

Deteksi Potensi Depresi dari Unggahan Media Sosial X Menggunakan Teknik NLP dan Model IndoBERT

Gilbert Fernando Situmorang*, Ronsen Purba

Fakultas Teknik Informatika, Magister Teknologi Informasi, Universitas Mikroskil, Medan, Indonesia

Email: gilbert.fernando@students.mikroskil.ac.id, ronsen@mikroskil.ac.id

Email Penulis Korespondensi: gilbert.fernando@students.mikroskil.ac.id

Submitted: 05/07/2024; Accepted: 06/09/2024; Published: 07/09/2024

Abstrak—Selama beberapa dekade terakhir, gangguan mental seperti depresi meningkat dan menjadi masalah kesehatan masyarakat yang serius. Banyak orang yang terdampak memilih untuk tidak mencari dukungan profesional karena stigma sosial. Media sosial seperti X memberikan peluang untuk mempelajari kesehatan mental dalam skala besar karena pengguna sering berbagi pengalaman dan emosi pribadi mereka. Namun memiliki tantangan terhadap pemahaman pola bahasa dan konteks unggahan sehingga diperlukan teknik dan model yang tepat untuk mendeteksi potensi depresi secara efektif. Dengan menggunakan teknik Natural Language Processing (NLP), penelitian ini menganalisis 37.554 teks dari unggahan media sosial untuk mendeteksi potensi depresi. Penelitian ini menggunakan model IndoBERT, adaptasi BERT yang telah dilatih pada data teks berbahasa Indonesia, untuk mengidentifikasi potensi depresi dari teks sosial media. Data dikumpulkan melalui scrapping menggunakan kata kunci berkonotasi negatif dan positif yang telah dikonsultasikan dengan psikiater. Proses pembersihan teks mencakup case folding, text cleaning, spell normalization, stopword removal, dan stemming. Data kemudian diberi label menggunakan model klasifikasi emosi IndoBERT, mengkategorikan emosi negatif sebagai depresi dan emosi positif sebagai normal. Model dilatih dan dievaluasi menggunakan metrik akurasi, precision, recall, dan F1-score, dengan hasil terbaik menunjukkan akurasi 94,91%, precision 94,91%, recall 94,91%, dan F1-score 94,91%. Hasil menunjukkan bahwa model IndoBERT efektif dalam mendeteksi potensi depresi dari teks media sosial. Namun, terdapat keterbatasan karena ketergantungan pada data unggahan media sosial yang mungkin tidak sepenuhnya mencerminkan kondisi emosional pengguna.

Kata Kunci: Deep Learning; Deteksi Depresi; IndoBERT; Media Sosial; Natural Language Processing

Abstract—Over the past few decades, mental disorders such as depression have increased and become a serious public health issue. Many affected individuals choose not to seek professional support due to social stigma. Social media platforms like X provide opportunities to study mental health on a large scale because users often share their personal experiences and emotions. However, there are challenges in understanding language patterns and context in posts, necessitating appropriate techniques and models to effectively detect potential depressions. Utilizing Natural Language Processing (NLP) techniques, this study analyzes 37,554 texts from social media posts to detect potential depressions. This study employs the IndoBERT model, an adaptation of BERT trained on Indonesian text data, to identify potential depression from social media texts. Data were collected through scrapping using negatively and positively connotated keywords, which were consulted with psychiatrists. The text pre-processing includes case folding, text cleaning, spell normalization, stopword removal and stemming. The data were then labeled using the IndoBERT emotion classification model, categorizing negative emotions as depression and positive emotions as normal. The model was trained and evaluated using accuracy, precision, recall, and F1-score metrics, with the best results showing an accuracy of 94.91%, precision of 94.91%, recall of 94.91%, and an F1-score of 94.91%. The results indicate that the IndoBERT model is effective in detecting potential depression from social media texts. However, there are limitations due to the reliance on social media posts, which may not fully reflect the users' emotional conditions.

Keywords: Deep Learning; Depression Detection; IndoBERT; Natural Language Processing; Social Media

1. PENDAHULUAN

Selama beberapa dekade terakhir gangguan mental semakin meningkat dan menjadi masalah kesehatan masyarakat yang serius di tingkat global [1]. Salah satu jenis gangguan mental yang paling umum ditemukan adalah depresi. Menurut laporan *World Health Organization* (WHO) ada sekitar 280 juta orang di seluruh dunia mengalami depresi dan lebih dari 700 ribu orang melakukan upaya bunuh diri setiap tahunnya [2]. Meskipun kasus depresi sangat tinggi, upaya deteksi dini yang efektif masih terbatas. Banyak orang yang terdampak memilih untuk tidak mencari dukungan profesional yang memadai, salah satu alasannya adalah stigma sosial yang membuat mereka malu untuk mengungkapkan kondisi kejiwaannya [3]. Stigma ini menyebabkan banyak kasus depresi tidak terdeteksi dan tidak ditangani dengan baik, sehingga memperburuk kondisi individu. Maka dari itu, penting untuk mendeteksi potensi depresi guna memungkinkan intervensi lebih awal, yang sangat penting untuk meningkatkan kesejahteraan jangka panjang dan mengurangi risiko gangguan mental lebih lanjut. Intervensi dini dapat memberikan dukungan tepat waktu dan mencegah kondisi menjadi lebih parah [4]. Pada masa kini media sosial menjadi bagian penting dalam kehidupan banyak orang. Munculnya media sosial memberikan peluang besar untuk mempelajari kesehatan mental termasuk potensi depresi dalam skala besar. Khususnya media sosial Twitter atau X dimana penggunaannya sering kali terbuka untuk berbagi pengalaman, perasaan dan juga emosi pribadinya, sehingga sangat dimungkinkan untuk mengeksplorasi dan mengidentifikasi potensi depresi melalui unggahan publik mereka [5]. Namun, terdapat tantangan utama dalam mendeteksi potensi depresi dari unggahan sosial media yaitu kompleksitas dalam mengidentifikasi tanda-tanda depresi dari teks media sosial, yang melibatkan pola bahasa dan konteks unggahan [6]. Untuk mengatasi tantangan tersebut, dibutuhkan model yang mampu memahami konteks dan nuansa bahasa yang kompleks dari unggahan sosial media, khususnya dalam bahasa Indonesia.

