

Analisis Sentimen Masyarakat Indonesia Terhadap Aplikasi TikTok Menggunakan Algoritma Logistic Regression

Fathur Rizal ^{1*}, Andi Wijaya ², Fuadz Hasyim ³

^{1,2,3} Teknik Informatika, Universitas Nurul Jadid, Probolinggo, Indonesia

Article Info

Article history:

Received Juli 5, 2024
Revised Juli 14, 2024
Accepted Juli 16, 2024

Keywords:

Analisis Sentimen
Klasifikasi
Logistic Regression
Sentimen
TikTok

ABSTRACT

Meningkatnya popularitas aplikasi TikTok di kalangan masyarakat Indonesia telah menimbulkan reaksi yang beragam dari masyarakat, memicu kebutuhan untuk analisis yang lebih mendalam mengenai sentimen publik terhadap platform ini. Penelitian ini bertujuan untuk memahami sikap yang dominan baik positif dan negatif terhadap TikTok di kalangan pengguna Indonesia. Dengan menggunakan algoritma Logistic Regression, yang dikenal dengan kemudahannya dan kapasitas interpretasi yang baik dalam klasifikasi sentimen, penelitian ini mengolah data ulasan pengguna yang diambil dari Google PlayStore. Analisis sentimen melibatkan tahapan pengambilan data, pra-pemrosesan (termasuk case folding, tokenisasi, normalisasi, dan stemming), serta pembobotan terms menggunakan TF-IDF. Hasil penelitian menunjukkan tingkat akurasi klasifikasi sentimen hampir sempurna, percobaan pertama (rasio 80:20) memberikan performa terbaik dengan akurasi 83%, yang menunjukkan efektivitas Logistic Regression dalam menganalisis sentimen. Performa model menunjukkan konsistensi dalam precision dan recall di semua rasio pengujian, mengindikasikan bahwa model tersebut cukup robust terhadap perubahan proporsi data pelatihan dan pengujian. Percobaan kedua dan ketiga juga memberikan performa yang baik pula dengan akurasi 81%.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Corresponding Author:

Fathur Rizal, Program Studi Teknik Informatika, Universitas Nurul Jadid, Karanganyar Paiton, Probolinggo 67291, Indonesia

Email: fathurrizal@unuja.ac.id

1. PENDAHULUAN

Aplikasi TikTok telah menjadi fenomena global sejak diluncurkan pada tahun 2016 oleh perusahaan teknologi ByteDance. Di Indonesia, aplikasi ini mengalami peningkatan popularitas yang signifikan, terutama di kalangan generasi muda [1], [2]. TikTok menawarkan platform untuk pengguna membuat, membagikan, dan menemukan video pendek yang kreatif dan menghibur. Namun, di balik kesuksesan dan popularitasnya, TikTok juga menuai berbagai kontroversi dan respons yang beragam dari masyarakat Indonesia. Beberapa pihak memuji kreativitas dan peluang ekonomi yang ditawarkan oleh aplikasi ini, sementara yang lain mengkhawatirkan dampak negatifnya terhadap kesehatan mental dan sosial, terutama pada remaja.

Dalam beberapa tahun terakhir, analisis sentimen telah menjadi alat yang populer untuk mengkaji persepsi masyarakat terhadap berbagai topik [3], [4], termasuk aplikasi media sosial seperti TikTok. Analisis sentimen adalah proses mengidentifikasi dan mengkategorikan opini yang dinyatakan dalam teks, khususnya untuk menentukan sikap terhadap topik tertentu positif, negatif, atau netral. Dengan menganalisis sentimen masyarakat Indonesia terhadap TikTok dapat memperoleh wawasan yang lebih dalam mengenai pandangan umum dan isu-isu utama yang dihadapi oleh pengguna aplikasi ini [4]. Metode yang sering digunakan dalam analisis sentimen adalah algoritma machine learning, salah satunya adalah Logistic Regression. Algoritma ini dikenal karena kesederhanaannya dan kemampuan interpretasinya yang baik dalam memprediksi kategori sentimen [5]. *Logistic Regression* dapat digunakan untuk mengklasifikasikan teks ulasan atau komentar


pengguna menjadi sentimen positif, negatif, atau netral berdasarkan fitur-fitur yang relevan dari teks tersebut[6].

