

PENERAPAN KOMBINASI METODE NAÏVE BAYES DAN LEXICON-BASED DENGAN OPTIMASI TF-IDF UNTUK KLASIFIKASI SENTIMEN TERHADAP FILM S-LINE PADA PLATFORM TIKTOK

Zaki Taquiuddin¹, Ade Irma Purnamasari², Denni Pratama³, Edi Wahyudin⁴.

Program Studi Teknik Informatika¹²
Program Studi Manajemen Informatika³⁴
Program Studi Rekayasa Perangkat Lunak³

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
zakitaquiuddin979@gmail.com

(*) Corresponding Author : zakitaquiuddin979@gmail.com
Published : 30 April 2026

Abstract—This research is motivated by the rapid growth of user interaction on TikTok, which generates diverse public opinions regarding the film *S-Line*. Understanding these opinions requires an effective sentiment analysis approach. The literature review indicates that Naïve Bayes, Lexicon-Based methods, and TF-IDF optimization are widely applied techniques in text classification, and their integration has the potential to enhance model performance. This study utilizes 2,851 TikTok comments collected through web scraping, followed by preprocessing, feature extraction using TF-IDF, incorporation of lexicon scores, and class balancing when necessary. The Naïve Bayes classifier is evaluated under multiple experimental scenarios to compare the performance between single-method and hybrid approaches. Findings show that combining TF-IDF with Lexicon-Based features produces more informative text representations and improves classification accuracy compared to single-method models. Evaluation metrics further reveal that the hybrid approach captures sentiment nuances more effectively, especially within informal and context-rich TikTok comments. Overall, this study concludes that the hybrid Naïve Bayes–TF-IDF–Lexicon method is an effective strategy for sentiment classification on dynamic and unstructured social media text data.

Keywords: Sentiment Analysis, Naïve Bayes, TF-IDF, Lexicon-Based, TikTok

Abstrak—Penelitian ini dilatarbelakangi oleh tingginya interaksi pengguna TikTok yang menghasilkan opini beragam terhadap film *S-Line*, sehingga diperlukan analisis sentimen untuk memahami persepsi publik secara lebih akurat. Kajian pustaka menunjukkan bahwa metode *Naïve Bayes*, pendekatan *Lexicon-Based*, dan optimasi *TF-IDF* merupakan teknik yang banyak digunakan dalam klasifikasi teks, dan kombinasi ketiganya berpotensi meningkatkan performa model. Penelitian ini menggunakan 2.851 komentar TikTok yang diperoleh melalui teknik *scraping*, kemudian melalui tahapan *preprocessing*, ekstraksi fitur menggunakan *TF-IDF*, penambahan skor leksikon, serta penyeimbangan data bila diperlukan. Model *Naïve Bayes* diuji dalam beberapa skenario untuk membandingkan performa metode tunggal dan metode kombinasi. Hasil penelitian menunjukkan bahwa integrasi *TF-IDF* dengan *Lexicon-Based* memberikan representasi fitur yang lebih informatif dan meningkatkan akurasi model dibandingkan penggunaan metode tunggal. Analisis metrik evaluasi mengindikasikan bahwa kombinasi metode mampu menangkap nuansa sentimen secara lebih baik pada komentar berbahasa informal khas TikTok. Secara keseluruhan, penelitian ini menyimpulkan bahwa pendekatan hybrid *Naïve Bayes–TF-IDF–Lexicon* merupakan strategi yang efektif dalam klasifikasi sentimen pada data media sosial yang bersifat dinamis dan tidak terstruktur.

Kata Kunci: Analisis Sentimen, Naïve Bayes, TF-IDF, Lexicon-Based, TikTok

INTRODUCTION

Perkembangan teknologi digital telah membawa perubahan besar dalam cara masyarakat mengekspresikan opini dan berinteraksi di ruang publik. Media sosial

menjadi salah satu wadah utama bagi masyarakat untuk menyampaikan pandangan, perasaan, dan reaksi terhadap berbagai isu, termasuk dalam bidang hiburan seperti film. Salah satu platform yang memiliki peran signifikan dalam hal ini adalah

TikTok, yang kini menjadi media ekspresi dan komunikasi paling populer di kalangan generasi muda [1].