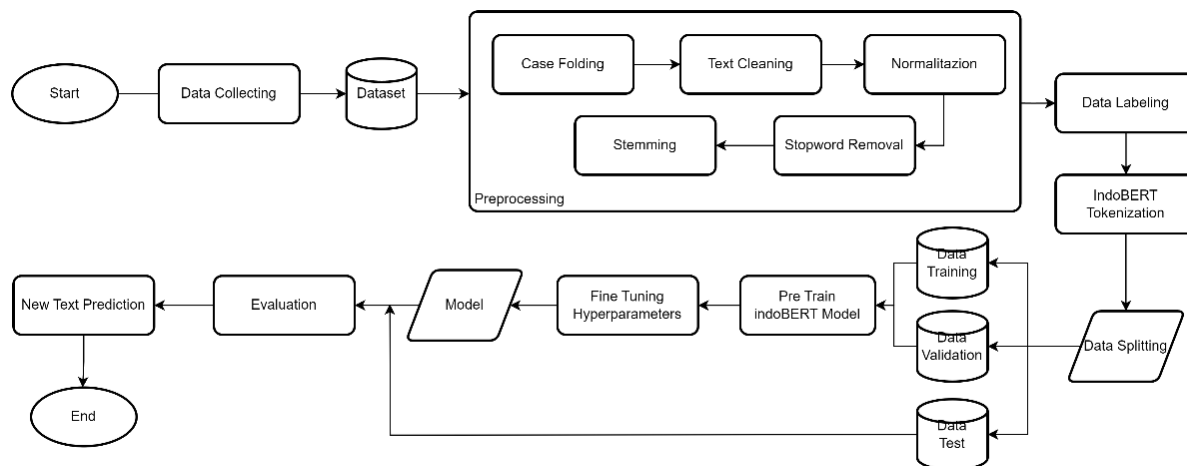
Natural Language Processing (NLP) memungkinkan analisis otomatis dari data linguistik yang berasal dari teks. Dalam konteks media sosial, NLP dapat digunakan untuk menggali fitur-fitur sentimen dari unggahan teks untuk dijadikan indikator dalam mendeteksi kondisi mental seseorang. Melalui metode komputasi yang canggih, NLP menganalisis bagaimana kata-kata, frasa serta struktur bahasa dalam teks dapat mengungkapkan emosi dan sentimen pengguna. Ini membantu dalam mengidentifikasi pola-pola yang mungkin menunjukkan adanya potensi gangguan seperti depresi atau kecemasan [7]. Salah satu pendekatan yang baru dan efektif dalam NLP adalah penggunaan *deep learning*, khususnya model *Transformer*. Tidak seperti model tradisional *deep learning*, model *Transformer* menggunakan mekanisme *self-attention* dalam memahami hubungan kontekstual antar data berurutan. Mekanisme ini memungkinkan *Transformer* untuk menangani dependensi jarak jauh antar elemen dalam urutan input dengan lebih efektif, serta memungkinkan pemrosesan paralel yang meningkatkan efisiensi komputasi [8]. Implementasi *Transformer* yang paling populer adalah *Bidirectional Encoder Representations from Transformers* (BERT). BERT mampu memahami konteks dua arah dalam teks, yang berarti model ini tidak hanya melihat kata-kata di sekitar kata target tetapi juga memahami makna dari kata-kata tersebut dalam konteks yang lebih luas. Ini membuat BERT sangat efektif dalam tugas-tugas seperti klasifikasi teks, analisis sentimen dan deteksi entitas [9]. Model BERT sendiri, telah diadopsi ke dalam berbagai bahasa, termasuk bahasa Indonesia melalui model IndoBERT. IndoBERT adalah implementasi BERT yang telah dilatih secara khusus pada data teks berbahasa Indonesia, memungkinkan model ini untuk menangkap nuansa dan konteks bahasa Indonesia dengan lebih baik, menjadikannya alat yang sangat berguna untuk penelitian dan aplikasi yang memerlukan pemahaman mendalam terhadap bahasa Indonesia [10].

Penelitian sebelumnya telah menunjukkan penggunaan *machine learning* dan *deep learning* dalam mendeteksi potensi depresi. Darmawan *et al.* [11] menggunakan *Support Vector Machine* (SVM) dengan kernel RBF untuk mendeteksi potensi depresi dari teks media sosial, mencapai akurasi 82,5%, *F1 Score* 0,692, *Precision* 0,715 dan *Recall* 0,671. Meskipun hasilnya menjanjikan, *tuning parameter* kernel RBF memerlukan waktu dan sumber daya yang besar, serta performa *recall* yang rendah menunjukkan potensi terlewatnya beberapa kasus depresi. Nugraha dan Azhar [12] menggunakan model LSTM-RNN dengan 50% *dropout* dan menurunkan *learning rate* pada Adam Optimizer, menghasilkan *precision*, *recall* dan *F1-score* masing-masing 86% dengan akurasi keseluruhan 86%. Meskipun performanya tinggi, penelitian ini menggunakan dataset yang kecil, yaitu hanya 4403 baris *tweet*. Nugroho *et al.* [13] membandingkan performa model *Long Short-Term Memory* (LSTM) dan *Bidirectional Long Short-Term Memory* (BiLSTM) dalam mendeteksi potensi depresi dari teks, dimana LSTM hanya mencapai akurasi 84,91% dan BiLSTM mencapai akurasi 94,12%. Hasil ini menunjukkan bahwa BiLSTM secara signifikan lebih efektif dalam memahami konteks penuh dari data sekuensial dengan membaca teks dalam dua arah. Kemampuan BiLSTM untuk menangkap informasi dari kedua arah membantu mengatasi keterbatasan LSTM yang hanya membaca teks dalam satu arah, sehingga memberikan pemahaman yang lebih komprehensif dan akurat. Kharparde *et al.* [14] membandingkan *Multinomial Naive Bayes*, XLNET dan BERT dalam mendeteksi potensi depresi dari 10.314 teks Twitter berbahasa Inggris, performa tertinggi dihasilkan oleh metode BERT dengan akurasi 99%, diikuti *Multinomial Naive Bayes* dengan akurasi 98% dan terakhir XLNET dengan akurasi 96%. Penelitian ini mengindikasikan bahwa BERT memiliki keunggulan signifikan dalam mendeteksi potensi depresi berbasis teks media sosial.

Berdasarkan temuan-temuan tersebut, penelitian ini bertujuan untuk merekomendasikan penggunaan model *deep learning modern* khususnya IndoBERT, dalam mendeteksi potensi depresi dari teks media sosial berbahasa Indonesia. IndoBERT dipilih karena kemampuannya membaca teks dalam dua arah dan memahami konteks tulisan dengan lebih baik, diharapkan mampu meningkatkan akurasi deteksi potensi depresi dibandingkan metode tradisional sebelumnya. Selain itu, penelitian ini juga berfokus pada peningkatan *recall* untuk memastikan tidak ada teks berpotensi depresi yang terlewatkan, melalui pemahaman yang lebih baik akan konteks penuh dari teks. Upaya untuk memperbesar dan memperbaiki kualitas dataset juga menjadi bagian penting dari penelitian ini, guna memastikan model yang dihasilkan lebih akurat dan andal. Dengan tujuan-tujuan ini, penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam deteksi dini depresi melalui analisis teks media sosial, serta mendorong penggunaan teknologi *deep learning modern* dalam bidang kesehatan mental.

2. METODOLOGI PENELITIAN

Bagian ini akan membahas tahapan-tahapan yang dilakukan peneliti dalam penelitian ini. Proses penelitian ini melibatkan beberapa langkah yang disusun secara sistematis untuk mencapai tujuan yang telah ditetapkan. Setiap tahapan dalam proses ini dirancang untuk memastikan bahwa model yang dihasilkan memiliki tingkat akurasi yang tinggi. Selain itu, langkah-langkah ini saling berkesinambungan untuk memastikan bahwa setiap tahap memberikan kontribusi maksimal terhadap hasil akhir penelitian. Dengan pendekatan ini, diharapkan penelitian ini dapat menghasilkan model yang robust dan dapat diandalkan untuk deteksi potensi depresi. Alur metode penelitian mulai dari pengumpulan data sampai dengan pembuatan model, serta melakukan pengujian dengan data baru dapat dilihat pada Gambar 1.



Gambar 1. Alur Metode Penelitian

Berdasarkan Gambar 1 setelah *dataset* berhasil dikumpulkan dilakukan *text preprocessing* yang meliputi *case folding*, *cleansing*, *normalization*, *stopword removal*, dan *stemming*. Setelah *preprocessing*, akan dilakukan pelabelan data menggunakan *pre-train model*, kemudian data akan dibagi menjadi tiga bagian, yaitu data training, data validasi dan data testing. Pada data *training* dan validasi, dilakukan ekstraksi fitur menggunakan *tokenizer* dari model IndoBERT. Proses selanjutnya adalah *training* model dan *fine-tuning*, dilakukan eksperimen penyesuaian nilai *hyperparameter* untuk mengoptimalkan performa model. Setelah itu, dilakukan evaluasi untuk menentukan hasil terbaik.