Penelitian yang dilakukan Sola Fide dkk (2021) tentang analisis sentimen ulasan TikTok di Google PlayStore menggunakan algoritma Support Vector Machine dengan kernel RBF dan metode asosiasi. Penelitian tersebut menganalisis sentimen publik (positif atau negatif) terhadap aplikasi TikTok di Indonesia. Beberapa proses yang dilakukan dalam analisis sentimen tersebut meliputi pengambilan data dengan proses scrapping data di Google Play, preprocessing data (case folding, cleaning, dan normalisasi kata), penilaian sentimen, feature selection (stopwords, stemming, dan tokenizing), pembobotan Term Frequency – Inverse Document Frequency, pembuatan data latih serta data uji, dan klasifikasi data menggunakan Support Vector Machine dan algoritma asosiasi. Hasil pengujian yang telah dilakukan, algoritma Support Vector Machine memperoleh hasil akurasi 90.62% dan kappa 81.24%, hal ini menunjukkan klasifikasi yang hampir sempurna. Dalam penelitian tersebut, sentimen positif umumnya berkaitan dengan konten, sedangkan sentimen negatif terkait masalah teknis seperti pendaftaran dan pemblokiran akun [4]. Penelitian serupa juga dilakukan oleh Junda Alfiah Zulqornain dkk (2021) dalam penelitiannya juga membahas tentang analisis sentimen masyarakat terhadap aplikasi tiktok menggunakan algoritma Naïve Bayes dan Categorical Proportional Difference. Aplikasi TikTok merupakan aplikasi yang dapat membagikan video, tetapi biasanya juga muncul video yang memiliki unsur vulgar yang dapat dilihat oleh anak dibawah umur karena aplikasi tersebut ini tidak terdapat batasan usia pemakai. Oleh sebab itu penelitian tersebut bertujuan untuk menganalisa sentimen pada ulasan aplikasi TikTok untuk membantu orang tua dalam pemilihan aplikasi untuk anaknya. Dataset yang digunakan dalam penelitian tersebut diambil dari Google PlayStore dari rating 1-5 yang berjumlah 1000 data dan mempunyai 2 kelas yakni positif dan negatif. Hasil akurasi terbaik yang diperoleh dalam penelitian tersebut yakni 0,729947 (73%), nilai precision sebesar 0,746854 (75%), nilai recall sebesar 0,926118 (93%), dan nilai f-measure 0,824511 (82%) [7].

Dalam penelitian ini, data yang digunakan akan dikumpulkan dari platform *google playstore* di mana pengguna Indonesia sering memberikan ulasan terhadap aplikasi TikTok disana. Data ini kemudian akan diproses dan dianalisis menggunakan algoritma *Logistic Regression* untuk mengidentifikasi pola sentimen yang dominan. Proses ini mencakup tahap pengumpulan data, pembersihan data, pembobotan *terms*, dan pelatihan model. Salah satu tantangan dalam analisis sentimen adalah memastikan bahwa data yang digunakan representatif dan bebas dari bias. Oleh karena itu, penting untuk mengumpulkan data dari berbagai sumber dan memastikan bahwa data tersebut mencakup berbagai perspektif pengguna. Hasil dari analisis sentimen ini diharapkan dapat memberikan gambaran yang jelas tentang bagaimana masyarakat Indonesia melihat TikTok. Misalnya, apakah mayoritas pengguna merasa bahwa TikTok adalah platform yang menyenangkan dan bermanfaat, ataukah ada kekhawatiran terkait privasi dan keamanan data. Informasi ini dapat digunakan di bidang teknologi dan komunikasi. Dengan memahami sentimen pengguna, dapat mengembangkan strategi yang lebih efektif untuk berinteraksi dengan audiens dan meningkatkan keterlibatan pengguna. Selain itu, penelitian ini juga dapat menjadi referensi bagi studi-studi selanjutnya yang ingin mengeksplorasi sentimen masyarakat terhadap aplikasi atau teknologi lainnya. Penelitian ini diharapkan dapat memberikan kontribusi yang signifikan dalam memahami dinamika sentimen masyarakat terhadap aplikasi TikTok di Indonesia.

2. METODE

Penelitian ini menggunakan metode analisis sentimen berbasis algoritma Logistic Regression untuk mengklasifikasikan sentimen masyarakat Indonesia terhadap aplikasi TikTok. Berikut adalah langkah-langkah yang dilakukan dalam penelitian ini:



Gambar 1. Tahapan Penelitian

Penelitian ini menggunakan data berupa ulasan atau komentar dari pengguna Indonesia terhadap aplikasi TikTok yang terdapat di Google PlayStore. Pengambilan data dilaksanakan dengan teknik scrapping pada komentar TikTok menggunakan Google Colaboratory, dengan syarat scrapping hanya dilakukan pada komentar yang ber-ID Indonesia serta penelitian ini menggunakan sejumlah 5.000 dataset dalam analisisnya. Preprocessing adalah tahap transformasi data mentah menjadi format yang lebih sesuai untuk analisis, bertujuan untuk mendapatkan informasi yang lebih autentik untuk proses analisis berikutnya. Dalam penelitian ini, preprocessing melibatkan beberapa langkah kunci termasuk pembersihan data, perbaikan, dan

penggabungan. Langkah-langkah spesifik yang akan diambil meliputi tokenisasi, di mana kalimat dipecah menjadi kata-kata individu; normalisasi, mengubah kata-kata tidak standar menjadi bentuk baku; penghapusan stopword untuk mengeliminasi kata-kata umum yang sering muncul namun kurang informatif; dan stemming, mengurangi kata-kata berimbuhan menjadi bentuk dasar.