TikTok menyediakan fitur-fitur yang memungkinkan pengguna untuk berbagi video pendek, memberikan komentar, dan menanggapi konten secara langsung. Interaksi yang sangat tinggi di *platform* ini menghasilkan data opini publik yang sangat besar dan beragam, sehingga menjadikannya sumber penting bagi penelitian analisis sentimen [2]. Data tersebut dapat digunakan untuk memahami preferensi, sikap, dan persepsi masyarakat terhadap berbagai topik, termasuk film yang sedang populer di kalangan pengguna TikTok.

Perkembangan teknologi informasi yang pesat telah mendorong munculnya berbagai platform media sosial sebagai sarana komunikasi dan ekspresi diri masyarakat. Salah satu platform yang sangat populer dan memiliki tingkat interaksi tinggi adalah TikTok, yang berbasis pada konten video singkat dengan fitur komentar sebagai wadah bagi pengguna untuk memberikan tanggapan dan opini terhadap suatu konten. Setiap video yang diunggah di TikTok dapat menghasilkan ribuan komentar, mencerminkan beragam ekspresi, pendapat, dan sentimen dari pengguna terhadap topik tertentu. Namun demikian, jumlah komentar yang sangat besar ini menimbulkan tantangan tersendiri dalam hal pengelolaan dan analisis data [3].

Penelitian oleh [4] menunjukkan bahwa penerapan algoritma klasifikasi dalam analisis sentimen di media sosial masih menghadapi tantangan besar pada tahap pra-pemrosesan data. Langkah-langkah seperti tokenization dan stopword removal memang telah diterapkan untuk normalisasi data, tetapi hasil klasifikasi masih kurang optimal karena masih banyak data yang belum melalui proses pembersihan secara menyeluruh. Hal ini menyebabkan model analisis tidak mampu sepenuhnya menangkap makna sebenarnya dari komentar pengguna.

Sementara itu, penelitian [5] yang menggunakan metode *Long Short-Term Memory (LSTM)* dengan optimasi *Stochastic Gradient Descent (SGD)* menunjukkan hasil yang cukup baik dalam mengklasifikasikan sentimen teks. LSTM memiliki kemampuan dalam memahami urutan dan konteks antar kata pada teks, namun tetap menghadapi kendala dalam menangani data komentar yang kompleks dan tidak terstruktur secara konsisten. Proses klasifikasi yang masih mengandung unsur manual juga berpotensi menurunkan akurasi hasil analisis.

Penelitian lain oleh [6] menekankan bahwa analisis sentimen tidak hanya berfokus pada pengelompokan komentar menjadi kategori sentimen semata, tetapi juga harus mempertimbangkan konteks sosial dan budaya yang melingkupi komentar tersebut. Artinya, sebuah komentar yang secara tekstual terlihat negatif, bisa saja bermakna positif dalam konteks tertentu. Tantangan semacam ini menegaskan pentingnya pengembangan model analisis yang lebih adaptif dan kontekstual untuk menangani data dengan kompleksitas tinggi dan nuansa emosional yang beragam.

