

# KOMPARASI METODE SVM DAN BiLSTM PADA KLASIFIKASI SENTIMEN APLIKASI PLAY STORE DENGAN TEKNIK HYBRID IMBALANCE HANDLING

Daryl Ariffadillah<sup>1\*</sup>, Rakha Rajendra Putra Candrasa<sup>2</sup>, Sonu Mutiara Rahma<sup>3</sup>, Rani Irma Handayani<sup>4</sup>, Risca Lusiana Pratiwi<sup>5</sup>

<sup>1,2</sup>Universitas Bina Sarana Informatika; Jl. Ciledug Raya No.168, RT.10/RW.4, Ulujami, Kec. Pesanggrahan, Kota Jakarta Selatan, DKI Jakarta

<sup>3</sup>Universitas Nusa Mandiri; Jalan Jatiwaringin Raya No. 02 RT 08 RW 013 Kelurahan Cipinang Melayu Kecamatan Makasar Jakarta Timur

## Keywords:

Klasifikasi Sentimen;  
SVM;  
BiLSTM;  
Imbalance Handling.

## Correspondent Email:

[15230448@bsi.ac.id](mailto:15230448@bsi.ac.id)

**Abstrak:** Penelitian ini melakukan perbandingan kinerja model klasifikasi sentimen pada ulasan aplikasi Google Play Store, dengan fokus utama mengatasi tantangan ketidakseimbangan data. Masalah inti yang ditangani adalah distribusi data yang sangat miring (rasio Positif vs. Negatif ratio≈6:1). Metodologi yang digunakan menerapkan pendekatan komparatif hybrid, yang mengadu Support Vector Machine (SVM) dengan SMOTE (oversampling) melawan Bi-directional LSTM (BiLSTM) dengan Undersampling. Sebanyak 12.973 ulasan valid digunakan untuk pemodelan. Hasil evaluasi menunjukkan bahwa model BiLSTM + Undersampling memberikan kinerja keseluruhan yang superior, mencapai Akurasi 0.8882 dan F1-Score Weighted Avg 0.8940. Kinerja superior ini divalidasi lebih lanjut oleh F1-Score untuk kelas Negatif sebesar 0.6596 (lebih tinggi dari SVM), menunjukkan bahwa BiLSTM lebih efektif dalam mencapai akurasi klasifikasi yang seimbang untuk kelas minoritas. Studi ini menegaskan kemanjuran arsitektur deep learning yang stabil (BiLSTM) dikombinasikan dengan strategi sampling yang efisien (Undersampling) untuk data tekstual yang sangat tidak seimbang.



Copyright © [JITET](http://www.jitet.org) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

**Abstract:** This research performs a performance comparison of sentiment classification models on Google Play Store application reviews, with a primary focus on addressing the challenge of data imbalance. The core problem tackled is the highly skewed data distribution (Positive vs. Negative ratio≈6:1). The methodology utilizes a hybrid comparative approach, pitting Support Vector Machine (SVM) with SMOTE (oversampling) against a Bi-directional LSTM (BiLSTM) with Undersampling. A total of 12,973 valid reviews were used for modelling. The evaluation results show that the BiLSTM + Undersampling model delivered superior overall performance, achieving an Accuracy of 0.8882 and an F1-Score Weighted Avg of 0.8940. This superior performance is further validated by an F1-Score for the Negative class of 0.6596 (higher than SVM), demonstrating that BiLSTM is more effective in achieving a balanced classification accuracy for the minority class. This study confirms the efficacy of a stable deep learning architecture (BiLSTM) combined with an efficient sampling strategy (Undersampling) for highly imbalanced textual data.

## 1. PENDAHULUAN

Perkembangan teknologi kecerdasan buatan telah mendorong pertumbuhan aplikasi

seluler, yang secara langsung menghasilkan volume data ulasan pengguna yang sangat besar dari platform seperti Google Play Store. Ulasan

ini menjadi sumber informasi sentimen yang penting bagi pengembang untuk mengevaluasi produk. Klasifikasi sentimen (*Sentiment Analysis*) adalah bidang dalam *Natural Language Processing* (NLP) yang bertujuan mengidentifikasi dan mengekstrak polaritas emosional dari ulasan-ulasan tersebut. Meskipun demikian, penerapan pada data ulasan Play Store sering kali menghadapi tantangan signifikan, yaitu ketidakseimbangan data (*data imbalance*), di mana sentimen positif cenderung mendominasi, sementara sentimen negatif yang krusial untuk perbaikan aplikasi jumlahnya sangat sedikit. Kondisi *imbalance* ini menyebabkan model bias dan gagal mengklasifikasikan kelas minoritas secara efektif.