Proses labeling data pada penelitian ini menggunakan Lexicon. Lexicon berfungsi untuk mengenali kata-kata dalam kalimat yang bersifat positif, negatif, atau netral dengan menghitung nilai polaritasnya[8]. Untuk mengidentifikasi sentimen kata, bisa digunakan dataset lexicon berbahasa Indonesia. Langkah awal dalam proses ini adalah memilih atau mengembangkan lexicon yang tepat. Setelah lexicon siap, proses pelabelan dilakukan dengan menganalisis teks yang akan diberi label. Teks tersebut dipecah menjadi unit yang lebih kecil, umumnya kata-kata, yang kemudian dipadankan dengan entri dalam lexicon. Setiap kata di skor berdasarkan nilai sentimen yang ada dalam lexicon; misalnya, kata "bahagia" mungkin diberi skor positif, sementara "sedih" diberi skor negatif. Metode ini memungkinkan untuk secara otomatis menghitung skor dari setiap kata dalam teks dan mengagregasinya untuk mendapatkan gambaran sentimen secara keseluruhan dari teks tersebut.

Metode *Term Frequency - Inverse Document Frequency* (TF-IDF) digunakan untuk memberikan bobot pada kata-kata yang terdapat dalam dokumen [9]. Proses ini meliputi dua tahapan utama: *Term Frequency* (TF) dan *Inverse Document Frequency* (IDF). Tahap TF mengukur frekuensi kemunculan kata dalam suatu dokumen, dimana kata yang lebih sering muncul mendapatkan nilai yang lebih tinggi. Sedangkan tahap IDF menghitung seberapa sering kata tersebut muncul di seluruh dokumen, memberikan bobot lebih tinggi pada kata-kata yang lebih unik[9], [10], [11]. Kata-kata yang umum muncul di banyak dokumen akan mendapatkan nilai IDF yang lebih rendah, menandakan keumumannya. Adapun persamaan yang digunakan yakni sebagai berikut:

$$TF(t, d) = \frac{N(t,d)}{T} \quad (1)$$

TF(t,d) mewakili frekuensi istilah dari istilah t dalam dokumen d, N(t,d) adalah jumlah kemunculan istilah t dalam dokumen d, dan T adalah jumlah total istilah dalam dokumen tersebut. Jadi, untuk setiap dokumen dan kata, nilai TF(t,d) yang berbeda akan diberikan.

$$IDF(t) = \frac{\log N}{N(t)} \quad (2)$$

IDF(t) merupakan inverse document frequency dari istilah t, N adalah jumlah dokumen, dan N(t) adalah jumlah dokumen yang mengandung istilah t. Adapun persamaan yang digunakan untuk menghitung Term Frequency - Inverse Document Frequency yakni sebagai berikut:

$$TF - IDF = TF * IDF \quad (3)$$

Split data dilakukan dengan membagi data menjadi rasio 80:20, 70:30, dan 60:40 untuk data pelatihan (training) dan data pengujian (testing). Tujuan dari pembagian ini adalah untuk mengevaluasi akurasi kinerja algoritma *Logistic Regression* dalam mengklasifikasikan sentimen masyarakat terhadap aplikasi TikTok. Untuk mengevaluasi kinerja algoritma *Logistic Regression*, penelitian ini menggunakan *Confusion Matrix*. *Confusion Matrix* memanfaatkan tabel matriks untuk menampilkan hasil klasifikasi data pengujian berdasarkan data pelatihan[12], [13]. Berikut ini adalah tabel Confusion Matrix yang mencakup empat kombinasi berbeda antara nilai prediksi dan nilai aktual.

		Actual Values	
		1 (Positive)	0 (Negative)
Predicted Values	1 (Positive)	TP (True Positive)	FP (False Positive) <i>Type I Error</i>
	0 (Negative)	FN (False Negative) <i>Type II Error</i>	TN (True Negative)

Gambar 2. Confusion Matrix

True Positive (TP) merupakan data positif yang diprediksi benar, True Negative (TN) merupakan data negatif yang diprediksi benar, False Postive (FP) merupakan data negatif namun diprediksi sebagai data positif, dan False Negative (FN) merupakan data positif namun diprediksi sebagai data negatif [14], [15], [16].

Skenario uji coba performa algoritma bertujuan untuk menghasilkan model terbaik saat proses training sampai dengan ketika model diimplementasikan. Dalam analisis sentimen ulasan aplikasi TikTok, pengujian dilakukan tiga kali dengan membagi data pelatihan dan pengujian dalam berbagai proporsi.

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Data

Data ulasan atau komentar aplikasi TikTok yang digunakan dalam penelitian ini berjumlah 5.000 data. Contoh dari data ulasan/komentar TikTok yang telah dikumpulkan dapat dilihat pada tabel 1.

