



Comparative Analysis of IndoBERT and TF-IDF Performance in Classifying EDOM Sentiments Using the K-Nearest Neighbor Algorithm

Analisis Perbandingan Kinerja IndoBERT dan TF-IDF dalam Mengklasifikasikan Sentimen EDOM Menggunakan Algoritma K-Nearest Neighbor

Tiffany Nabarian¹, Siti Nurhalizah^{2*}, Salman El Farisi³

^{1,2,3}Program Studi Teknik Informatika, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Indonesia

E-Mail: ¹nabarian@nurulfikri.ac.id,

²siti22224ti@student.nurulfikri.ac.id, ³salman@nurulfikri.ac.id

Received Feb 02nd 2026; Revised Mar 18th 2026; Accepted Apr 07th 2026; Available Online Apr 20th 2026

Corresponding Author: Siti Nurhalizah

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

In higher education, lecturers contribute significantly to improving the quality of learning. At Sekolah Tinggi Teknologi Terpadu Nurul Fikri (STT NF), the Lecturer Evaluation by Students (EDOM) is conducted at the end of each semester, yielding substantial student comment data. However, the analysis of these comments is currently performed manually, making the process inefficient and potentially subjective. Furthermore, there has been no comparative study of the most appropriate text representation method for pairing with the K-Nearest Neighbor (KNN) algorithm, specifically for EDOM data. Therefore, the purpose of this study is to analyze and compare the performance of IndoBERT and TF-IDF in representing text for the sentiment classification of EDOM comments using KNN. The research methodology follows the CRISP-DM framework and uses the 2024 EDOM dataset. The results indicate that the IndoBERT+KNN model achieves an accuracy of 0.903, demonstrating more balanced precision, recall, and F1 scores across classes compared to the TF-IDF+KNN model, which achieved an accuracy of 0.820 with less balanced evaluation metrics. These findings suggest that IndoBERT's contextual representation is more effective than TF-IDF's word frequency-based approach in handling the complexity of EDOM comments when applied to the distance-based KNN algorithm. Based on these results, this study provides recommendations for selecting an optimal text representation method to develop a more objective and efficient sentiment analysis system.

Keywords: IndoBERT, K-Nearest Neighbor, Lecturer Evaluation, Sentiment Analysis, TF-IDF

Abstrak

Dalam konteks pendidikan tinggi, dosen berkontribusi besar terhadap peningkatan kualitas pembelajaran. Di Sekolah Tinggi Teknologi Terpadu Nurul Fikri (STT NF), Evaluasi Dosen oleh Mahasiswa (EDOM) dilaksanakan setiap akhir semester dan menghasilkan data komentar mahasiswa. Namun, analisis masih dilakukan secara manual sehingga kurang efisien dan berpotensi subjektif. Selain itu, belum terdapat kajian komparatif mengenai metode representasi yang sesuai untuk digunakan bersama algoritma K-Nearest Neighbor (KNN) khususnya pada data EDOM. Tujuan dari penelitian ini adalah menganalisis dan membandingkan kinerja IndoBERT dan TF-IDF dalam merepresentasikan teks untuk klasifikasi sentimen komentar EDOM menggunakan KNN. Metode penelitian mengacu pada tahapan CRISP-DM dengan dataset komentar EDOM tahun 2024. Hasil penelitian menunjukkan bahwa IndoBERT+KNN menghasilkan *accuracy* sebesar 0,903 serta menunjukkan nilai *precision*, *recall*, dan *F1-score* yang lebih seimbang antarkelas dibandingkan TF-IDF+KNN yang memperoleh *accuracy* sebesar 0,820 dengan performa metrik evaluasi yang cenderung kurang seimbang antarkelas. Hasil ini menunjukkan representasi kontekstual IndoBERT lebih efektif dalam menangani kompleksitas komentar EDOM dan algoritma KNN yang berbasis jarak dibandingkan dengan pendekatan berbasis frekuensi kata pada TF-IDF. Berdasarkan temuan tersebut, penelitian ini memberikan pemilihan metode representasi teks yang lebih optimal untuk pengembangan analisis sentimen secara lebih objektif dan efisien.

Kata Kunci: Analisis Sentimen, Evaluasi Dosen, IndoBERT, K-Nearest Neighbor, TF-IDF

1. PENDAHULUAN

Dalam sistem pendidikan tinggi, dosen memiliki peran dan tanggung jawab dalam melaksanakan Tridharma Perguruan Tinggi, yaitu mentransformasikan, mengembangkan, serta menyebarluaskan ilmu pengetahuan melalui kegiatan pendidikan dan pengajaran, penelitian, serta pengabdian kepada masyarakat [1]. Untuk menjaga dan meningkatkan kualitas pembelajaran, perguruan tinggi menerapkan Evaluasi Dosen oleh Mahasiswa (EDOM) sebagai penilaian umpan balik kinerja dosen. Di Sekolah Tinggi Teknologi Terpadu Nurul Fikri (STT NF), EDOM dilaksanakan setiap akhir semester dan menghasilkan informasi berbentuk numerik dan teks seperti komentar mahasiswa. Namun, pada praktiknya, pengelolaan komentar tersebut saat ini masih dilakukan secara konvensional sehingga membutuhkan durasi yang relatif lama serta berpotensi menimbulkan subjektivitas dan interpretasi.

Untuk memperoleh hasil evaluasi yang lebih akurat, diperlukan penerapan analisis sentimen agar komentar mahasiswa dapat diolah menjadi informasi yang terstruktur dan bermanfaat [2]. Seiring perkembangan teknologi pemrosesan bahasa alami, analisis sentimen memungkinkan identifikasi opini positif dan negatif secara otomatis, lebih cepat dan lebih akurat [3]. *K-Nearest Neighbor (KNN)* merupakan salah satu algoritma klasifikasi yang umum digunakan, termasuk kedalam algoritma *supervised learning* berbasis perhitungan jarak yang menentukan kelas berdasarkan mayoritas tetangga terdekat [4], [5]. Kinerja *KNN* sangat dipengaruhi oleh representasi vektor teks karena proses pengukuran jarak dilakukan pada ruang dimensi tinggi [6], sehingga pemilihan metode representasi teks menjadi faktor krusial.

