



ANALISIS SENTIMEN KOMENTAR YOUTUBE TERHADAP PERILISAN IPHONE 17 SERIES MENGUNAKAN ALGORITMA NAIVE BAYES (*Sentiment Analysis of YouTube Comments on The Release of The Iphone 17 Series Using The Naive Bayes Algorithm*)

Faniah Iftitakhul Kamilah^{1*},
Muhammad Zaini Rochman², Harun Al Rosyid³

Program Studi S1 Pendidikan Teknologi Informasi^{1,2,3}
Fakultas Teknik^{1,2,3}
Universitas Negeri Surabaya^{1,2,3}

*Correspondent Author: faniahiftitakhul.22020@mhs.unesa.ac.id

Author Email: faniahiftitakhul.22020@mhs.unesa.ac.id¹,
muhhammadzaini.22036@mhs.unesa.ac.id², harunrosyid@unesa.ac.id³

Received: November 10, 2025. **Revised:** December 23, 2025. **Accepted:**
December 25, 2025. **Issue Period:** Vol.9 No.2 (2025), Pp. 418-429

Abstrak: Perilisan iPhone 17 Series memicu reaksi beragam di *platform* YouTube yang mencerminkan opini publik. Penelitian bertujuan untuk menganalisis sentimen komentar masyarakat menggunakan algoritma *Naive Bayes*. Data komentar dikumpulkan melalui teknik *scraping*, melalui tahapan *preprocessing*, dan dilabeli secara otomatis menggunakan model *Indonesian RoBERTa*. Hasil evaluasi terhadap 1.849 data uji menghasilkan akurasi sebesar 61%. Performa model menunjukkan kemampuan yang baik dalam menangkap kritik pengguna, ditandai dengan *recall* sentimen negatif sebesar 0.71. Sementara itu, sentimen positif teridentifikasi dengan *precision* 0.64 dan sentimen netral dengan *recall* 0.50. Penelitian ini menyimpulkan bahwa respons pasar terpolarisasi antara kritik dan apresiasi, serta membuktikan bahwa Naive Bayes mampu mengklasifikasikan opini dengan performa yang cukup seimbang pada seluruh kategori sentimen.

Kata kunci: analisis sentimen, youtube, iphone 17, naive bayes, RoBERTa, text mining.

Abstract: The release of the iPhone 17 Series sparked diverse reactions on the YouTube platform, reflecting public opinion. This study aims to analyze community sentiment using the Naive Bayes algorithm. Comment data was collected via scraping, underwent intensive preprocessing, and was automatically labeled using the Indonesian RoBERTa model. Evaluation on 1,849 test samples yielded an accuracy of 61%. The model demonstrated strong performance in capturing user criticism, evidenced by a Negative sentiment Recall of 0.71. Meanwhile, Positive sentiment was identified with a Precision of 0.64, and Neutral sentiment achieved a Recall of 0.50. The study concludes that market response is polarized between criticism and appreciation, demonstrating that Naive Bayes can classify opinions with fairly



DOI: 10.52362/jisicom.v9i2.2198

Ciptaan disebarluaskan di bawah [Lisensi Creative Commons Atribusi 4.0 Internasional](https://creativecommons.org/licenses/by/4.0/).



I. PENDAHULUAN

Perkembangan teknologi di era Revolusi Industri 4.0 telah mengubah kebiasaan masyarakat dalam mencari informasi suatu produk. Selain sebagai sarana interaksi, media sosial juga berfungsi sebagai sumber referensi utama sebelum pengambilan keputusan pembelian. Di Indonesia, YouTube menempati posisi strategis sebagai platform yang paling sering diakses untuk mencari ulasan produk elektronik [1]. Kanal-kanal teknologi populer memiliki pengaruh signifikan terhadap minat beli konsumen karena menyajikan informasi visual yang dianggap lebih objektif dibandingkan iklan konvensional [2]. Fenomena ini menghasilkan jutaan data interaksi berupa komentar yang merepresentasikan opini publik secara *real-time*.