2.1. Pengumpulan Data

Menurut studi yang dilakukan oleh Akbar dan Ahmed. [15], salah satu ciri *tweet* berpotensi depresi adalah didalamnya terkandung kata yang bersifat negatif, hal ini menandakan pengguna sedang mengekspresikan emosi negatifnya. Dari temuan tersebut akan digunakan kata kunci berkonotasi negatif untuk mengumpulkan data *tweet* dengan teknik *scraping* melalui *platform* apify. Agar *tweet* yang didapat lebih relevan, dalam proses pengumpulan kata kunci dilakukan konsultasi dengan Psikiater untuk menentukan kata-kata yang sering digunakan oleh orang yang berpotensi mengidap depresi. Selain itu dikumpulkan juga kata kunci yang berlawanan dengan depresi agar data yang diperoleh seimbang. Kumpulan kata tersebut dapat dilihat pada Tabel 1.

Tabel 1. Kata Kunci Penelusuran Data

Kata Kunci	
Berpotensi Depresi	Bersalah, Cemas, Depresi, Diabaikan, Dikucilkan, Frustasi, Gagal, Galau, Gelisah, Hilang kendali, Hampa, Kecewa, Kesepian, Lelah, Menyerah, Menyesal, Pasrah, Putus asa, Sedih, Sendirian, Stress, Tak berharga, Terasing, Terisolasi, Terluka, Terpuruk, Tertekan, Tersisih, Tidak berarti, Tidak berdaya, Tidak berguna, Tidak didengar, Tidak mampu
Normal	Antusias, Bahagia, Berharga, Berhasil, Bersama, Ceria, Dekat, Dihargai, Dipercaya, Diterima, Gembira, Mampu, Optimis, Positif, Riang, Semangat, Senang, Sukses, Tenang

Tabel 1 menyajikan kumpulan kata kunci yang digunakan untuk penelusuran data, yang dibagi menjadi dua kategori Berpotensi Depresi dan Normal.

2.2. Pemrosesan Data

Pemrosesan teks melibatkan beberapa tahap yang bertujuan untuk menyiapkan dan menyempurnakan data tekstual untuk analisis atau penggunaan lebih lanjut. Tahapan-tahapan ini biasanya mencakup konversi huruf besar-kecil (*case folding*), penghapusan simbol, konversi kata slang (*spell normalization*), *stemming* dan penghapusan kata stop (*stopword*) [16].

a. Case Folding.

Case Folding merujuk pada proses pengolahan teks yang menjadikan keseluruhan huruf menjadi huruf kecil untuk konsistensi analisis. Tujuannya agar tiap kata dalam teks menjadi identik.

b. Text Cleaning.

Text cleaning dilakukan untuk menghapus karakter ataupun kata yang dianggap mengganggu pada data teks. Gangguan yang dimaksud dapat berupa tanda baca, *url*, *emoji*, dan *hashtag*.

c. Spell Normalization

Spell Normalization adalah langkah penting dalam meningkatkan aksesibilitas dan analisis data tekstual dari berbagai bahasa. *Spell Normalization* bertujuan mengubah kata – kata tidak baku seperti singkatan dan slang sehingga dapat mengurangi keragaman kata dan meningkatkan akurasi. Pada penelitian ini kata baku diperoleh

dari kamus "bahasa alay" diakses dari [Kamus Alay - Colloquial Indonesian Lexicon](#) (GitHub). Sampel kata baku ditampilkan pada Tabel 2.

Tabel 2. Sampel *Spell Normalization*

No	Slang	formal
1	met	selamat
2	smg	semoga
3	jgn	jangan
4	sampe	sampai
..
15396	gaharus	Enggak harus

d. *Stopword Removal*

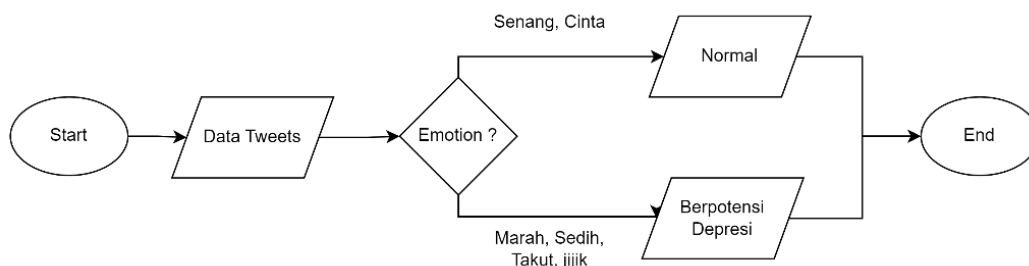
Penghapusan *stopword* secara signifikan akan berdampak pada efisiensi dan akurasi tugas NLP seperti pengambilan informasi, klasifikasi teks dan analisis sentimen. Prosesnya melibatkan kata – kata umum yang dianggap tidak relevan untuk analisis, sehingga mengurangi kumpulan data dan meningkatkan efisiensi komputasi [17]. Contoh kata *stopword* meliputi “adalah”, “bagaimana”, “begitulah”, “berikut” dan “kalau”.

e. *Stemming*

Stemming mengubah kata – kata ke bentuk dasarnya dengan cara menghapus imbuhan dari kata tersebut. *Stemming* dapat mengurangi ketaksaan dalam sebuah kata. Akurasi juga dapat ditingkatkan dengan *stemming* karena terjadi pengurangan keragaman kata. Pada penelitian ini digunakan *library* sastrawi untuk melakukan *stemming*.

2.3. Pelabelan Data

Pelabelan data merupakan proses memberikan kelas pada data, yang berperan penting dalam melatih dan mengevaluasi model pembelajaran mesin. Pada penelitian ini, pelabelan akan dilakukan dengan cara mengekstrak emosi dari teks menggunakan model klasifikasi emosi *pre-trained* IndoBERT. Berdasarkan emosi yang diekstraksi, data akan dikategorikan ke dalam dua kelas: depresi dan normal. Emosi negatif yaitu marah, sedih, takut, dan jijik akan dikategorikan sebagai depresi, sedangkan emosi positif seperti senang dan cinta akan dikategorikan sebagai normal, sesuai dengan metode yang digunakan pada penelitian Nugraha dan Azhar. [13]. Proses pelabelan ini bertujuan untuk mengidentifikasi kondisi emosi yang menunjukkan tanda-tanda depresi dalam teks tweet, memberikan landasan yang kuat untuk analisis lebih lanjut. Alur pelabelan depresi ini dapat dilihat pada Gambar 2.



Gambar 2. Alur Pelabelan Data


Gambar 2 menunjukkan alur pelabelan data yang dimulai dari kumpulan *tweet*, yang kemudian dievaluasi berdasarkan emosi yang diekspresikan. *Tweet* dengan emosi positif seperti senang dan cinta dikategorikan sebagai normal, sedangkan *tweet* dengan emosi negatif seperti marah, sedih, takut, dan jijik dikategorikan sebagai berpotensi depresi.