Tabel 1. Komentar/Ulasan Aplikasi TikTok

No	Komentar/Ulasan
1	Aplikasi gak jelas, padahal enggak pernah ngirim/ngetik aneh aneh malah ditanggguhkan nungguin lama tetep gak bisa, gak bisa ngirim pesan, enggak bisa terima pesan tolong ya aplikasi nya di perbaiki lagi
2	Skrang Tiktok Terlalu sensitif biar kata tidak mengandung kata Negatif... Biar pun bahasa daerah yang kata membangun Semangat... Sedikit-Sediki di hapus.. Biar pun di Banding" tetap aja di hapus....Tolong di perhatikan dan belajar bahasa daerah
3	Terlalu banyak pelanggaran yg di berikan Padahal vidio buat sendiri tapi kena pelanggaran sampai 3 point Tolong di perbaiki sistem nya

3.2. Pre-processing Data

Tahap pertama sebelum proses klasifikasi data adalah preprocessing. Tahapan preprocessing yang dilakukan meliputi case folding, tokenisasi, penghapusan stopword, dan stemming.

Tabel 2. Hasil Case Folding

No	Komentar/Ulasan	Case Folding
1	Aplikasi gak jelas, padahal enggak pernah ngirim/ngetik aneh aneh malah ditanggguhkan nungguin lama tetep gak bisa, gak bisa ngirim pesan, enggak bisa terima pesan tolong ya aplikasi nya di perbaiki lagi	aplikasi gak jelas, padahal enggak pernah ngirim/ngetik aneh aneh malah ditanggguhkan nungguin lama tetep gak bisa, gak bisa ngirim pesan, enggak bisa terima pesan tolong ya aplikasi nya di perbaiki lagi
2	Skrang Tiktok Terlalu sensitif biar kata tidak mengandung kata Negatif... Biar pun bahasa daerah yang kata membangun Semangat... Sedikit-Sediki di hapus.. Biar pun di Banding" tetap aja di hapus....Tolong di perhatikan dan belajar bahasa daerah	skrang tiktok terlalu sensitif biar kata tidak mengandung kata negatif... biar pun bahasa daerah yang kata membangun semangat... sedikit-sediki di hapus.. biar pun di banding" tetap aja di hapus....tolong di perhatikan dan belajar bahasa daerah
3	Terlalu banyak pelanggaran yg di berikan Padahal vidio buat sendiri tapi kena pelanggaran sampai 3 point Tolong di perbaiki sistem nya	terlalu banyak pelanggaran yg di berikan padahal vidio buat sendiri tapi kena pelanggaran sampai 3 point tolong di perbaiki sistem nya

Tabel 2 adalah hasil dari proses case folding dalam proses ini bertujuan untuk mengonversi kata-kata menjadi huruf kecil, dan menghapus semua kalimat selain teks seperti tanda baca, simbol, emoji, dan lainnya, juga menghapus angka dalam sebuah kalimat dalam dokumen. Tahap selanjutnya dari preprocessing adalah tokenisasi, di Tabel 3 dapat dilihat bahwa proses ini memecah sebuah kalimat menjadi token sehingga dapat diproses di tahap berikutnya.

Tabel 3. Hasil Tokenisasi

No	Case Folding	Tokenisasi
1	aplikasi gak jelas, padahal enggak pernah ngirim/ngetik aneh aneh malah ditanggguhkan nungguin lama tetep gak bisa, gak bisa ngirim pesan, enggak bisa terima pesan tolong ya aplikasi nya di perbaiki lagi	['aplikasi', 'gak', 'jelas', 'padahal', 'enggak', 'pernah', 'ngirim', 'ngetik', 'aneh', 'aneh', 'malah', 'ditanggguhkan', 'nungguin', 'lama', 'tetep', 'gak', 'bisa', 'gak', 'bisa', 'ngirim', 'pesan', 'enggak', 'bisa',

No	Case Folding	Tokenisasi
		'terima', 'pesan', 'tolong', 'ya', 'aplikasi', 'nya', 'di', 'perbaiki', 'lagi']
2	skrang tiktok terlalu sensitif biar kata tidak mengandung kata negatif... biar pun bahasa daerah yang kata membangun semangat... sedikit-sediki di hapus.. biar pun di banding" tetap aja di hapus...tolong di perhatikan dan belajar bahasa daerah	['skrang', 'tiktok', 'terlalu', 'sensitif', 'biar', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'biar', 'pun', 'bahasa', 'daerah', 'yang', 'kata', 'membangun', 'semangat', 'sedikit', 'sediki', 'di', 'hapus', 'biar', 'pun', 'di', 'banding', 'tetap', 'aja', 'di', 'hapus', 'tolong', 'di', 'perhatikan', 'dan', 'belajar', 'bahasa', 'daerah']
2	terlalu banyak pelanggaran yg di berikan padahal vidio buat sendiri tapi kena pelanggaran sampai 3 point tolong di perbaiki sistem nya	['terlalu', 'banyak', 'pelanggaran', 'yg', 'di', 'berikan', 'padahal', 'vidio', 'buat', 'sendiri', 'tapi', 'kena', 'pelanggaran', 'sampai', '3', 'point', 'tolong', 'di', 'perbaiki', 'sistem', 'nya']

Tabel 4 adalah hasil dari normalisasi. Normalisasi dalam penelitian ini dilakukan dengan mengonversi kata-kata non-standar menjadi kata-kata standar sesuai dengan Kamus Besar Bahasa Indonesia (KBBI) dengan mencocokkannya dengan dataset yang sudah dimiliki (kalimat informal - kalimat formal).

