ahli psikologi dan pengguna umum.
4. Studi Klinis dan Validasi Jangka Panjang: Rekrut individu pengguna media sosial untuk penelitian jangka panjang di mana prediksi model dibandingkan dengan hasil klinis (seperti wawancara psikologis, kuesioner PHQ-9 secara langsung) guna mengukur tingkat akurasi risiko yang sebenarnya.
5. Etika dan Privasi: Lakukan penelitian lebih dalam tentang metode penerapan sistem deteksi risiko depresi di aplikasi nyata dengan persetujuan pengguna, perlindungan data, serta pendekatan intervensi yang etis.
6. Pembaharuan Model Secara Berkala: Mengingat bahwa bahasa di sosial media mengalami perubahan yang cepat (slang, emoji, hashtag), pertimbangkan untuk menerapkan strategi pembelajaran terus-menerus agar model tetap diperbarui dengan data terbaru dan mempertahankan relevansinya.

**5. IMPLIKASI PRAKTIK DAN PENERAPAN SISTEM**

**5.1 Potensi Penerapan di Layanan Kesehatan Mental**

Hasil dari kajian ini memiliki dampak praktis yang signifikan bagi sistem kesehatan mental berbasis digital di Indonesia. Model deteksi risiko depresi yang tepat bisa diterapkan dalam:

1. Sistem Skrining Awal di Perguruan Tinggi: Institusi pendidikan dapat memanfaatkan sistem ini di media sosial atau forum internal mereka untuk secara tidak langsung mendeteksi mahasiswa yang berisiko tinggi mengalami depresi, sehingga memungkinkan intervensi yang lebih awal oleh para konselor.
2. Aplikasi Layanan Telekonseling: Model ini dapat dimanfaatkan sebagai proses penyaringan otomatis untuk mengidentifikasi dan mengutamakan pengguna yang sangat memerlukan penanganan segera dari psikolog atau psikiater, sehingga meningkatkan efektivitas layanan.
3. Pemantauan Kesehatan Masyarakat: Sistem ini dapat menyajikan data epidemiologi secara real-time mengenai pola dan kelompok geospasial dari tanda-tanda depresi.

**5.2 Prototipe Implementasi Sistem**

Untuk mendemonstrasikan kapabilitas model, sebuah prototipe sederhana dikembangkan menggunakan arsitektur *microservice* yang ringan:

Table 2. Prototipe Implementasi Sistem

Komponen	Teknologi	Fungsi
Antarmuka (Frontend)	Streamlit	Menyediakan <i>interface</i> input teks yang sederhana dan visualisasi hasil klasifikasi secara <i>real-time</i> .
Logika Model (Backend)	Python 3.10 + PyTorch	Menghosting model IndoBERTtweet yang telah di-

		<i>fine-tune.</i>
<b>Pustaka Utama</b>	Transformers, Scikit-learn, Matplotlib	Menangani pemuatan model, prediksi, pra-pemrosesan, dan visualisasi.

Prototipe ini mampu menerima input teks dari pengguna dan, dalam waktu kurang dari satu detik, menghasilkan probabilitas skor untuk setiap kelas risiko depresi (Kelas 0, 1, 2) bersama dengan rekomendasi tindakan (jika skor Kelas 1 atau 2 tinggi).

## 6. KETERBATASAN DAN PENELITIAN LANJUTAN

Meskipun IndoBERTweet menunjukkan kinerja yang unggul, penelitian ini memiliki beberapa keterbatasan yang membuka jalan bagi arah penelitian di masa depan:

1. Keterbatasan Data *Platform: Dataset* saat ini terbatas pada Twitter. Ekspresi linguistik di *platform* lain seperti Instagram (keterlibatan gambar), TikTok (video/audio), atau forum daring (bahasa yang lebih panjang dan terstruktur) mungkin berbeda.
  - Rekomendasi Lanjutan: Memperluas pengumpulan data lintas *platform* untuk menciptakan *dataset* yang lebih umum (*platform-agnostic*).
2. Faktor Multimodal yang Terabaikan: Analisis hanya didasarkan pada teks murni. Di media sosial, emoji, gambar, dan meme seringkali membawa muatan emosional signifikan yang dapat mengubah makna tekstual (*multimodality*).
  - Rekomendasi Lanjutan: Mengembangkan model *multimodal deep learning* yang dapat mengintegrasikan fitur teks dengan fitur visual/emoji untuk meningkatkan akurasi, terutama dalam kasus sarkasme.
3. Validasi Klinis: Label yang berkaitan dengan depresi yang didasarkan pada teks, meskipun sudah diuji oleh para ahli psikologi, belum melalui validasi langsung melalui wawancara klinis dengan pengguna. Data di media sosial hanya menunjukkan kemungkinan risiko, dan bukan diagnosis yang jelas.
  - Rekomendasi Lanjutan: Melaksanakan penelitian prospektif di mana skor prediksi dari model diuji dengan skor alat klinis yang diperoleh dari wawancara lanjutan dengan pengguna (setelah mendapatkan persetujuan etis).
4. Interpretasi Model: Model transformer cenderung berfungsi sebagai kotak hitam. Ketidakjelasan dalam interpretasi dapat mengurangi kepercayaan para ahli psikologi.
  - Rekomendasi Lanjutan: Menciptakan model yang dapat diinterpretasi, misalnya dengan menerapkan teknik LIME (Local Interpretable Model-agnostic Explanations) atau SHAP (SHapley Additive exPlanations) secara menyeluruh, untuk menjelaskan prediksi model dengan menggunakan bahasa psikologis..