Dalam kajian analisis sentimen, berbagai metode telah dikembangkan untuk mengklasifikasikan opini publik menjadi kategori positif, negatif, atau netral. Setiap metode memiliki keunggulan dan keterbatasan tersendiri dalam hal akurasi, kecepatan, dan kemampuan generalisasi. Salah satu pendekatan yang paling umum digunakan adalah *Naïve Bayes*, yang dikenal karena kesederhanaannya serta efisiensinya dalam menangani data dalam jumlah besar [7]. *Naïve Bayes* sering diterapkan dalam klasifikasi biner maupun multiklas, dan hasilnya cukup baik dalam konteks analisis sentimen. Namun, penelitian menunjukkan bahwa akurasi model ini dapat meningkat secara signifikan ketika dikombinasikan dengan teknik feature extraction seperti Term Frequency–Inverse Document Frequency (TF–IDF) [8]. *TF–IDF* berperan dalam memberikan bobot yang lebih besar pada kata-kata penting serta mengurangi pengaruh kata umum, sehingga representasi teks menjadi lebih bermakna dalam proses klasifikasi.

Meskipun demikian, pendekatan berbasis *Naïve Bayes* masih memiliki keterbatasan, terutama dalam memahami konteks emosional dan makna tersirat yang tidak sepenuhnya dapat ditangkap oleh model statistik semata. Di sisi lain, pendekatan berbasis *lexicon (Lexicon-Based Approach)* menawarkan kemampuan dalam mengenali kata-kata yang memiliki muatan emosi tertentu, sehingga dapat memberikan pemahaman yang lebih dalam tentang ekspresi perasaan dalam teks [9]. Pendekatan ini telah terbukti efektif dalam analisis opini publik, seperti pada penelitian mengenai sentimen masyarakat terhadap vaksin COVID-19. Namun, pendekatan *lexicon* juga memiliki kelemahan, yaitu keterbatasan dalam menangani variasi bahasa, konteks kalimat, dan dependensi pada kualitas serta kelengkapan kamus *lexicon* yang digunakan [10].

Penelitian lain mengungkapkan bahwa metode berbasis *lexicon*, meskipun mampu menghasilkan ringkasan efisien terhadap sentimen positif dan negatif, sering kali tidak cukup fleksibel dalam menangkap variasi ekspresi yang kompleks

di media sosial[11]. Oleh karena itu, pendekatan yang mengombinasikan metode *Naïve Bayes* dan *Lexicon-Based* dengan dukungan optimasi *TF-IDF* dianggap sebagai solusi potensial untuk meningkatkan akurasi serta ketepatan analisis sentimen. Kombinasi ini dapat mengintegrasikan kekuatan model statistik dalam klasifikasi data besar dengan kemampuan pendekatan berbasis leksikal dalam memahami konteks emosional dan semantik teks.

Selain itu, platform TikTok memiliki karakteristik unik dibandingkan media sosial lainnya. Konten di TikTok bersifat singkat, multimodal, dan sangat interaktif, sehingga komentar pengguna sering kali mengandung ekspresi yang kompleks dan bervariasi. Penelitian oleh (Villa-Ruiz et al., 2021), serta [13] menunjukkan bahwa interaksi di TikTok mencerminkan keterlibatan emosional pengguna yang tinggi, namun penelitian mengenai analisis sentimen terhadap konten film di platform ini masih sangat terbatas. Penelitian terdahulu lebih banyak berfokus pada topik kesehatan atau edukasi publik di TikTok, bukan pada opini terhadap film [14]

Lebih lanjut, [3] menegaskan pentingnya penggunaan metode pembobotan seperti *TF-IDF* dalam meningkatkan performa klasifikasi sentimen. Namun, penelitian tersebut belum mengkaji integrasi metode tersebut dalam konteks TikTok yang memiliki pola bahasa informal dan dinamis. Dengan demikian, terdapat celah penelitian berupa kurangnya eksplorasi kombinasi *Naïve Bayes*, pendekatan berbasis leksikon, dan *TF-IDF* secara bersamaan dalam analisis sentimen komentar film di TikTok.