Tabel 4. Hasil Normalisasi

No	Tokenisasi	Normalisasi
1	['aplikasi', 'gak', 'jelas', 'padahal', 'enggak', 'pernah', 'ngirim', 'ngetik', 'aneh', 'aneh', 'malah', 'ditanggihkan', 'nungguin', 'lama', 'tetep', 'gak', 'bisa', 'gak', 'bisa', 'ngirim', 'pesan', 'enggak', 'bisa', 'terima', 'pesan', 'tolong', 'ya', 'aplikasi', 'nya', 'di', 'perbaiki', 'lagi']	['aplikasi', 'tidak', 'jelas', 'padahal', 'tidak', 'pernah', 'mengirim', 'mengetik', 'aneh', 'aneh', 'malah', 'ditanggihkan', 'menunggu', 'lama', 'tetap', 'tidak', 'bisa', 'tidak', 'bisa', 'mengirim', 'pesan', 'tidak', 'bisa', 'terima', 'pesan', 'tolong', 'ya', 'aplikasi', 'nya', 'di', 'perbaiki', 'lagi']
2	['skrang', 'tiktok', 'terlalu', 'sensitif', 'biar', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'biar', 'pun', 'bahasa', 'daerah', 'yang', 'kata', 'membangun', 'semangat', 'sedikit', 'sediki', 'di', 'hapus', 'biar', 'pun', 'di', 'banding', 'tetap', 'aja', 'di', 'hapus', 'tolong', 'di', 'perhatikan', 'dan', 'belajar', 'bahasa', 'daerah']	['skrang', 'tiktok', 'terlalu', 'sensitif', 'biar', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'biar', 'pun', 'bahasa', 'daerah', 'yang', 'kata', 'membangun', 'semangat', 'sedikit', 'sediki', 'di', 'hapus', 'biar', 'pun', 'di', 'banding', 'tetap', 'aja', 'di', 'hapus', 'tolong', 'di', 'perhatikan', 'dan', 'belajar', 'bahasa', 'daerah']
3	['terlalu', 'banyak', 'pelanggaran', 'yg', 'di', 'berikan', 'padahal', 'vidio', 'buat', 'sendiri', 'tapi', 'kena', 'pelanggaran', 'sampai', '3', 'point', 'tolong', 'di', 'perbaiki', 'sistem', 'nya']	['terlalu', 'banyak', 'pelanggaran', 'yang', 'di', 'berikan', 'padahal', 'video', 'buat', 'sendiri', 'tapi', 'kena', 'pelanggaran', 'sampai', '3', 'point', 'tolong', 'di', 'perbaiki', 'sistem', 'nya']

Tabel 5 adalah hasil dari proses Penghapusan Stopword, pada tahap ini bertujuan untuk mengambil kata-kata penting dan membuang kata-kata yang kurang penting serta tidak memiliki makna.

Tabel 5. Hasil Stopword

No	Normalisasi	Stopword
2	['aplikasi', 'tidak', 'jelas', 'padahal', 'tidak', 'pernah', 'mengirim', 'mengetik', 'aneh', 'aneh', 'malah', 'ditanggihkan', 'menunggu', 'lama', 'tetap', 'tidak', 'bisa', 'tidak', 'bisa', 'mengirim', 'pesan', 'tidak', 'bisa', 'terima', 'pesan', 'tolong', 'ya', 'aplikasi', 'nya', 'di', 'perbaiki', 'lagi']	['aplikasi', 'tidak', 'jelas', 'padahal', 'tidak', 'pernah', 'mengirim', 'mengetik', 'aneh', 'aneh', 'malah', 'ditanggihkan', 'menunggu', 'lama', 'tetap', 'tidak', 'bisa', 'tidak', 'bisa', 'mengirim', 'pesan', 'tidak', 'bisa', 'terima', 'pesan', 'tolong', 'aplikasi', 'perbaiki', 'lagi']
3	['skrang', 'tiktok', 'terlalu', 'sensitif', 'biar', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'biar', 'pun', 'bahasa', 'daerah', 'yang', 'kata', 'membangun', 'semangat', 'sedikit', 'sediki', 'di', 'hapus', 'biar', 'pun', 'di', 'banding', 'tetap', 'aja', 'di', 'hapus', 'tolong', 'di', 'perhatikan', 'dan', 'belajar', 'bahasa', 'daerah']	['sekarang', 'tiktok', 'terlalu', 'sensitif', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'bahasa', 'daerah', 'kata', 'membangun', 'semangat', 'sedikit', 'sedikit', 'hapus', 'hapus', 'tolong', 'perhatikan', 'belajar', 'bahasa', 'daerah']

