

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Landasan Teori

##### 2.1.1 Media Sosial dan TikTok sebagai Ruang Opini Publik

Media sosial telah mentransformasi cara masyarakat memproduksi, mengonsumsi, dan menyebarkan opini. Platform seperti TikTok, dengan lebih dari 160 juta pengguna aktif di Indonesia, tidak hanya menjadi sarana hiburan, tetapi juga ruang diskursus publik yang masif dan *real-time*. Kolom komentar TikTok memungkinkan pengguna mengekspresikan sikap, emosi, dan argumen terhadap berbagai isu sosial, politik, maupun budaya [8].

Studi tentang TikTok menunjukkan bahwa komentar pengguna dapat dianalisis menggunakan *sentiment analysis* untuk memetakan opini publik secara sistematis. Penelitian oleh Cheng dan Li menemukan bahwa sentimen negatif pada video berita TikTok justru meningkatkan *engagement* (*like*, komentar, *share*), mengindikasikan bahwa emosi berperan sebagai penggerak partisipasi digital [9]. Hal ini memperkuat argumen bahwa kolom komentar TikTok merepresentasikan data opini autentik yang bernilai untuk analisis kebijakan publik.

Beberapa penelitian juga memanfaatkan ulasan dan komentar TikTok (misalnya di Play Store/App Store) untuk mengukur persepsi dan kepuasan pengguna terhadap platform. Namun, analisis sentimen pada teks TikTok berbahasa Indonesia menghadapi tantangan unik: bahasa informal, slang, singkatan, dan *code-mixing* yang tinggi. Oleh karena itu, pendekatan NLP yang digunakan harus mampu menangkap konteks semantik dalam variasi linguistik tersebut [10].

Tabel Karakteristik Data Komentar TikTok untuk Analisis Sentimen ditunjukkan pada tabel 2.1 sebagai berikut:

Tabel 2. 1 Karakteristik Data Komentar TikTok untuk Analisis Sentimen

| Karakteristik | Deskripsi                                      | Implikasi untuk NLP                                                  |
|---------------|------------------------------------------------|----------------------------------------------------------------------|
| Panjang teks  | Sangat pendek ( $\leq 280$ karakter)           | Memerlukan model yang efektif untuk <i>short-text classification</i> |
| Bahasa        | Informal, slang, <i>code-mixing</i> ID-EN-Jawa | <i>Preprocessing</i> khusus + model pra-latih bahasa Indonesia       |
| Emosi         | Ekspresif, hiperbolik, sarkastik               | Diperlukan fitur pragmatik atau konteks bidireksional                |
| Volume        | Masif, <i>real-time</i>                        | Pendekatan otomatis berbasis <i>deep learning</i>                    |
| Noise         | <i>Emoji, hashtag, mention, typo</i>           | Tahap <i>cleaning</i> dan normalisasi yang <i>robust</i>             |

### 2.1.2 Dampak Sosial dan Diskursus Digital

Judi *online* (*online gambling*) di Indonesia merupakan fenomena multidimensi dengan dampak sosial-ekonomi dan psikologis yang serius. Studi oleh Kuncara dan Sudaryono serta Laras *et al.* mengidentifikasi dampak utama meliputi ketidakstabilan keuangan rumah tangga, peningkatan utang, penurunan produktivitas kerja, serta perpecahan keluarga. Kemudahan akses melalui platform digital dan promosi agresif via media sosial menjadi faktor pendorong utama meluasnya praktik ini [11].

Dalam konteks diskursus digital, media sosial menjadi ruang penyebaran informasi dan opini tentang judi *online*. Analisis jejaring komentar YouTube pada isu “Indonesia Darurat Judi *Online*” menunjukkan bahwa platform digital memfasilitasi pertukaran narasi publik, meskipun pola interaksinya cenderung satu arah (*broadcast*) ketimbang deliberatif [12].

