

## BAB II

### KAJIAN LITERATUR

#### 2.1. Tinjauan Pustaka

Pada bagian ini berisikan landasan teori dan akan dijelaskan tinjauan pustaka yang berkaitan dengan penelitian yang dilakukan.

##### 2.1.1. Deteksi Potensi Depresi

Mendeteksi potensi depresi telah menjadi semakin canggih melalui integrasi teknologi dan analisis data. Berbagai sistem dan metodologi inovatif telah muncul, dengan fokus pada indikator yang berbeda seperti ucapan, aktivitas media sosial dan isyarat non-verbal. Kemajuan ini bertujuan untuk memfasilitasi deteksi dini dan intervensi tepat waktu [4].

Mendeteksi potensi depresi melalui media sosial telah mendapatkan daya tarik karena banyaknya konten buatan pengguna yang mencerminkan keadaan emosional [5]. Studi terbaru telah menggunakan teknik *machine learning* canggih untuk menganalisis unggahan media sosial, mengungkapkan hasil yang menjanjikan dalam mengidentifikasi gejala depresi [11].

Sementara teknologi ini menunjukkan harapan dalam meningkatkan deteksi dini depresi, sangat penting untuk menyeimbangkan penerapannya dengan pertimbangan etis dan perlunya pengawasan manusia dalam perawatan kesehatan mental.

##### 2.1.2. Natural Language Processing

*Natural Language Processing* (NLP) adalah bidang multifaset yang memungkinkan komputer untuk memahami, menafsirkan dan memanipulasi bahasa manusia. Ini mencakup berbagai teknik dan aplikasi, mengubah teks tidak terstruktur menjadi data terstruktur untuk analisis. NLP dimulai dengan mengubah teks mentah menjadi format numerik, seperti vektor atau matriks, yang dapat diproses oleh algoritma. Evolusi dari representasi pembelajaran berbasis aturan ke konteks yang peka terhadap konteks ini telah secara signifikan meningkatkan pemahaman tentang aspek sintaksis dan semantik Bahasa [13].

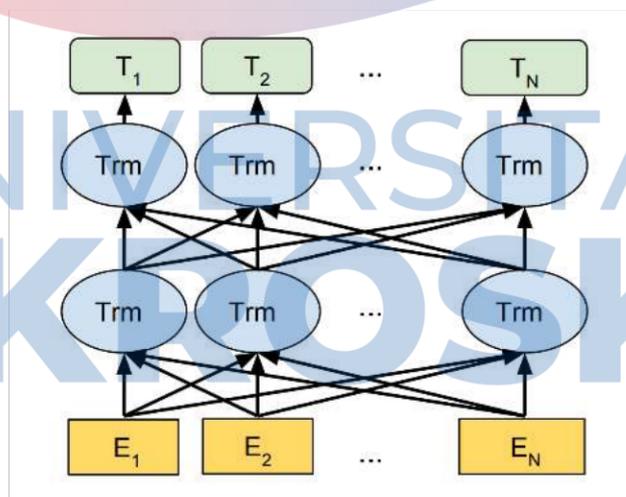
NLP diterapkan di berbagai domain, termasuk perawatan kesehatan dan geosains. Dalam perawatan kesehatan, ini membantu dalam mengekstraksi informasi klinis penting dari catatan kesehatan elektronik, meningkatkan pengambilan keputusan [14]. Dalam

geosains, teknik NLP menerjemahkan deskripsi geologi menjadi vektor numerik, memfasilitasi analisis semantik dan pemodelan prediktif.

Terlepas dari kemajuannya, NLP menghadapi tantangan, terutama dalam mengintegrasikan dengan metodologi penelitian tradisional. Validitas data digital dan kekhawatiran mengenai pendekatan prediktif tetap menjadi rintangan yang signifikan [15]. Singkatnya, sementara NLP telah membuat langkah besar dalam pemrosesan teks, integrasinya ke bidang mapan terus menghadirkan tantangan dan peluang untuk penelitian masa depan.

### 2.1.3. 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) [16]. 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 [17]. Ilustrasi arsitektur dasar model BERT ditunjukkan pada 2.1.



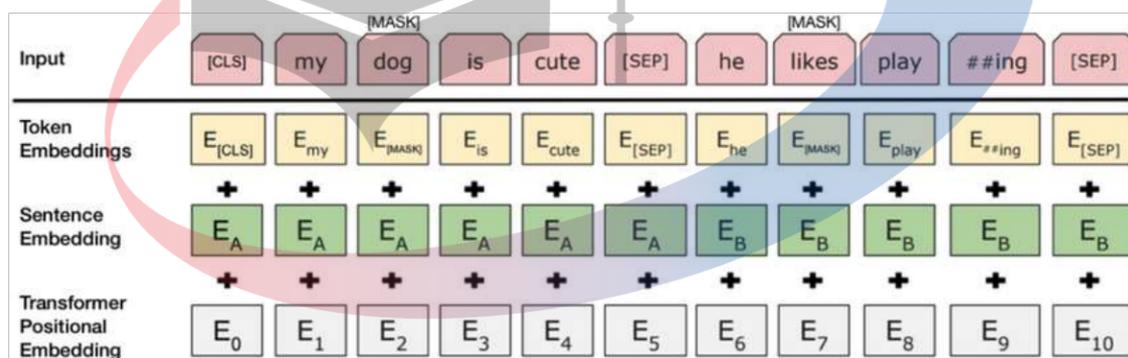
Gambar 2.1 Arsitektur Dasar Model BERT [17]

Gambar 2.1. 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 [17]. 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.

#### 2.1.4. 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 2.2. mengilustrasikan proses tokenisasi dalam BERT, termasuk token embeddings, segment embeddings, dan position embeddings.



Gambar 2.2 Proses Tokenisasi dalam Model BERT [18]

Gambar 2.2. 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 [19].

#### 2.1.5. 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 [20]. IndoBERT tersedia dalam beberapa varian, yang berbeda. Tabel 2.1. menunjukkan perbedaan utama diantara varian-varian IndoBERT tersebut.

Tabel 2.1 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 2.1. 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.

### 2.1.6. 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 2.2.

Tabel 2.2 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 2.2., 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).

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

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

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

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

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

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

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

## 2.2. Penelitian Terdahulu

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.* [21] 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.* [22] 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.

UNIVERSITAS  
MIKROSKIL