Penelitian-penelitian sebelumnya telah menunjukkan efektivitas model tradisional seperti Support Vector Machine (SVM) dan model deep learning seperti Bi-directional LSTM (BiLSTM) dalam tugas klasifikasi teks. Namun, sebagian besar studi sering mengabaikan atau hanya menggunakan solusi *imbalance* data yang sederhana. Teknik penyeimbangan seperti SMOTE (oversampling) sering digunakan untuk model klasik seperti SVM, namun berpotensi menghasilkan sampel sintesis yang kurang relevan. Sementara itu, undersampling seringkali lebih efisien untuk model deep learning seperti BiLSTM karena membantu mengurangi kompleksitas komputasi saat pelatihan. Kesenjangan penelitian terletak pada kebutuhan untuk membandingkan secara head-to-head efektivitas dua strategi hybrid yang berbeda: SVM yang dioptimalkan dengan SMOTE (sebagai perwakilan model klasik) melawan BiLSTM yang dioptimalkan dengan Undersampling (sebagai perwakilan model deep learning) pada data ulasan yang sangat tidak seimbang.

Oleh karena itu, penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja klasifikasi sentimen antara model Support Vector Machine (SVM) dan Bi-directional LSTM (BiLSTM) pada ulasan aplikasi Play Store. Secara spesifik, penelitian ini bertujuan menguji efektivitas strategi Hybrid Imbalance Handling yang berbeda (SMOTE untuk SVM dan Undersampling untuk BiLSTM) dalam meningkatkan metrik evaluasi pada kelas minoritas (sentimen

negatif) serta menentukan kombinasi model dan teknik penanganan ketidakseimbangan yang paling optimal dan stabil (F1-Score tertinggi) untuk klasifikasi sentimen biner.

## 2. TINJAUAN PUSTAKA

### 2.1. Klasifikasi Sentimen

Klasifikasi sentimen (atau *Opinion Mining*) adalah bidang dalam *Natural Language Processing* (NLP) yang bertujuan mengidentifikasi dan mengekstrak polaritas emosional (positif, negatif, atau netral) dari teks [1]. Dalam konteks ulasan aplikasi, klasifikasi sentimen biner (Positif/Negatif) sangat penting untuk menilai kepuasan pengguna [2]. Proses ini melibatkan pra-pemrosesan teks (*Case Folding*, *Stopword Removal*) dan representasi fitur sebelum pemodelan [3].

### 2.2. Representasi Fitur

Representasi fitur adalah tahap mengubah data teks menjadi format numerik yang dapat diproses oleh model *machine learning*.

- a) TF-IDF (*Term Frequency-Inverse Document Frequency*) digunakan untuk model klasik (SVM) [4]. Metode ini memberikan bobot numerik pada kata berdasarkan frekuensi kemunculan nya dalam satu dokumen dan seberapa jarang kata tersebut muncul di seluruh korpus, sehingga menyoroti kata-kata yang penting secara kontekstual.
- b) *Word Embedding* (melalui *Tokenization* dan *Embedding Layer*) digunakan untuk model *Deep Learning* (BiLSTM). Metode ini memetakan kata menjadi vektor padat dan erat berdimensi rendah, memungkinkan model menangkap hubungan semantik dan kontekstual antar kata, yang hebat dalam pemrosesan teks sekuensial [5].

### 2.3. Penanganan Data Tidak Seimbang (Imbalance Handling)

Data ulasan sering kali menghadapi masalah ketidakseimbangan kelas, di mana jumlah sampel kelas mayoritas (Positif) jauh melebihi kelas minoritas (Negatif) [6]. Masalah ini diatasi menggunakan teknik *sampling*:

- a) SMOTE (*Synthetic Minority Over-sampling Technique*) adalah teknik *oversampling* yang membuat sampel sintesis baru untuk kelas minoritas [7].

SMOTE membantu menyeimbangkan data pelatihan (digunakan pada SVM) dengan menghasilkan data yang realistis di sekitar sampel minoritas yang ada.