Metode representasi teks yang umum digunakan dalam analisis sentimen adalah *Term Frequency-Inverse Document Frequency (TF-IDF)* dan *IndoBERT*. *TF-IDF* memberikan bobot berdasarkan tingkat kepentingan atau frekuensi term dalam dokumen [7], sedangkan *IndoBERT*, yang memiliki arsitektur serupa *BERT* dan dilatih dalam korpus besar berbahasa Indonesia yang mampu memahami konteks linguistik dengan lebih baik [8]. Penelitian sebelumnya menunjukkan bahwa *TF-IDF* menghasilkan akurasi 74,4% [9], lalu penelitian [10] mendapatkan peningkatan hasil akurasi hingga 91%, dengan *recall* 99% serta presisi 96%. Sementara itu *IndoBERT* meningkatkan akurasi dari 77,7% menjadi 90,5% [11] dan penelitian [12] Menunjukkan bahwa kinerja *TF-IDF* cenderung bervariasi, sedangkan *IndoBERT* memberikan peningkatan performa yang lebih konsisten setelah dilakukan proses optimasi. Temuan tersebut menunjukkan bahwa kedua metode memiliki potensi untuk meningkatkan performa klasifikasi sentimen.

Walaupun demikian, sebagian besar penelitian sebelumnya memosisikan algoritma klasifikasi sebagai *black box* yang hanya dievaluasi berdasarkan skor akurasi akhir. Penelitian yang secara spesifik membedah keterkaitan antara karakteristik pembentukan ruang vektor teks, baik yang berbasis frekuensi (*TF-IDF*) maupun berbasis konteks (*IndoBERT*), dengan sensitivitas perhitungan jarak algoritma *KNN* masih sangat terbatas. Kesenjangan inilah yang menjadi fokus utama penelitian, yaitu menganalisis secara empiris bagaimana representasi teks memengaruhi cara kerja *KNN*, khususnya dalam menangani data teks tidak terstruktur seperti komentar EDOM.


Berpijak pada kesenjangan tersebut, rumusan masalah pada penelitian ini adalah: bagaimana komparasi efektivitas antara representasi teks berbasis konteks (*IndoBERT*) dan berbasis frekuensi (*TF-IDF*) dalam memengaruhi kinerja klasifikasi sentimen algoritma *KNN* pada data EDOM? Penelitian ini secara spesifik menganalisis dampak perbedaan pembentukan vektor dari kedua metode representasi tersebut terhadap tingkat metrik evaluasi, yaitu akurasi, presisi, *recall*, dan *F1-score*.

Penelitian ini memberikan dua kontribusi utama. Secara teoretis, penelitian ini menunjukkan bukti empiris mengenai karakteristik dan sensitivitas algoritma *KNN* terhadap metode ekstraksi fitur pada dataset teks berbahasa Indonesia. Secara praktis, melalui pendekatan siklus penuh *CRISP-DM* hingga tahapan deployment, penelitian ini merekomendasikan model analisis sentimen terbaik yang siap diimplementasikan untuk memetransformasi komentar mahasiswa menjadi umpan balik yang terstruktur, objektif, dan efisien, sehingga mampu mendukung tata kelola mutu pembelajaran secara berkelanjutan.

2. BAHAN DAN METODE

Cross Industry Standard Process for Data Mining (CRISP-DM) merupakan metodologi yang digunakan dalam penelitian ini. Pendekatan ini dipilih karena memiliki tahapan yang terstruktur, sistematis, dan bersifat iteratif, sehingga sesuai untuk penelitian di bidang analisis sentimen. Dalam pelaksanaannya, penelitian ini menggunakan metode kuantitatif komparatif untuk menganalisis dan membandingkan kinerja kedua metode representasi teks, yaitu *IndoBERT* dan *TF-IDF*, dalam proses klasifikasi sentimen. Pemilihan kedua metode tersebut didasarkan pada kesenjangan penelitian terdahulu, di mana sebagian besar studi masih berfokus pada hasil akhir tanpa mengkaji pengaruh representasi teks terhadap mekanisme kerja algoritma. Oleh karena itu, penelitian ini membandingkan representasi berbasis frekuensi (*TF-IDF*) dan berbasis konteks (*IndoBERT*) untuk melihat pengaruhnya terhadap pembentukan ruang vektor dan hasil klasifikasi. Selain itu, algoritma *KNN* dipilih karena berbasis perhitungan jarak, sehingga sensitif terhadap kualitas representasi fitur. Hal ini menjadikan *KNN* relevan untuk mengevaluasi bagaimana perbedaan representasi teks memengaruhi kinerja klasifikasi, sebagaimana didukung oleh beberapa penelitian sebelumnya [13], [14], dan [15] yang menunjukkan performa kompetitif *KNN*. Data yang digunakan merupakan data EDOM tahun

2024 semester ganjil dan genap yang diperoleh melalui kerja sama dengan pihak kampus berdasarkan perjanjian *Non-Disclosure Agreement (NDA)* yang telah ditandatangani. Seluruh data telah melalui proses anonimisasi untuk menghilangkan informasi identitas responden maupun dosen terkait, sehingga aspek kerahasiaan dan etika penelitian tetap terjaga. Tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Business Understanding

Tahapan *Business Understanding* berfokus pada identifikasi masalah dan menetapkan tujuan penelitian. Hasil identifikasi menunjukkan bahwa pengelolaan komentar EDOM untuk analisis sentimen belum optimal serta belum banyak terdapat kajian komparatif metode representasi teks yang sesuai dengan karakteristik data EDOM serta algoritma KNN. Kondisi ini menyebabkan proses evaluasi belum berjalan secara optimal dan objektif. Berdasarkan permasalahan tersebut, penelitian ini difokuskan pada perbandingan metode *IndoBERT* dan *TF-IDF* dalam mengklasifikasikan sentimen komentar EDOM untuk menentukan pendekatan yang paling efektif dalam mendukung evaluasi kinerja dosen.

2.2. Data Understanding

Tahap *data understanding* bertujuan untuk memahami karakteristik dan kondisi data penelitian. Data diperoleh dari Kepala Program Studi (Kaprodi) Teknik Informatika melalui perjanjian NDA, kemudian dilakukan eksplorasi awal untuk mengidentifikasi jumlah, struktur, dan jenis data. Dataset yang diperoleh mencakup informasi berbentuk numerik dan teks. Namun, penelitian ini memfokuskan pada data teks berupa komentar mahasiswa. Selanjutnya, dilakukan seleksi data untuk memisahkan atribut yang relevan, seperti nama dosen dan komentar mahasiswa, sebelum tahap analisis dilakukan.