Dalam pemilihan model *pre-trained* untuk mengekstrak emosi dari *tweet*, dilakukan percobaan untuk menentukan model klasifikasi emosi yang terbaik. Dua model *pre-trained* yang paling populer dari platform *Hugging Face*, yaitu *indobert-emotion-classification* dan *prediksi-emosi-indobert*, dipilih untuk diuji pada data yang digunakan oleh penelitian Nugraha dan Azhar [13], dimana data yang mereka gunakan dianotasi secara manual sehingga keakuratan label lebih terjamin.

Hasil pengujian menunjukkan bahwa model *prediksi-emosi-indobert* secara signifikan lebih baik dalam mengklasifikasikan emosi dibandingkan model *indobert-emotion-classification*. Dari 4.403 data, model *prediksi-emosi-indobert* berhasil mengklasifikasikan 4.139 emosi dengan akurat, sedangkan model *indobert-emotion-classification* hanya mampu mengklasifikasikan 1.771 data dengan akurat. Berdasarkan hasil percobaan ini, model *prediksi-emosi-indobert* dipilih untuk mengekstrak emosi pada dataset penelitian ini.

2.4. BERT (Bidirectional Encoder Representations from Transformers)

BERT adalah model pembelajaran mendalam yang dikembangkan oleh Google dan dirilis pada tahun 2018. BERT dirancang untuk merepresentasikan kata-kata dalam konteks sebagai bagian dari tahap persiapan pemrosesan bahasa alami (*Natural Language Processing, NLP*) [18]. Model BERT menggunakan beberapa lapisan *Transformer (Trm)* yang saling terhubung untuk memproses input teks. Setiap lapisan *Transformer* terdiri dari mekanisme perhatian (*attention mechanism*) yang memungkinkan model untuk mempertimbangkan konteks dari semua kata dalam kalimat, baik dari arah kiri maupun kanan [19]. Ilustrasi arsitektur dasar model BERT ditunjukkan pada Gambar 3.

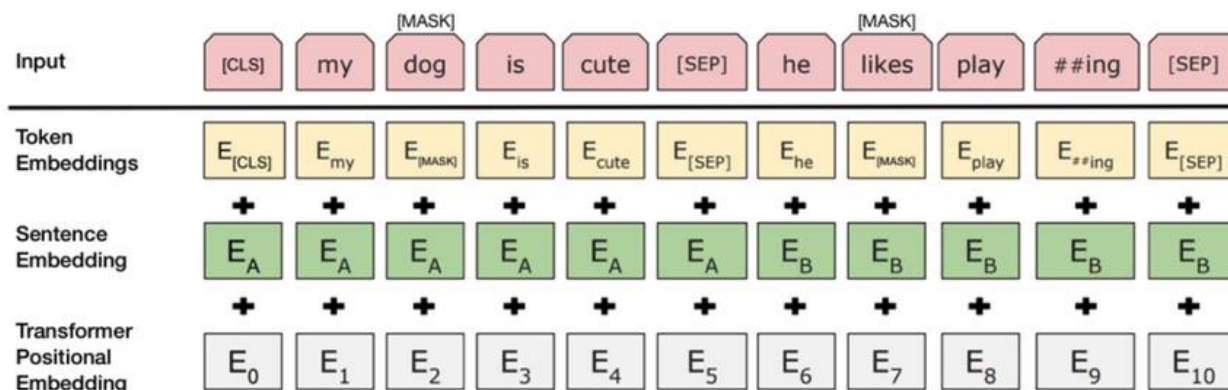


Gambar 3. Arsitektur Dasar Model BERT [19]

Gambar 3 menunjukkan arsitektur dasar model BERT (*Bidirectional Encoder Representations from Transformers*), yang terdiri dari 3 komponen utama untuk pemrosesan teks. Pada bagian atas gambar, terdapat input token (T_1, T_2, \dots, T_N) yang merepresentasikan kata-kata dalam teks. Token ini diubah menjadi vektor numerik melalui *embedding layer* (E_1, E_2, \dots, E_N). Vektor-vektor ini kemudian diproses melalui beberapa lapisan *transformer* (Trm), yang menggunakan mekanisme *self-attention* dan lapisan *feed-forward* untuk memahami konteks antar kata secara *bidirectional*. Setelah melalui *transformer blocks*, model menghasilkan output yang kaya akan informasi konteks [19]. Dalam penelitian ini, arsitektur BERT digunakan untuk mendeteksi potensi depresi dari teks media sosial berbahasa Indonesia, dengan penekanan pada peningkatan akurasi melalui pemahaman konteks yang lebih baik.

2.4.1. BERT Tokenizer

BERT *Tokenizer* adalah alat yang mengubah teks mentah menjadi token yang dapat diproses oleh model BERT. BERT *Tokenizer* menggunakan metode *WordPiece* untuk memecah kata-kata menjadi sub-kata atau token berdasarkan frekuensi kemunculannya dalam korpus pelatihan. Gambar 4 mengilustrasikan proses tokenisasi dalam BERT, termasuk token embeddings, segment embeddings, dan position embeddings.



Gambar 4. Proses Tokenisasi dalam Model BERT [20]

Gambar 4 menunjukkan proses ini dimulai dengan menambahkan token khusus seperti [CLS] di awal dan [SEP] di akhir setiap *input*. Kemudian, teks dipecah menjadi sub-kata sehingga kata-kata yang jarang muncul dapat diuraikan menjadi unit yang lebih kecil dan lebih umum. Setiap token atau sub-kata ini kemudian dipetakan ke ID numerik yang sesuai dalam kosakata model. Selain itu, *attention masks* dan *segment IDs* juga dihasilkan untuk membantu model memahami struktur input dan fokus pada bagian-bagian yang relevan selama pemrosesan [21].

2.4.2. IndoBERT

IndoBERT merupakan adaptasi dari model BERT (*Bidirectional Encoder Representations from Transformers*) yang dirancang khusus untuk menangani teks berbahasa Indonesia. Dikembangkan untuk mengatasi kebutuhan pemrosesan bahasa alami (*Natural Language Processing, NLP*) dalam konteks bahasa Indonesia, IndoBERT dilatih menggunakan korpus teks yang luas dan beragam dari sumber-sumber berbahasa Indonesia, termasuk berita, media sosial, dan dokumen bahasa Indonesia lainnya [22]. IndoBERT tersedia dalam beberapa varian, yang berbeda. Tabel 3 menunjukkan perbedaan utama diantara varian-varian IndoBERT tersebut.

Tabel 3. Varian Model IndoBERT

Model	Params	Layers	Heads	Emb. Size	Hidden Size	FFN Size
IndoBERT-lite _{BASE}	11.7M	12	12	128	768	3072
IndoBERT _{BASE}	124.5M	12	12	768	768	3072
IndoBERT-lite _{LARGE}	17.7M	24	16	128	1024	4096
IndoBERT _{LARGE}	335.2M	24	16	1024	1024	4096

Tabel 3 menyajikan berbagai varian model IndoBERT, termasuk IndoBERT-lite_{BASE}, IndoBERT_{BASE}, IndoBERT-lite_{LARGE}, dan IndoBERT_{LARGE}, dengan perbedaan dalam jumlah *parameter*, *layers*, *heads*, *embedding*, ukuran *hidden layer*, dan ukuran *feed-forward network*. Dalam penelitian ini, digunakan model IndoBERT Base karena kompleksitas dan kinerjanya yang seimbang. IndoBERT Base memiliki 124.5 juta parameter, yang cukup besar untuk menangkap berbagai pola dalam data teks tanpa memerlukan sumber daya komputasi yang sangat besar seperti model yang lebih besar. Hal ini menawarkan keseimbangan antara akurasi dan efisiensi komputasi, menjadikannya sebagai pilihan ideal.