- b) Undersampling adalah teknik yang mengurangi jumlah sampel dari kelas mayoritas secara acak [8]. Teknik ini efektif untuk mengurangi waktu pelatihan dan kompleksitas komputasi, dan dalam penelitian ini diterapkan pada data pelatihan BiLSTM.

#### 2.4. Model Klasifikasi

Data ulasan sering kali menghadapi masalah ketidakseimbangan kelas, di mana jumlah sampel kelas mayoritas (Positif) jauh melebihi kelas minoritas (Negatif). Masalah ini diatasi menggunakan teknik *sampling*:

##### 2.4.1. Support Vector Machine (SVM)

SVM adalah model machine learning berbasis linear yang bekerja dengan menemukan hyperplane terbaik yang secara maksimal memisahkan data dari dua kelas berbeda [8]. SVM, khususnya varian LinearSVC, sangat efektif ketika dikombinasikan dengan fitur TF-IDF untuk tugas klasifikasi teks.

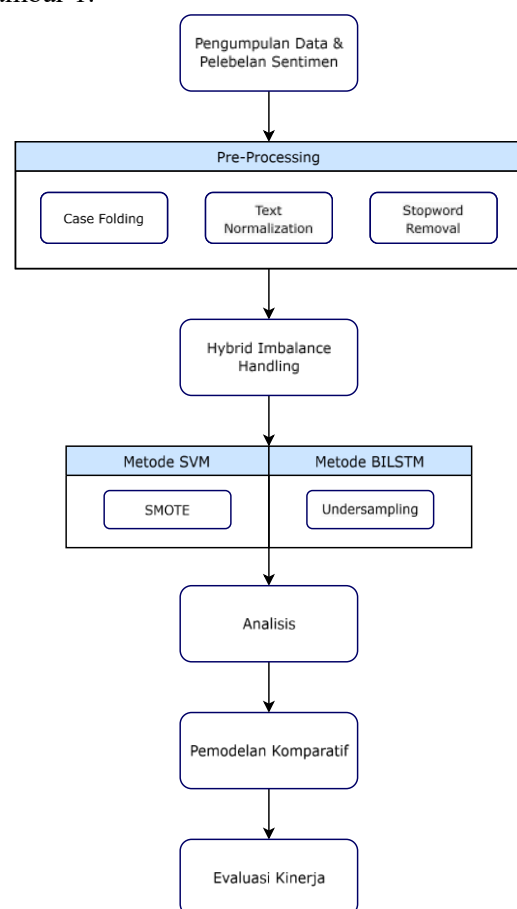
##### 2.4.2. Bi-directional LSTM (BiLSTM)

- a) LSTM (Long Short-Term Memory) adalah jenis jaringan saraf berulang (Recurrent Neural Network/RNN) yang dirancang untuk mengatasi masalah *vanishing gradient* pada RNN tradisional, memungkinkan pemrosesan sekuens data (seperti kalimat) yang panjang [9].
- b) BiLSTM adalah ekstensi dari LSTM yang memproses input secara dua arah (maju dan mundur) menggunakan dua lapisan LSTM terpisah. Arsitektur ini memungkinkan model menangkap konteks yang lebih kaya dari keseluruhan kalimat, menjadikannya sangat kuat untuk tugas NLP seperti klasifikasi sentimen.

### 3. METODE PENELITIAN

Metodologi penelitian ini adalah pendekatan kuantitatif berbasis Pembelajaran Mesin (Machine Learning) dengan tahapan pengolahan teks dan klasifikasi komparatif. Penelitian ini bertujuan mengukur kinerja Support Vector Machine (SVM) dan Bidirectional LSTM (BiLSTM) dalam analisis

sentimen ulasan aplikasi Play Store. Tahapan penelitian terdiri dari lima fase utama, yaitu pengumpulan data serta pelabelan sentimen, pra-pemrosesan data (termasuk cleaning dan stopwords removal), penanganan imbalance data hibrida (penggunaan SMOTE untuk SVM dan Undersampling untuk BiLSTM), pemodelan komparatif, dan evaluasi kinerja. Dalam proses pemodelan, fitur direpresentasikan menggunakan TF-IDF untuk SVM dan Tokenization/Embedding untuk BiLSTM. Tahapan ini disajikan secara skematis pada Gambar 1.