Hal ini menegaskan pentingnya pemetaan sentimen untuk memahami persepsi masyarakat secara komprehensif. Program penyuluhan berbasis komunitas

dan edukasi digital dinilai efektif untuk meningkatkan kesadaran publik dan mitigasi dampak judi *online* [13].

Namun, efektivitas kebijakan tersebut memerlukan instrumen evaluasi berbasis data. Analisis sentimen terhadap komentar TikTok dapat menyediakan *evidence-based insight* bagi regulator dalam merancang strategi komunikasi dan intervensi yang tepat sasaran.

### 2.1.3 Analisis Sentimen dan Tantangan Teks Indonesia Informal

#### 1. Definisi dan Tujuan

Analisis sentimen adalah teknik *Natural Language Processing* (NLP) untuk mengklasifikasikan teks berdasarkan polaritas opini (positif, negatif, netral) guna memahami “suasana hati” kolektif di media sosial. Dalam konteks penelitian ini, analisis sentimen diterapkan untuk memetakan persepsi publik Indonesia terhadap judi *online* melalui komentar TikTok [14].

#### 2. Tantangan Teks Indonesia Informal

Teks media sosial berbahasa Indonesia memiliki karakteristik linguistik yang kompleks:

- a. Slang dan singkatan : “gpp”, “bgt”, “yang”, “udh”
- b. *Code-mixing* : Campuran bahasa Indonesia, Jawa, dan Inggris
- c. *Sarkasme* dan ironi : Makna tersirat yang bertentangan dengan literal teks
- d. *Noise* : *Emoji*, *hashtag*, *typo*, repetisi karakter

Pendekatan berbasis leksikon seperti *SentiWordNet* dan VADER memiliki keunggulan dalam kecepatan komputasi serta kemudahan penerapan untuk

pemetaan polaritas dasar tanpa memerlukan proses pelatihan model. Namun, kelemahannya terletak pada sifatnya yang kaku dan tidak adaptif terhadap konteks, sehingga cenderung salah mengklasifikasi teks *code-mixed* Indonesia-Jawa ketika kata bernuansa positif justru muncul dalam kalimat bernada netral atau negatif [15].

Model multibahasa seperti mBERT menawarkan kelebihan berupa fleksibilitas transfer learning lintas bahasa, yang memungkinkan analisis tanpa bergantung pada korpus tunggal yang masif. Akan tetapi, performanya menurun signifikan pada data campuran Indonesia-Inggris, di mana akurasi hanya mencapai sekitar 76% akibat tingginya kebisingan linguistik serta representasi vektor yang kurang spesifik untuk menangani struktur sintaksis lokal yang tidak baku [16].

Arsitektur berbasis *attention* dan model *deep learning* konvensional memberikan kelebihan dalam menangkap ketergantungan sekuensial antar token, sehingga lebih unggul dibanding metode statistik tradisional untuk klasifikasi teks standar. Sayangnya, metode tersebut memiliki keterbatasan mendasar saat menghadapi sarkasme dalam teks Indonesia-Inggris, yang masih memerlukan integrasi fitur pragmatik atau mekanisme konteks ekstra-kalimat agar dapat mencapai *F1-score* >94% secara konsisten [17].

### 3. *Preprocessing untuk Teks Informal*

Untuk mengatasi tantangan tersebut, diperlukan tahap *preprocessing* khusus. Penelitian oleh Tho et al. secara empiris menunjukkan bahwa ketidakhadiran tahap normalisasi dan penanganan *code-mixing* yang sistematis menyebabkan penurunan akurasi yang signifikan pada pendekatan berbasis leksikon, khususnya ketika memproses teks yang memadukan bahasa Indonesia dengan variasi bahasa daerah.

Studi tersebut menegaskan bahwa penyetaraan morfologis, penghapusan *noise* digital, dan standarisasi istilah *slang* merupakan prasyarat mutlak sebelum proses klasifikasi dilakukan. Berdasarkan temuan tersebut, alur *preprocessing* dalam penelitian ini dirancang untuk mengantisipasi bias linguistik dan menjamin konsistensi input teks.

