

Public Sentiment Analysis on Demonstration Actions Using IndoBERT Based on Transfer Learning

Ni Putu Dina Agustina^{1*}, I Dewa Ayu Pradnya Pratiwi Tentriajaya^{2*}, I Gusti Ngurah Lanang Wijayakusuma^{3*}

* Matematika, Universitas Udayana

agustina.2208541043@unud.ac.id¹, tentriajaya.2208541013@unud.ac.id², lanang_wijaya@unud.ac.id²

Article Info

Article history:

Received 2025-12-26

Revised 2026-01-14

Accepted 2026-02-10

Keyword:

BERT,
IndoBERT,
Sentiment Analysis,
Transfer Learning,
Politics,
DPR.

ABSTRACT

Sentiment analysis based on language modeling plays a crucial role in mapping public perception of socio-political dynamics in Indonesia. This study aims to evaluate public sentiment toward the House of Representatives of the Republic of Indonesia (DPR RI) in response to the August 2025 demonstrations using the IndoBERT model based on transfer learning. The dataset comprises 1,815 Indonesian-language opinion texts classified into positive and negative sentiments. Due to a substantial class imbalance dominated by negative opinions, a hybrid sampling strategy combining oversampling and undersampling was employed to obtain a balanced dataset of 650 samples per class. The research methodology included text preprocessing, an 80:20 training–testing split, and fine-tuning the IndoBERT-base-p1 model. Experimental results indicate that the proposed model achieves robust and balanced performance, with an overall accuracy of 85%. Precision and F1-score for both sentiment classes reached 0.85, while recall values were 0.86 for negative sentiment and 0.85 for positive sentiment, demonstrating the model's ability to identify both classes effectively without bias toward the majority class. Despite the dominance of negative sentiment in the original dataset, the application of data balancing techniques successfully mitigated class imbalance effects, enabling fair and proportional sentiment classification. These findings confirm that the IndoBERT-based transfer learning approach is effective in capturing public sentiment related to mass demonstrations and can provide valuable, data-driven insights for policymakers in understanding societal concerns in the digital era.



This is an open access article under the [CC-BY-SA](#) license.

I. PENDAHULUAN

Dalam beberapa bulan terakhir, Indonesia mengalami beragam protes sebagai bentuk kekecewaan terhadap kebijakan politik dan sosial pemerintah, khususnya pada Agustus 2025, aksi demonstrasi besar terjadi di depan gedung Dewan Perwakilan Rakyat Republik Indonesia (DPR RI) yang dipicu oleh kontroversi terkait tunjangan anggota DPR yang dinilai berlebihan dan tidak sesuai dengan kondisi ekonomi sebagian besar masyarakat Indonesia, ditambah kinerja DPR yang dinilai kurang memuaskan. Demonstran terdiri dari mahasiswa, pekerja dan aktivis yang menuntut pencabutan kebijakan tersebut, namun berujung pada bentrokan antara massa dengan aparat keamanan, di mana

polisi dikerahkan secara bear-besaran dan beberapa orang ditangkap dalam proses penertiban aksi masa tersebut.

Seiring dengan berlangsungnya aksi demo ini, pemberitaan dan konten terkait demonstrasi tersebar luas di berbagai platform media sosial. Media sosial tidak hanya menjadi tempat berbagi informasi, tetapi juga wadah bagi publik untuk menyuarakan ekspresi, kritik, dukungan serta reaksi emosional mereka terhadap dinamika yang terjadi di lapangan. Interaksi tersebut menghasilkan sejumlah besar teks digital yang merepresentasikan opini masyarakat secara real-time.

Dalam konteks ini, penting untuk memahami persepsi publik yang diekspresikan di media sosial. Persepsi ini dapat menunjukkan bagaimana masyarakat merespons isu besar seperti konflik sosial atau demonstrasi. Analisis seperti ini

membantu pembuat kebijakan dan pemangku kepentingan lain untuk memahami dan melihat gambaran asli opini masyarakat yang tersebar di ruang digital.

Untuk mengevaluasi kecendrungan opini masyarakat, analisis sentimen menjadi pendekatan yang tepat. Analisis sentimen merupakan bagian dari *Natural Language Processing* (NLP) yang bertujuan mengidentifikasi dan mengkategorikan informasi dalam teks menjadi label seperti positif, negatif ataupun netral [3][5][6].

