



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 3 (2025) pp: 6627-6635

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Sentimen Ulasan Aplikasi TikTok di Google Playstore Menggunakan Algoritma Naive Bayes

M. Taufik Fajar Maulana¹, Bangkit Indarmawan Nugroho², Erni Unggul Sedyu Utami³

¹Teknik Informatika, Universitas Harkat Negeri

^{2,3}Sistem Informasi, Universitas Harkat Negeri

¹taufikfajar093@gmail.com, ²bangkit_in@stmik-tegal.ac.id, ³eunggulsu@gmail.com

Abstrak

Aplikasi mobile seperti TikTok telah menjadi bagian penting dari aktivitas sehari-hari sehingga perlu dipahami perspektif pengguna melalui ulasan untuk meningkatkan kualitas aplikasi. Penelitian ini menganalisis sentimen ulasan pengguna TikTok di Google Playstore, mengevaluasi performa algoritma klasifikasi, serta mengidentifikasi dinamika sentimen dan kata kunci utama sebagai dasar pengambilan keputusan strategis. Sebanyak 3.000 ulasan dikumpulkan dengan teknik web scraping dan diproses melalui tahapan pre-processing teks seperti casefolding, penghapusan tanda baca, normalisasi, stopword removal, tokenizing, dan stemming. Fitur teks diekstraksi menggunakan metode TF-IDF, sedangkan analisis sentimen dilakukan dengan algoritma Naive Bayes. Hasil klasifikasi menunjukkan 54,6% ulasan bersentimen positif, 44,1% negatif, dan 1,4% netral. Model Naive Bayes menghasilkan akurasi 83% dengan nilai precision, recall, dan F1-score yang baik pada setiap kelas sentimen. Analisis temporal dari April hingga Juni 2025 menunjukkan adanya fluktuasi sentimen, sementara identifikasi kosakata dominan pada ulasan negatif memberikan masukan langsung bagi pengembang untuk perbaikan fungsi aplikasi. Penelitian ini menyimpulkan bahwa analisis sentimen efektif sebagai dasar strategi peningkatan kualitas aplikasi secara berkelanjutan.

Kata kunci: Analisis Sentimen, Naive Bayes, TikTok, Ulasan Pengguna, Google Playstore.

1. Latar Belakang

Kemajuan teknologi informasi dan komunikasi (TIK) telah mengubah secara drastis cara individu berinteraksi, memperoleh, dan menyebarkan informasi. Teknologi digital memungkinkan informasi tersebar lebih cepat, melampaui batas geografis, serta meningkatkan aksesibilitas sehingga berdampak besar pada sektor ekonomi, sosial, dan budaya [1]. Namun, kemudahan akses ini juga menimbulkan tantangan baru berupa kesenjangan digital, risiko informasi yang sulit diverifikasi, serta subjektivitas kebenaran yang dipengaruhi opini publik [2][3].

Fenomena yang menonjol dari perkembangan TIK adalah meningkatnya popularitas video pendek di media sosial. Hampir semua platform kini menghadirkan fitur ini karena terbukti efektif menarik perhatian pengguna. Popularitas tersebut didorong oleh durasi singkat, kemudahan produksi melalui ponsel pintar, serta algoritma yang mendukung viralitas [4]. Selain itu, sifat interaktif video pendek memicu partisipasi aktif pengguna. Secara psikologis, konsumsi video pendek dikaitkan dengan pelepasan dopamin dan munculnya FOMO (*Fear of Missing Out*), sehingga pengguna terdorong terus mengonsumsi konten [5]. Platform seperti TikTok bahkan mengalami pertumbuhan pesat secara global, termasuk Indonesia yang menjadi salah satu pasar terbesar [6][7].

Melihat popularitas TikTok, penting untuk memahami persepsi pengguna yang tercermin dari ulasan di *Google Playstore*. Analisis manual terhadap volume ulasan yang besar tidak lagi memadai, sehingga diperlukan pendekatan otomatis berbasis analisis sentimen [8]. Penelitian ini difokuskan pada ulasan TikTok dari *Google Playstore* dengan menggunakan algoritma *Naive Bayes* yang dikenal sederhana, efisien, serta efektif dalam menangani data teks berdimensi tinggi [9].