Tabel *Pipeline Preprocessing* Teks Komentar TikTok ditunjukkan pada tabel 2.2 sebagai berikut:

Tabel 2. 2 Pipeline Preprocessing Teks Komentar TikTok

| <b>Tahap</b>                  | <b>Operasi</b>                                            | <b>Contoh Transformasi</b>                         |
|-------------------------------|-----------------------------------------------------------|----------------------------------------------------|
| <i>Cleaning</i>               | Hapus URL, <i>mention</i> , <i>hashtag</i> , <i>emoji</i> | “Cek link bit.ly/xyz ☹️ #judol” → “Cek link judol” |
| <i>Normalization</i>          | Standarkan singkatan dan slang                            | “gpp bgt sih” → “tidak apa-apa banget sih”         |
| <i>Tokenization</i>           | Pecah teks menjadi token                                  | “saya tidak setuju” → [“saya”, “tidak”, “setuju”]  |
| <i>Stopword Removal</i>       | Hapus kata umum tidak informatif                          | [“saya”, “tidak”, “setuju”] → [“tidak”, “setuju”]  |
| <i>Stemming/Lemmatization</i> | Reduksi ke bentuk dasar                                   | “berjudi”, “penjudian” → “judi”                    |
| <i>Code-mix Handling</i>      | Deteksi dan normalisasi campuran bahasa                   | “gua ga mau deh” → “saya tidak mau deh”            |

#### 2.1.4 Arsitektur Transformer dan Model BERT

##### 1. Mekanisme *Self-Attention*

Arsitektur Transformer memperkenalkan mekanisme *self-attention* yang memungkinkan model menimbang hubungan antar token dalam satu urutan tanpa ketergantungan berantai seperti RNN [18].

Rumus *scaled dot-product attention*:

$$\text{Attention}(Q, K, V) = \text{softmax} \left( \frac{QK^T}{\sqrt{d_k}} \right) V$$

di mana  $Q$  (*Query*),  $K$  (*Key*), dan  $V$  (*Value*) adalah matriks hasil proyeksi linear dari *input*, dan  $d_k$  adalah dimensi *key* untuk *scaling*.

*Multi-Head Attention* memungkinkan model menangkap berbagai tipe hubungan semantik secara paralel:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) W^O$$

$$\text{dimana } \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$$

## 2. *BERT: Bidirectional Encoder Representations from Transformers*

BERT menggunakan arsitektur Transformer *encoder* berlapis dan belajar representasi kata dengan konteks dua arah (*bidirectional*) melalui dua tugas pra-pelatihan:

- a. *Masked Language Modeling* (MLM): Memprediksi token yang di-*mask* dalam kalimat.
- b. *Next Sentence Prediction* (NSP): Memprediksi apakah dua kalimat berurutan [19].

Tabel keunggulan BERT dibanding *word embedding* statis (*Word2Vec*, *GloVe*) ditunjukkan pada Tabel 2.3 sebagai berikut:


Tabel 2. 3 Perbandingan BERT vs. Word Embedding Statis

| Aspek           | <i>Word Embedding Statis</i>                     | BERT                                             |
|-----------------|--------------------------------------------------|--------------------------------------------------|
| Konteks         | Satu representasi per kata                       | Representasi dinamis berdasarkan konteks kalimat |
| Arah            | <i>Unidirectional</i> atau <i>non-contextual</i> | <i>Bidirectional</i> (kiri-kanan)                |
| <i>Polysemy</i> | Tidak dapat membedakan makna ganda               | Dapat membedakan makna berdasarkan konteks       |

| Aspek              | <i>Word Embedding Statis</i> | BERT                                                   |
|--------------------|------------------------------|--------------------------------------------------------|
| Transfer Learning  | Terbatas                     | Sangat efektif via <i>fine-tuning</i>                  |
| Performa Tugas NLP | Moderat                      | <i>State-of-the-art</i> pada berbagai <i>benchmark</i> |

Pada tugas klasifikasi teks, *embedding* BERT digunakan sebagai lapisan masukan untuk jaringan lanjutan (misalnya BiGRU, CNN, atau lapisan klasifikasi sederhana), dan terbukti meningkatkan akurasi dibanding model berbasis *GloVe/FastText* atau CNN/RNN biasa [20].