Industri *smartphone* global terus menunjukkan dinamika persaingan yang ketat, di mana Apple secara konsisten menjadi pusat perhatian pasar. Peluncuran seri terbaru, iPhone 17 Series, pada kuartal akhir tahun ini telah memicu gelombang diskusi di ruang digital. Antusiasme publik terlihat dari ribuan komentar yang membanjiri video peluncuran dan ulasan produk. Berdasarkan studi terdahulu pada seri iPhone 14 Pro [3], diketahui bahwa respons masyarakat terhadap produk Apple sangat beragam, mulai dari apresiasi terhadap inovasi fitur hingga kritik tajam mengenai harga dan kebijakan komponen. Opini-opini ini merupakan aset berharga bagi konsumen sebagai pertimbangan pembelian, dan bagi produsen sebagai bahan evaluasi strategi pemasaran [4].

Namun, volume komentar yang sangat besar menciptakan tantangan *Big Data* yang tidak terstruktur (*unstructured data*). Menganalisis ribuan komentar secara manual tidak hanya memakan waktu dan biaya, tetapi juga rentan terhadap bias subjektif peneliti. Tanpa pengolahan yang tepat, informasi strategis yang tersembunyi di dalam data tekstual tersebut tidak dapat dimanfaatkan. Oleh karena itu, diperlukan pendekatan komputasi melalui teknik *text mining* dan analisis sentimen untuk mengekstraksi informasi tersebut menjadi wawasan yang terukur [5].

Analisis sentimen bertujuan mengklasifikasikan polaritas opini ke dalam kategori positif, netral, atau negatif. Dalam penerapannya, penentuan algoritma klasifikasi sangat menentukan akurasi hasil. Algoritma *Naive Bayes* sering menjadi pilihan utama dalam analisis teks karena karakteristiknya yang sederhana namun memiliki performa tinggi dalam menangani data berdimensi besar seperti teks komentar media sosial [6]. Berbagai penelitian sebelumnya, seperti pada analisis ulasan *e-commerce* dan perbandingan algoritma pada ulasan *gadget* [7], [8], [9], membuktikan bahwa *Naive Bayes* mampu memberikan tingkat akurasi dan kecepatan komputasi yang optimal dibandingkan metode lain dalam konteks klasifikasi sentimen sederhana.

Meskipun penelitian mengenai analisis sentimen produk elektronik sudah banyak dilakukan [8], [10], penelitian yang secara spesifik membedakan respons publik terhadap iPhone 17 Series pada periode awal peluncurannya masih terbatas. Respons pasar pada fase *early adoption* ini sangat krusial karena sering kali berbeda dengan sentimen jangka panjang.

Berdasarkan urgensi tersebut, penelitian ini memiliki tujuan untuk menganalisis sentimen komentar YouTube terhadap perlisian iPhone 17 Series dengan menerapkan algoritma *Naive Bayes*. Penelitian ini diharapkan mampu memberikan gambaran komprehensif mengenai persepsi publik serta membuktikan efektivitas metode *Naive Bayes* dalam mengolah data opini berbahasa Indonesia yang dinamis.

II. TINJAUAN PUSTAKA

2.1. Analisis Sentimen

Analisis sentimen atau yang disebut sebagai *opinion mining* merupakan cabang dari pemrosesan bahasa alami dalam mengidentifikasi dan mengkategorikan opini yang terkandung dalam teks sumber [10]. Tujuan utamanya menentukan kecenderungan sikap penulis terhadap topik tertentu (positif, negatif, atau netral). Dalam konteks industri teknologi, analisis sentimen sangat krusial karena dapat mengungkapkan persepsi konsumen terhadap fitur produk, harga, dan layanan purna jual secara cepat dan massal [8].