Terdapat beberapa metode analisis sentimen, sebelumnya metode tradisional seperti *Naive Bayes* dan *Support Vector Machine* (SVM) sering kali gagal menangkap konteks mendalam dan makna dinamis dalam teks bahasa Indonesia yang kompleks[7][8][9]. Untuk mengatasi keterbatasan tersebut, teknologi Deep Learning berbasis arsitektur Transformer menawarkan solusi yang lebih efektif [8][10]. Salah satu model yang paling unggul adalah BERT (*Bidirectional Encoder Representations from Transformers*) yang dikembangkan oleh Google[3][5][6]. BERT memiliki kemampuan untuk memahami hubungan antar kata dalam kalimat secara dua arah (*bidirectional*), sehingga mampu menangkap konteks kalimat atau teks secara lebih akurat dibandingkan model searah [2][3][11]. Penggunaan BERT dalam bahasa Indonesia semakin optimal dengan hadirnya IndoBERT, yakni jenis model *pre-trained* yang dilatih khusus menggunakan korpus teks bahasa Indonesia yang sangat luas, mencakup data dari Wikipedia, berita, hingga media sosial [3][5][11].

Penelitian terdahulu telah banyak mengimplementasikan IndoBERT untuk berbagai tugas analisis sentimen dan membuktikan keunggulannya dibandingkan metode konvensional. Penelitian oleh Saputri et al. (2021) dan Qolbu et al. (2025) menunjukkan bahwa IndoBERT secara signifikan mengungguli model klasik seperti *Naive Bayes* dan *SVM* dalam klasifikasi sentimen pada data Twitter[3][9]. Dalam konteks perbandingan model, penelitian Ashari et al. (2025) membuktikan bahwa arsitektur *bidirectional* pada BERT menghasilkan akurasi yang lebih tinggi (79,36%) dibandingkan model GPT yang bersifat *unidirectional* (75,59%) dalam menangani teks informal[2]. Selain itu, IndoBERT telah berhasil diterapkan pada berbagai isu sensitif dan strategis. Sebagai contoh, analisis sentimen terhadap kampanye lingkungan menghasilkan akurasi sebesar 71,58%[5], isu kebijakan investasi nasional mencapai akurasi hingga 97,71% melalui teknik augmentasi data [7], dan kasus korupsi besar yang melibatkan perusahaan negara berhasil diklasifikasikan dengan akurasi 84% menggunakan model hibrida IndoBERT-RCNN[8]. Beberapa penelitian juga menyoroti bahwa penggunaan teknik Transfer Learning dan *fine-tuning* pada IndoBERT sangat penting untuk meningkatkan pemahaman model terhadap konteks lokal dan nuansa emosional dalam diskusi politik yang hangat, seperti putusan Mahkamah Konstitusi dan konflik global[4][7][12]. Meskipun demikian, terdapat tantangan pada dataset yang tidak seimbang (*imbalanced*), di mana sentimen negatif

sering kali mendominasi diskursus publik di media sosial[1][6][9].

Oleh karena itu, penelitian ini bertujuan untuk menerapkan model IndoBERT berbasis Transfer Learning untuk melakukan analisis sentimen publik terhadap aksi demonstrasi yang khususnya terjadi pada Agustus 2025. Penelitian ini memfokuskan analisis pada dinamika opini publik terkait gerakan masa yang memiliki karakteristik bahasa yang sangat emosional. Hasil dari analisis ini diharapkan dapat memberikan gambaran bagi para pemangku kebijakan dalam memahami reaksi serta kerohanian masyarakat di era digital secara akurat dan berbasis data.