Gambar Arsitektur Model BERT untuk klasifikasi sentimen ditunjukkan pada gambar 2.1 sebagai berikut:



Gambar 2. 1 Arsitektur BERT untuk Klasifikasi Teks

### 2.1.5 IndoBERT merupakan Pengembangan dan Keunggulan untuk Bahasa Indonesia

Bahasa Indonesia masih dikategorikan sebagai bahasa *low-resource* dalam ekosistem *Natural Language Processing* (NLP) global, utamanya akibat terbatasnya ketersediaan korpus digital terstruktur dan *dataset* beranotasi berkualitas tinggi untuk pelatihan model. Keterbatasan ini menyebabkan pendekatan pemrosesan bahasa konvensional sering kali gagal menangkap variasi

linguistik, struktur sintaksis, serta konteks semantik khas Indonesia, khususnya ketika diterapkan pada teks informal di media sosial [21].

Sebagai respons terhadap kesenjangan sumber daya tersebut, inisiatif IndoNLU mengembangkan model pra-latih (*pre-trained model*) khusus bahasa Indonesia bernama IndoBERT. Model ini dilatih menggunakan korpus teks Indonesia yang masif dan dirancang sebagai standar baku (*benchmark*) untuk berbagai tugas pemahaman bahasa alami, sehingga mampu menghasilkan representasi vektor yang lebih akurat dan sensitif terhadap konteks dibandingkan model multibahasa generik.

Seiring dengan meningkatnya kebutuhan pemrosesan teks digital yang lebih dinamis, varian seperti IndoBERTweet dan IndoLEM dikembangkan dengan fokus khusus pada data media sosial serta percakapan informal. Adaptasi ini melengkapi arsitektur dasar IndoBERT melalui penyesuaian vokabular dan pola linguistik yang dominan di platform digital, yang secara signifikan meningkatkan ketahanan model terhadap penggunaan slang, singkatan, serta karakteristik teks pendek yang tidak baku [22].

#### 1. Spesifikasi IndoBERT:

- a. Dilatih pada korpus 21 GB teks Indonesia (berita, Wikipedia, media sosial).
- b. Arsitektur: 12-layer Transformer, 768 *hidden units*, 12 *attention heads* (~110M parameters).
- c. Vokabular: 32.000 token menggunakan *WordPiece*.
- d. Tugas pra-pelatihan: MLM + NSP.

## 2. Keunggulan IndoBERT untuk Teks Informal Indonesia:

Penelitian pada teks campuran Indonesia-Jawa-Inggris menunjukkan bahwa arsitektur pra-latih monolingual seperti IndoBERT dan IndoBERTweet secara konsisten melampaui model multibahasa generik seperti mBERT dan XLM-R dalam hal presisi, *recall*, dan F1-*score*. Kapasitas model monolingual ini terbukti lebih adaptif dalam menangkap nuansa semantik lokal serta struktur *code-mixing* yang kompleks, yang tercermin dari pencapaian F1-*score* sebesar 94,14% pada tugas analisis sentimen. Meski demikian, validasi empiris pada studi tersebut masih berfokus pada konteks percakapan sosial umum, sehingga belum sepenuhnya teruji pada domain isu sensitif yang memiliki polaritas emosional ekstrem seperti judi *online* [23].