Tabel 1. Format Data EDOM

Dosen	Semester	Komentar
Dosen_1	20241	Mohon lebih sering memberikan feedback pada tugas-tugas mahasiswa, agar kami tahu di mana letak kesalahan dan bagaimana cara memperbaikinya.
Dosen_2	20242	Dosen udah ngejelasin dengan cukup jelas dan juga ngasih praktik yang sesuai, jadi aku ngerasa terbantu banget. Tugas dan proyek yang dikasih juga bikin kita lebih paham dan bisa langsung nyoba. Mungkin saran aku, bisa lebih sering dikaitin sama tools atau teknologi jaringan yang dipakai di dunia kerja sekarang biar makin update.

Berdasarkan Tabel 1, karakteristik komentar EDOM berbeda dibandingkan dengan ulasan produk atau komentar terkait isu tertentu. Dalam satu komentar, mahasiswa sering kali memuat lebih dari satu umpan balik, seperti apresiasi sekaligus kritik dan saran. Misalnya, pada komentar Dosen_2 (pada Tabel 1), mahasiswa memberikan penilaian positif terhadap metode pengajaran, namun juga menyampaikan saran terkait relevansi materi dengan perkembangan teknologi. Kompleksitas dan sifat kontekstual ini menjadikan analisis sentimen komentar EDOM lebih menantang, sehingga diperlukan metode representasi teks yang mampu menangkap karakteristik tersebut secara tepat.

2.3. Data Preparation

Tahap *data preparation* meliputi *data cleaning*, *preprocessing*, pelabelan serta representasi teks sebagai langkah penting sebelum analisis. Pada tahap *data cleaning* dilakukan penghapusan data duplikat, pengecekan *missing value*, serta penyaringan komentar kurang dari dua kata. Selanjutnya, *preprocessing* dilakukan guna membersihkan serta menyeragamkan teks agar siap untuk dianalisis lebih lanjut [16]. Seluruh proses *preprocessing* diterapkan secara konsisten pada kedua metode representasi guna menjaga standarisasi data. Tahap pelabelan dilakukan menggunakan *auto-label* berbasis *IndoBERT* untuk menghasilkan kelas sentimen positif dan negatif. Pada tahap terakhir, dilakukan proses representasi teks

dengan mengonversi komentar menjadi vektor angka agar dapat digunakan sebagai input pada proses pemodelan.

1. *Term Frequency-Inverse Document Frequency (TF-IDF)*, diterapkan sebagai teknik untuk menghitung nilai bobot setiap kata dalam dokumen [17]. *TF* mengukur jumlah kemunculan suatu kata, sedangkan *IDF* menilai tingkat kepentingan suatu kata dalam dokumen [18]. Perkalian keduanya menghasilkan nilai numerik yang merepresentasikan teks.
2. *IndoBERT*, merupakan model *BERT monolingual* bahasa Indonesia yang dikembangkan guna meningkatkan performa tugas *NLP* [19]. Pendekatan ini dapat memahami konteks kata secara dua arah (*bidirectional*), sehingga mampu membentuk representasi makna yang lebih tepat dan kontekstual [20]. *IndoBERT* dilatih menggunakan 4 miliar kata atau setara 250 juta kalimat berbahasa Indonesia dari berbagai sumber [21]. Model yang diterapkan dalam penelitian ini adalah *IndoBERT-base-p2* pengembangan dari *base-p1* karena model lebih efektif memahami konteks Bahasa Indonesia dan menunjukkan performa terbaik pada tugas analisis sentimen [22].

2.4. Modeling

Tahap *modeling* dilakukan dengan algoritma *K-Nearest Neighbor (KNN)* yang mengklasifikasikan data berdasarkan jarak terdekat antar data uji dan data latih [23]. Dua kombinasi model, *IndoBERT + KNN* dan *TF-IDF + KNN*, diuji untuk menganalisis pengaruh perbedaan representasi teks terhadap kinerja klasifikasi sentimen. Proses pada tahap ini meliputi penentuan nilai *K* terbaik menggunakan *cross-validation* pada data *training*. Hal ini dilakukan agar model bekerja secara stabil serta meminimalkan *overfitting* pada data latih [24]. Selanjutnya, pada proses pemodelan dilakukan perhitungan jarak antardaerah menggunakan pendekatan Euclidean Distance yang dirumuskan pada persamaan (1).

$$d(xy) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

2.5. Evaluation

Tahap evaluasi dilakukan dengan memanfaatkan *confusion matrix* untuk memperoleh nilai *Accuracy*, *Precision*, *Recall*, dan *F1-Score* yang dihitung berdasarkan *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. *Confusion matrix* menggambarkan distribusi hasil klasifikasi dalam bentuk jumlah prediksi yang benar maupun salah, sehingga mempermudah analisis performa sistem klasifikasi [25]. Rumus perhitungan *Accuracy*, *Precision*, *Recall*, dan *F1-Score* disajikan pada persamaan (2), (3), (4), dan (5).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

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

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (5)$$

Hasil evaluasi dari dua kombinasi model, yaitu *IndoBERT + KNN* dan *TF-IDF + KNN*, kemudian dibandingkan untuk menganalisis perbedaan kinerja klasifikasi sentimen. Hasil perbandingan metrik tersebut menjadi dasar dalam menentukan metode representasi teks dengan kinerja terbaik pada klasifikasi sentimen komentar EDOM.

2.6. Deployment

Tahap *deployment* merupakan tahapan terakhir penelitian, yang berfokus pada implementasi model dengan kinerja klasifikasi terbaik ke dalam sistem sederhana berbasis Streamlit agar dapat digunakan secara praktis. Platform Streamlit dipilih karena banyak digunakan dalam pengembangan aplikasi web untuk keperluan *machine learning* dan *data science*, serta memungkinkan pembuatan antarmuka yang cepat dan interaktif.

3. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dan pembahasan penelitian yang dilakukan menggunakan metodologi *CRISP-DM* untuk menganalisis perbandingan kinerja *IndoBERT* dan *TF-IDF* dalam mengklasifikasikan sentimen komentar EDOM menggunakan algoritma *K-Nearest Neighbor (KNN)*. Tahapan dimulai dari *business understanding* untuk mengidentifikasi permasalahan dan tujuan penelitian, kemudian dilanjutkan dengan *data understanding*. Pada tahap ini diketahui bahwa data EDOM yang digunakan yaitu data EDOM

2024 semester ganjil dan genap, terdiri atas data numerik dan teks berupa komentar mahasiswa. Namun, penelitian ini hanya memanfaatkan data teks berupa nama dosen dan komentar mahasiswa untuk keperluan analisis.

3.1. Data Preparation

Tahap *data preparation* merupakan langkah penting sebelum pemodelan, yang meliputi data cleaning, *preprocessing*, *labeling* dan representasi teks. Pada tahap *data cleaning* dilakukan penghapusan komentar kosong, komentar yang hanya berisi simbol atau tanda baca, komentar terlalu singkat dan tidak bermakna, serta data duplikat dan *missing value* yang berpotensi mengganggu proses analisis sentimen. Setelah pembersihan, jumlah data berkurang dari 14.365 menjadi 5.615. Pengurangan signifikan ini disebabkan oleh banyaknya komentar duplikat seperti “tidak ada” dan “cukup”, yang teridentifikasi sebanyak 8.984 data.

Tahap selanjutnya adalah *preprocessing* yang meliputi beberapa proses, yaitu normalisasi dengan mengonversi istilah tidak baku ke bentuk standar sesuai KBBI, *text cleaning* dan *case folding* untuk membersihkan elemen tidak relevan serta menyeragamkan huruf menjadi kecil, tokenisasi untuk memecahkan teks ke dalam unit kata (token), *stopword removal* guna menyaring kata umum yang tidak memiliki pengaruh signifikan terhadap sentimen seperti “dan”, “di”, “yang”, dan kata sejenisnya, serta *stemming* untuk mengembalikan kata ke bentuk dasarnya sehingga representasi makna menjadi lebih seragam. Pada Tabel 2 disajikan hasil *preprocessing* yang telah dilakukan.

Tabel 2. Hasil *Preprocessing*

Tahapan	Hasil
Data Awal	Dosen udah ngejelasin dengan cukup jelas dan juga ngasih praktik yang sesuai, jadi aku ngerasa terbantu banget. Tugas dan proyek yang dikasih juga bikin kita lebih paham dan bisa langsung nyoba. Mungkin saran aku, bisa lebih sering dikaitin sama tools atau teknologi jaringan yang dipakai di dunia kerja sekarang biar makin update.
Normalisasi Teks	Dosen sudah ngejelasin dengan cukup jelas dan juga memberikan praktik yang sesuai, jadi aku ngerasa terbantu banget. Tugas dan proyek yang bikin kita lebih paham dan bisa langsung nyoba. Mungkin saran aku, bisa lebih sering dikaitin sama tools atau teknologi jaringan yang dipakai di dunia kerja sekarang biar makin update.
Text Cleaning	dosen sudah ngejelasin dengan cukup jelas dan juga memberikan praktik yang sesuai jadi aku ngerasa terbantu banget tugas dan proyek yang dikasih juga bikin kita lebih paham dan bisa langsung nyoba mungkin saran aku bisa lebih sering dikaitin sama tools atau teknologi jaringan yang dipakai di dunia kerja sekarang biar makin update
Tokenisasi	['dosen', 'sudah', 'ngejelasin', 'dengan', 'cukup', 'jelas', 'dan', 'juga', 'memberikan', 'praktik', 'yang', 'sesuai', 'jadi', 'aku', 'ngerasa', 'terbantu', 'banget', 'tugas', 'dan', 'proyek', 'yang', 'dikasih', 'juga', 'bikin', 'kita', 'lebih', 'paham', 'dan', 'bisa', 'langsung', 'nyoba', 'mungkin', 'saran', 'aku', 'bisa', 'lebih', 'sering', 'dikaitin', 'sama', 'tools', 'atau', 'teknologi', 'jaringan', 'yang', 'dipakai', 'di', 'dunia', 'kerja', 'sekarang', 'biar', 'makin', 'update']
Stopword Removal	['dosen', 'ngejelasin', 'cukup', 'jelas', 'memberikan', 'praktik', 'sesuai', 'jadi', 'aku', 'ngerasa', 'terbantu', 'banget', 'tugas', 'proyek', 'dikasih', 'bikin', 'lebih', 'paham', 'langsung', 'nyoba', 'mungkin', 'saran', 'aku', 'lebih', 'sering', 'dikaitin', 'sama', 'tools', 'teknologi', 'jaringan', 'dipakai', 'dunia', 'kerja', 'sekarang', 'biar', 'makin', 'update']
Stemming	['dosen', 'ngejelasin', 'cukup', 'jelas', 'beri', 'praktik', 'sesuai', 'jadi', 'aku', 'ngerasa', 'bantu', 'banget', 'tugas', 'proyek', 'kasih', 'bikin', 'lebih', 'paham', 'langsung', 'nyoba', 'mungkin', 'saran', 'aku', 'lebih', 'sering', 'dikaitin', 'sama', 'tools', 'teknologi', 'jaring', 'pakai', 'dunia', 'kerja', 'sekarang', 'biar', 'makin', 'update']
Data Akhir	dosen ngejelasin cukup jelas beri praktik sesuai jadi aku ngerasa bantu banget tugas proyek kasih bikin lebih paham langsung nyoba mungkin saran aku lebih sering dikaitin sama tools teknologi jaring pakai dunia kerja sekarang biar makin update

Tahap selanjutnya yaitu *labeling*, Pada penelitian ini, komentar akan diberikan label positif dan negatif menggunakan auto label menggunakan *IndoBERT*. Proses pelabelan ini *BERT* tujuan untuk mengubah komentar mahasiswa menjadi data berlabel yang siap digunakan pada proses *training* dan evaluasi model. Namun, terdapat ketidakseimbangan jumlah data antarkelas: kelas sentimen positif 3.354 dan sentimen negatif 1.841. Oleh karena itu, dilakukan proses penyeimbangan data (*data balancing*) sehingga jumlah data pada masing-masing kelas menjadi sama, yaitu 1.841 pada masing-masing kelas. Hasil pelabelan dapat dilihat pada Tabel 3.