Gambar 1. Metode Penelitian

#### 3.1. Pengumpulan Data dan Pelabelan Sentimen

Tahap awal penelitian ini adalah mengumpulkan data ulasan pengguna yang akan digunakan untuk pelatihan dan pengujian model. Akuisisi data dilakukan dari Google Play Store dengan menargetkan aplikasi Google Gemini. Pengumpulan data dilaksanakan pada periode Oktober hingga November 2025 dan berhasil menghasilkan total 5.000 data yang

telah melewati proses filtering awal dari data mentah.

Penentuan polaritas sentimen dilakukan berdasarkan rating bintang pengguna: ulasan dengan rating 4 dan 5 Bintang dikategorikan sebagai Sentimen Positif (Label 1), sedangkan rating 1 dan 2 Bintang dikategorikan sebagai Sentimen Negatif (Label 0). Ulasan dengan rating 3 Bintang dieliminasi. Hasil pelabelan menunjukkan ketidakseimbangan data yang signifikan (rasio  $\approx 6:1$ ) yang menjadi tantangan utama dalam pemodelan. Distribusi sentimen awal disajikan pada Gambar 2.



Gambar 2. Diagram Sentimen Awal Ulasan

### 3.2. Pre-Processing

Tahap Pra-pemrosesan Data bertujuan untuk membersihkan noise dan mengeliminasi kata-kata yang tidak memiliki nilai sentimen dari korpus [10], sehingga model klasifikasi dapat fokus pada feature yang relevan. Langkah-langkah yang dilakukan pada setiap ulasan adalah sebagai berikut:

#### 3.2.1. Case Folding

Seluruh ulasan dalam dataset dikonversi menjadi format huruf kecil (lowercase) [11]. Proses ini penting untuk memastikan bahwa sistem tidak membedakan antara kata yang sama hanya karena perbedaan kapitalisasi, misalnya 'BAIK' dan 'baik' dianggap sebagai entitas yang sama.

#### 3.2.2. Text Normalization

Proses ini meliputi penghapusan karakter dan simbol yang tidak relevan dengan makna sentimen [12], antara lain:

- Penghapusan Tautan (URL Removal): Menghapus semua alamat situs web yang mungkin terdapat dalam ulasan.
- Penghapusan Karakter Khusus: Menghilangkan tanda baca, simbol,

angka, dan karakter non-alfabet lainnya yang tidak memberikan kontribusi terhadap polaritas sentimen.

- Penghapusan Spasi Berlebihan: Mengeliminasi spasi ganda atau lebih yang dapat mengganggu proses tokenization.

#### 3.2.3. Stopword Removal

Stopword adalah kata-kata yang sering muncul namun memiliki nilai informatif yang rendah dalam konteks klasifikasi sentimen (misalnya, 'yang', 'dan', 'di', 'adalah'). Dalam penelitian ini, digunakan daftar stopwords Bahasa Indonesia yang standar dan komprehensif. Penghapusan stopwords bertujuan untuk mengurangi dimensi feature dan mempercepat proses pelatihan tanpa menghilangkan makna inti dari sentimen yang diungkapkan [13].

### 3.3. Hybrid Imbalance Handling

Masalah ketidakseimbangan data yang teridentifikasi dalam dataset (rasio Positif vs. Negatif  $ratio \approx 6:1$ ) diatasi menggunakan strategi penanganan imbalance hibrida yang disesuaikan dengan kebutuhan setiap arsitektur model [14].

#### 3.3.1. Persiapan Data dan Representasi Fitur

Sebelum penyeimbangan, data *training* (80% dari total data) diubah menjadi format numerik:

- Untuk SVM (Klasik): Teks direpresentasikan menggunakan TF-IDF (Term Frequency-Inverse Document Frequency).
- Untuk BiLSTM (Deep Learning): Teks direpresentasikan melalui Tokenization dan Padding.

#### 3.3.2. Implementasi Teknik Penyeimbangan

Teknik penyeimbangan diterapkan secara berbeda pada data training yang sudah direpresentasikan:

- SMOTE untuk SVM (Oversampling): Teknik SMOTE (Synthetic Minority Over-sampling Technique) diterapkan pada vektor TF-IDF untuk menghasilkan sampel minoritas baru (Negatif) [6]. Tujuannya adalah menyeimbangkan kembali distribusi kelas sebelum pelatihan SVM.