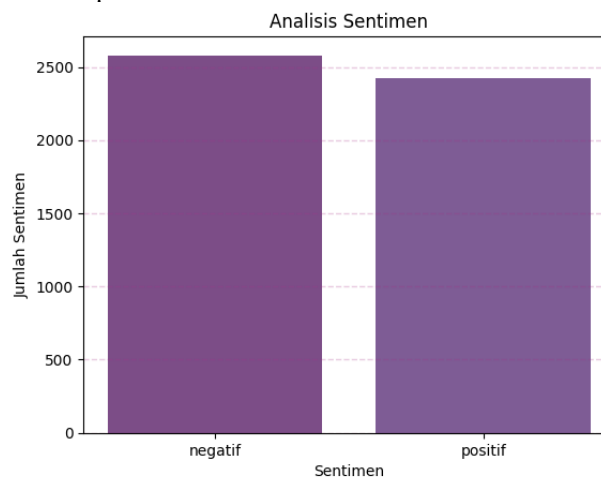
No	Normalisasi	Stopword
5	['terlalu', 'banyak', 'pelanggaran', 'yang', 'di', 'berikan', 'padahal', 'video', 'buat', 'sendiri', 'tapi', 'kena', 'pelanggaran', 'sampai', '3', 'point', 'tolong', 'di', 'perbaiki', 'sistem', 'nya']	['terlalu', 'banyak', 'pelanggaran', 'berikan', 'padahal', 'video', 'buat', 'sendiri', 'kena', 'pelanggaran', 'sampai', '3', 'point', 'tolong', 'perbaiki', 'sistem']

Tabel 6 adalah hasil dari proses stemming pada tahap proses menggabungkan kata-kata dasar yang telah difilter, dalam proses ini juga kalimat yang awalnya token digabung menjadi kalimat biasa menggunakan library sastrawi.

Tabel 6. Hasil Stemming

No	Stopword	Stemming
1	['aplikasi', 'tidak', 'jelas', 'padahal', 'tidak', 'pernah', 'mengirim', 'menetik', 'aneh', 'aneh', 'malah', 'ditangguhkan', 'menunggu', 'lama', 'tetap', 'tidak', 'bisa', 'tidak', 'bisa', 'mengirim', 'pesan', 'tidak', 'bisa', 'terima', 'pesan', 'tolong', 'aplikasi', 'perbaiki', 'lagi']	['aplikasi', 'tidak', 'jelas', 'padahal', 'tidak', 'pernah', 'kirim', 'tik', 'aneh', 'aneh', 'malah', 'tangguh', 'tunggu', 'lama', 'tetap', 'tidak', 'bisa', 'tidak', 'bisa', 'kirim', 'pesan', 'tidak', 'bisa', 'terima', 'pesan', 'tolong', 'aplikasi', 'baik', 'lagi']
2	['sekarang', 'tiktok', 'terlalu', 'sensitif', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'bahasa', 'daerah', 'kata', 'membangun', 'semangat', 'sedikit', 'sedikit', 'hapus', 'hapus', 'tolong', 'perhatikan', 'belajar', 'bahasa', 'daerah']	['sekarang', 'tiktok', 'terlalu', 'sensitif', 'kata', 'tidak', 'mengandung', 'kata', 'negatif', 'bahasa', 'daerah', 'kata', 'bangun', 'semangat', 'sedikit', 'sedikit', 'hapus', 'hapus', 'tolong', 'perhatikan', 'belajar', 'bahasa', 'daerah']
3	['terlalu', 'banyak', 'pelanggaran', 'berikan', 'padahal', 'video', 'buat', 'sendiri', 'kena', 'pelanggaran', 'sampai', '3', 'point', 'tolong', 'perbaiki', 'sistem']	['terlalu', 'banyak', 'langgar', 'beri', 'padahal', 'video', 'buat', 'diri', 'kena', 'langgar', 'sampai', '3', 'point', 'tolong', 'baik', 'sistem']

Setelah tahap preprocessing hingga stemming, langkah selanjutnya adalah mencocokkan terms pada dataset Lexicon Indonesia yang telah disiapkan untuk menghasilkan nilai polaritas kalimat yang akan digunakan untuk menentukan sentimen positif dan negatif. Perbandingan jumlah dataset setelah Pre-processing dan lexicon adalah 2579 sentimen negatif (51.58%) dan 2421 sentimen positif (48.42%) dengan total 5,000 data. Persentase data dapat dilihat pada Gambar 3.



Gambar 3. Perbandingan data sentimen positif dan negatif

Setelah melakukan tahapan lexicon dan pelabelan data, langkah selanjutnya adalah menghitung bobot setiap terms berdasarkan frekuensi kemunculan terms tersebut dalam dokumen menggunakan metode TF-IDF. TF-IDF adalah statistik numerik yang dapat menunjukkan kata kunci dengan kata-kata tertentu. Selain itu, TF-IDF juga dikenal efisien, sederhana, dan akurat. Untuk menghitung TF-IDF menggunakan persamaan yang telah dijelaskan pada metode penelitian.

3.3. Pembagian Data (Data Split)

Proses klasifikasi data teks komentar/ulasan aplikasi TikTok menggunakan Logistic Regression dibagi menjadi 2 bagian, yaitu data pelatihan dan data pengujian. Data yang digunakan adalah data yang telah diproses dan dilabeli sebelumnya. Dataset ulasan sebanyak 5000 data dibagi dengan perbandingan rasio 80%, 70%, dan 60% untuk data pelatihan dan 20%, 30%, dan 40% untuk data pengujian. Perbandingan jumlah data yang digunakan dapat dilihat pada tabel 7 berikut.