Tabel 3. Hasil Pelabelan

Komentar	Label
dosen ngejelasin cukup jelas beri praktik sesuai jadi aku ngerasa bantu banget tugas proyek kasih bikin lebih paham langsung nyoba mungkin saran aku lebih sering dikaitin sama tools teknologi jaring pakai dunia kerja sekarang biar makin update	Positif

Komentar	Label
mohon lebih sering beri feedback tugas tugas mahasiswa tahu mana letak salah bagaimana cara baik	Negatif

Setelah proses pelabelan, tahap berikutnya adalah representasi teks dengan menggunakan dua metode, yaitu *TF-IDF* dan *IndoBERT*. Pada metode *TF-IDF*, representasi teks menggunakan *TF-IDF* menghasilkan matriks fitur dengan ukuran (2945, 4013) untuk data *training* dan (737, 4013) untuk data *testing*, Nilai 4013 merepresentasikan total fitur berupa kosakata unik yang dihasilkan dari seluruh korpus data.

Tabel 4. Hasil Pembobotan TF dan IDF

Kata	Total TF	Skor TF	Total DF	Skor IDF
Lebih	835	0.030814	-	-
Materi	778	0.030814	-	-
Ajar	759	0.027149	-	-
Akademik	-	-	2	7.889591
Ahli	-	-	2	7.889591
Pahamin	-	-	2	7.889591

Pada Tabel 4 ditampilkan hasil perhitungan *Term Frequency* (TF) yang menunjukkan bahwa kata “lebih”, “materi”, dan “ajar” memiliki nilai Tf tertinggi, yang menandakan bahwa ketiga kata tersebut paling sering muncul dalam komentar EDOM serta perannya yang dominan dalam evaluasi. Sementara itu, nilai *Inverse Document Frequency* (IDF) tertinggi diperoleh kata-kata yang jarang muncul seperti “akademik”, “ahli”, dan “pahamin”, yang hanya terdapat pada dua dokumen sehingga memiliki skor IDF sebesar 7.889591. Hal ini menunjukkan bahwa kata dengan tingkat kemunculan yang rendah dalam korpus akan memperoleh nilai IDF yang lebih besar. Secara keseluruhan, representasi *TF-IDF* mampu menangkap karakteristik komentar mahasiswa dengan menyeimbangkan frekuensi kemunculan dan tingkat keunikan kata dalam korpus.

Selanjutnya, representasi teks menggunakan *IndoBERT* dilakukan dengan model *IndoBERT-base-p2* dengan parameter *batch size* 32 dan *maximum sequence length* 128. Pemilihan parameter dilakukan dengan mempertimbangan keseimbangan antarperforma dan keterbatasan sumber daya komputasi dalam penelitian. Proses ini menghasilkan vektor *embedding* berdimensi tetap yang mampu merepresentasikan makna secara kontekstual dengan mempertimbangkan hubungan antar kata dalam kalimat. *Embedding* pada data *training* menghasilkan matriks berukuran (2945, 768), sedangkan data *testing* berukuran (737, 768). Angka 768 merupakan dimensi *embedding* yang dihasilkan oleh model.

Tabel 5. Hasil *Embedding IndoBERT*


Token	Nilai (3 dimensi)	Panjang Vektor (L2 Norm)
[CLS]	[1.3052518, 2.4150581, 0.42519823]	27.890251
Saran	[0.2937478, 1.4273262, 3.1279526]	27.987991
Sistem	[0.14183742, 1.6548457, 2.7067547]	27.974365
Jadwal	[0.23439583, 1.1811959, 1.6159943]	27.976606
Mohon	[0.31091592, 0.979637, -0.37875938]	28.007483
Timbang	[-0.3074194, 1.6863796, 1.5200175]	27.987898
Bentrok	[0.21210995, 0.88610095, 0.46113542]	28.011196
Giat	[1.0247587, 1.7329912, -0.71751195]	27.970581
Pribadi	[1.0955318, 1.9924082, 0.6929964]	28.004456
[SEP]	[0.58034676, 1.451295, 0.9064023]	28.090223

Tabel 5 merupakan contoh *embedding* pada komentar “saran sistem jadwal mohon timbang bentrok giat pribadi”. Hasil tersebut menunjukan bahwa *IndoBERT* menambahkan token khusus [CLS] pada bagian awal dan [SEP] pada bagian akhir kalimat. Token [CLS] berfungsi untuk merepresentasikan keseluruhan kalimat, sedangkan [SEP] menandai batas akhir teks. Selanjutnya, kalimat dipecah menjadi token sebagaimana yang ditunjukkan pada Tabel. Setiap token dikonversi menjadi indeks numerik berdasarkan kosakata model, kemudian direpresentasikan sebagai vektor berdimensi 768. Meskipun di tabel hanya menampilkan beberapa dimensi awal, setiap token sebenarnya memiliki 768 nilai yang merepresentasikan posisinya dalam ruang multidimensi. Perbedaan nilai antar token menunjukkan variasi makna dalam konteks kalimat. Sebagaimana contoh, kata “saran”, “mohon”, dan “timbang” merepresentasikan nuansa permintaan, sedangkan “sistem”, “jadwal”, dan “bentrok” menggambarkan konteks permasalahan teknis atau akademik.


Nilai panjang vektor (L2-Norm) yang relatif sama menunjukkan bahwa perbedaan makna ditentukan oleh arah vektor, bukan panjangnya. Dengan demikian, suatu komentar direpresentasikan sebagai titik dalam ruang vektor berdimensi tinggi. Jika terdapat komentar lain dengan makna yang mirip, maka posisi titiknya akan berdekatan. Sebaliknya, jika maknanya berbeda, jarak akan semakin jauh.