Rumusan masalah penelitian ini meliputi: bagaimana persepsi pengguna TikTok berdasarkan analisis sentimen ulasan di *Google Playstore*, seberapa optimal kinerja algoritma *Naive Bayes* dalam klasifikasi, apakah hasil klasifikasi dapat dijadikan acuan peningkatan kualitas aplikasi, serta bagaimana dinamika sentimen pengguna berubah dari waktu ke waktu. Penelitian ini dibatasi hanya menggunakan data ulasan dari *Google Playstore* dan berfokus pada penerapan *Naive Bayes* tanpa membandingkan dengan algoritma lain. Tujuannya adalah

menganalisis persepsi pengguna, mengevaluasi kinerja *Naive Bayes*, memanfaatkan hasil klasifikasi sebagai dasar pengambilan keputusan, dan mengidentifikasi dinamika perubahan sentimen [10].

Penelitian ini diharapkan memberi manfaat bagi beberapa pihak. Bagi penulis, penelitian ini memperkaya pemahaman dalam bidang *Natural Language Processing* (NLP) dan *Machine Learning* khususnya analisis sentimen. Bagi perguruan tinggi, penelitian ini memberi kontribusi akademik yang signifikan dengan menambah literatur dan menjadi referensi bagi penelitian selanjutnya. Dengan demikian, penelitian ini tidak hanya memberi gambaran holistik tentang persepsi pengguna TikTok, tetapi juga berkontribusi pada pengembangan keilmuan di bidang analisis sentimen teks berbahasa Indonesia [11].

2. Metode Penelitian

Penelitian ini melibatkan metode kuantitatif dengan pendekatan eksperimen komputasional. Penelitian kuantitatif merupakan tipe penelitian yang dapat menemukan informasi baru dengan menggunakan teknik statistik atau pendekatan kuantitatif lainnya [12]. Data yang dikumpulkan akan dianalisis menggunakan teknik analisis sentimen berbasis pembelajaran mesin untuk membagi opini pengguna menjadi tiga kategori yaitu positif, negatif, dan netral.

Model yang digunakan bersifat *supervised learning*, yaitu model yang dilatih berdasarkan data latih yang telah diberi label. Algoritma *Naive Bayes* dipilih sebab memiliki keunggulan dalam mengolah data teks serta memperlihatkan kinerja yang baik dalam masalah klasifikasi yang berfokus pada sentimen [13].

2.1. Populasi dan Sampel

Populasi yang menjadi fokus dalam penelitian ini adalah seluruh ulasan pengguna aplikasi TikTok yang tersedia di *Google Playstore*. Pemilihan *Google Playstore* sebagai sumber populasi didasarkan pada ketersediaan data ulasan yang luas dan representatif dari pengalaman pengguna secara global. Populasi ini mencakup berbagai masukan, opini, dan pengalaman pengguna yang mencerminkan persepsi mereka terhadap aplikasi.

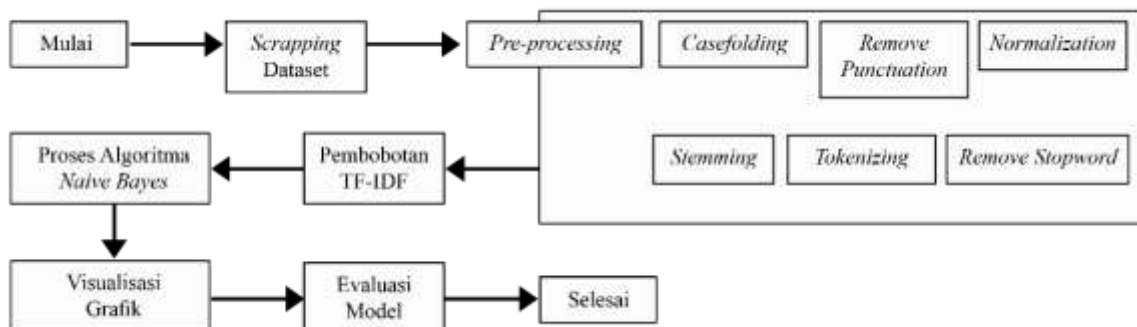
Berdasarkan populasi yang ada, sampel penelitian dipilih secara khusus untuk tiga bulan, yakni April, Mei, dan Juni 2025. Setiap bulan, dikumpulkan 1000 data ulasan, sehingga keseluruhan sampel yang digunakan dalam analisis adalah sebanyak 3000 data ulasan. Pemilihan sampel ini ditujukan untuk memperoleh data yang relevan dan mencerminkan dinamika persepsi pengguna saat ini, dianggap memadai untuk analisis sentimen yang menyeluruh dan untuk mengidentifikasi pola-pola sentimen yang signifikan.