Tabel 7. Pembagian Data (Data Split)

Percobaan Ke	Training	Testing
	80%	20%
1	2060 (negatif) 1940 (positif)	519 (negatif) 418 (positif)
	70%	30%
2	1797 (negatif) 1703 (positif)	782 (negatif) 718 (positif)
	60%	40%
3	1537 (negatif) 1463 (positif)	1042 (negatif) 958 (positif)


3.4. Klasifikasi Logistic Regression

Proses klasifikasi menggunakan *Logistic Regression* pada penelitian ini dilakukan dengan 3 kali percobaan. Percobaan pertama dilakukan dengan menggunakan persentase data 80% data latih dan 20% data uji. Percobaan kedua dilakukan dengan menggunakan persentase data 70% data latih dan 30% data uji. Percobaan ketiga dilakukan dengan menggunakan persentase data 60% data latih dan 40% data uji. Adapun hasil dari beberapa skema percobaan yang dilakukan yakni sebagai berikut:

Tabel 8. Hasil Percobaan atau Pengujian

Percobaan Ke	Akurasi	Precision (Negatif)	Precision (Positif)	Recall (Negatif)	Recall (Positif)
1 (80:20)	0.832 (83%)	0.85 (85%)	0.81 (81%)	0.82 (82%)	0.84 (84%)
2 (70:30)	0.812 (81%)	0.85 (85%)	0.78 (78%)	0.77 (77%)	0.85 (75%)
3 (60:40)	0.8115 (81%)	0.86 (86%)	0.77 (77%)	0.77 (77%)	0.86 (86%)


Hasil eksperimen pertama menunjukkan bahwa algoritma Logistic Regression mencapai tingkat akurasi yang sangat baik dalam mengklasifikasikan sentimen ulasan atau komentar aplikasi TikTok, dengan akurasi mencapai 83%. Hasil evaluasi dari pengujian model Logistic Regression menggunakan 80% data latih dan 20% data uji ditampilkan dalam Confusion Matrix untuk menilai kinerja algoritma tersebut. Detail hasil pengujian dapat dilihat pada Gambar 4.




Gambar 4. Confusion Matrix Percobaan Pertama

Berdasarkan confusion matrix gambar 4, dapat diketahui bahwa data ulasan negatif yang terprediksi negatif (benar) sebanyak 426 dan yang terprediksi positif (salah) sebanyak 93. Sedangkan data ulasan positif yang terprediksi negatif (salah) sebanyak 75 dan yang terprediksi positif (benar) sebanyak 390.

Hasil eksperimen kedua dan ketiga menunjukkan bahwa algoritma Logistic Regression mencapai tingkat akurasi yang baik pula dalam mengklasifikasikan sentimen ulasan atau komentar aplikasi TikTok, dengan akurasi sebesar 81% untuk percobaan kedua dan ketiga. Hasil evaluasi dari pengujian model Logistic Regression menggunakan 70% dan 60% untuk data latih dan 30% dan 40% untuk data uji ditampilkan dalam Confusion Matrix untuk menilai kinerja algoritma tersebut. Detail hasil pengujian dapat dilihat pada Gambar 5 dan 6.



Gambar 5. Confusion Matrix Percobaan Kedua



Gambar 6. Confusion Matrix Percobaan Ketiga

Berdasarkan confusion matrix percobaan kedua, dapat diketahui bahwa data ulasan negatif yang terprediksi negatif (benar) sebanyak 606 dan yang terprediksi positif (salah) sebanyak 176. Sedangkan data ulasan positif yang terprediksi negatif (salah) sebanyak 106 dan yang terprediksi positif (benar) sebanyak 612. Pada percobaan ketiga, data ulasan negatif yang terprediksi negatif (benar) sebanyak 799 dan yang terprediksi positif (salah) sebanyak 243. Sedangkan data ulasan positif yang terprediksi negatif (salah) sebanyak 134 dan yang terprediksi positif (benar) sebanyak 824.

4. KESIMPULAN

Dari hasil pengujian, percobaan pertama (rasio 80:20) memberikan performa terbaik dengan akurasi 83%, yang menunjukkan efektivitas Logistic Regression dalam menganalisis sentimen. Performa model menunjukkan konsistensi dalam precision dan recall di semua rasio pengujian, mengindikasikan bahwa model tersebut cukup robust terhadap perubahan proporsi data pelatihan dan pengujian. Percobaan kedua dan ketiga juga memberikan performa yang baik pula dengan akurasi 81%. Model menunjukkan akurasi yang tinggi dan konsisten di semua skenario pengujian, namun performa terbaik dicapai pada rasio pelatihan dan pengujian 80:20. Hal ini menunjukkan bahwa proporsi pelatihan yang lebih tinggi membantu model dalam memahami variasi dalam data, menghasilkan prediksi yang lebih akurat. Namun, bahkan dengan penurunan rasio pelatihan, model masih mampu mempertahankan akurasi yang relatif tinggi, yang membuktikan keefektifan metode Logistic Regression dalam analisis sentimen berbasis teks.