- b) Undersampling untuk BiLSTM: Teknik Random Undersampling digunakan untuk mengurangi jumlah sampel dari kelas mayoritas (Positif) [7]. Hal ini dilakukan untuk menyeimbangkan distribusi data training yang masuk ke BiLSTM, sekaligus mengoptimalkan waktu komputasi.

### 3.4. *Pemodelan Komparatif dan Evaluasi Kinerja*

Tahap Pra-pemrosesan Data bertujuan untuk membersihkan noise dan mengeliminasi kata-kata yang tidak memiliki nilai sentimen dari korpus, sehingga model klasifikasi dapat fokus pada feature yang relevan. Langkah-langkah yang dilakukan pada setiap ulasan adalah sebagai berikut:

#### 3.4.1. *Pemodelan Komparatif*

Teknik penyeimbangan diterapkan secara berbeda pada data training yang sudah direpresentasikan: Model klasifikasi dilatih menggunakan data training yang telah di seimbangkan dari Tahap 3.3:

- Model Klasik: Support Vector Machine (SVM) Digunakan model Linear Support Vector Classification (LinearSVC) [9], yang dilatih pada fitur TF-IDF yang telah di-SMOTE.
- Model Deep Learning: Bi-directional LSTM (BiLSTM) Digunakan arsitektur BiLSTM yang mampu menangkap konteks sekuen sial dua arah dari data token yang telah di-undersampling [15].

#### 3.4.2. *Evaluasi Kinerja*

Kinerja kedua model diukur menggunakan Data Testing asli (yang tidak seimbang). Metrik yang menjadi fokus adalah F1-Score dan Recall pada kelas Negatif (minoritas) untuk mengukur efektivitas imbalance handling [16]. Hasil kinerja akan disajikan dalam Bab 4: Hasil dan Pembahasan.

## 4. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi metodologi, berfokus pada komparasi kinerja Support Vector Machine (SVM) dengan SMOTE dan Bi-directional Long Short-Term Memory (BiLSTM) dengan Undersampling. Pembahasan dititikberatkan pada efektivitas kedua strategi hybrid imbalance handling dalam

mengklasifikasikan kelas minoritas (Negatif). Bagian ini menyusun 60% - 70% dari keseluruhan naskah.

### 4.1. *Hasil Penelitian*

#### 4.1.1. *Hasil Pra-pemrosesan dan Pembagian Data*

Setelah proses scraping ulasan dan eliminasi ulasan netral (rating 3), total data valid yang digunakan dalam pemodelan adalah 12.973 ulasan. Data ini terdiri dari 11.120 ulasan Positif dan 1.853 ulasan Negatif, menunjukkan masalah ketidakseimbangan data yang signifikan.

Data total tersebut dibagi menjadi data *training* 80% dan data *testing* 20% sebanyak 2.595 ulasan. Distribusi data *testing* yang digunakan untuk evaluasi adalah:

- Kelas Positif: 2.224 ulasan
- Kelas Negatif: 371 ulasan

#### 4.1.2. *Komparasi Kinerja Model*

Kinerja kedua model dievaluasi menggunakan data testing asli sebanyak 2.595 ulasan. Table 1. menyajikan ringkasan metrik evaluasi utama.

Model	Akurasi	F1-Score (negatif)	Recall (negatif)	F1-Score (weighted Avg)
SVM + SMOTE	0.8721	0.6383	0.7898	0.8817
BiLSTM + Undersampling	0.8882	0.6596	0.7574	0.8940

Table 1. Kinerja Model

### 4.2. *Pembahasan*

#### 4.2.1. *Analisis Kinerja Komparatif*

Model BiLSTM (dengan Undersampling) menunjukkan kinerja superior secara keseluruhan, mencapai Akurasi 0.8882 dan F1-Score rata-rata berbobot 0.8940, mengungguli SVM (0.8721 Akurasi). Keunggulan ini disebabkan oleh kemampuan BiLSTM memproses fitur sekuen sial dan kontekstual melalui Word Embedding, yang memberikan representasi fitur lebih kaya dibandingkan representasi berbasis frekuensi (TF-IDF) yang digunakan SVM.