Sebelumnya, pendekatan berbasis leksikon (*lexicon-based approach*) telah diuji untuk menangani analisis sentimen pada teks campuran Indonesia-Jawa. Meskipun metode ini menawarkan kecepatan komputasi dan kemudahan interpretasi tanpa memerlukan infrastruktur pelatihan yang kompleks, sifat kamus yang statis menjadi kendala utama dalam pemrosesan konteks dinamis. Keterbatasan ini menyebabkan kesalahan klasifikasi yang signifikan, terutama ketika kata bernuansa positif muncul dalam kalimat yang secara semantik bermakna netral atau negatif pada struktur *code-mixed*.

Pada data campuran Indonesia-Inggris di platform Twitter, penerapan model *Transformer* seperti IndoBERTweet terbukti efektif dengan mencapai akurasi sekitar 76,5%. Mekanisme *transfer learning* pada model ini memungkinkan adaptasi yang lebih cepat terhadap variasi bahasa tidak baku

dan *code-mixing*, sehingga secara signifikan mengungguli pendekatan leksikon konvensional maupun *embedding* statis. Namun, implementasi pendekatan ini tetap memerlukan pertimbangan terhadap alokasi sumber daya komputasi yang lebih besar serta penyesuaian representasi vokabular agar selaras dengan karakteristik linguistik spesifik masing-masing platform media sosial.

Tabel perbandingan performa model sentimen Bahasa Indonesia ditunjukkan pada tabel 2.4 sebagai berikut:

Tabel 2. 4 Perbandingan Performa Model Sentimen Bahasa Indonesia

| <b>Model</b>       | <b><i>Dataset</i></b> | <b><i>Accuracy</i></b> | <b><i>Precision</i></b> | <b><i>Recall</i></b> | <b><i>F1-Score</i></b> |
|--------------------|-----------------------|------------------------|-------------------------|----------------------|------------------------|
| <i>Naïve Bayes</i> | Twitter ID            | 82.1%                  | 81.5%                   | 80.9%                | 81.2%                  |
| SVM + TF-IDF       | TikTok ID             | 89.7%                  | 88.9%                   | 89.1%                | 89.0%                  |
| mBERT              | Code-mixed ID-EN      | 76.0%                  | 75.8%                   | 75.3%                | 75.5%                  |
| IndoBERT           | Sentimen ID           | 91.2%                  | 90.8%                   | 91.0%                | 90.9%                  |
| IndoBERTweet       | Code-mixed ID-Jawa-EN | 93.8%                  | 94.0%                   | 94.2%                | 94.14%                 |

Hasil ini menunjukkan bahwa model pra-latih monolingual Indonesia lebih sesuai untuk menangani variasi dialek, slang, dan campuran bahasa lokal dibanding model umum multibahasa.

### 2.1.6 Teknik *Fine-Tuning* pada Model Transformer

#### 1. Konsep Transfer *Learning* dan *Fine-Tuning*

Model Transformer pra-latih seperti BERT/IndoBERT biasanya digunakan dengan pendekatan transfer *learning*: model dilatih terlebih dahulu pada tugas generik (misalnya *masked language modeling*),

kemudian di-*fine-tune* pada tugas spesifik seperti klasifikasi sentimen [23].

## 2. Proses *Fine-Tuning* untuk Klasifikasi Sentimen

- Tambahkan lapisan klasifikasi linear di atas representasi token [CLS]
- Bekukan atau *unfreeze* lapisan BERT sesuai strategi komputasi
- Latih seluruh model dengan *learning rate* kecil (biasanya 2e-5 hingga 5e-5) selama beberapa *epoch* (3–10)
- Gunakan *early stopping* berdasarkan performa pada *validation set*

Berikut adalah rumus dari Fungsi *Loss* untuk *Fine-Tuning* Klasifikasi:

$$\mathcal{L} = \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \log(\hat{y}_{i,c})$$

di mana:

$N$  = jumlah sampel dalam *batch*

$C$  = jumlah kelas sentimen (3: Positif, Netral, Negatif)

$y_{i,c}$  = label ground truth (*one-hot encoding*)