II. METODE

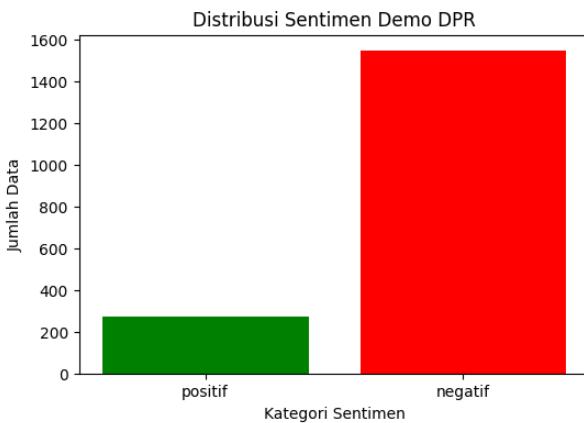
1) Dataset

Dataset yang digunakan pada penelitian ini merupakan dataset sekunder yang diperoleh dari platform Github. Dataset ini berisi teks opini masyarakat terkait aksi demonstrasi yang ditujukan kepada Dewan Perwakilan Rakyat Republik Indonesia (DPR RI) pada Agustus 2025 dengan jumlah data sebanyak 1.815 data. Setiap data berisi teks opini dan label sentimen yang mengindikasikan kecenderungan opini tersebut, yaitu positif dan negatif. Label Positif menggambarkan dukungan moral terhadap demonstran, ajakan damai atau penolakan terhadap kekerasan, dan kritik yang lebih santai, sementara label Negatif mencerminkan kemarahan, kecaman, kritik tajam atau ketidakpuasan terhadap kinerja DPR maupun aparat kepolisian. Dataset ini merupakan dataset bersih yang siap diolah atau dianalisis.



Gambar 1. Visualisasi Wordcloud

Adapun visualisasi WordCloud disajikan pada Gambar 1 digunakan untuk menampilkan kata-kata yang paling sering muncul dalam setiap kategori sentimen. Semakin besar ukuran kata pada WordCloud, semakin sering kata tersebut muncul dalam teks opini.



Gambar 2 Distribusi Sentimen Data Demo DPR

Gambar 2 menunjukkan distribusi data tiap kelas sentimen. Terlihat bahwa data pada kelas tersebut tidak seimbang, dengan jumlah data pada kelas negatif jauh lebih banyak dibandingkan dengan kelas positif. Dengan demikian, pada penelitian ini digunakan teknik penyeimbangan dataset secara hibrid yaitu oversampling dan undersampling.

2) Pre-processing Data

Adapun *pre-processing* data yang dilakukan pada penelitian ini yaitu sebagai berikut :

A. Label Encoding

Pada tahap ini, label kategori negatif dan positif diubah menjadi nilai numerik menggunakan *LabelEncoder* untuk memudahkan pemrosesan oleh model. Label 0 untuk sentimen negatif dan label 1 untuk sentimen positif.

B. Pembagian Data

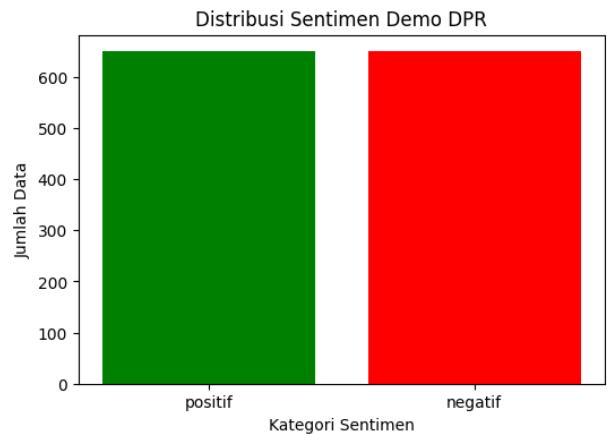
Dataset yang digunakan pada penelitian ini dibagi menjadi data latih (training set) dan data uji (testing set) dengan proporsi sebanyak 80% data latih dan 20% data uji. Untuk menjaga keseimbangan distribusi kelas pada kedua subset data, proses pembagian data dilakukan menggunakan stratified random sampling, sehingga proporsi masing-masing kelas pada data latih dan data uji tetap merepresentasikan distribusi kelas pada dataset awal. Hal ini penting untuk memastikan bahwa evaluasi model tidak bias dan dapat digeneralisasi [13].

C. Penanganan Kelas yang Tidak Seimbang

Seperti yang telah dijelaskan sebelumnya, strategi penyeimbangan data yang digunakan adalah teknik hibrid yang mengkombinasikan oversampling pada kelas minoritas dan undersampling pada kelas mayoritas. Pendekatan ini

dipilih berdasarkan temuan Chawla, N.V., dkk yang menyatakan bahwa metode hibrid menghasilkan performa klasifikasi yang lebih stabil dibandingkan penerapan teknik tunggal, karena mampu mengatasi keterbatasan masing-masing metode sekaligus[14].