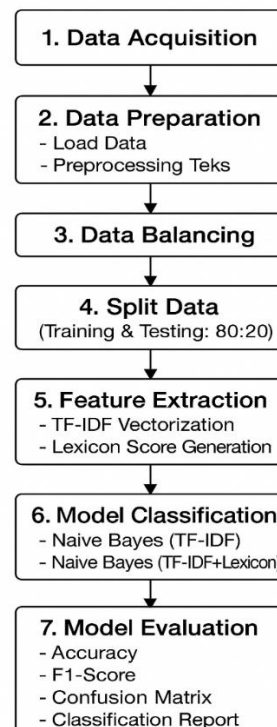
Kombinasi ketiga metode ini diharapkan dapat menghasilkan model klasifikasi yang lebih akurat dan kontekstual, karena masing-masing pendekatan memiliki keunggulan yang saling melengkapi. *Naïve Bayes* menawarkan efisiensi dan kesederhanaan dalam klasifikasi; *Lexicon-Based* memberikan sensitivitas terhadap makna emosional; dan *TF-IDF* membantu menonjolkan kata penting sekaligus mengurangi dominasi kata umum. Dengan mengintegrasikan ketiganya, model dapat menangkap nuansa sentimen yang lebih kompleks dan sesuai dengan gaya komunikasi pengguna TikTok,[15].

Secara keseluruhan, penelitian ini memiliki potensi kontribusi yang signifikan dalam pengembangan model analisis sentimen berbasis kombinasi metode, khususnya untuk komentar film di platform TikTok. Hasil penelitian diharapkan tidak hanya meningkatkan akurasi klasifikasi, tetapi juga

memberikan pemahaman yang lebih mendalam tentang opini publik terhadap film, yang dapat dimanfaatkan oleh industri perfilman, pembuat konten, maupun peneliti di bidang data sains sosial.

MATERIALS AND METHODS

Penelitian ini disusun untuk menjelaskan alur logis dalam pelaksanaan eksperimen mulai dari pengumpulan data hingga evaluasi dan perbandingan hasil. Prosedur penelitian terdiri dari beberapa tahapan utama sebagaimana ditunjukkan pada Gambar 1.



Gambar 1 Prosedur Penelitian

Penelitian ini diawali dengan tahap akuisisi data, yaitu pengumpulan data yang digunakan sebagai bahan utama dalam pelatihan dan pengujian model klasifikasi sentimen. Data yang digunakan merupakan data sekunder yang diperoleh dari platform Kaggle, yaitu dataset "*Hasil_Labelling_Data_film_Sline_dari_TikTok.csv*" (Amalsyah et al., 2025). Dataset ini berisi 2.851 komentar pengguna TikTok terkait film *Sline* yang telah diberi label sentimen secara manual menjadi kelas positif dan negatif berdasarkan skor sentimen hasil pendekatan *Lexicon-Based Sentiment Analysis*. Dataset terdiri dari tujuh atribut, meliputi tanggal, waktu, jumlah *likes* (*diggCount*), ID pengguna, teks komentar hasil *stemming*, skor sentimen numerik, dan label sentimen.

Tahap selanjutnya adalah data preparation, yang bertujuan untuk memastikan kualitas data sebelum digunakan dalam proses pemodelan. Dataset diimpor menggunakan library Pandas dalam format CSV, kemudian dilakukan eksplorasi data untuk memahami struktur, tipe data, distribusi statistik, serta keberadaan nilai kosong. Proses *text preprocessing* diterapkan untuk membersihkan teks komentar, meliputi *lowercasing*, penghapusan karakter non-alfanumerik, serta normalisasi teks agar lebih konsisten dan representatif sebagai masukan model klasifikasi.

Berdasarkan hasil eksplorasi, ditemukan adanya ketidakseimbangan kelas (*class imbalance*), di mana kelas negatif mendominasi dengan 2.316 data, sedangkan kelas positif hanya berjumlah 535 data. Kondisi ini berpotensi menyebabkan bias model terhadap kelas mayoritas. Meskipun pada eksperimen ini tidak dilakukan teknik *data balancing* secara eksplisit, permasalahan tersebut dicatat sebagai keterbatasan penelitian. Untuk mengurangi dampaknya, evaluasi model lebih difokuskan pada metrik yang robust terhadap data tidak seimbang, seperti *F1-score*, serta direkomendasikan penerapan metode *oversampling*, *undersampling*, atau *class weighting* pada penelitian selanjutnya.