$\hat{y}_{i,c}$  = probabilitas prediksi dari lapisan *softmax*

## 3. Strategi Optimasi *Fine-Tuning*

Tabel *Hyperparameter* Rekomendasi untuk *Fine-Tuning* IndoBERT

Tabel 2. 5 Hyperparameter Rekomendasi untuk Fine-Tuning IndoBERT


| <i>Hyperparameter</i> | Nilai Rekomendasi | Justifikasi                                                    |
|-----------------------|-------------------|----------------------------------------------------------------|
| <i>Learning Rate</i>  | 2e-5 – 5e-5       | Mencegah <i>catastrophic forgetting</i> pada weights pra-latih |
| <i>Batch Size</i>     | 16 – 32           | Menyeimbangkan stabilitas gradien dan memori GPU               |

| <i>Hyperparameter</i> | <b>Nilai<br/>Rekomendasi</b> | <b>Justifikasi</b>                                                  |
|-----------------------|------------------------------|---------------------------------------------------------------------|
| <i>Epochs</i>         | 3 – 5                        | Cukup untuk konvergensi tanpa <i>overfitting</i> pada data terbatas |
| <i>Weight Decay</i>   | 0.01                         | Regularisasi untuk mencegah <i>overfitting</i>                      |
| <i>Warmup Steps</i>   | 10% dari total steps         | Stabilisasi gradien di awal pelatihan                               |
| <i>Dropout Rate</i>   | 0.1 – 0.3                    | Mengurangi <i>overfitting</i> pada lapisan klasifikasi              |

Strategi pembekuan sebagian lapisan awal (*layer freezing*) pada arsitektur Transformer direkomendasikan dalam beberapa studi sebagai pendekatan efisien untuk menghemat komputasi dan mencegah *overfitting* pada *dataset* berukuran terbatas. Dengan mempertahankan representasi linguistik umum yang telah dipelajari selama pra-pelatihan, metode ini memungkinkan konvergensi lebih cepat dan menurunkan kebutuhan memori GPU secara signifikan, sehingga cocok untuk skenario dengan sumber daya komputasi terbatas.

Di sisi lain, pada tugas klasifikasi teks pendek dan dinamis seperti komentar media sosial, penerapan *full fine-tuning* pada seluruh lapisan model terbukti lebih layak secara komputasi dan mampu menghasilkan performa optimal. Pendekatan ini memungkinkan arsitektur Transformer beradaptasi secara mendalam terhadap konteks domain target, sehingga dapat menangkap pola semantik kompleks, variasi dialek, dan struktur *code-mixed* dengan akurasi yang lebih konsisten, sebagaimana dibuktikan pada analisis sentimen teks campuran Indonesia-Jawa-Inggris [23].

Gambar alur *Fine-Tuning* IndoBERT, ditunjukkan pada gambar 2.2 sebagai berikut:



Gambar 2. 2 Diagram Alur *Fine-Tuning* IndoBERT

### 2.1.7 Metrik Evaluasi Klasifikasi Teks

Kinerja model klasifikasi sentimen dievaluasi menggunakan metrik berikut:

#### a. *Confusion Matrix*

Tabel Contoh *Confusion Matrix* 3-Kelas ditunjukkan pada tabel 2.6 sebagai berikut :

Matriks 3×3 untuk kasus 3 kelas (Positif, Netral, Negatif):

Tabel 2. 6 Contoh Confusion Matrix 3-Kelas

| Prediksi \ Aktual | Positif           | Netral            | Negatif           |
|-------------------|-------------------|-------------------|-------------------|
| Positif           | TP <sub>p</sub>   | FP <sub>pn</sub>  | FP <sub>pne</sub> |
| Netral            | FN <sub>np</sub>  | TN <sub>n</sub>   | FP <sub>ne</sub>  |
| Negatif           | FN <sub>e9p</sub> | FN <sub>e9n</sub> | TN <sub>e9</sub>  |

Rumus Metrik Evaluasi:

Berikut merupakan rumus *Accuracy*, *Precision*, *Recall*, *F1-Score* (*Binary Case*):

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{Precision} = \frac{TP}{TP + FP} \text{ (seberapa banyak prediksi positif yang benar)}$$

$$\text{Recall} = \frac{TP}{TP + FN} \text{ (seberapa banyak prediksi positif yang terdeteksi)}$$

$$\text{F1-Score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \text{ (harmonic mean)}$$

b. Untuk *Multi-Class* (3 kelas):

*Macro-average* : Rata-rata metrik per kelas (setiap kelas diberi bobot sama)

*Micro-average* : Agregasi global TP/FP/FN sebelum menghitung metrik

*Weighted-average* : Rata-rata terbobot berdasarkan *support* tiap kelas

Dalam konteks penelitian ini, *F1-score macro-average* dipilih sebagai metrik utama karena:

1. *Dataset* mungkin tidak seimbang (*imbalanced*) antar kelas sentimen.
2. *F1-score* menyeimbangkan *precision* dan *recall*, penting untuk mendeteksi sentimen minoritas (mis. negatif kritis).
3. Standar evaluasi pada penelitian sentimen bahasa Indonesia terkini [23].

Tabel Interpretasi Nilai Metrik Evaluasi ditunjukkan pada tabel 2.7 sebagai berikut :

Tabel 2. 7 Interpretasi Nilai Metrik Evaluasi

| Rentang Nilai | Interpretasi    | Tindakan Rekomendasi                                                            |
|---------------|-----------------|---------------------------------------------------------------------------------|
| $\geq 0.90$   | Sangat Baik     | Model siap <i>deploy</i> ; lakukan analisis error minor                         |
| 0.80 – 0.89   | Baik            | Optimasi <i>hyperparameter</i> atau augmentasi data                             |
| 0.70 – 0.79   | Cukup           | Evaluasi <i>preprocessing</i> atau pertimbangkan arsitektur alternatif          |
| $< 0.70$      | Perlu Perbaikan | Tinjau kualitas label, ukuran <i>dataset</i> , atau strategi <i>fine-tuning</i> |

## 2.2 Penelitian Terdahulu

Bagian ini menyajikan kajian literatur sistematis terhadap penelitian-penelitian terdahulu yang relevan dengan topik analisis sentimen, arsitektur Transformer, dan penerapannya pada media sosial berbahasa Indonesia. Tujuan utama dari tinjauan ini adalah untuk (1) mengidentifikasi kesenjangan penelitian (*research gap*) yang belum terjawab, (2) menegaskan posisi dan kebaruan (*novelty*) penelitian ini dalam peta akademik yang ada, serta (3) menghindari duplikasi yang tidak disengaja. Sesuai ketentuan *template*, matriks literatur *review* disusun berdasarkan minimal 7 penelitian berbeda yang diterbitkan dalam rentang waktu 2021–2026, dengan sumber dari jurnal ilmiah bereputasi, prosiding konferensi, atau publikasi resmi lembaga.

Tabel matriks literatur review dan posisi penelitian ditunjukkan pada tabel 2.8 sebagai berikut :

Tabel 2. 8 Matriks literatur review dan posisi penelitian

Analisis Sentimen Komentar Tiktok Terhadap Judi *Online* Di Indonesia Menggunakan *Fine-Tuning* IndoBERT