2.2. Teknik Pengumpulan Data

Teknik pengumpulan data yang digunakan pada penelitian ini adalah *web scraping*, yakni metode otomatis untuk mengambil data dari halaman web menggunakan bantuan skrip pemrograman [14]. Dalam penelitian ini, *web scraping* diterapkan pada halaman aplikasi TikTok di *Google Playstore* demi mendapatkan data ulasan pengguna. Data yang diambil mencakup tanggal ulasan, teks ulasan, dan rating yang diberikan oleh pengguna. Proses ini dilakukan dengan bahasa pemrograman Python, memanfaatkan pustaka *google-play-scrapers* untuk mengekstrak konten halaman web. Setelah *scraping* selesai, data yang telah diperoleh disimpan sebagai file CSV untuk mendukung kemudahan pengolahan pada tahapan selanjutnya, yaitu pra-pemrosesan dan analisis sentimen dengan algoritma *Naive Bayes*.

2.3. Teknik Analisis Data

Alur pada penelitian ini ditunjukkan pada Gambar 1 berikut:



Gambar 1. Alur Penelitian

Teknik analisis data dalam penelitian ini dilakukan melalui beberapa tahapan sistematis yang dimulai dari proses *pre-processing* data hingga evaluasi performa model klasifikasi. Proses awal yang dilakukan adalah *pre-processing* untuk memastikan data teks bersih dan siap diproses dalam pelatihan model [15]. *Pre-processing* mencakup proses *casefolding*, yaitu mengubah seluruh karakter teks menjadi huruf kecil agar data menjadi konsisten. Langkah berikutnya adalah menghilangkan tanda baca (*remove punctuation*) untuk membersihkan dan merapikan teks. Langkah normalisasi dilakukan untuk mengubah variasi kata ke bentuk yang lebih baku. Kosakata umum yang tidak memiliki nilai informasi penting kemudian dihapus melalui tahapan *remove stopwords*. Setelah itu, teks dipecah menjadi token atau kata-kata tunggal melalui proses *tokenizing*. *Stemming* dilakukan di akhir tahap pra-pemrosesan untuk mengembalikan kata ke bentuk dasar sehingga fokus makna dalam teks lebih terjaga.

Setelah dilakukan *pre-processing* data langkah selanjutnya adalah menghitung bobot TF-IDF (*Term Frequency-Inverse Document Frequency*) yaitu teknik pembobotan statistik yang menilai pentingnya suatu kata dalam dokumen relatif terhadap seluruh korpus [16], dengan menggabungkan frekuensi kata dalam dokumen (TF) dan kelangkaannya di seluruh dokumen (IDF). Semakin tinggi nilainya, semakin penting dan unik kata tersebut dalam dokumen. Berikut adalah rumus TF-IDF:

$$TF = \frac{\text{Jumlah kemunculan kata "X" dalam sebuah dokumen}}{\text{Jumlah Seluruh Kata dalam dokumen tersebut}} \quad (1)$$

$$IDF = \log\left(\frac{\text{Jumlah dokumen dalam korpus}}{\text{Jumlah dokumen yang mengandung kata "X"}}\right) \quad (2)$$

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

Selanjutnya dilakukan proses perhitungan probabilitas untuk setiap ulasan yang belum diketahui sentimennya termasuk dalam kategori sentimen positif, netral, atau negatif dengan *Teorema Bayes* dengan rumus seperti berikut:

$$P(H | X) = \frac{P(X|H)P(H)}{P(X)} \quad (4)$$

Dimana $P(X|H)$ merepresentasikan peluang terjadinya X jika asumsi H dianggap benar, $P(H)$ adalah probabilitas prior hipotesis H yang menunjukkan probabilitas awal kemunculan setiap kelas sentimen sebelum mempertimbangkan data spesifik, serta $P(X)$ adalah probabilitas dari X secara umum yang berfungsi sebagai faktor normalisasi dalam perhitungan.