Setelah proses *preprocessing*, dataset dibagi menjadi data latih dan data uji dengan rasio 80:20 menggunakan fungsi *train_test_split* dari Scikit-learn. Parameter *stratify* digunakan untuk menjaga proporsi kelas sentimen tetap seimbang pada kedua subset. Dari proses ini diperoleh 2.280 data untuk pelatihan dan 571 data untuk pengujian. Tahap berikutnya adalah ekstraksi fitur, di mana teks diubah menjadi representasi numerik menggunakan metode TF-IDF dengan batas maksimal 5.000 fitur. Selain itu, digunakan fitur tambahan berupa *Lexicon Score* untuk menangkap informasi sentimen semantik, yang kemudian dinormalisasi menggunakan *MinMaxScaler* agar kompatibel dengan algoritma klasifikasi.

Pada tahap klasifikasi, penelitian ini menggunakan algoritma *Multinomial Naïve Bayes* karena efisien secara komputasi dan sesuai untuk data teks dengan fitur sparse. Dua skenario model diterapkan, yaitu model berbasis TF-IDF saja dan model kombinasi TF-IDF dengan *Lexicon Score*. Evaluasi kinerja model dilakukan menggunakan *confusion matrix* dan *classification report* yang menampilkan nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas.

Visualisasi *confusion matrix* disajikan menggunakan *heatmap* untuk memperjelas pola kesalahan dan keberhasilan prediksi model.

RESULTS AND DISCUSSION

Penilaian kinerja model menggunakan berbagai metrik seperti *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, serta *Balanced accuracy*. Subbab ini memaparkan analisis mendalam mengenai hasil perbandingan kedua skenario, termasuk kekuatan dan kelemahan model dalam mengklasifikasi sentimen positif dan negatif. Evaluasi ini menjadi dasar interpretasi performa model secara keseluruhan. *Accuracy*.

Hasil Skenario (TF-IDF)

Tabel 1 memaparkan performa model *Multinomial Naïve Bayes* ketika menggunakan fitur TF-IDF saja. Metrik seperti *precision*, *recall*, *F1-score*, dan *accuracy* disajikan untuk masing-masing kelas sentimen. Tabel ini menjadi acuan awal dalam menilai efektivitas representasi fitur tunggal.

Tabel 1 Hasil Klasifikasi Skenario 1 (TF-IDF Only)

Metrik	Positif	Negatif
Precision	100.00%	82.56%
Recall	8.41%	100.00%
F1-score	15.52%	90.45%
Support	107	464

Accuracy: 82.84% *Balanced Accuracy*: 54.21%
 Model menunjukkan bias yang kuat terhadap kelas negatif: Dari 107 data positif, hanya 9 yang terdeteksi (*Recall* = 8.41%). Semua 464 data negatif berhasil diidentifikasi (*Recall* = 100%). *Precision* positif sempurna (100%) karena model sangat konservatif dalam memprediksi positif. Akurasi tampak tinggi karena dominasi kelas negatif.

Hasil Skenario 2 (TF-IDF + Lexicon)

Tabel 2 menampilkan hasil evaluasi model setelah penambahan *Lexicon Score* ke dalam fitur. Dengan menyajikan metrik performa untuk setiap kelas, tabel ini memungkinkan perbandingan langsung dengan Skenario 1 sehingga dampak fitur tambahan terhadap performa model dapat dianalisis secara jelas.