## 7. KESIMPULAN

Hasil studi ini menunjukkan bahwa penggunaan model IndoBERTweet sebagai pendekatan berbasis transformator dapat secara efektif mengurangi risiko depresi di kalangan pengguna media sosial, khususnya Twitter. Melalui serangkaian langkah, termasuk pengumpulan data, pemrosesan teks, tokenisasi, penyempurnaan, dan evaluasi menggunakan metrik seperti akurasi, presisi, recall, dan skor F1, sistem ini mampu mengklasifikasikan tingkat risiko depresi dengan kinerja yang konsisten. Hasil studi ini menunjukkan bahwa IndoBERTweet memiliki pemahaman yang lebih baik tentang konteks bahasa Indonesia informal dibandingkan model pembelajaran mesin tradisional. Ini berarti model ini lebih mampu menganalisis pola linguistik yang sering digunakan oleh pengguna yang mungkin mengalami depresi.

Selain menunjukkan efektivitas model, studi ini juga berkontribusi pada pengembangan sistem penilaian kesehatan mental berbasis pembelajaran mesin di Indonesia. Dengan memanfaatkan data dari media sosial, sistem ini dapat menyediakan sistem peringatan dini (EWS) yang dapat membantu organisasi layanan kesehatan, psikolog, dan peneliti mengidentifikasi risiko depresi dengan lebih cepat dan efektif. Hal ini sangat relevan dalam upaya meningkatkan penggunaan media sosial sebagai sarana bagi pengguna untuk mengekspresikan emosi, keluhan, atau ciri-ciri psikologis mereka, terutama remaja dan dewasa muda.

Namun, penelitian ini juga memiliki beberapa keterbatasan yang perlu diatasi. Keterbatasan ini menyoroti banyaknya data yang masih belum reliabel, kemungkinan bias dalam analisis, dan konteks linguistik media sosial. Oleh karena itu, penelitian lebih lanjut diperlukan untuk meningkatkan variasi dataset, menggabungkan data multi-platform, dan menyelidiki model transformator lain, seperti IndoBERT Large, IndoRoBERTa, atau model multibahasa yang lebih besar. Integrasi AI yang dapat dijelaskan (XAI) juga dapat digunakan untuk memberikan penjelasan yang lebih detail tentang klasifikasi model.

Dengan demikian, temuan keseluruhan studi ini menunjukkan bahwa IndoBERTweet merupakan model yang bermanfaat dan efektif yang dapat digunakan dalam sistem penilaian risiko depresi berbasis teks bahasa Indonesia. Dengan pengembangan lebih lanjut, sistem ini berpotensi untuk diterapkan dalam skala yang lebih

komprehensif sebagai pendukung perangkat dini gangguan kesehatan, sehingga menjadi landasan bagi penelitian lebih lanjut di bidang NLP, analisis sentimen, dan teknologi kesehatan mental berbasis AI.

#### 8. DAFTAR PUSTAKA

- [1] Chandra, V., et al. (2023). Mental Health Analysis in Social Media with Deep Learning. *IEEE Access*, 11, 392–404.
- [2] Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of NAACL-HLT*.
- [3] Liu, T., et al. (2024). Ethical Considerations in Social Media Mental Health Research: A Systematic Review. *Journal of Medical Internet Research (JMIR)*, 26(7), e10231.
- [4] Maranta, A., et al. (2022). IndoBERTweet: A Pre-trained Language Model for Indonesian Twitter Data. *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (ACL)*.
- [5] Nugraha, R., & Fikri, M. (2022). Deteksi Kesehatan Mental Mahasiswa Indonesia dengan Algoritma NLP. *Jurnal Teknologi Informasi*, 8(2), 56–67.
- [6] Nugraha, R., Purwitasari, D., & Kautsar, F. W. (2020). IndoBERT: Pretrained Language Model for Indonesian. *Proceedings of the 2020 International Conference on Asian Language Processing (IALP)*.
- [7] Rahman, Z., & Iskandar, H. (2024). Adaptive Language Modeling for Emotion Detection in Low-Resource Languages. *ACM Transactions on Artificial Intelligence*, 5(3).
- [8] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems (NeurIPS)*, 30.
- [9] Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2020). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *NAACL*.
- [10] Cahyani, D., & Adriani, M. (2021). IndoBERTweet: Pretrained Language Model for Indonesian Social Media Text. *Journal of Indonesian NLP Research*.
- [11] Wulandari, A., & Lestari, D. (2022). Klasifikasi tingkat depresi berbasis analisis teks bahasa Indonesia menggunakan model Transformer. *Jurnal Teknologi Informasi dan Ilmu Komputer*.