Pada langkah berikutnya dilakukan ekstraksi fitur dengan tujuan merepresentasikan teks dalam format numerik yang dapat dibaca oleh algoritma. Selanjutnya, proses klasifikasi sentimen diterapkan dengan memanfaatkan algoritma *Naïve Bayes* yang terkenal efektif dan efisien dalam menangani data berbasis teks. Evaluasi performa model dilakukan dengan menggunakan metrik akurasi, *precision*, *recall*, serta *F1-score*, yaitu nilai rata-rata harmonis dari *precision* dan *recall*. Berikut rumus-rumus yang digunakan untuk mengukur akurasi, *precision*, *recall*, dan *F1-score*.

$$Recall = \frac{TP}{(TP+FN)} \quad (5)$$

$$F1 = \frac{(Precision \times Recall)}{(Precision+Recall)} \quad (6)$$

$$Accuracy = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Sampel}} \quad (7)$$

TP (*True Positive*) merupakan jumlah prediksi yang tepat untuk suatu kelas, FP (*False Positive*) adalah jumlah prediksi yang keliru di mana data diklasifikasikan ke kelas tersebut padahal seharusnya tidak, sedangkan FN (*False Negative*) merujuk pada jumlah data yang sebenarnya termasuk dalam kelas tersebut tetapi salah diklasifikasikan ke kelas lain.

Analisis hasil dari model ini akan lebih dikaji untuk memahami distribusi sentimen serta kecenderungan pendapat pengguna mengenai aplikasi TikTok. Langkah-langkah analisis ini diharapkan mampu menyajikan representasi yang objektif mengenai persepsi pengguna, berdasarkan data ulasan yang terdapat pada di *Google Playstore*.

3. Hasil dan Diskusi

Penelitian ini dimulai dengan proses pengumpulan data ulasan pengguna TikTok yang diambil dari *Google Playstore* melalui teknik *web scraping* menggunakan *library google_play_scraper* dalam bahasa pemrograman Python. Data yang dikumpulkan mencakup tanggal, isi ulasan, rating bintang, dan label sentimen awal yang ditentukan otomatis berdasarkan rating: 4–5 sebagai "Positif", 3 sebagai "Netral", dan 1–2 sebagai "Negatif". *Scraping* difokuskan pada ulasan tiga bulan terakhir untuk menjaga relevansi, dengan target 1000 ulasan per bulan, sehingga total mencapai 3000 ulasan. Tabel 1 menyajikan contoh struktur data yang diperoleh dari proses *scraping*.

Tabel 1. Data Ulasan Hasil *Scraping*

Tanggal	Ulasan	Rating	Kategori
2025-06-29	Kenapa biyasaya eroror kg bisa di buka	1	Negatif
2025-06-29	mntap	5	Positif
2025-06-29	Aplikasi terkadang susah dibuka	2	Negatif
2025-04-29	Tidak bisa di hapus	3	Netral

3.1. Pre-processing

Tahap *pre-processing* adalah langkah penting dalam konteks analisis sentimen yang ditujukan untuk mengolah teks menjadi bentuk yang terstruktur sehingga dapat diproses secara optimal oleh algoritma. Data ulasan yang didapat dari *web scraping* sering kali memiliki karakter yang tidak terkait, format yang tidak konsisten, atau kata-kata yang tidak standar, yang dapat mempengaruhi keakuratan analisis. Karena itu, dilakukan serangkaian tahap *pre-processing* untuk mengonversi teks kasar menjadi susunan yang lebih terstruktur dan bernilai informasi. Proses ini mencakup *casefolding*, menghilangkan tanda baca, normalisasi, *tokenization*, penghapusan *stopword*, dan *stemming*. Setiap langkah ini berperan dalam mengurangi kompleksitas data, menghapus kebisingan, dan menyeragamkan representasi kata. Hasil *pre-processing* ditunjukkan pada tabel 2 berikut.

Tabel 2. Hasil *Pre-processing*

Ulasan Hasil <i>Scraping</i>	Hasil <i>Stemming</i>	Clean Ulasan
Kenapa biyasaya eroror kg bisa di buka	['biasa', 'error', 'buka']	biasa error buka
Mntap	['mantap']	mantap
Aplikasi terkadang susah dibuka	['aplikasi', 'terkadang', 'susah', 'buka']	aplikasi terkadang susah buka
Sangat bagus kualitas vidionya ka	['sangat', 'bagus', 'kualitas', 'video']	sangat bagus kualitas video
Bagus, tapi banyak bug nya, mohon untuk developer nya ya... 😊👍	['bagus', 'banyak', 'bug', 'mohon', 'developer']	bagus banyak bug mohon developer

3.2. Pembobotan TF-IDF

Setelah *pre-processing*, teks ulasan dikonversi ke format numerik menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF). Berikut hasil TF-IDF dari kata "bagus" yang disajikan pada Tabel 3.