2.5. Evaluasi Model.

Tahap evaluasi model dilaksanakan untuk menilai kualitas dari model yang telah dibuat. Evaluasi ini mencakup pengukuran akurasi, *F1 score*, *recall* dan *precision* dari masing – masing algoritma. Proses evaluasi hasil menggunakan *confusion matrix*. *Confusion matrix* merupakan alat yang digunakan untuk menilai performa model dengan perbandingan label prediksi dan label aktual dari data [11]. Evaluasi performa menggunakan *confusion matrix* ditampilkan pada Tabel 4.

Tabel 4. Evaluasi Performa Menggunakan Confusion Matrix

Data Aktual	Data Prediksi		
	True	False	Total
True	TP	FN	P
False	FP	TN	N
Total	P'	N'	P + N

TP (*True Positive*) mengacu pada data positif yang berhasil diprediksi dengan benar, sedangkan TN (*True Negative*) mengacu pada data negatif yang diprediksi sebagai positif. Sebaliknya, FP (*False Positive*) adalah data negatif yang salah diprediksi sebagai positif, dan FN (*False Negative*) adalah data positif yang salah diprediksi sebagai negatif. Berdasarkan Tabel 1, nilai akurasi, *F1 score*, *recall*, dan presisi dari suatu model dapat dihitung dengan menggunakan rumus – rumus berikut.

Akurasi merupakan perbandingan jumlah data yang diprediksi benar dan jumlah total data. Dihitung dengan persamaan 1.

$$Accuracy = \frac{TP+TN}{P+N} \quad (1)$$

F1 score merupakan rata-rata dari presisi dan *recall* yang dihitung menggunakan persamaan 2.

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (2)$$

Precision merupakan jumlah data positif yang diprediksi benar dan jumlah data yang diharapkan positif. Dihitung dengan persamaan 3.

$$Precision = \frac{TP}{P'} \quad (3)$$

Recall merupakan rasio jumlah data positif yang diprediksi benar dan jumlah total data yang memiliki label positif asli. Dihitung dengan persamaan 4.

$$Recall = \frac{TP}{P} \quad (4)$$

3. HASIL DAN PEMBAHASAN

3.1. Data Tweet

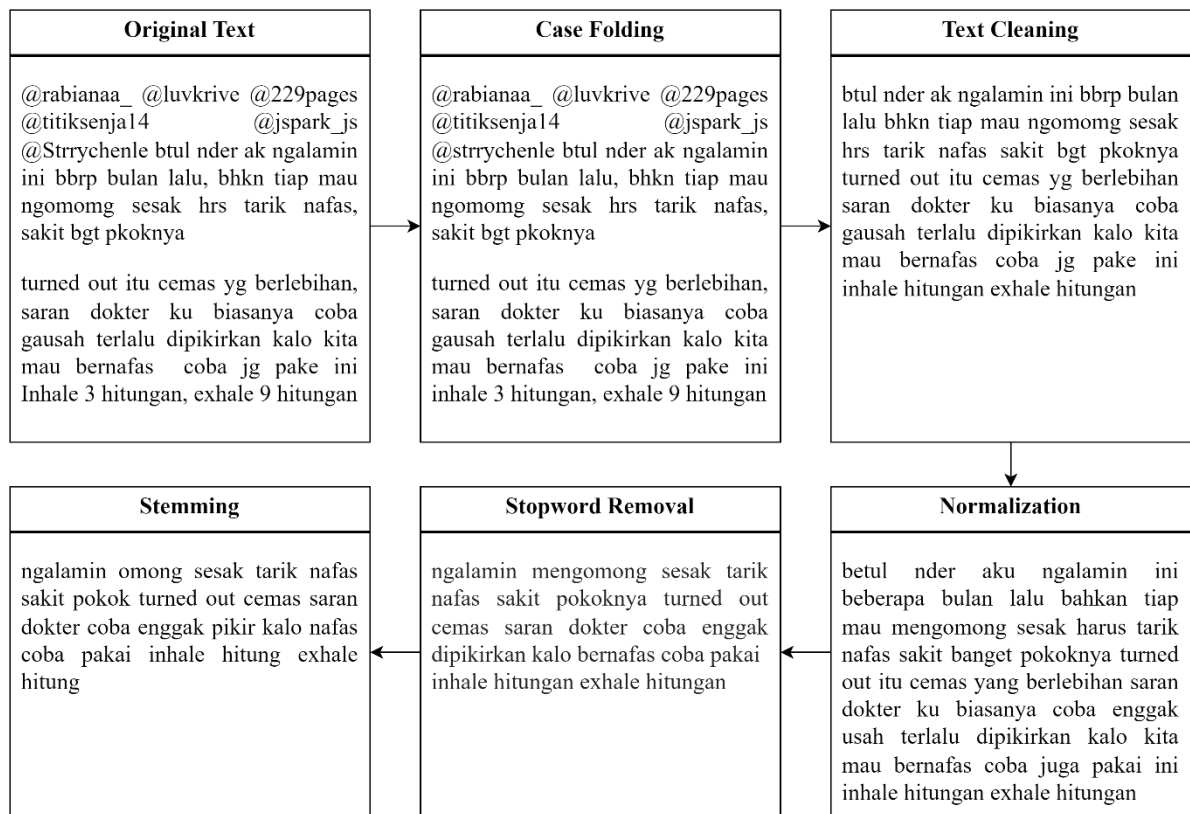
Data dikumpulkan menggunakan *platform* apify dengan filter *search term* kata kunci yang telah dikumpulkan dan *created post* mulai dari Januari 2023 sampai dengan Mei 2024. Dari hasil *scraping* diperoleh 44.399 data tweet, kemudian dilakukan pembuangan untuk data yang duplikat sehingga data yang akan digunakan untuk penelitian ini berjumlah 37.554 data. Sample data ditampilkan pada Tabel 5.

Tabel 5. Sample Data Teks dari Media Sosial X

No	Text
1	@rabianaa_ @luvkrive @229pages @titiksenja14 @jspark_js @Strychenle btul nder ak ngalamin ini bbrp bulan lalu, bhkn tiap mau ngomomg sesak hrs tarik nafas, sakit bgt pkoknya turned out itu cemas yg berlebihan, saran dokter ku biasanya coba gausah terlalu dipikirkan kalo kita mau bernafas coba jg pake ini Inhale 3 hitungan, exhale 9 hitungan
2	@collegemenfess Ini ni yg membuat gw pengen child free atau malah gk nikah Membuat anaknya cemas dan merasa bersalah di setiap keputusannya dan untuk pilihan masa depannya
3	Sayang, jgn pernah cemas dengan cintaku yg begitu dalam... Karna sebesar apapun cinta tulus itu, nda akan mengikatmu nda juga memaksamu...
4	Rasanya klo ga dikelarin detik itu jg guw khawatir bgt. Inget jg dlu gue mencemaskan kondisi semua org yg padahal sebenarnya orgnya sendiri ga cemas ama kondisinya mereka, karena ya emg ga knp-knp. Bahkan gue lg di luar pun kadang kambuh anxietynya sampe temen gue sadar—
..
37554	Sering terjadi. In my case, malah yang sempet aku sharing in banyaknya lebih sukses dariku KWKW Semoga jadi ilmu yang berkah:"))

3.2. Pemrosesan Data

Hasil dari proses pembersihan data mulai dari case folding sampai dengan stemming ditampilkan pada Gambar 5.