Tabel 2 Hasil Klasifikasi Skenario 2 (TF-IDF + Lexicon)

Metrik	Positif	Negatif
Precision	100.00%	81.98%
Recall	4.67%	100.00%
F1-score	8.93%	90.10%

Support	107	464
----------------	-----	-----

Accuracy: 82.14% *Balanced Accuracy*: 52.34%
Penambahan *Lexicon Score* justru menurunkan performa: *Recall* positif turun dari 8.41% menjadi 4.67% Hanya 5 dari 107 data positif yang terdeteksi Akurasi turun 0.70% Model menjadi lebih konservatif dalam memprediksi kelas positif

Confusion Matrix

Tabel 2 menyajikan confusion matrix dari model pada Skenario 1. Informasi mengenai True Positive, False Positive, True Negative, dan False Negative disajikan untuk memahami pola kesalahan dan keberhasilan model dalam mengklasifikasi masing-masing kelas sentimen.

Tabel 3 Confusion Matrix Skenario 1

	Prediksi Positif	Prediksi Negatif
Aktual Positif	9	98
Aktual Negatif	0	464

Tabel 3 memperlihatkan matriks kebingungan untuk Skenario 2, memberikan gambaran detail mengenai performa prediksi setelah penambahan fitur *Lexicon*. Matriks ini memungkinkan peneliti mengevaluasi perubahan pola prediksi dibandingkan Skenario 1.

Tabel 4 Confusion Matrix Skenario 2

	Prediksi Positif	Prediksi Negatif
Aktual Positif	5	102
Aktual Negatif	0	464

Kedua skenario menunjukkan : False Positive = 0 (tidak ada negatif yang salah diprediksi sebagai positif). False Negative sangat tinggi (98 dan 102). Model sangat konservatif dan cenderung memprediksi negatif.

Perbandingan Kedua Skenario

Tabel 5 menyajikan perbandingan langsung berbagai metrik antara Skenario 1 dan Skenario 2. Perbandingan mencakup akurasi, *precision*, *recall*, *F1-score*, *Balanced accuracy*, dan metrik agregat lainnya. Tabel ini berfungsi untuk menunjukkan apakah penambahan fitur memberikan dampak positif atau negatif terhadap performa model secara keseluruhan.

Tabel 5 Perbandingan Lengkap Metrik Evaluasi Kedua Skenario


Metrik	Skenario 1	Skenario 2	Selisih	Metrik
Akurasi	82.84%	82.14%	-0.70%	Akurasi
Precision Positif	100.00%	100.00%	0.00%	Precision Positif
Recall Positif	8.41%	4.67%	-3.74%	Recall Positif
F1 Positif	15.52%	8.93%	-6.59%	F1 Positif
Precision Negatif	82.56%	81.98%	-0.58%	Precision Negatif
Recall Negatif	100.00%	100.00%	0.00%	Recall Negatif
F1 Negatif	90.45%	90.10%	-0.35%	F1 Negatif
Balance d Acc	54.21%	52.34%	-1.87%	Balance d Acc
Macro F1	52.98%	49.51%	-3.47%	Macro F1
Weighted F1	76.41%	74.89%	-1.52%	Weighted F1

Penambahan fitur leksikon tidak memberikan *improvement*, bahkan menurunkan performa pada kelas minoritas. Hal ini menunjukkan bahwa: Masalah utama ada pada ketidakseimbangan data, bukan pada kekurangan fitur Satu fitur leksikon tidak cukup signifikan dibandingkan 2.816 fitur TF-IDF Prior probability kelas negatif yang sangat besar mendominasi keputusan model

Pada Gambar 2 menyajikan perbandingan lengkap sepuluh metrik evaluasi antara Skenario 1 dan Skenario 2, meliputi akurasi, *precision*, *recall*, *F1-score* pada masing-masing kelas, serta metrik agregat seperti *Balanced Accuracy*, Macro F1, dan Weighted F1. Penyajian metrik secara menyeluruh ini bertujuan untuk memastikan bahwa evaluasi tidak hanya berfokus pada satu indikator, tetapi mempertimbangkan berbagai aspek performa model secara menyeluruh.