Tabel 3. Hasil TF-IDF kata "bagus"

Clean ulasan	T1	T2	T3	Tn	f (jml "bagus")	n (jml token)	TF=f/n	DF	IDF	TF-IDF	Total TF-IDF
U1	biasa	error	buka	...	0	3	0	63	1,4799	0	513,54266
U2	mntap				0	1	0	63	1,4799	0	
U3	bagus	kualitas	video	...	1	3	0,333	63	1,4799	0,4933	
...	513,54266
U2999	apk	bagus	buat	...	1	26	0,038	63	1,4799	0,0569	
U3000	makin	jadi	jadi	...	0	17	0	63	1,4799	0	

Berdasarkan Tabel 3, dilakukan perhitungan nilai TF-IDF terhadap kata "bagus" dari masing-masing ulasan yang telah melalui proses tokenisasi. Nilai TF diperoleh dengan membagi frekuensi kemunculan kata "bagus" (f) dalam setiap ulasan dengan jumlah total token (n) pada ulasan tersebut. Sementara itu, nilai IDF dihitung berdasarkan

jumlah total dokumen (N) dibagi jumlah dokumen yang mengandung kata “bagus” (DF), yang kemudian diambil logaritmanya. Pada tabel, nilai DF untuk kata “bagus” adalah 683 dan IDF-nya sebesar 1,4799. Nilai TF-IDF selanjutnya diperoleh dari hasil perkalian antara TF dan IDF. Sebagai contoh, pada ulasan U3, kata ”bagus” muncul sebanyak satu kali dari tiga token (TF = 0,3333), sehingga nilai TF-IDF-nya adalah 0,4933. Proses ini dilakukan untuk seluruh ulasan hingga diperoleh akumulasi nilai TF-IDF dari kata “bagus” sebesar 513,54266. Gambar 2 berikut menyajikan 20 kata dalam ulasan yang memiliki nilai TF-IDF tertinggi.

	term	tfidf		term	tfidf
4	bagus	513.542663	63	lambat	103.398498
3	mantap	220.503752	8	bug	103.224649
101	oke	193.379513	222	buruk	96.257846
16	tiktok	178.302882	266	senang	87.640742
33	aplikasi	158.870097	47	sering	80.415224
313	seru	133.750994	11	apk	78.377895
2	buka	129.205852	7	banyak	78.167234
79	suka	123.010663	286	foto	74.562247
242	baik	118.632159	245	sekali	65.226707
127	hibur	115.501294			
328	keren	114.671038			

Gambar 2. Hasil TF-IDF

3.3. Proses Algoritma Naive Bayes

Setelah melalui tahap *pre-processing* dan pembobotan TF-IDF, data ulasan pengguna siap diklasifikasikan ke dalam kategori sentimen menggunakan algoritma *Naive Bayes*. Pada proses ini dihitung probabilitas untuk setiap ulasan yang belum diketahui sentimennya termasuk dalam kategori sentimen positif, netral, atau negatif. Label sentimen dasar ditentukan berdasarkan rating ulasan yaitu nilai rating 4–5 diklasifikasikan sebagai sentimen positif, 3 sebagai netral, dan kurang dari 3 sebagai sentimen negatif.

Berdasarkan dataset yang telah dikumpulkan sebanyak 3.000 data diketahui ulasan dengan kategori positif sebanyak 1.618 data, ulasan kategori negatif sebanyak 1.147 data dan ulasan dengan kategori netral sebanyak 235 data. Dari data tersebut maka bisa dihitung probabilitas awal tiap kelas (P(H)) sebagai berikut:

$$P(\text{kategori}) = \frac{\text{Jumlah data (kategori)}}{\text{(Total Data)}}$$