Gambar 5. Proses *Preprocessing Text*


Gambar 5 menunjukkan hasil dalam proses *preprocessing* teks yang digunakan dalam penelitian ini. Dimulai dari teks asli yang diambil dari media sosial, proses ini melalui beberapa langkah untuk membersihkan dan mempersiapkan data. Langkah pertama adalah *case folding*, yang mengubah seluruh teks menjadi huruf kecil. Kemudian, *text cleaning* membersihkan teks dari karakter khusus, *mention*, dan tanda baca yang tidak diperlukan. Selanjutnya, normalisasi dilakukan untuk mengubah kata-kata informal atau singkatan menjadi bentuk standar. Setelah itu, *stopword removal* menghapus kata-kata umum yang tidak memberikan nilai informatif, seperti "dan" dan "yang". Terakhir, *stemming* mengubah kata-kata ke bentuk dasarnya. Proses ini memastikan bahwa teks yang digunakan lebih bersih, terstruktur, dan siap untuk dianalisis oleh model machine learning seperti IndoBERT, meningkatkan kualitas analisis teks dalam penelitian ini.

3.3. Pelabelan Data


Data tweet yang telah melalui proses pembersihan akan digunakan untuk ekstraksi fitur emosi menggunakan model pre-trained klasifikasi emosi. Model yang dipilih untuk tugas ini adalah model prediksi-emosi-indobert, yang telah terbukti lebih efektif dalam mengklasifikasikan emosi pada *tweet*. Pemilihan model ini didasarkan pada hasil evaluasi komparatif yang menunjukkan kinerja superior dibandingkan model lainnya. Fitur emosi diekstraksi dari setiap tweet, emosi negatif seperti marah, sedih, takut, dan jijik akan dikategorikan sebagai 1 atau teks berpotensi depresi, sedangkan emosi positif seperti senang dan cinta akan dikategorikan sebagai 0 atau teks normal. Pendekatan ini memungkinkan klasifikasi yang lebih tepat antara data yang mencerminkan kondisi depresi dan data yang mencerminkan kondisi normal, sesuai dengan metodologi yang digunakan dalam penelitian Nugraha dan Azhar. [12]. Implementasi ini memastikan bahwa analisis emosi dilakukan secara komprehensif, mempertimbangkan nuansa emosi yang diekspresikan dalam *tweet*. Data teks yang telah melalui proses pembersihan akan diprediksi menggunakan *pre trained* model yang telah dilatih untuk menentukan label emosinya. Setelah label emosi diperoleh, dilakukan proses penentuan lebih lanjut dimana emosi negatif akan dikategorikan sebagai depresi, sedangkan emosi positif atau netral akan dikategorikan sebagai tidak depresi. Proses ini memungkinkan klasifikasi yang lebih terperinci dan membantu dalam memahami kondisi emosional dari teks yang dianalisis. Sampel data dapat dilihat pada Tabel 6 dan distribusi kelas emosi serta depresi dapat dilihat pada Gambar 6 dan Gambar 7.

Tabel 6. Sampel Data dengan Label Emosi dan Depresi

No	Original Text	Clean Text	Emotion	Label
1	@rabianaa_ @luvkrive @229pages @titiksenja14 @jspark_js @Strrychenle btw nder ak ngalamin ini bbrp bulan lalu, bhkn tiap mau ngomong sesak hrs tarik nafas, sakit bgt pkoknyaturned out itu cemas yg berlebihan, saran dokter ku biasanya coba gausah terlalu dipikirkan kalo kita mau bernafas coba jg pake ini Inhale 3 hitungan, exhale 9 hitungan	ngalamin omong sesak tarik nafas sakit pokok turned out cemas saran dokter coba enggak pikir kalo nafas coba pakai inhale hitung exhale hitung	TAKUT	1
2	@collegemenfess Ini ni yg membuat gw pengen child free atau malah gk nikah Membuat anaknya cemas dan merasa bersalah di setiap keputusannya dan untuk pilihan masa depannya	nih gue pengen child free enggak nikah anak cemas salah putus pilih depan	TAKUT	1
3	Sayang, jgn pernah cemas dengan cintaku yg begitu dalam... Karna sebesar apapun cinta tulus itu, nda akan mengikatmu nda juga memaksamu...	sayang cemas cinta apa cinta tulus indak ikat indak paksa	SEDIH	1
4	Rasanya klo ga dikelarin detik itu jg guw khawatir bgt. Inget jg dlu gue mencemaskan kondisi semua org yg padahal sebenarnya orgnya sendiri ga cemas ama kondisinya mereka, karena ya emg ga knp-knp. Bahkan gue lg di luar pun kadang kambuh anxietynya sampe temen gue sadar—	kalo enggak dikelarin detik gue khawatir gue cemas kondisi orang orgnya enggak cemas kondisi ya enggak knpknp gue kadang kambuh anxietynya teman gue sadar	TAKUT	1
..
37554	Sering terjadi. In my case, malah yang sempet aku sharing in banyaknya lebih sukses dariku KWKW Semoga jadi ilmu yang berkah:")	my case sharing banyak sukses dari kwkw moga ilmu berkah	SENANG	0



Gambar 6. Distribusi Label Emosi



Gambar 7. Distribusi Label Depresi

Gambar 6 menunjukkan jumlah tweet yang dikategorikan ke dalam berbagai label emosi. Terlihat bahwa emosi sedih dan senang mendominasi dengan jumlah tweet masing-masing sebanyak 12.457 dan 12.422. Sementara itu, emosi marah juga memiliki jumlah yang signifikan yaitu 9.843 tweet. Di sisi lain, emosi takut, cinta, dan jijik memiliki jumlah *tweet* yang jauh lebih sedikit, masing-masing sebanyak 2.011, 529, dan 292 tweet. Distribusi ini menunjukkan variasi emosi yang diekspresikan pengguna dalam *tweet* mereka, yang dapat memberikan konteks tambahan dalam analisis potensi depresi. Emosi seperti sedih, takut, marah dan jijik dapat menjadi indikator awal adanya potensi depresi pada pengguna media sosial. Gambar 7 menunjukkan distribusi *tweet* berpotensi depresi dalam *dataset*. Label normal (0) dan berpotensi depresi (1) masing-masing memiliki jumlah tweet sebanyak 13.243 dan 24.311. Terlihat bahwa jumlah *tweet* berpotensi depresi hampir dua kali lipat dibandingkan dengan tweet normal. Hal ini menunjukkan bahwa dalam *dataset* ini, terdapat kecenderungan yang signifikan untuk adanya potensi depresi yang diekspresikan oleh pengguna.

3.4. Visualisasi Data

Dilakukan visualisasi data menggunakan *word cloud*, untuk memahami kata yang sering muncul dalam teks *tweet* berdasarkan kelasnya. Frekuensi kemunculan kata ditunjukkan berdasarkan ukuran *font* dalam *word cloud*. Semakin besar ukuran *font* maka semakin tinggi frekuensi kemunculan kata tersebut. Frekuensi kemunculan kata dapat dilihat pada Gambar 8 dan Gambar 9.



Gambar 8. Word Cloud dengan Label Normal



Gambar 9. Word Cloud dengan Label Depresi

Gambar 8 dan Gambar 9 menampilkan *wordcloud* dari *dataset* dengan label 0 (normal) dan label 1 (berpotensi depresi) untuk menunjukkan frekuensi kata yang muncul. Pada Gambar 8 yang berlabel 0, kata-kata seperti bahagia, semangat, sukses, optimis, dan senang mendominasi, menunjukkan suasana hati positif dan emosi bahagia. Sementara itu Gambar 9, yang berlabel 1 didominasi oleh kata-kata seperti stres depresi, gagal, dan salah, yang mencerminkan emosi negatif dan suasana hati yang buruk.