Implementasi dilakukan dengan menentukan target kuantitatif spesifik sebanyak 650 sampel untuk setiap kelas. Penetapan target tetap ini penting sebagai kontrol terhadap ukuran dataset hasil penyeimbangan untuk menghindari pembengkakan data berlebihan pada oversampling atau kehilangan informasi penting pada undersampling. Strategi ini merupakan bentuk *controlled hybrid sampling* yang memberikan keuntungan ganda yaitu mempertahankan karakteristik distribusional asli melalui pengacakan sistematis, sekaligus menjamin kesetaraan numerik antar kelas[15]. Teknik hybrid sampling yang digunakan mengombinasikan random oversampling dengan mereplikasi data kelas minoritas, serta random undersampling yang dilakukan dengan mengurangi jumlah data kelas mayoritas, sehingga masing-masing jumlahnya menjadi 650. Gambar 3 menunjukkan distribusi sentimen yang telah diterapkan penyeimbangan data.



Gambar 3 Distribusi Sentimen setelah Kombinasi Oversampling dan Undersampling

D. Tokenisasi dengan IndoBERT

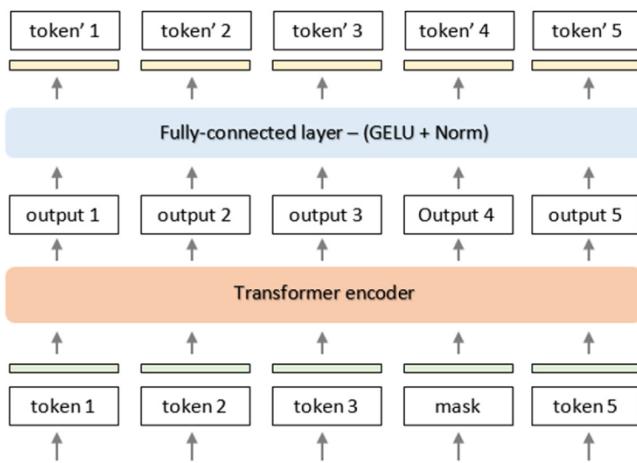
Teks hasil *pre-processing* dikonversi menjadi representasi numerik menggunakan tokenizer dari model *IndoBERT-base-p1* dengan konfigurasi: *max_length* = 128 token, *padding* = 'max_length', dan *truncation* = True. Pemilihan model ini didasarkan pada kemampuannya dalam memahami konteks bahasa Indonesia, yang diperoleh melalui pelatihan pada korpus berukuran besar.

3) Implementasi IndoBERT

Model yang digunakan dalam penelitian ini adalah model IndoBERT sebagai base model. IndoBERT adalah *pretrained language model* berbasis BERT yang telah dilatih pada korpus berbahasa Indonesia sehingga mampu memahami konteks linguistik, struktur kalimat, serta variasi penggunaan

bahasa yang berbeda-beda dalam konteks bahasa Indonesia[6][11].

IndoBERT menggunakan arsitektur transformers untuk memahami kontekstual Bahasa Indonesia [7], model ini memiliki beberapa varian, seperti IndoBERT-base dan IndoBERT-large[5] yang dibedakan berdasarkan jumlah parameter dan kedalaman lapisan transformernya. Varian *base* lebih ringan dan umum digunakan untuk tugas klasifikasi teks atau analisis sentimen dengan dataset berukuran sedang. IndoBERT *base* memiliki 12 lapisan transformer (*layers*) dan 768 dimensi vector [11].



Gambar 4 Tahap Tokenisasi IndoBERT [16]

Proses klasifikasi sentimen dengan IndoBERT dimulai dari tahap tokenisasi, Gambar 4 menunjukkan alur umum proses tokenisasi, di mana setiap token direpresentasikan sebagai vektor. Pada tahap ini, model menambahkan token khusus berupa [CLS] di awal kalimat sebagai representasi keseluruhan input, [SEP] di akhir kalimat sebagai penanda batas, serta [PAD] untuk menyamakan panjang sekuens dalam setiap batch. Seluruh token kemudian dikonversi menjadi indeks numerik berdasarkan kosakata yang telah ditetapkan oleh tokenizer IndoBERT. Token yang ditampilkan pada Gambar 4.