$$P(\text{Positif}) = \frac{1611}{3000} = 0,53933$$

$$P(\text{Negatif}) = \frac{1147}{3000} = 0,38233$$

$$P(\text{Netral}) = \frac{235}{3000} = 0,07833$$

Selanjutnya perlu dihitung nilai probabilitas semua kata untuk setiap kategori (P(X | H)). berdasarkan dataset diketahui jumlah seluruh kata pada ulasan kategori positif sebanyak 6.767, jumlah kata pada ulasan kategori negatif sebanyak 10.708 dan jumlah kata pada ulasan netral sebanyak 2.113. berdasarkan data tersebut maka dapat dihitung nilai P(X | H) misalnya pada ulasan pertama dengan isi ulasan “biasa error buka”. Berdasarkan dataset yang ada diketahui jumlah masing-masing kata pada setiap kategori adalah sebagai berikut:

Tabel 4. Jumlah Kata Setiap Kategori

Kategori	“biasa”	“error”	“buka”
Positif	46	14	83
Negatif	131	36	298
Netral	20	7	58

Kemudian dihitung TF untuk setiap kata pada masing-masing kategori. Berikut contoh proses menghitung nilai TF dari kata ”biasa”:

$$TF = \frac{\text{Jumlah kata di kategori}}{\text{total kata di kategori}}$$

$$TF(\text{biasa} | \text{Positif}) = \frac{46}{6767} = 0,00679$$

$$TF(\text{biasa} | \text{Negatif}) = \frac{131}{10708} = 0,01223$$

$$TF(\text{biasa} | \text{Netral}) = \frac{20}{2113} = 0,00946$$

Setelah semua kata dihitung maka menghasilkan data sebagai berikut:

Tabel 5. Hasil TF-IDF Kata Setiap Kategori

Kata	TF Positif	TF Negatif	TF Netral
biasa	0,00679	0,01223	0,00946
error	0,00206	0,00336	0,00331
buka	0,01226	0,02783	0,02783

Selanjutnya dihitung probabilitas untuk setiap kelas tanpa P(X) seperti berikut:

$$P(\text{Positif} | \text{biasa error buka}) = 0,53933 \times 0,00679 \times 0,00206 \times 0,01226 = 0,0000000924872877$$

$$P(\text{Negatif} | \text{biasa error buka}) = 0,38233 \times 0,01223 \times 0,00336 \times 0,02783 = 0,000000437237415$$

$$P(\text{Netral} | \text{biasa error buka}) = 0,07833 \times 0,00946 \times 0,00331 \times 0,02744 = 0,0000000673025259$$

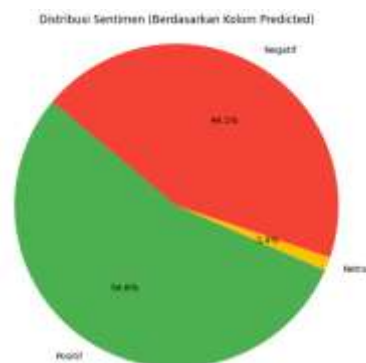
Setelah dilakukan perhitungan untuk ketiga kategori dihasilkan nilai probabilitas tertinggi terdapat pada kategori negatif maka ulasan tersebut diprediksi sebagai negatif.

Setelah setiap ulasan diklasifikasikan menggunakan logika Naive Bayes yang diimplementasikan hasilnya dapat diringkas dalam tabel yang menunjukkan perbandingan antara sentimen aktual dan sentimen yang diprediksi oleh model. Tabel 6 berikut menyajikan beberapa contoh hasil klasifikasi yang memberikan gambaran langsung mengenai kinerja model pada tingkat ulasan individual.

Tabel 6. Ulasan Hasil Klasifikasi Naive Bayes

Ulasan	Kategori (Aktual)	Prediksi
Biasa error buka	Negatif	Negatif
Bagus kualitas video	Positif	Positif
Apk lumayan lengkap video	Positif	Positif
Bug masyaallah	Netral	Negatif
Kreator template tiktok sedang kendala anchor muncul biasa edit capek pas posting ...	Netral	Netral

Berdasarkan hasil klasifikasi sentimen, dari total 3000 data model berhasil melakukan prediksi ulasan dengan kategori positif sebanyak 1.637 data, ulasan dengan kategori negatif sebanyak 1.322 data dan ulasan dengan kategori netral sebanyak 41 data. Dengan demikian, persentase distribusi proporsi sentimen ulasan pengguna aplikasi TikTok ditampilkan dalam Gambar 3.