3.2. Modeling

Tahap *modeling* dilakukan dengan menerapkan algoritma *K-Nearest Neighbor (KNN)* menggunakan skema pembagian data sebesar 80% untuk data *training* dan 20% untuk data *testing*. Pada algoritma KN, parameter utama yang ditentukan adalah nilai K (*number of neighbors*), karena parameter ini berpengaruh langsung terhadap kemampuan model dalam mengklasifikasi data. Penentuan nilai K terbaik dilakukan menggunakan metode *cross-validation* dengan metrik evaluasi *F1-macro* dan pengujian dilakukan pada beberapa nilai K dalam rentang 1 hingga 31. Penentuan rentang nilai K dari 1 hingga 31 dilakukan untuk menghindari nilai K yang terlalu kecil yang berpotensi menyebabkan *overfitting* maupun nilai K yang terlalu besar yang dapat menyebabkan *underfitting*.



Gambar 2. Cross-Validation TF-IDF




Gambar 3. Cross-Validation IndoBERT

Hasil *cross-validation* menunjukkan bahwa pada representasi *TF-IDF* yang ditunjukkan pada Gambar 2, performa meningkat seiring bertambahnya nilai K, dengan nilai terbaik pada K=31 dan rata-rata *F1-macro* sebesar 0,8297. Model kemudian dilatih menggunakan K tersebut dan dievaluasi menggunakan data *testing*. Sementara itu, pada representasi *IndoBERT* yang ditunjukkan pada Gambar 3, performa meningkat hingga mencapai titik optimal sebelum menurun pada K yang lebih besar. Nilai terbaik diperoleh pada K=17 dengan rata-rata *F1-macro* sebesar 0,9014, menunjukkan keseimbangan optimal antara presisi dan sensitivitas. Model selanjutnya dilatih dengan K=17 dan diuji pada data *testing* untuk memperoleh performa akhir.


3.3. Evaluation

Tahap evaluasi dilakukan untuk mengukur kinerja model klasifikasi pada data menggunakan metrik yang dihitung berdasarkan *confusion matrix*, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Evaluasi membandingkan dua pendekatan, yaitu *TF-IDF+KNN* dan *IndoBERT+KNN*, berdasarkan nilai K terbaik masing-masing.

Gambar 4 menunjukkan hasil *confusion matrix* metode *TF-IDF+KNN*, diperoleh TP=254, TN=351, FP=144, dan FN=18, dengan *accuracy* sebesar 0,820. Model menunjukkan kinerja yang cukup baik, dengan nilai *recall* sebesar 0,95 pada kelas negatif dan 0,69 pada kelas positif. Lalu *precision* 0,75 pada kelas negatif dan 0,93 pada kelas positif, dan *F1-score* 0,84 pada kelas negatif dan 0,79 pada kelas positif. Berdasarkan hasil tersebut, terlihat adanya ketidakseimbangan performa antarkelas. Model menunjukkan nilai *recall* yang lebih tinggi pada kelas negatif dibandingkan dengan kelas positif, sementara nilai *precision* memperlihatkan kecenderungan yang berlawanan.




Gambar 4. Confusion Matrix TF-IDF+KNN



Gambar 5. Confusion Matrix IndoBERT+KNN

Sementara itu, Gambar 5 menunjukkan hasil *confusion matrix* metode *IndoBERT+KNN* yang menghasilkan TP=344, TN=322, FP=24, dan FN=47, dengan *accuracy* sebesar 0,903. Nilai *recall* pada kelas negatif 0,87 dan kelas positif 0,93, lalu *precision* pada kelas negatif 0,93 dan kelas positif 0,88, dan *F1-score* pada kelas negatif 0,90 dan kelas positif 0,91. Berdasarkan hasil evaluasi, model menunjukkan kinerja yang seimbang dan sangat baik pada kedua kelas. *Recall* yang tinggi pada kelas positif menunjukkan kemampuan model dalam mendeteksi sebagian besar komentar positif secara efektif. Di sisi lain, *precision* yang tinggi pada kelas negatif menunjukkan bahwa prediksi sentimen negatif yang dihasilkan cenderung akurat. Berikut ditampilkan tabel yang memuat hasil perbandingan evaluasi kinerja kedua metode representasi teks.



Gambar 6. Grafik Perbandingan Hasil Evaluasi


Berdasarkan Gambar 6, terdapat perbedaan performa yang cukup signifikan antara kedua metode. Hasil menunjukkan bahwa IndoBERT+KNN lebih unggul dibandingkan TF-IDF+KNN. Perbedaan performa

tersebut berkaitan dengan beberapa hal, seperti karakteristik data EDOM yang cenderung memuat lebih dari satu umpan balik dalam satu komentar, lalu dalam hal ini, kualitas representasi teks menjadi krusial karena algoritma *KNN* melakukan klasifikasi berdasarkan kedekatan jarak antarvektor. Representasi yang mampu menangkap makna semantik akan menghasilkan pengukuran jarak yang lebih relevan.

TF-IDF merepresentasikan teks berdasarkan frekuensi dan keunikan kata dalam korpus, meskipun efektif membedakan kata umum dan spesifik, *TF-IDF* memperlakukan kata secara independen tanpa mempertimbangkan hubungan makna antarkata, sehingga kurang optimal dalam menangani komentar campuran. Sementara *IndoBERT*, menggunakan pendekatan *bidirectional*, representasi kontekstual *embedding* berdimensi 768 memungkinkan setiap token memiliki makna kontekstual yang berbeda dalam suatu kalimat. Hal ini menjelaskan mengapa *IndoBERT+KNN* menghasilkan performa yang lebih seimbang dan akurat. Dengan demikian, hasil menunjukkan bahwa perbedaan karakteristik representasi teks berpengaruh langsung terhadap kinerja algoritma *KNN*.

3.4. Deployment

Setelah diperoleh metode dengan performa terbaik, model selanjutnya *dideploy* ke dalam sistem sederhana berbasis web menggunakan Streamlit. Sistem memungkinkan pengguna mengunggah file EDOM yang berisi nama dosen dan komentar mahasiswa, kemudian memprosesnya secara otomatis sesuai dengan tahapan penelitian yang sudah dilakukan. Sistem juga menampilkan jumlah data setelah dan sebelum *preprocessing* serta visualisasi hasil klasifikasi dalam bentuk *donut chart* untuk menunjukkan distribusi sentiment positif dan negatif.