Indeks token selanjutnya dipetakan ke dalam ruang vektor melalui embedding yang mencakup *token embedding*, *position embedding*, dan *segment embedding*. Hasil embedding ini menjadi masukan bagi arsitektur IndoBERT, yang terdiri dari 12 lapisan encoder Transformer. Setiap lapisan dilengkapi dengan mekanisme *multi-head self-attention* yang memungkinkan model menganalisis hubungan antar-token secara bidirectional, sehingga makna setiap kata dipahami berdasarkan keseluruhan kalimat [5]. Dari keluaran encoder, model mengambil representasi vektor dari token [CLS] sebagai ringkasan informasi seluruh teks. Vektor ini kemudian diteruskan ke lapisan klasifikasi berupa *fully connected layer* untuk menghasilkan nilai *logits* sesuai jumlah kelas yang ditetapkan dalam penelitian. Terakhir, fungsi aktivasi softmax digunakan untuk mengubah logits tersebut

menjadi probabilitas kelas, sehingga model dapat menentukan label sentimen akhir dari setiap input teks.

A. Hyperparameter

Pada penelitian ini digunakan beberapa hyperparameter seperti learning rate sebesar 1×10^{-5} , batch size sebesar 16, dan jumlah epoch sebanyak 5. Penentuan nilai hyperparameter tersebut mengacu pada praktik umum fine-tuning model berbasis BERT untuk tugas klasifikasi teks.

B. Transfer Learning dan Fine Tuning

Pemanfaatan *transfer learning* memungkinkan model untuk memanfaatkan representasi bahasa yang telah dipelajari sebelumnya, sehingga proses pelatihan menjadi lebih efisien dan akurat meskipun dataset penelitian relatif terbatas. Selanjutnya, dilakukan proses *fine-tuning* terhadap model IndoBERT. Pada tahap ini, seluruh parameter model disesuaikan secara bertahap menggunakan data latih sehingga IndoBERT mampu mengenali pola sentimen lebih spesifik pada data yang digunakan. Proses *fine-tuning* dilakukan menggunakan arsitektur BertForSequenceClassification, yang menambahkan lapisan klasifikasi di atas encoder IndoBERT untuk menghasilkan prediksi label sentimen. Penelitian ini menerapkan pendekatan fully fine-tuning, di mana seluruh parameter IndoBERT dioptimalkan menggunakan data latih agar model beradaptasi secara menyeluruh terhadap karakteristik dataset.

4) Metrik Evaluasi

Evaluasi kinerja model diawali dengan menyusun confusion matriks, yakni suatu matriks yang merepresentasikan hubungan antara hasil prediksi model dan label aktual pada data uji. Matriks ini berfungsi sebagai alat untuk mengukur sejauh mana model mampu menghasilkan prediksi yang tepat dan mengidentifikasi kesalahan prediksi yang terjadi pada masing-masing kelas.

Berdasarkan informasi yang diperoleh dari confusion matriks, selanjutnya dihitung berbagai metrik evaluasi yang mencerminkan kualitas prediksi model, meliputi *accuracy*, *precision*, *recall*, dan *F1-Score*.

A. Accuracy

Accuracy diperoleh dengan menghitung proporsi prediksi yang tepat pada kelas positif maupun kelas negatif terhadap total keseluruhan data uji. Metrik ini memberikan gambaran menyeluruh mengenai tingkat ketepatan model dalam melakukan klasifikasi. Perhitungan *accuracy* dapat dilakukan dengan persamaan berikut.