Penerapan analisis sentimen pada produk *smartphone* telah banyak dilakukan dalam penelitian sebelumnya untuk memetakan kepuasan pelanggan. Sebuah studi oleh Arum Prabowo (2024) yang meneliti ulasan iPhone 14 Pro menunjukkan bahwa analisis sentimen berbasis aspek mampu memberikan wawasan mendalam mengenai fitur kamera dan baterai yang paling banyak dibahas pengguna [3]. Temuan dari analisis ini dapat digunakan oleh perusahaan untuk mengevaluasi strategi pemasaran dan oleh calon konsumen sebagai referensi objektif sebelum



membeli produk. Selain itu, penelitian pada platform *e-commerce* juga membuktikan bahwa analisis sentimen yang tepat dapat mempercepat kemampuan produsen dalam beradaptasi dengan dinamika tren pasar [6].

2.2. YouTube sebagai Sumber Data

Dalam era media sosial, YouTube telah bertransformasi menjadi salah satu platform paling berpengaruh dalam ekosistem pemasaran digital, khususnya untuk produk elektronik. Berbeda dengan data terstruktur pada basis data tradisional, komentar YouTube merupakan data tidak terstruktur yang mencerminkan opini publik secara *real-time* dan jujur [1]. Interaksi antara kreator video dengan penonton menciptakan volume data tekstual yang sangat besar yang berisi preferensi dan keluhan pengguna terhadap *smartphone* terbaru [2].

Penelitian yang dilakukan oleh Cahyani dan Fauzan (2025) menunjukkan bahwa ulasan dan komentar di YouTube memiliki dampak signifikan terhadap keputusan pembelian konsumen Gen Z [2]. Hal ini menjadikan kolom komentar YouTube sebagai sumber data yang kaya untuk digali menggunakan teknik *text mining*. Dengan mengekstraksi informasi dari ribuan komentar yang muncul saat peluncuran produk, peneliti dapat menangkap sentimen pasar yang mungkin tidak terdeteksi melalui survei konvensional.

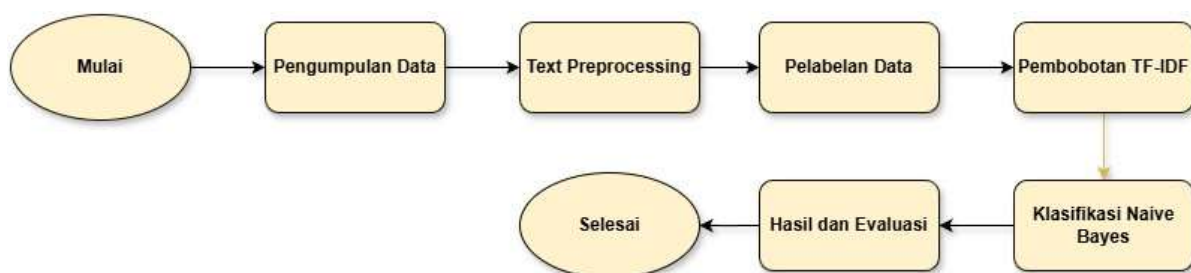
2.3. Algoritma Naive Bayes

Salah satu metode *machine learning* yang populer dan efektif untuk klasifikasi teks adalah *Naive Bayes*. Pendekatan ini didasarkan pada Teorema Bayes yang menghitung kemungkinan suatu kelas berdasarkan fitur-fitur kata yang muncul pada dokumen [7]. Algoritma ini bekerja dengan asumsi bahwa keberadaan fitur tertentu dalam kelas tidak bergantung pada keberadaan fitur lainnya (*independence assumption*).

Meskipun asumsi independensi ini jarang terjadi dalam bahasa manusia yang kompleks, *Naive Bayes* terbukti memiliki kinerja yang baik dalam mengeksekusi analisis sentimen, terutama pada data berdimensi tinggi seperti teks media sosial. Studi komparasi yang dilakukan oleh [4] menunjukkan bahwa *Naive Bayes* sering kali unggul dalam hal kecepatan komputasi dibandingkan metode lain seperti *Support Vector Machine* (SVM) ketika menangani dataset ulasan *gadget* yang besar, menjadikannya pilihan yang tepat untuk analisis data komentar dari YouTube.