| No | Judul Penelitian                                                                          | Nama Peneliti, Tahun, Index          | Metode Penelitian                                           | Hasil                                               | Keunggulan dan Kelemahan                                                                                             | Perbandingan                                                                                                                                  |
|----|-------------------------------------------------------------------------------------------|--------------------------------------|-------------------------------------------------------------|-----------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | Implementasi Algoritma Klasifikasi untuk Analisis Sentimen Media Sosial TikTok Tahun 2025 | Manalu et al., 2025, JUTITI          | SVM + TF-IDF pada 5.000 komentar TikTok berbahasa Indonesia | Akurasi 89,7%; efektif untuk teks pendek [10]       | <b>Keunggulan:</b> Sempel dan cepat<br><b>Kelemahan:</b> Tidak menangkap konteks semantik dan ironi                  | Penelitian ini menggunakan IndoBERT untuk menangkap konteks bidireksional pada <i>dataset</i> 20× lebih besar (99.065 komentar)               |
| 2  | <i>Code-Mixed Sentiment Analysis using Transformer for Twitter Social Media Data</i>      | Astuti et al., 2023, IJACSA          | IndoBERTweet untuk data Twitter ID-EN <i>code-mixed</i>     | Akurasi 76,5%; F1 75,51% [21]                       | <b>Keunggulan:</b> Model monolingual unggul untuk <i>code-mixed</i><br><b>Kelemahan:</b> Fokus Twitter, bukan TikTok | Penelitian ini mengadaptasi IndoBERT untuk platform TikTok dengan karakteristik slang dan emoji yang lebih intensif                           |
| 3  | Dinamika Opini Publik di Media Sosial TikTok                                              | Fahrudin dan Wulandari, 2025, JUITIK | Analisis deskriptif kualitatif + sentiment lexicon          | Sentimen negatif dominan pada isu kontroversial [8] | <b>Keunggulan:</b> Memberikan insight sosiologis<br><b>Kelemahan:</b> Metode leksikon kurang akurat untuk slang      | Penelitian ini menggunakan pendekatan <i>deep learning</i> (IndoBERT) untuk akurasi klasifikasi yang lebih tinggi dan generalisasi lebih baik |

| No | Judul Penelitian                                                                                         | Nama Peneliti, Tahun, Index               | Metode Penelitian                                                             | Hasil                                                          | Keunggulan dan Kelemahan                                                                                               | Perbandingan                                                                                                                            |
|----|----------------------------------------------------------------------------------------------------------|-------------------------------------------|-------------------------------------------------------------------------------|----------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------|
| 4  | <i>Code-Mixed Sentiment Analysis on Indonesian-Javanese-English Text Using Transformer Models</i>        | Hidayatullah, 2024, ICITISEE              | Perbandingan mBERT, XLM-R, IndoBERT, IndoBERTweet                             | IndoBERTweet F1=94,14% untuk <i>code-mixed</i> ID-Jawa-EN [23] | <b>Keunggulan:</b> Benchmark komprehensif<br><b>Kelemahan:</b> <i>Dataset</i> terbatas, tidak spesifik judul           | Penelitian ini memfokuskan pada domain judi <i>online</i> dengan <i>dataset</i> spesifik TikTok, mengisi gap <i>domain-specific</i> NLP |
| 5  | <i>Social-mediated communication and network dynamics in online gambling discourse</i>                   | Siregar dan Nugroho, 2025, Front. Commun. | Social Network Analysis pada komentar YouTube “Indonesia Darurat Judi Online” | Pola interaksi satu arah; sentimen negatif mendominasi [12]    | <b>Keunggulan:</b> Perspektif jaringan sosial<br><b>Kelemahan:</b> Tidak ada klasifikasi sentimen otomatis             | Penelitian ini melengkapi dengan klasifikasi sentimen otomatis skala besar menggunakan IndoBERT untuk insight kuantitatif               |
| 6  | <i>Text Sentiment Classification Based on BERT Embedding and Sliced Multi-Head Self-Attention Bi-GRU</i> | Zhang et al., 2023, Sensors               | Hybrid BERT + Bi-GRU + Multi-Head Attention                                   | Akurasi 94,2% pada <i>dataset</i> Inggris [20]                 | <b>Keunggulan:</b> Arsitektur <i>hybrid</i> <i>powerful</i><br><b>Kelemahan:</b> Kompleks, butuh <i>resource</i> besar | Penelitian ini menggunakan <i>fine-tuning</i> IndoBERT murni untuk efisiensi komputasi dan kemudahan replikasi di konteks Indonesia     |