Gambar 7. Sistem Analisis Sentimen

Selain itu, tersedia fitur filter berdasarkan nama dosen yang menampilkan presentase sentimen dalam bentuk tabel dan *donut chart* seperti pada Gambar 7, sehingga memudahkan evaluasi kinerja berdasarkan dosen secara lebih terstruktur. Meskipun sistem telah berjalan fungsional, masih terdapat beberapa keterbatasan, seperti perbedaan hasil *preprocessing* dibandingkan dengan hasil di Google Colab, serta waktu pemrosesan *embedding IndoBERT* yang relatif lama akibat keterbatasan spesifikasi perangkat dan ukuran model, selain itu sistem belum menyediakan informasi-informasi penting seperti mengidentifikasi kata kunci dominan yang mempengaruhi sentimen serta visualisasi tren sentimen untuk membantu proses pengambilan keputusan berbasis data.

4. KESIMPULAN

Berdasarkan hasil analisis dan evaluasi, klasifikasi sentimen komentar EDOM menggunakan *IndoBERT* sebagai metode representasi teks terbukti lebih unggul dibandingkan *TF-IDF* pada algoritma *K-Nearest Neighbor (KNN)*. Hasil ini memberikan penegasan empiris bahwa perbedaan karakteristik representasi teks berdampak langsung terhadap kualitas pembentukan ruang vektor dan sensitivitas kinerja algoritma *KNN*. *IndoBERT* yang berbasis konteks mampu merepresentasikan makna semantik secara komprehensif dibandingkan dengan *TF-IDF* yang murni berbasis frekuensi. Representasi kontekstual ini terbukti lebih optimal ketika diproses oleh algoritma *KNN* yang mengandalkan pendekatan perhitungan jarak spasial antar data, khususnya dalam menangani karakteristik komentar EDOM yang kompleks dan memuat sentimen opini yang beragam.

Evaluasi kuantitatif menunjukkan bahwa model *IndoBERT+KNN* mencapai tingkat akurasi sebesar 0,903, disertai dengan distribusi nilai *precision*, *recall*, dan *F1-score* yang lebih seimbang antarkelas sentimen. Sebaliknya, model *TF-IDF+KNN* hanya mencapai akurasi sebesar 0,820 dengan rata-rata *F1-score*

yang cukup baik, namun memiliki ketimpangan distribusi *precision* dan *recall* antarkelas. Hal ini membuktikan bahwa *IndoBERT* tidak sekadar unggul dalam metrik akurasi, tetapi juga memiliki konsistensi yang lebih tangguh. Kesimpulan ini menjawab rumusan masalah penelitian, bahwa pemilihan metode representasi teks yang selaras dengan cara kerja algoritma merupakan kunci penentu kualitas sistem prediksi. Secara praktis, implementasi model *IndoBERT*+*KNN* dapat secara signifikan meningkatkan objektivitas dan efisiensi analisis sentimen komentar EDOM, sehingga mampu mendukung institusi dalam evaluasi kinerja dosen yang sepenuhnya digerakkan oleh data (*data-driven*).

Sebagai arah pengembangan penelitian selanjutnya, meskipun arsitektur *IndoBERT*+*KNN* telah menunjukkan kinerja yang solid, pendekatan klasifikasi dapat dieksplorasi lebih lanjut menggunakan algoritma berbasis *deep learning* yang secara ilmiah dirancang untuk data sekuensial dan kontekstual, seperti penerapan *LSTM*, *BiLSTM*, atau *fine-tuning* langsung pada model *IndoBERT*. Selain itu, pada aspek rekayasa perangkat lunak. Optimalisasi waktu komputasi saat *embedding* perlu ditingkatkan. Sistem masa depan juga direkomendasikan untuk mengintegrasikan fitur tambahan, seperti ekstraksi kata kunci dominan dan visualisasi tren sentimen guna mendukung eksekutif kampus dalam pengambilan keputusan strategis tata kelola akademik.

REFERENSI

- [1] UU. “Undang-Undang Republik Indonesia Nomor 14 Tahun 2005 tentang Guru dan Dosen,” 2005. Accessed: Nov. 23, 2025. [Online]. Available: <https://peraturan.bpk.go.id/Details/40266/uu-no-14-tahun-2005>
- [2] P. M. Abraham and K. R. K. U. R, “Feature Based Sentiment Analysis of Mobile Product Reviews using Machine Learning Techniques,” *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 2, pp. 2289–2296, Apr. 2020, doi: 10.30534/ijatcse/2020/210922020.
- [3] W. M. Munandar, “Sentiment Analysis of Student Comment on the College Performance Evaluation Questionnaire Using Naïve Bayes and *IndoBERT*,” Nov. 2023. doi: <https://doi.org/10.30595/juita.v11i2.17336>.
- [4] I. B. Ketut and S. Arnawa, “Analisis Sentimen pada Media Sosial Terhadap Perkuliahan Hybrid Menggunakan Algoritma TF IDF dan K Nearest Neighbor,” *JSI*, vol. 17, no. Vol 17 No 1 (2022): Jurnal Sistem dan Informatika (JSI), pp. 40–46, Apr. 2023, doi: <https://doi.org/10.30864/jsi.v17i1.495>.
- [5] F. Acito, “k Nearest Neighbors,” in *Predictive Analytics with KNIME*, Cham: Springer Nature Switzerland, 2023, pp. 209–227. doi: 10.1007/978-3-031-45630-5_10.
- [6] R. Dila and A. Ramadhanu, “Penerapan Hybrid Intelligence System Untuk Klasifikasi Sentimen Eyeliner, Lipstik dan HandBody Menggunakan Metode *KNN* dan *PCA*,” *JATI(Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 2, Apr. 2025, doi: <https://doi.org/10.36040/jati.v9i2.13099>.
- [7] D. Septiani and I. Isabela, “Analisis Term Frequency Inverse Document Frequency (*TF-IDF*) Dalam Temu Kembali Informasi Pada Dokumen Teks,” *SINTESIA: Jurnal Sistem dan Teknologi Informasi Indonesia*, no. Vol. 1 No. 2 (2022): SINTESIA, Oct. 2023, Accessed: Nov. 04, 2025. [Online]. Available: <https://journal.unj.ac.id/unj/index.php/SINTESIA/article/view/39364>
- [8] S. Dharmawan, Viny, C. Mawardi, Novario, and J. Perdana, “Klasifikasi Ujaran Kebencian Menggunakan Metode FeedForward Neural Network (*IndoBERT*),” Jun. 2023. doi: <https://doi.org/10.24912/jiksi.v11i1.24066>.
- [9] M. Hafizh Mahendra, D. Triantoro Mardiansyah, and K. Muslim Lhaksana, “Analisis Sentimen Tweet COVID-19 Menggunakan Metode *K-Nearest Neighbors* dengan Ekstraksi Fitur *TF-IDF* dan CountVectorizer,” *Dike: Jurnal Ilmu Multidisiplin*, pp. 37–43, Aug. 2023, doi: <https://doi.org/10.69688/dike.v1i2.35>.
- [10] K. Mustaqim, F. A. Amaresti, and I. N. Dewi, “Analisis Sentimen Ulasan Aplikasi PosPay untuk Meningkatkan Kepuasan Pengguna dengan Metode *K-Nearest Neighbor (KNN)*,” *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 1, pp. 11–20, Jun. 2024, doi: 10.29408/edumatic.v8i1.24779.
- [11] A. Amrullah, “Analisis Sentimen Publik terkait Migrasi Tenaga Kerja Indonesia di Platform X menggunakan SVM-*IndoBERT*,” *Jurnal UJMC*, vol. 11, no. 1, pp. 53–63, Jun. 2025, doi: <https://doi.org/10.52166/ujmc.v11i1.9891>.
- [12] A. Putri, S. Agustian, Jasril, and I. Afrianty, “Eksplorasi Fitur FastText, *TF-IDF* dan *IndoBERT* Pada Metode *K-Nearest Neighbor* Untuk Klasifikasi Sentimen,” Jan. 2025. doi: <https://doi.org/10.31849/zn.v7i1.24779>.
- [13] N. A. H. Syifa, A. Nugroho, and R. Firliana, “Perbandingan Algoritma Naïve Bayes Classifier Dan *K-Nearest Neighbors* Untuk Analisis Sentimen Covid-19 Di Twitter,” *JIF*, Mar. 2023, doi: <https://doi.org/10.33884/jif.v11i01.7069>.
- [14] D. Muhidin and A. Wibowo, “Perbandingan Kinerja Algoritma Support Vector Machine Dan *K-Nearest Neighbor* Terhadap Analisis Sentimen Kebijakan New Normal,” *STRING*, vol. 15, Dec. 2020.