III. METODOLOGI PENELITIAN

Penelitian ini menggunakan *Naive Bayes Classifier* untuk mengklasifikasikan sentimen publik. Metode ini kemudian akan dievaluasi untuk mengetahui tingkat akurasi model dalam menganalisis sentimen masyarakat terutama terhadap perilisan iPhone 17 Series. Alur dan skema pada penelitian ini dituangkan pada Gambar 1 berikut.



Gambar 1. Alur dan Skema Penelitian

3.1. Pengumpulan Data

Data penelitian ini diperoleh dari komentar publik pada platform YouTube, khususnya pada video-video yang mengulas (*review*) perilisan iPhone 17 Series. Proses pengumpulan data dilakukan menggunakan teknik *web scraping* atau *data crawling* dengan memanfaatkan *Application Programming Interface* (API) resmi YouTube.

Implementasi teknis dilakukan menggunakan bahasa pemrograman Python dengan bantuan *library googleapiclient.discovery*. *Library* ini berfungsi untuk mengakses layanan YouTube Data API v3 yang memungkinkan ekstraksi data komentar secara otomatis, terstruktur, dan efisien. Data yang diambil meliputi teks



komentar, nama pengguna, dan waktu posting. Seluruh data mentah kemudian disimpan dengan format *Comma-Separated Values* (.csv) untuk memudahkan tahapan *preprocessing* dan analisis selanjutnya.

3.2. Text Preprocessing

Text preprocessing merupakan proses fundamental dalam pengolahan data teks karena berfungsi menyiapkan data mentah agar lebih terstruktur, bersih, dan siap diproses pada tahap analisis lanjutan [11]. Tahap ini meliputi pembersihan teks, *case folding*, *tokenisasi*, penghapusan *stopwords*, serta *stemming* sehingga kualitas data meningkat dan dapat diolah secara optimal oleh algoritma *machine learning* [12]. Data yang telah melalui tahapan *text preprocessing* memungkinkan proses ekstraksi fitur, pengelompokan, maupun klasifikasi teks dilakukan dengan lebih akurat, efisien, dan konsisten.

3.3. Pelabelan Data

Tahap *labelling* dilakukan menggunakan pendekatan otomatis (*automatic labeling*) dengan memanfaatkan model *Pre-trained Transformer*, yaitu Indonesian RoBERTa (*wl1wo/indonesian-roberta-base-sentiment-classifier*). Hal ini berbeda dengan metode pelabelan manual yang memakan waktu atau metode leksikon yang kaku. Penggunaan model berbasis Transformer dipilih karena kemampuannya yang baik dalam memahami konteks semantik dan struktur bahasa Indonesia yang kompleks, termasuk penggunaan bahasa informal di media sosial.

Dalam penelitian ini, model RoBERTa diterapkan untuk memprediksi dan memberikan label sentimen (Positif, Negatif, atau Netral) pada seluruh data komentar yang telah melalui tahap *preprocessing*. Hasil pelabelan otomatis ini kemudian divalidasi dan digunakan sebagai *ground truth* atau label target untuk melatih algoritma klasifikasi *Naive Bayes* pada tahap selanjutnya [13]. Pendekatan ini memungkinkan efisiensi tinggi dalam mengolah dataset berskala besar tanpa mengorbankan akurasi pemahaman konteks kalimat.

3.4. Pembobotan TF-IDF

Setelah proses pelabelan dilakukan, pembobotan TF-IDF (*Term Frequency-Inverse Document Frequency*) digunakan dalam mengukur tingkat kepentingan setiap kata dalam dokumen terhadap keseluruhan korpus. TF-IDF dirancang untuk mengevaluasi sejauh mana suatu istilah memiliki nilai informatif dalam dokumen dibandingkan dengan dokumen lainnya. Berdasarkan berbagai penelitian, TF-IDF terbukti efektif sebagai metode representasi fitur sebelum proses klasifikasi teks [14]. Bobot kata yang dihasilkan melalui perhitungan TF-IDF berperan penting dalam meningkatkan performa model, khususnya dalam tugas klasifikasi sentimen pada data ulasan. Selain itu, TF-IDF mampu membangun representasi vektor teks yang akurat sehingga mendukung keberhasilan berbagai model klasifikasi dalam mengolah dan memahami konteks dokumen secara lebih tepat [15].