3.5. Pembuatan Model

Dalam pembuatan model, proses paling awal yang dilakukan adalah pembagian dataset menjadi data *training*, validasi, dan *testing*. Data *training* digunakan untuk melatih model, data validasi digunakan untuk memeriksa kinerja model selama pelatihan dan mendeteksi *overfitting*, sementara data testing digunakan untuk evaluasi kinerja akhir model. Setelah proses pembagian data, langkah berikutnya adalah proses *tokenizing* yang termasuk fase *input*, penambahan token khusus [CLS], [SEP] dan proses *encoding*. Tahapan BERT *tokenizing* dapat dilihat pada Gambar 10.

5	3-e5	16	92,07%	92,04%	92,07%	92,05%
5	4-e5	128	93,06%	93,03%	93,06%	93,04%
5	4-e5	64	92,72%	92,69%	92,72%	92,69%
5	4-e5	32	92,51%	92,48%	92,51%	92,48%
5	4-e5	16	91,48%	91,45%	91,48%	91,46%
5	5-e5	128	92,97%	92,95%	92,97%	92,96%
5	5-e5	64	92,14%	92,10%	92,14%	92,11%
5	5-e5	32	91,85%	91,82%	91,85%	91,83%
5	5-e5	16	90,89%	90,84%	90,89%	90,84%

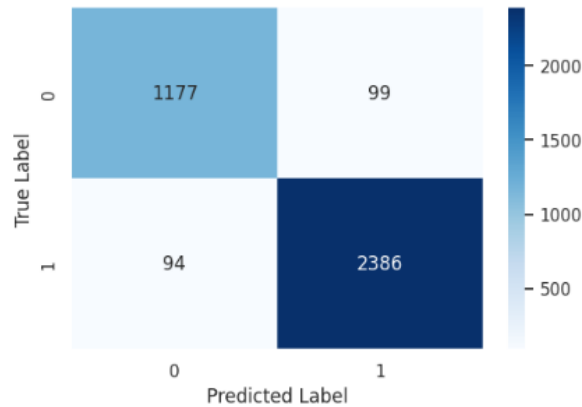
Tabel 7 menyajikan hasil eksperimen model yang dilatih dengan menggunakan 70% data untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian, dengan berbagai konfigurasi *hyperparameter* seperti jumlah *epoch*, *learning rate*, dan ukuran *batch*. Hasil terbaik dicapai dengan *learning rate* 2e-5 dan *batch size* 128, menghasilkan akurasi 94,05%, presisi 94,03%, *recall* 94,05%, dan F1 *score* 94,04%.

Tabel 8. Hasil Eksperimen 80% *Training*, 10% Validasi dan 10% *Testing*

Epocs	Learning Rate	Batch Size	Akurasi	Presisi	Recall	F1 Score
5	2-e5	128	94,91%	94,91%	94,91%	94,91%
5	2-e5	64	94,52%	94,50%	94,52%	94,50%
5	2-e5	32	93,72%	93,70%	93,72%	93,70%
5	2-e5	16	93,26%	93,23%	93,26%	93,23%
5	3-e5	128	94,38%	94,37%	94,38%	94,37%
5	3-e5	64	93,77%	93,76%	93,77%	93,76%
5	3-e5	32	93,10%	93,09%	93,10%	93,09%
5	3-e5	16	92,25%	92,21%	92,25%	92,21%
5	4-e5	128	93,50%	93,42%	93,45%	93,42%
5	4-e5	64	93,13%	93,10%	93,13%	93,11%
5	4-e5	32	92,33%	92,30%	92,33%	92,30%
5	4-e5	16	92,04%	92,01%	92,04%	92,02%
5	5-e5	128	93,32%	93,29%	93,32%	93,29%
5	5-e5	64	92,92%	92,89%	92,92%	92,89%
5	5-e5	32	92,31%	92,27%	92,31%	92,28%
5	5-e5	16	90,71%	90,65%	90,71%	90,63%

Tabel 8 menyajikan hasil eksperimen model dengan pembagian data 80% untuk pelatihan, 10% untuk validasi, dan 10% untuk pengujian, dengan berbagai konfigurasi *hyperparameter*, termasuk jumlah *epoch*, *learning rate*, dan ukuran *batch*. Hasil terbaik dicapai dengan *learning rate* 2e-5 dan *batch size* 128, menghasilkan akurasi 94,91%, presisi 94,91%, *recall* 94,91%, dan F1 *score* 94,91%.

Kedua eksperimen menunjukkan bahwa pemilihan *hyperparameter* sangat mempengaruhi kinerja model. Hasil pada Tabel 7 dan Tabel 8 konsisten menunjukkan konfigurasi terbaik dengan *learning rate* 2e-5 dan *batch size* 128. Berdasarkan eksperimen dengan model IndoBERT, konfigurasi optimal diperoleh dengan pembagian data 80% pelatihan, 10% validasi, dan 10% pengujian, serta *hyperparameter batch size* 128, *learning rate* 2e-5, dan 5 *epoch*. Konfigurasi ini menghasilkan akurasi, presisi, *recall*, dan F1 *score* yang konsisten sebesar 94,91%. Hasil *confusion matrix* dari model terbaik dapat dilihat pada Gambar 11.



Gambar 11. *Confusion Matrix* dari Model IndoBERT dengan Performa Terbaik.

Gambar 11 memperlihatkan bahwa model berhasil mengidentifikasi 1177 sampel negatif dengan benar (*True Negative*) dan 2386 sampel positif dengan benar (*True Positive*). Kesalahan prediksi terjadi pada 99 sampel negatif yang sebagai positif (*False Positive*) dan 94 sampel positif yang diprediksi sebagai negatif (*False Negative*). Hasil ini menunjukkan bahwa model memiliki akurasi tinggi dengan kesalahan yang relatif rendah dalam mendeteksi potensi depresi.

3.7. Implementasi Model.

Untuk pengujian model, 5 data teks baru diambil secara acak dari platform X. Data *tweet* tersebut dimasukkan kedalam model untuk diprediksi atau dideteksi secara otomatis apakah teks berpotensi depresi atau tidak. Hasil deteksi bisa dilihat pada table 9.

Tabel 9. Hasil Prediksi Model Terhadap Data Baru

No	Text	Aktual	Prediksi
1	Perasaan campur aduk, kadang gelisah kadang takut	1	1
2	Akhir akhir ini sering ngerasa cemas, ntah apa yang terjadi	1	1
3	Semoga tahun ini mendapat kabar baik terus, aminn ya rab...	0	0
4	Terulang lg kesalahanku yg dulu, merasa bodoh karna belum bisa berubah	1	1
5	lagi ga ada duit, pantasan gelisahh mulu	1	1

Tabel 9 menunjukkan hasil prediksi model terhadap lima data teks baru dengan mencantumkan label aktual dan hasil prediksi model. Pada contoh pertama, "Perasaan campur aduk, kadang gelisah kadang takut," label aktual dan prediksi model adalah 1 (berpotensi depresi). Contoh kedua, "Akhir akhir ini sering ngerasa cemas, ntah apa yang terjadi," juga menunjukkan label aktual dan prediksi 1. Contoh ketiga, "Semoga tahun ini mendapat kabar baik terus, aminn ya rab...," memiliki label aktual dan prediksi 0 (normal). Dua contoh terakhir, "Terulang lg kesalahanku yg dulu, merasa bodoh karna belum bisa berubah" dan "lagi ga ada duit, pantasan gelisahh mulu," keduanya memiliki label aktual dan prediksi 1. Model menunjukkan kemampuan yang baik dalam mendeteksi potensi depresi, dengan hasil prediksi yang sesuai dengan label aktual pada kelima contoh teks baru.