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

B. Precision

Precision dihitung sebagai rasio antara jumlah prediksi positif yang benar (*true positive*) dengan seluruh prediksi yang dikategorikan sebagai positif oleh model, baik yang benar maupun yang salah. Metrik ini sangat penting terutama pada situasi ketika kesalahan klasifikasi berupa *false positive* harus diminimalkan. Perhitungan *precision* dapat dilakukan dengan persamaan berikut:

$$Precision = \frac{TP}{TP+FP}$$

C. Recall

Recall atau sensitivitas mengukur kemampuan model dalam mengenali seluruh sampel yang secara aktual termasuk dalam kelas positif. Nilai ini diperoleh dari perbandingan antara *true positive* dan total data *positif* aktual. Metrik ini krusial pada kondisi di mana terjadinya false negative memiliki konsekuensi yang signifikan. Metrik ini penting dalam konteks di mana kesalahan negatif (*false negative*) sangat merugikan. Persamaan matematis untuk *recall* yaitu sebagai berikut :

$$Recall = \frac{TP}{TP+FN}$$

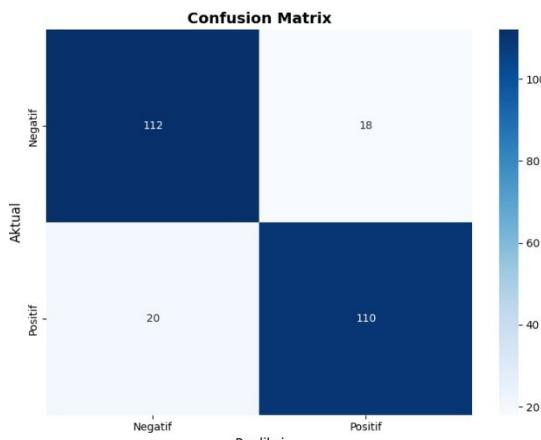
D. F1-Score

F1-Score merupakan ukuran evaluasi yang menggabungkan *precision* dan *recall* ke dalam satu nilai harmonis dengan memperhitungkan keberadaan kesalahan false positive dan false negative. Metrik ini sangat bermanfaat dalam kondisi ketidakseimbangan distribusi kelas, karena mampu memberikan representasi kinerja model yang lebih stabil. Nilai *F1-Score* akan tinggi apabila *precision* dan *recall* memiliki nilai yang sama-sama baik. Adapun rumus untuk menghitung *F1-Score* yaitu sebagai berikut:

$$F1 - Score = 2x \frac{Precision \times Recall}{Precision + Recall}$$

III. HASIL DAN PEMBAHASAN

Gambar 5 menunjukkan confusion matriks dari model IndoBERT yang telah melalui penanganan ketidakseimbangan data dengan pendekatan hybrid sampling (oversampling dan undersampling). Model berhasil mengklasifikasikan sebanyak 112 dari 130 data negatif (86.2%) dengan benar, dengan 18 data (13.8%) salah terklasifikasi sebagai positif. Sementara, pada kelas positif, model berhasil memprediksi 110 dari 130 data positif (84.61%) dengan tepat, sementara 20 data (15.39%) lainnya terdeteksi sebagai sentimen negatif.



Gambar 5. Confusion Matriks

TABEL 1.
HASIL EVALUASI MODEL INDOBERT

	Precision	Recall	F1-Score	Support
Negatif	0,85	0,86	0,85	130
Positif	0,85	0,85	0,85	130
Accuracy			0,85	

Kemudian, dilihat dari segi metrik evaluasi :

A. Precision

Nilai presisi label negatif dan positif sebesar 0,85 artinya sebanyak 85% benar-benar diprediksi sebagai negative, begitu pula untuk label positif. Hal ini mencerminkan model jarang salah menebak kelas yang diprediksi, baik negative maupun positif.

B. Recall

Nilai recall label negatif sebesar 0,86 artinya dari semua data negative, model berhasil menebak 86% sebagai negatif. Sementara untuk label positif, dari semua data positif yang sebenarnya, 85% berhasil ditebak sebagai positif. Hal ini mencerminkan model cukup baik dalam menangkap data yang benar-benar termasuk tiap kelas, dan dalam hal ini model bekerja sedikit lebih baik pada kelas negatif.

C. F1-Score

Nilai F1-Score pada kelas negatif dan positif yaitu sebesar 0,85 yang menunjukkan model seimbang dalam performa untuk kedua kelas, karena F1-Score adalah harmonis antara *precision* dan *recall* yang menunjukkan keseimbangan antara prediksi yang tepat dan kemampuan model dalam mengangkap semua data kelas tersebut.

D. Accuracy

Secara keseluruhan, akurasi model mencapai 85%, mengindikasikan bahwa sebagian besar prediksi model sesuai dengan label sebenarnya.