Rumus menghitung TF :

$$TF(t, d) = \frac{\text{Jumlah kemunculan kata } t \text{ dalam dokumen } d}{\text{Total jumlah kata dalam dokumen } d}$$

Rumus menghitung IDF :

$$IDF(t) = \log \frac{\text{Total jumlah dokumen dalam korpus}}{\text{Jumlah dokumen dalam korpus yang mengandung kata } t}$$

Rumus menghitung TF-IDF :

$$TF - IDF(t, d) = TF(t, d) \times IDF(t)$$

Keterangan:

t = kata tertentu

d = dokumen tertentu

3.5. Klasifikasi Naive Bayes

Algoritma *Naive Bayes* merupakan algoritma klasifikasi probabilistik yang mengkalkulasi peluang suatu *instance* termasuk ke dalam kelas tertentu berdasarkan distribusi frekuensi fitur dalam dataset. Algoritma ini banyak dipilih karena kesederhanaan, efisiensi, dan kecepatan baik dalam pelatihan maupun prediksi bahkan pada





dataset teks berdimensi tinggi [16]. Dalam konteks analisis sentimen dan klasifikasi teks, *Naive Bayes* telah terbukti efektif, terutama bila digabungkan dengan teknik representasi fitur seperti TF-IDF [17].

3.6. Hasil dan Evaluasi

Setelah seluruh proses analisis sentimen dengan algoritma *Naive Bayes* diperoleh, tahap berikutnya adalah melakukan evaluasi terhadap hasil tersebut. Evaluasi ini penting untuk menilai serta membandingkan performa metode yang digunakan. Kinerja model kemudian ditampilkan melalui *Confusion Matrix* sebagai alat visual untuk melihat distribusi prediksi benar dan salah. Selain itu, untuk memberikan gambaran sebaran kata yang dominan di dalam data, dilakukan pula visualisasi *wordcloud* yang menampilkan frekuensi kemunculan kata secara lebih intuitif.

IV. PEMBAHASAN DAN HASIL

4.1. Pengumpulan Data

Terdapat 9497 berupa komentar masyarakat di platform Youtube dengan topik review perilsan iphone 17. Beberapa video yang membahas perilsan iPhone 17 berhasil dikumpulkan menggunakan teknik *data crawling* dengan bantuan *library Python googleapiclient.discovery*, yang memungkinkan akses ke berbagai layanan API Google, termasuk YouTube Data API. Seluruh komentar yang terkumpul disimpan dalam format CSV dan digunakan sebagai dasar untuk proses analisis sentimen selanjutnya.

4.2. Hasil Preprocessing

Tahapan *text preprocessing* dilakukan untuk mempersiapkan data asli sebelum melanjutkan ke langkah pemrosesan berikutnya. Secara umum, fase ini melibatkan penghapusan informasi yang tidak relevan atau melakukan penyesuaian format data agar sistem lebih mudah dalam memprosesnya. Dalam penelitian ini, *text preprocessing* dikerjakan menggunakan bahasa pemrograman *Python* pada platform *Google Colab* dengan beberapa proses, yaitu *cleaning*, *case folding*, *tokenizing*, *stopword removal*, dan *stemming*.

Cleaning (pembersihan teks) bertujuan untuk menghapus *noise* pada data teks misalnya URL, tanda baca tak perlu, karakter khusus, atau simbol agar teks menjadi lebih bersih dan siap diproses [18].

Case Folding (normalisasi huruf) dilakukan dengan mengubah seluruh huruf pada teks menjadi huruf kecil (*lowercase*) sehingga variasi kapitalisasi tidak menyebabkan kata yang sama dianggap berbeda, dan memudahkan proses komparasi dan analisis [19].