4. KESIMPULAN

Model IndoBERT terbukti efektif dalam mendeteksi potensi depresi dari teks media sosial, dengan akurasi 94.91%, precision 94.91%, recall 94.91%, dan F1-score 94.91%, menjadikannya alat yang cukup andal dalam menganalisis sentimen dan kondisi mental dari teks yang diunggah pengguna media sosial. Penelitian ini mengungkapkan bahwa meskipun IndoBERT menunjukkan performa yang sangat baik, namun ada keterbatasan yang perlu diperhatikan, seperti ketergantungan pada data unggahan media sosial yang mungkin tidak sepenuhnya mencerminkan kondisi emosional pengguna karena faktor-faktor eksternal seperti privasi dan keengganan pengguna untuk mengekspresikan perasaan sebenarnya di platform publik. Selain itu, penelitian ini hanya terbatas pada analisis teks dan belum mengintegrasikan data multimodal seperti gambar atau video yang mungkin juga mengandung informasi penting tentang kondisi emosional pengguna. Untuk penelitian selanjutnya, direkomendasikan untuk mengembangkan model yang mampu mengintegrasikan data teks dan data multimodal serta melakukan validasi eksternal melalui kolaborasi dengan ahli kesehatan mental untuk memastikan akurasi dan relevansi model dalam konteks klinis. Dengan perbaikan ini, diharapkan sistem deteksi depresi berbasis *deep learning* dapat menjadi alat yang lebih efektif dalam mendukung kesehatan mental masyarakat.

REFERENCES

- [1] R. Ding and Y. Sun, “Detecting Depression in Social Media using Machine Learning,” Academy and Industry Research Collaboration Center (AIRCC), Jul. 2022, pp. 277–291. doi: 10.5121/csit.2022.121223.
- [2] World Health Organization, “Depressive disorder (depression),” World Health Organization. Accessed: Jul. 04, 2024. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/depression>
- [3] J. Philip Thekkekkara, S. Yongchareon, and V. Liesaputra, “An attention-based CNN-BiLSTM model for depression detection on social media text,” *Expert Syst Appl*, vol. 249, Sep. 2024, doi: 10.1016/j.eswa.2024.123834.
- [4] A. Del Casale, C. Zocchi, G. D. Kotzalidis, F. Fiaschè, and P. Girardi, “Prevention of Depression in Children, Adolescents, and Young Adults: The Role of Teachers and Parents,” *Psychiatry International*, vol. 2, no. 3, pp. 353–364, Sep. 2021, doi: 10.3390/psychiatryint2030027.
- [5] F. Apriliani and W. Maharani, “DEPRESSION DETECTION ON SOCIAL MEDIA TWITTER USING XLNET METHOD,” *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 1, pp. 172–180, Feb. 2023, doi: 10.29100/jupi.v8i1.3345.
- [6] A. Annadurai, P. Anand, S. R. Madhavan, and V. R. S. M., “Deep Learning for Detecting Depression: Unveiling Emotional Distress from Tweets,” in *2023 7th International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*, 2023, pp. 848–855. doi: 10.1109/I-SMAC58438.2023.10290160.
- [7] M. R. Febriansyah, Nicholas, R. Yunanda, and D. Suhartono, “Stress detection system for social media users,” in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 672–681. doi: 10.1016/j.procs.2022.12.183.
- [8] S. Islam *et al.*, “A Comprehensive Survey on Applications of Transformers for Deep Learning Tasks,” Jun. 2023, [Online]. Available: <http://arxiv.org/abs/2306.07303>
- [9] A. Roethel, M. Ganzha, and A. Wróblewska, “Enriching language models with graph-based context information to better understand textual data,” May 2023, [Online]. Available: <http://arxiv.org/abs/2305.11070>
- [10] F. Koto, A. Rahimi, J. H. Lau, and T. Baldwin, “IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP,” Online. [Online]. Available: <https://huggingface.co/>
- [11] F. Darmawan, M. Joe, Y. I. Kurniawan, and L. Afuan, “Analisis Sentimen Kemungkinan Depresi dan Kecemasan pada Twitter Menggunakan Support Vector Machine,” *Jurnal Eksplora Informatika*, vol. 13, no. 1, pp. 24–36, Sep. 2023, doi: 10.30864/eksplora.v13i1.854.
- [12] Ivan Dwi Nugraha and Y. Azhar, “Deteksi Depresi Pengguna Twitter Indonesia Menggunakan LSTM-RNN,” *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, vol. 11, no. 3, pp. 320–329, Dec. 2022, doi: 10.23887/janapati.v11i3.50674.
- [13] K. Setyo Nugroho, I. Akbar, and A. Nizar Suksmawati, “Seminar Nasional Hasil Riset Prefix-RTR DETEKSI DEPRESI DAN KECEMASAN PENGGUNA TWITTER MENGGUNAKAN BIDIRECTIONAL LSTM,” 2021.
- [14] A. A. Khaparde, R. Das, and R. Bhargava, “Transformer Based Approach for Depression Detection,” in *Proceedings - International Conference on Developments in eSystems Engineering, DeSE*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 369–374. doi: 10.1109/DeSE58274.2023.10099629.
- [15] Mohammad Kaosain Akbar and Sk. Musfique Ahmed, “A Systematic Review on Strategies of Depression Detection from Social Media,” *international journal of engineering technology and management sciences*, vol. 6, no. 5, pp. 885–897, Sep. 2022, doi: 10.46647/ijetms.2022.v06i05.136.
- [16] N. Nofiyani and W. Wulandari, “Implementasi Electronic Data Processing Untuk meningkatkan Efektifitas dan Efisiensi Pada Text Mining,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 3, p. 1621, Jul. 2022, doi: 10.30865/mib.v6i3.4332.
- [17] S. Sarica and J. Luo, “Stopwords in Technical Language Processing,” Jun. 2020, doi: 10.1371/journal.pone.0254937.
- [18] S. Islam and L. Zhang, “A Review on BERT: Language Understanding for Different Types of NLP Task,” 2024, doi: 10.20944/preprints202401.1857.v1.
- [19] Towards AI, “Understanding BERT,” Towards AI. Accessed: Jul. 03, 2024. [Online]. Available: <https://towardsai.net/p/nlp/understanding-bert>
- [20] P. Jain, W. Quamer, R. Pamula, and V. Saravanan, “SpSAN: Sparse self-attentive network-based aspect-aware model for sentiment analysis,” *J Ambient Intell Humaniz Comput*, vol. 14, Aug. 2021, doi: 10.1007/s12652-021-03436-x.
- [21] T. Wolf *et al.*, “Transformers: State-of-the-Art Natural Language Processing.” [Online]. Available: <https://github.com/huggingface/>
- [22] B. Wilie *et al.*, “IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding,” Sep. 2020, [Online]. Available: <http://arxiv.org/abs/2009.05387>
- [23] C. Sun, X. Qiu, Y. Xu, and X. Huang, “How to Fine-Tune BERT for Text Classification?,” May 2019, [Online]. Available: <http://arxiv.org/abs/1905.05583>