Berdasarkan metrik evaluasi tersebut, model memiliki performa yang cukup konsisten dan seimbang antara kelas negatif dan positif, meskipun sedikit lebih sensitif terhadap kelas negatif, tetapi perbedaannya kecil hanya 0,01 (relatif seimbang) sehingga tidak terlalu bias ke salah satu kelas.

Dominasi sentimen negatif dalam data asli memang tercermin dalam pola pembelajaran model, namun dengan teknik penyeimbangan data yang tepat, model mampu mengenali kedua kelas sentimen secara seimbang dan tidak terjebak dalam bias terhadap pola negatif.

IV. KESIMPULAN

Berdasarkan hasil evaluasi dengan confusion matriks dan metrik *precision*, *recall*, *F1-Score*, dan *accuracy*, model IndoBERT menunjukkan performa yang cukup baik dan seimbang dalam mengklasifikasikan sentimen negatif maupun positif. Model memiliki *precision* dan *F1-Score* sebesar 0,85 untuk kedua kelas, serta *recall* 0,86 untuk negatif

dan 0,85 untuk positif, menunjukkan kemampuan yang hampir seimbang dalam menebak kelas dan menangkap data aktual. Akurasi keseluruhan model mencapai 85%, menegaskan sebagian besar prediksi sudah sesuai dengan label sebenarnya. Meskipun data asli memiliki dominasi sentimen negatif, penerapan teknik penyeimbangan data membuat model tidak bias terhadap kelas negatif, sehingga mampu mengenali kedua kelas sentimen secara proporsional. Secara keseluruhan, model dapat dikatakan relatif seimbang, dengan performa sedikit lebih sensitif terhadap kelas negatif namun perbedaannya sangat kecil, sehingga analisis sentimen tetap dapat dilakukan dengan adil untuk kedua kelas.

Hasil prediksi tetap memberikan gambaran awal yang relevan mengenai arah opini publik, meskipun terdapat keseimbangan dalam dataset hasil proses, dominasi ekspresi negatif dalam data asli mencerminkan gaya penyampaian kritik yang lebih keras terhadap kinerja DPR dan aparat kepolisian yang dinilai tidak pro rakyat atau demonstran. Berdasarkan penelitian ini, diharapkan dapat dijadikan indikator penting dalam memahami respons masyarakat terhadap dinamika sosial politik terkait aksi demonstrasi tersebut. Selain itu, diharapkan dapat menjadi masukan bagi pemerintah dan DPR atau aparat kepolisian untuk lebih peka terhadap aspirasi publik, dengan memperhatikan bahwa tingginya ekspresi kekecewaan publik memerlukan penanganan melalui perbaikan kebijakan yang sigap serta evaluasi berkelanjutan agar kepercayaan masyarakat dapat pulih kembali.