- [15] Y. MZ, J. E. Bororing, and N. Fuadiah, "Penerapan Metode *K-Nearest Neighbor* dan Decision Tree Untuk Analisis Sentimen (Studi Kasus Mario Dandi)," *IJITECH(Indonesian Journal Of Information Technology)*, Dec. 2023, doi: <https://doi.org/10.71155/fcy1h865>.
- [16] M. E. Siregar, S. Dermawan, and A. A. Hisyam, "Perbandingan Kinerja Naive Bayes dan KNN Dalam Analisis Sentimen Komentar X dengan dan Tanpa Text Preprocessing (Studi Kasus: Danantara)," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 3, Jul. 2025, doi: 10.23960/jitet.v13i3.6612.
- [17] M. Furqan, S. Mayang Sari, and P. Ilmu Komputer Fakultas Sains dan Teknologi, "Analisis Sentimen Menggunakan *K-Nearest Neighbor* Terhadap New Normal Masa Covid-19 Di Indonesia Sentiment Analysis using *K-Nearest Neighbor* towards the New Normal During the Covid-19 Period in Indonesia," *Techno.COM*, vol. 21, no. 1, pp. 52–61, Feb. 2022, [Online]. Available: www.tripadvisor.com
- [18] V. Meida Hersianty, E. Larasati Amalia, D. Puspitasari, and D. Wahyu Wibowo, "Penerapan Algoritma *TF-IDF* Dan Cosine Similarity Dalam Sistem Rekomendasi Lowongan Pekerjaan," Feb. 2025, doi: <https://doi.org/10.36040/jati.v9i1.12406>.
- [19] F. Koto, A. Rahimi, J. H. Lau, and T. Baldwin, "IndoLEM and *IndoBERT*: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP," Nov. 2020, [Online]. Available: <http://arxiv.org/abs/2011.00677>
- [20] A. Pratama Putra, "Pengukuran Tingkat Akurasi Pada Ulasan E-Commerce Menggunakan Metode *INDOBERT* Dengan Optimizer Adam," *Jurnal Komputer, Informasi dan Teknologi*, vol. 5, no. 1, pp. 1–15, 2025, doi: 10.53697/jkomitek.v5i1.
- [21] B. Wilie *et al.*, "IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding," Oct. 2020, [Online]. Available: <http://arxiv.org/abs/2009.05387>
- [22] Wildan Amru Hidayat and V. R. S. Nastiti, "Perbandingan Kinerja Pre-Trained *IndoBERT*-Base dan *IndoBERT*-Lite Pada Klasifikasi Sentimen Ulasan TikTok Tokopedia Seller Center Dengan Model *IndoBERT*," *JSiI (Jurnal Sistem Informasi)*, vol. 11, no. 2, pp. 13–20, Sep. 2024, doi: 10.30656/jsii.v11i2.9168.
- [23] J. Homepage, S. R. Cholil, T. Handayani, R. Prathivi, and T. Ardianita, "Implementasi Algoritma Klasifikasi *K-Nearest Neighbor (KNN)* Untuk Klasifikasi Seleksi Penerima Beasiswa," Jul. 2021, doi: <https://doi.org/10.31294/ijcit.v6i2.10438>.
- [24] N. Dewi and R. E. Putra, "Pengembangan Sistem Analisis Sentimen Masyarakat Terhadap Chatgpt Pada Twitter Dengan Perbandingan Metode Naive Bayes Classifier Dan *K-Nearest Neighbors*," *JINACS(Journal of Informatics and Computer Science)*, vol. 5, 2023, doi: <https://doi.org/10.26740/jinacs.v5n03.p344-357>.
- [25] R. Nurhidayat and K. E. Dewi, "Penerapan Algoritma *K-Nearest Neighbor* dan Fitur Ekstraksi N-Gram dalam Analisis Sentimen Berbasis Aspek," *Komputa : Jurnal Ilmiah Komputer dan Informatika*, vol. 12, no. 1, May 2023, doi: <https://doi.org/10.34010/komputa.v12i1.9458>.