Gambar 3. Grafik Distribusi Ulasan TikTok

Gambar 3 menunjukkan distribusi sentimen dari ulasan pengguna aplikasi TikTok setelah diklasifikasikan oleh model *Naive Bayes*. Hasil klasifikasi menunjukkan bahwa data ulasan positif sebesar 54.6%, ulasan negatif sebesar 44.1%, dan ulasan netral sebesar 1.4%. Hasil tersebut mengindikasikan bahwa mayoritas ulasan pengguna terhadap aplikasi TikTok bersifat positif, meskipun ulasan bernada negatif juga ditemukan dalam jumlah yang cukup besar.



Gambar 6. Confusion Matrix Model Klasifikasi Sentimen

Berdasarkan *Confusion Matrix* tersebut, akurasi model dapat dihitung sebagai rasio jumlah prediksi yang benar terhadap total seluruh sampel. Jumlah ulasan yang diprediksi dengan benar adalah 1444 data sebagai positif, 40 data sebagai netral, dan 1019 data sebagai negatif. Pada perhitungan manual akurasi dari matiks diatas sebagai berikut:

$$\text{Accuracy} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Seluruh Sampel}} \times 100\%$$

$$\text{Accuracy} = \frac{1444+40+1019}{144+0+174+66+40+129+127+1+1019} \times 100\%$$

$$\text{Accuracy} = 83\%$$

Tingkat akurasi 83% menunjukkan efektivitas model *Naive Bayes* dalam menangani klasifikasi sentimen ulasan pengguna TikTok secara menyeluruh.

Selain akurasi, kinerja model juga dievaluasi menggunakan metrik *precision*, *recall*, dan *F1-Score* yang disajikan dalam hasil pengujian *Naive Bayes*. Metrik-metrik ini memberikan gambaran yang lebih rinci tentang kinerja model untuk setiap kelas sentimen. Hasil metrik evaluasi tersebut disajikan pada Gambar 7 berikut.

Hasil Evaluasi Model:			
	precision	recall	f1-score
Negatif	0.7708	0.8884	0.8254
Netral	0.9756	0.1702	0.2899
Positif	0.8821	0.8925	0.8873
accuracy	0.8343		

Gambar 7. Hasil Pengujian Naive Bayes

Berdasarkan Gambar 7 dapat diketahui bahwa presisi dalam mengukur akurasi seberapa banyak prediksi benar dimana kelas netral memiliki presisi tertinggi dengan nilai 0.97. Sementara itu, *recall* (sensitivitas) untuk menilai kemampuan model dalam menemukan seberapa banyak kasus positif yang sebenarnya berhasil diidentifikasi dimana kelas positif memiliki *recall* tertinggi dengan nilai 0.88. Selanjutnya, *F1-Score* tertinggi yaitu 0.88 sehingga mengindikasikan kinerja terbaik untuk kelas tersebut.

4. Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa persepsi pengguna TikTok di *Google Playstore* mayoritas positif sebesar 54,6%, meskipun ulasan negatif masih signifikan sebesar 44,1% dan netral 1,4%, yang menandakan adanya aspek yang perlu diperbaiki. Algoritma *Naive Bayes* menunjukkan performa baik dengan akurasi 83% serta metrik evaluasi *precision*, *recall*, dan *F1-score* yang memuaskan, di mana *F1-score* tertinggi mencapai 0,88, sehingga layak digunakan dalam klasifikasi sentimen. Hasil klasifikasi ini bermanfaat sebagai dasar pengambilan keputusan strategis, khususnya dalam mengidentifikasi kata-kata dominan pada ulasan negatif seperti “buka,” “bug,” “update,” dan “lambat” yang menunjukkan permasalahan teknis dan fungsionalitas utama untuk diprioritaskan perbaikannya. Selain itu, dinamika sentimen bulanan dari April hingga Juni 2025 memperlihatkan fluktuasi persepsi pengguna, di mana sentimen negatif sempat menurun pada Mei namun kembali meningkat di Juni, menandakan bahwa persepsi pengguna bersifat dinamis sehingga memerlukan pemantauan berkelanjutan agar pengembang dapat merespons tren dan masalah secara tepat waktu.