DAFTAR PUSTAKA

- [1] M. Fazri and A. Voutama, "Analisis Sentimen Publik Terhadap Danantara Di Media Sosial X Menggunakan NLP dan Pembelajaran Mesin," *JOISIE (Journal Of Information Systems And Informatics Engineering)*, Vol. 9, No. 1, Pp. 197–206, 2025, doi: 10.35145/joisie.v9i1.4924.
- [2] P. Ashari, N. Mutiah, And D. Prawira, "Perbandingan Kinerja Model Deep Learning Bert Dan Gpt Dalam Analisis Sentimen Komentar Video Youtube (Studi Kasus : Film Dirty Vote)," *Jurnal Edukasi dan Penelitian Informatika*, Vol. 11, No. 1, Pp. 66–75, 2025. *Online*. Available:<http://36.95.239.66/id/eprint/3974>.
- [3] F. Sugandi, "Analisis Sentiment Masyarakat Indonesia Pada Media Sosial Terhadap Isu Ijazah Palsu Mantan Presiden Menggunakan Algoritma Berbasis Transformer (BERT)," *Journal of Science and Social Research*, Vol. 8, No.3, Pp. 4762-4768,2025,doi:<https://doi.org/10.54314/jssr.v8i3.4209>.
- [4] M. G. Al-Kadzim, Rasim, and Herbert, "Analisis Perubahan Sentimen Publik di Media Sosial X terhadap Konflik Palestina-Israel Menggunakan Model IndoBERT," *Digital Transformation Technology (Digitech)*, vol. 4, no. 2, pp. 1167–1180, Sep. 2024, doi: 10.47709/digitech.v4i2.5312.
- [5] D. E. Putro, D. Juarsa, B. P. P. Hermana, B. Bagastian, And H. Sulistiani, "Analisis Sentimen Publik Terhadap 'Save Raja Ampat ' Di Media Sosial Menggunakan Model Indobert," *Bulletin Of Computer Science Research*, vol. 5, no. 5, pp. 1067–1075, 2025, doi: 10.47065/bulletincsr.v5i5.621.
- [6] A. T. Kumara, M. Ridwan, and A. Kunaefi, "Klasifikasi Sentimen Netizen Media Sosial X terhadap Kandidat Cawapres pada Pilpres 2024 menggunakan IndoBERT," 2024.
- [7] A. Y. Pratama, G. A. Sanjaya, N. K. Lubis, And M. R. Aditya, "Analisis Sentimen Publik Terkait Danantara Menggunakan Algoritma Indobert Pada Platform Media Sosial," *Metik Jurnal*,2025, doi: 10.47002/Metik.V9i1.1055.
- [8] W. J. Kusoema and I. Ibrahim, "Analisis Sentimen dalam Kasus Korupsi PT. Pertamina menggunakan Metode IndoBERT dan RCNN," *Jurnal Sistem Informasi (SISTEMASI)*, vol. 14, no. 5, pp. 2246–2257, 2025. [Online], doi: sistemasi.ftik.unisi.ac.id
- [9] A. A. Qolbu, N. Fitriyati, and N. Inayah, "Performa Naïve Bayes , SVM , dan IndoBERT pada Analisis Sentimen Twitter IndiHome dengan Strategi Penanganan Data Tidak Seimbang," vol. 814, no. 1, pp. 29–44, 2025, doi: 10.14421/fourier.2025.141.29-44.
- [10] M. R. Nur, Y. Wibisono, and R. Megasari, "Analisis Sentimen dan Pemodelan Topik pada Post tentang Merek Teknologi di X Menggunakan Fine-tuning IndoBERT dan BERTopic," *Jurnal Kutechnology Sistem Informasi (JUKTISI)*, vol. 4, no. 2, pp. 743–750, Sep. 2025, doi: 10.62712/juktisi.v4i2.508
- [11] M. Ramdan, F. R. Umbara, And R. Ilyas, "Analisis Sentimen Pengguna Aplikasi Sambara (E-Samsat) Jawa Barat Menggunakan Metode Indobert," *Jurnal Global Ilmiah*, Vol. 2, No. 12, Pp. 1173–1182, 2025, doi: <https://doi.org/10.55324/jgi.v2i12.272>.
- [12] L. Septian, T. Aljauza, And C. Juliane, "Analisis Sentimen Putusan Mahkamah Konstitusi Terhadap Batas Usia Capres Dan Cawapres Menggunakan Indobert," *Indonesian Journal Of Computer Science*, Vol. 12, No. 1, Pp. 4428–4439, 2024, doi: 10.33022/ijcs.v12i6.3614
- [13] S. Jeyabharathy, A. Padmapriya, A. K. Sangaiah, and C. Zhang, "Stratified Sampling-Based Deep Learning Approach to Increase Prediction Accuracy of Unbalanced Dataset," *Electronics*, vol. 12, no. 21, p. 4423, 2023, doi: 10.3390/electronics12214423
- [14] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002. [Online], doi: doi.org/10.1613/jair.953
- [15] A. Fernández, S. García, F. Herrera, and N. V. Chawla, "SMOTE for Learning from Imbalanced Data: Progress and Challenges," *Journal of Artificial Intelligence Research*, vol. 61, pp. 863–905, 2018. [Online], doi: 10.1613/jair.1.11192
- [16] C. H. Miranda, G. Sanchez-Torres, and D. Salcedo, "Exploring the Evolution of Sentiment in Spanish Pandemic Tweets: A Data Analysis Based on a Fine Tuned BERT Architecture," *Data (Basel)*, vol. 8, no. 6, p. 96, May 2023. doi: 10.3390/data8060096