Secara visual, grafik menunjukkan bahwa kedua skenario memiliki kecenderungan performa yang relatif berdekatan, menandakan bahwa strategi pemrosesan dan kombinasi fitur yang

diterapkan pada masing-masing skenario menghasilkan tingkat efektivitas yang sebanding. Perbedaan nilai pada *precision* dan *recall*, khususnya pada kelas positif yang jumlahnya jauh lebih sedikit, menjadi indikator penting dalam memahami sensitivitas model terhadap data minoritas. Sementara itu, konsistensi pada metrik agregat seperti Macro F1 dan Weighted F1 memperlihatkan bahwa model tetap mampu menjaga stabilitas performa meskipun menghadapi ketidakseimbangan kelas.



Gambar 2 Distribusi Prediksi yang Berbeda Antara Kedua Skenario

CONCLUSION

Kesimpulan ini merangkum hasil penelitian yang mencakup temuan utama, performa kombinasi metode Naïve Bayes, TF-IDF, dan pendekatan Lexicon-Based, serta pengaruhnya terhadap proses klasifikasi sentimen komentar TikTok terhadap film S-Line. Rumusan kesimpulan disusun berdasarkan analisis eksperimen, evaluasi model, serta pembahasan pada bab sebelumnya untuk memberikan gambaran menyeluruh mengenai efektivitas metode yang digunakan. Adapun kesimpulan penelitian ini adalah sebagai berikut.

Hasil eksperimen menunjukkan bahwa penggunaan metode TF-IDF saja maupun TF-IDF + Lexicon-Based belum mampu menghasilkan klasifikasi yang optimal karena ketidakseimbangan kelas pada dataset. Kedua skenario menghasilkan akurasi yang sama yaitu 81,33%, namun model gagal mendeteksi kelas positif (*recall* = 0), yang menunjukkan dominasi kelas negatif sebesar 81,23% sangat memengaruhi performa model Naïve Bayes. Kondisi ini membuktikan bahwa peningkatan kualitas fitur tanpa penanganan imbalance data belum cukup untuk meningkatkan performa klasifikasi.

Integrasi *Lexicon Score* sebagai fitur tambahan terbukti memberikan representasi emosional yang lebih kaya, karena mampu menambahkan informasi semantik dari kata-kata sentimental. Meskipun demikian,

peningkatan akurasi belum terjadi secara signifikan karena pengaruh imbalance data lebih dominan dibanding pengayaan fitur. Hasil ini menegaskan bahwa metode Lexicon-Based efektif dalam memberi bobot emosional pada kata-kata tertentu, tetapi tetap memerlukan penanganan distribusi kelas yang seimbang agar berfungsi optimal bersama Naïve Bayes.