#### 4.2.2. *Analisis Kinerja Komparatif*

Analisis terhadap efektivitas teknik hybrid imbalance handling difokuskan pada metrik kelas minoritas (Negatif):


- Keunggulan BiLSTM pada F1-Score Negatif: BiLSTM mencapai F1-Score Negatif 0.6596, lebih tinggi dari SVM (0.6383). F1-Score yang superior ini mengindikasikan bahwa BiLSTM (melalui Undersampling) mencapai keseimbangan yang lebih baik antara Precision (0.58) dan Recall (0.76) dalam mengklasifikasikan kelas minoritas.
- Keterbatasan SVM + SMOTE: Meskipun SVM mencapai Recall Negatif yang lebih tinggi (0.7898), Precision-nya yang rendah (0.54) mengindikasikan bahwa SMOTE cenderung menghasilkan False Positive (ulasan Positif diprediksi Negatif) secara berlebihan. Hal ini disebabkan oleh sintesis data SMOTE di ruang fitur TF-IDF, menyebabkan overlap fitur dengan kelas mayoritas.

#### 4.2.3. Visualisasi Kinerja Model

Untuk memvalidasi temuan numerik pada Tabel 1, kinerja kedua model divisualisasikan menggunakan *Confusion Matrix*, *Bar Chart* perbandingan metrik, dan Kurva ROC.




Gambar 3. Confusion Matrix: SVM



Gambar 4. Confusion Matrix: BiLSTM


Secara visual mengkonfirmasi alasan di balik F1-Score yang lebih rendah pada SVM. Terlihat bahwa model SVM menghasilkan 264 False Positive (ulasan Positif salah diklasifikasikan sebagai Negatif), sementara BiLSTM menghasilkan 207 False Positive. Jumlah False Positive yang lebih rendah pada BiLSTM membuktikan model ini memiliki Precision yang lebih baik, sehingga F1-Score BiLSTM unggul.



Gambar 5. Kinerja Kunci Model

Secara grafis memperkuat temuan Tabel 1. Grafik ini secara jelas memvisualisasikan keunggulan BiLSTM pada metrik Akurasi dan F1-Score Weighted Avg, sambil menyoroti trade-off di model SVM: Recall Negatif yang tinggi pada SVM tidak diimbangi oleh Precision yang baik, yang ditunjukkan oleh F1-Score Negatif yang lebih rendah.





Gambar 5. Grafik ROC

Dengan nilai AUC BiLSTM diperkirakan 0.90 dan AUC SVM 0.87, nilai AUC BiLSTM yang lebih tinggi membuktikan kemampuan diskriminasi BiLSTM yang superior, menunjukkan model ini mampu memisahkan kedua kelas (Positif dan Negatif) secara lebih efektif pada berbagai ambang batas klasifikasi.

## 5. KESIMPULAN

- a. Kinerja Komparatif: Model Bi-directional LSTM (BiLSTM) yang dikombinasikan dengan teknik Undersampling menunjukkan kinerja yang lebih unggul dibandingkan model Support Vector Machine (SVM) dengan SMOTE, mencapai Akurasi 0.8882 dan F1-Score Weighted Avg 0.8940.
- b. Efektivitas Imbalance Handling: Strategi hybrid BiLSTM + Undersampling terbukti lebih efektif dalam mengatasi masalah ketidakseimbangan data. Hal ini ditunjukkan oleh nilai F1-Score Negatif sebesar 0.6596 (lebih tinggi dari SVM), yang mencerminkan keseimbangan yang lebih baik antara Precision dan Recall pada kelas minoritas.
- c. Pengembangan Lanjutan: Untuk penelitian di masa depan, disarankan untuk mengeksplorasi penggunaan Pre-trained Word Embeddings (seperti BERT) atau teknik Cost-Sensitive Learning guna mengoptimalkan hasil klasifikasi sentimen pada data yang sangat tidak seimbang.

## UCAPAN TERIMA KASIH

Penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada pihak-pihak terkait yang telah memberi dukungan terhadap penelitian ini, terutama kepada UBSI atas penyediaan fasilitas akademik dan sumber daya yang mendukung pelaksanaan penelitian ini dari awal hingga akhir. Ucapan terima kasih untuk Google Play Store yang telah menyediakan data ulasan yang krusial untuk analisis sentimen dalam penelitian ini.