Referensi

- [1] S. T. Jokhanan Kristiyono and M. M. Kom, *Konvergensi Media: Transformasi Media Komunikasi di era digital pada Masyarakat Berjejaring*. Prenada Media, 2022.
- [2] R. Jayanthi and A. Dinaseviani, "Kesenjangan digital dan solusi yang diterapkan di Indonesia selama pandemi COVID-19," *JURNAL IPTEKKOM (Jurnal Ilmu Pengetahuan & Teknologi Informasi)*, vol. 24, no. 2, pp. 187–200, 2022.
- [3] C. A. Septiyadi, Z. Khafifah, A. S. Khumairoh, and A. F. Hidayatullah, "Truth dan Post Truth dalam Perspektif AI-Kindi pada Era Milenial (Media Sosial)," *Jurnal Penelitian Humaniora*, vol. 22, no. 1, pp. 40–50, 2021.
- [4] F. A. Hasny, S. H. Renadia, and I. Irwansyah, "Eksplorasi konsep diri para pengguna TikTok dalam memenuhi social needs pada uses and gratification theory," *Jurnal Lensa Mutiara Komunikasi*, vol. 5, no. 2, pp. 114–127, 2021.
- [5] H. Febriani and S. Komsiah, "Hubungan Intensitas Menonton Konten Video Dance TikTok Dengan Perilaku Fear Of Missing Out Pada Remaja," *IKRA-ITH HUMANIORA: Jurnal Sosial dan Humaniora*, vol. 9, no. 1, pp. 259–265, 2025.
- [6] A. L. Panayitsa and P. Al Falah, "Dampak Aplikasi Tiktok Terhadap Kebudayaan Indonesia," *Filosofi: Publikasi Ilmu Komunikasi, Desain, Seni Budaya*, vol. 2, no. 1, pp. 75–88, 2025.
- [7] A. Mario, "Analisis Followers to Likes Ratio Tik Tok Pada 5 Brand Sepatu Lokal Indonesia Terbaik," 2021.
- [8] O. Manullang, C. Prianto, and N. H. Harani, "Analisis Sentimen Untuk Memprediksi Hasil Calon Pemilu Presiden Menggunakan Lexicon Based Dan Random Forest," *Jurnal Ilmiah Informatika*, vol. 11, no. 02, pp. 159–169, 2023.
- [9] P. Ramadani, R. Fadillah, Q. Adawiyah, S. Suerni, and B. R. Al Ghazali, "Perbandingan Algoritma Naïve Bayes, C4. 5, dan K-Nearest Neighbor untuk Klasifikasi Kelayakan Program Keluarga Harapan," *Jurnal Media Informatika*, vol. 6, no. 1, pp. 775–782, 2024.
- [10] D. Nurwahidah, G. Dwilestari, N. D. Nuris, and R. Narasati, "Analisis Sentimen Data Ulasan Pengguna Aplikasi Google Kelas Pada Google Play Store Menggunakan Algoritma Naïve Bayes," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 6, pp. 3673–3678, 2023.
- [11] R. L. Mustofa, T. L. Mustofa, and C. E. Widodo, "Analisis Sentimen Berbasis Aspek Pada Aplikasi Elektronik Survei Kepuasan Masyarakat (E-SKM) Jawa Tengah Menggunakan Indobert," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 4, pp. 867–874, 2025.
- [12] M. M. Ali, "Metodologi penelitian kuantitatif dan penerapan nya dalam penelitian," *JPIB: Jurnal Penelitian Ibnu Rusyd*, vol. 1, no. 2, pp. 1–5, 2022.
- [13] F. Panjaitan *et al.*, "Studi Komparatif Algoritma Machine Learning Pada Analisis Sentimen Media Sosial," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 2, pp. 3145–3152, 2025.
- [14] A. Z. Rizquina and C. I. Ratnasari, "Implementasi Web Scraping untuk Pengambilan Data Pada Website E-Commerce," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 4, pp. 377–383, 2023.
- [15] R. A. Afif, "Analisis Sentimen Aplikasi Adiraku di Google Play Store Menggunakan Metode Support Vectore Machine," *JURNAL FASILKOM*, vol. 15, no. 1, pp. 163–171, 2025.
- [16] D. Septiani and I. Isabela, "Analisis term frequency inverse document frequency (tf-idf) dalam temu kembali informasi pada dokumen teks," *Sistem dan Teknologi Informasi Indonesia (SINTESIA)*, vol. 1, no. 2, pp. 81–88, 2022.