REFERENCE

- [1] S. Bhoyar, S. Giradkar, S. Burghate, and S. Shende, "Movie Sentiment Review Analysis," *International Scientific Journal of Engineering and Management*, vol. 02, no. 04, 2023, doi: 10.55041/isjem00251.
- [2] I. Apriyani, A. Fauzi, D. S. Kusumaningrum, and H. H. Handayani, "Analisis Sentimen Performa Timnas Sepak Bola Indonesia pada Kolom Komentar Aplikasi TikTok Menggunakan Algoritma Machine Learning," *Jurnal Accounting Information System (AIMS)*, vol. 8, no. 1, pp. 76–89, 2025, doi: 10.32627/aims.v8i1.1160.
- [3] I. A. H. Hidayah, R. Kusumawati, Z. Abidin, and M. Imamuddin, "Analysis of Public Sentiment Towards The TikTok Application Using The Naive Bayes Algorithm and Support Vector Machine," *Journal of Computer Networks, Architecture and High Performance Computing*, vol. 6, no. 2, pp. 881–891, 2024, doi: 10.47709/cnahpc.v6i2.3990.
- [4] Pius Deski Manalu, Mutiara Simanjuntak, and Chairil Umri, "Implementasi Algoritma Klasifikasi untuk Analisis Sentimen Media Sosial Tiktok Tahun 2025," *Jurnal Teknik Informatika dan Teknologi Informasi*, vol. 5, no. 1, pp. 488–504, 2025, doi: 10.55606/jutiti.v5i2.5644.
- [5] M. Z. F. Rizky, Y. Sibaroni, and S. S. Prasetyowati, "Sentiment Analysis on TikTok App using Long Short-Term Memory (LSTM) with Stochastic Gradient Descent (SGD) Optimization," *Jurnal Media Informatika Budidarma*, vol. 8, no. 3, p. 1292, 2024, doi: 10.30865/mib.v8i3.7699.
- [6] A. Bello, S. C. Ng, and M. F. Leung, "A BERT Framework to Sentiment Analysis of Tweets," *Sensors*, vol. 23, no. 1, 2023, doi: 10.3390/s23010506.
- [7] S. Chirgaiya, D. Sukheja, N. Shrivastava, and R. Rawat, "Analysis of sentiment based movie reviews using machine learning techniques," *Journal of Intelligent and Fuzzy Systems*, vol. 41, no. 5, pp. 5449–5456, 2021, doi: 10.3233/JIFS-189866.

- [8] R. A. Putranto, M. D. Purbolaksono, and W. Astuti, "Sentiment Analysis of Practo Application Reviews Using Naïve Bayes and TF-IDF Methods," *Jurnal Media Informatika Budidarma*, vol. 7, no. 3, p. 1070, 2023, doi: 10.30865/mib.v7i3.6311.
- [9] P. A. Sumitro, Rasiban, D. I. Mulyana, and W. Saputro, "Analisis Sentimen Terhadap Vaksin Covid-19 di Indonesia pada Twitter Menggunakan Metode Lexicon Based," *J-ICOM - Jurnal Informatika dan Teknologi Komputer*, vol. 2, no. 2, pp. 50–56, 2021, doi: 10.33059/j-icom.v2i2.4009.
- [10] A. R. Fachrur, "Sentiment Analysis of Hotel Reviews in Anyer Beach Tourism Area: A Lexicon-Based Text Mining Approach," *JELAJAH: Journal of Tourism and Hospitality*, vol. 5, no. 2, 2024, doi: 10.33830/jelajah.v5i2.10264.
- [11] W. A. Akbari, T. Tukino, B. Huda, and M. Muslih, "Sentiment Analysis of Twitter User Opinions Related to Metaverse Technology Using Lexicon Based Method," *Sinkron*, vol. 8, no. 1, pp. 195–201, 2023, doi: 10.33395/sinkron.v8i1.11992.
- [12] C. Villa-Ruiz, B. Kassamali, D. R. Mazori, M. Min, G. Cobos, and A. LaChance, "Overview of TikTok's most viewed dermatologic content and assessment of its reliability," *Journal of the American Academy of Dermatology*, vol. 85, no. 1, pp. 273–274, 2021, doi: 10.1016/j.jaad.2020.12.028.
- [13] L. J. Wanberg and D. R. Pearson, "Evaluating the Disease-Related Experiences of TikTok Users With Lupus Erythematosus: Qualitative and Content Analysis," *JMIR Infodemiology*, vol. 4, no. 1, 2024, doi: 10.2196/51211.
- [14] K. Sallaku, D. De Fano, V. S. Ha, and A. Russo, "Breakdown of the co-creation process on social media: developing the value co-washing framework and stakeholders dynamics," *Journal of Asia Business Studies*, vol. 19, no. 1, pp. 23–53, 2025, doi: 10.1108/JABS-02-2024-0110.
- [15] S. Tabinda Kokab, S. Asghar, and S. Naz, "Transformer-based deep learning models for the sentiment analysis of social media data," *Array*, vol. 14, 2022, doi: 10.1016/j.array.2022.100157.