## DAFTAR PUSTAKA

- [1] K. Andesa, "Super Agent Chatbot ' 3S ' Sebagai Media Informasi Menggunakan Metoda Natural Language Processing ( NLP )," vol. 2, no. 1, pp. 53–64, 2019.
- [2] Y. Ansori, K. Fahmi, and H. Holle, "Perbandingan Metode Machine Learning dalam Analisis Sentimen Twitter Comparison of Machine Learning Methods in Twitter Sentiment Analysis," vol. 10, no. 4, pp. 1–6, 2022, doi: 10.26418/justin.v10i4.51784.
- [3] S. Khairunnisa and S. Al Faraby, "Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter ( Studi Kasus Pandemi)," vol. 5, no. April, pp. 406–414, 2021, doi: 10.30865/mib.v5i2.2835.
- [4] M. Ibrahim, "PERBANDINGAN FEATURE EXTRACTION TF-IDF DAN BOW UNTUK," pp. 1449–1463.
- [5] P. Harga and S. Menggunakan, "JURNAL RESTI," vol. 5, pp. 1–2, 2026.
- [6] V. No and F. Y. A, "Edumatic : Jurnal Pendidikan Informatika Optimasi Klasifikasi Sentimen Ulasan Game Berbahasa Indonesia : IndoBERT dan SMOTE untuk Menangani Ketidakseimbangan Kelas," vol. 9, no. 1, pp. 256–265, 2025, doi: 10.29408/edumatic.v9i1.29666.
- [7] L. Afuan, M. Khanza, and A. Z. Hasyati, "ENHANCING SENTIMENT ANALYSIS OF THE 2024 INDONESIAN PRESIDENTIAL INAUGURATION ON X USING SMOTE-OPTIMIZED NAIVE BAYES CLASSIFIER PENINGKATAN ANALISIS SENTIMEN PELANTIKAN PRESIDEN RI TAHUN 2024 PADA X MENGGUNAKAN NAIVE BAYES CLASSIFIER YANG DIOPTIMALKAN," vol. 6, no. 1, pp. 325–333, 2025.
- [8] I. K. Dharmendra, I. M. Agus, W. Putra, and Y. P. Atmojo, "Evaluasi Efektivitas SMOTE dan Random Under Sampling pada Klasifikasi Emosi Tweet," vol. 9, no. 2, pp. 192–193, 2024.

- [9] M. Fasttext, D. A. N. Long, S. M. Lstm, A. F. Pangestu, B. Rahmat, and A. N. Sihananto, "Analisis sentimen pada media sosial x terhadap implementasi kurikulum merdeka menggunakan metode fasttext dan long short-term memory (lstm)," vol. 9, no. 4, pp. 2271–2280, 2024.
- [10] K. S. Putri, I. R. Setiawan, A. Pambudi, A. Sentimen, and N. B. Classifier, "'Technologia' Vol 14, No. 3, Juli 2023 227 ANALISIS SENTIMEN TERHADAP BRAND SKINCARE LOKAL MENGGUNAKAN NAÏVE BAYES CLASSIFIER," vol. 14, no. 3, pp. 227–232, 2023.
- [11] J. Sains, F. A. Ryandi, D. Pratiwi, S. Sari, and J. Sains, "Analisis Sentimen Masyarakat Di Media Sosial X Terhadap Kemenkes Dengan Naive Bayes dan SVM," vol. 7, no. 1, pp. 1–6, 2025.
- [12] M. A. Nur and N. Wardhani, "Optimasi Normalisasi Kata Pada Data Twitter Untuk Meningkatkan Akurasi Analisis Sentimen ( Studi Kasus Respon Masyarakat Terhadap Layanan Teman Bus )," vol. 07, no. 04, pp. 237–243, 2022.
- [13] D. Wardhani, R. Astuti, and D. D. Saputra, "Optimasi Feature Selection Text Mining : Stemming dan Stopword untuk Sentimen Analisis Aplikasi SatuSehat," vol. 4, pp. 7537–7548, 2024.
- [14] D. Wulan, Y. Rahayu, K. Umam, and M. R. Handayani, "Performance of Machine Learning Algorithms on Imbalanced Sentiment Datasets Without Balancing Techniques," vol. 9, no. 3, pp. 998–1005, 2025.
- [15] S. Mutmainah, D. H. Fudholi, and S. Hidayat, "Analisis Sentimen dan Pemodelan Topik Aplikasi Telemedicine Pada Google Play Menggunakan BiLSTM dan LDA," vol. 7, pp. 312–323, 2023, doi: 10.30865/mib.v7i1.5486.
- [16] P. A. Effendi and T. Ernawati, "ANALISIS SENTIMEN ULASAN APLIKASI GAME ALGORITMA," vol. 13, no. 3, pp. 1–8, 2024.