REFERENSI

- [1] F. A. Indriyani, A. Fauzi, and S. Faisal, "Analisis Sentimen Aplikasi TikTok Menggunakan Algoritma Naive Bayes dan Support Vector Machine," *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, vol. 10, no. 2, pp. 176–184, Jul. 2023, doi: 10.37373/teknov10i2.419.
- [2] D. P. Fajrina, Syafriandi, N. Amalita, and A. Salma, "Sentiment Analysis of TikTok Application on Twitter using The Naive Bayes Classifier Algorithm," *UNP Journal of Statistics and Data Science*, vol. 1, no. 5, pp. 392–398, Nov. 2023, doi: 10.24036/ujsds/vol1-iss5/103.
- [3] M. Isnain, G. N. Elwirehardja, and B. Pardamean, "Sentiment Analysis for TikTok Review Using VADER Sentiment and SVM Model," *Procedia Comput Sci*, vol. 227, pp. 168–175, 2023, doi: 10.1016/j.procs.2023.10.514.

- [4] S. Fide, Suparti, and Sudarno, "Analisis Sentimen Ulasan Aplikasi TikTok di Google Play Menggunakan Metode Support Vector Machine (SVM) dan Asosiasi," *Jurnal Gaussian*, vol. 10, no. 3, pp. 346–358, 2021, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/>
- [5] A. Novantika, "Analisis Sentimen Ulasan Pengguna Aplikasi Video Conference Google Meet menggunakan Metode SVM dan Logistic Regression," *PRISMA, Prosiding Seminar Nasional Matematika*, vol. 5, pp. 808–813, 2022, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [6] I. Rahmawati and T. R. Fitriani, "Analisis Sentimen Menggunakan Algoritma Logistic Regression Pada Penerbangan Lion Air berdasarkan Ulasan Pengguna Platform Online," *Jejaring Penelitian dan Pengabdian Masyarakat (JPPM)*, vol. 1, no. 1, pp. 3024–8167, 2023.
- [7] J. A. Zulqornain, Indriati, and P. P. Adikara, "Analisis Sentimen Tanggapan Masyarakat Aplikasi Tiktok Menggunakan Metode Naïve Bayes dan Categorical Propotional Difference (CPD)," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 7, pp. 2886–2890, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [8] A. Pradhan, M. R. Senapati, and P. K. Sahu, "Improving sentiment analysis with learning concepts from concept, patterns lexicons and negations: Improving sentiment analysis with learning concepts," *Ain Shams Engineering Journal*, vol. 13, no. 2, Mar. 2022, doi: 10.1016/j.asej.2021.08.004.
- [9] B. K. Hananto, A. Pinandito, and A. P. Kharisma, "Penerapan Maximum TF-IDF Normalization Terhadap Metode KNN Untuk Klasifikasi Dataset Multiclass Panichella Pada Review Aplikasi Mobile," *Jurnal Pengembangan Teknologii Informasi dan Ilmu Komputer*, vol. 2, no. 12, pp. 6812–6823, 2018, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [10] P. Bafna, D. Pramod, and A. Vaidya, "Document Clustering: TF-IDF Approach," in *International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*, 2016, pp. 61–66.
- [11] B. Das and S. Chakraborty, "An Improved Text Sentiment Classification Model Using TF-IDF and Next Word Negation."
- [12] P. Sudhir and V. D. Suresh, "Comparative study of various approaches, applications and classifiers for sentiment analysis," *Global Transitions Proceedings*, vol. 2, no. 2, pp. 205–211, Nov. 2021, doi: 10.1016/j.gltp.2021.08.004.
- [13] H. Rahab, A. Zitouni, and M. Djoudi, "SANA: Sentiment analysis on newspapers comments in Algeria," *Journal of King Saud University - Computer and Information Sciences*, vol. 33, no. 7, pp. 899–907, Sep. 2021, doi: 10.1016/j.jksuci.2019.04.012.
- [14] F. F. Irfani, M. Triyanto, A. D. Hartanto, and Kusnawi, "Analisis Sentimen Review Aplikasi Ruanguru Menggunakan Algoritma Support Vector Machine," *Jurnal Bisnis, Manajemen dan Informatika*, vol. 16, no. 3, pp. 258–266, 2020.
- [15] I. Novitasari, T. B. Kurniawan, D. A. Dewi, and Misinem, "Analisis Sentimen Masyarakat Terhadap Tweet Ruang Guru Menggunakan Algoritma Naive Bayes Classifier (NBC)," *Jurnal Mantik*, vol. 6, no. 3, pp. 2685–4236, 2022.
- [16] D. Ardiansyah, A. Saepudin, R. Aryanti, E. Fitriani, and Royadi, "Analisis Sentimen Review Pada Aplikasi Media Sosial Tiktok Menggunakan Algoritma K-NN dan SVM Berbasis PSO," *Jurnal Informatika Kaputama (JIK)*, vol. 7, no. 2, pp. 233–241, 2023.