Tokenization dijelaskan sebagai tahap memecah teks menjadi kata-kata setelah *case folding*, dengan menghapus URL, mention, hashtag, angka, tanda baca, dll. Sehingga setiap kata dalam teks dapat dianalisis secara terpisah, sebuah tahap dasar dalam *teks preprocessing* untuk analisis data teks [20].

Stopword removal (penghapusan kata umum) dilakukan untuk menghapus kata umum yang sering muncul namun kurang membawa informasi penting (misalnya “dan”, “yang”, “di”) agar fitur yang relevan lebih menonjol dan *noise* berkurang. *Stopword removal* merupakan proses untuk menghilangkan kata-kata yang kerap muncul tetapi tidak berkontribusi signifikan terhadap analisis makna [21].

Stemming merupakan mengubah kata ke bentuk dasar (*root word*) dengan menghapus imbuhan sehingga variasi kata dengan makna sama (misalnya “berjalan,” “berjalanlah,” “jalan”) dikenali sebagai satu kata dasar yang sama, mengurangi redundansi dan memperkecil ukuran kosakata [22].

Tabel 1. Contoh Komentar yang telah di Preprocessing

Proses	Data
Data awal	Kameranya jelek cuy td jg uda tes.. Gw uda batalin beli, untung blm kebeli 🤔
<i>Cleaning</i>	Kameranya jelek cuy td jg uda tes Gw uda batalin beli untung blm kebeli
<i>Case folding</i>	kameranya jelek cuy td jg uda tes gw uda batalin beli, untung blm kebeli
<i>Tokenization</i>	['kameranya', 'jelek', 'cuy', 'td', 'jg', 'uda', 'tes', 'gw', 'uda', 'batalin', 'beli',



‘untung’, ‘blm’, ‘kebeli’]

Stopword removal [‘kameranya’, ‘jelek’, ‘tes’, ‘batalin’, ‘beli’, ‘untung’, ‘kebeli’]

Stemming [‘kamera’, ‘jelek’, ‘tes’, ‘batal’, ‘beli’, ‘untung’, ‘beli’]

Data akhir kamera jelek tes batal beli untung beli

4.3. Pelabelan Data

Proses *labelling* dilakukan secara otomatis menggunakan pendekatan *Transfer Learning* yang memanfaatkan model *pre-trained Indonesian RoBERTa (w11wo/indonesian-roberta-base-sentiment-classifier)*. Berbeda dengan metode berbasis kamus (*lexicon*) yang hanya mencocokkan kata per kata, model RoBERTa mampu memahami konteks kalimat dan nuansa bahasa gaul yang dominan pada data komentar YouTube.

Model ini mengklasifikasikan setiap komentar ke dalam tiga kategori sentimen, yaitu positif, netral, dan negatif. Seluruh kategori tersebut dipertahankan dan digunakan secara utuh dalam tahap analisis utama untuk memberikan gambaran distribusi opini publik yang komprehensif, serta untuk mengukur kemampuan algoritma *Naive Bayes* dalam membedakan polaritas sentimen yang beragam.

Tabel 2. Contoh Komentar yang telah diberikan Label

Contoh Komentar	Label Data
Biasa aja iPhone skrg 🤔	Negatif
emang tinggi ya pajaknya..	Negatif

4.4. Hasil Perhitungan TF-IDF

TF-IDF memberikan bobot pada setiap istilah berdasarkan tingkat kemunculannya dalam sebuah dokumen maupun dalam keseluruhan kumpulan data. Teknik ini menilai tingkat kepentingan suatu kata dengan membandingkan frekuensi kemunculannya pada dokumen tertentu terhadap seluruh korpus, sehingga kata-kata yang memiliki relevansi tinggi akan lebih menonjol, sementara istilah umum dengan frekuensi tinggi akan memperoleh bobot yang lebih rendah. Berikut disajikan contoh hasil perhitungan TF-IDF pada salah satu komentar dalam dataset.

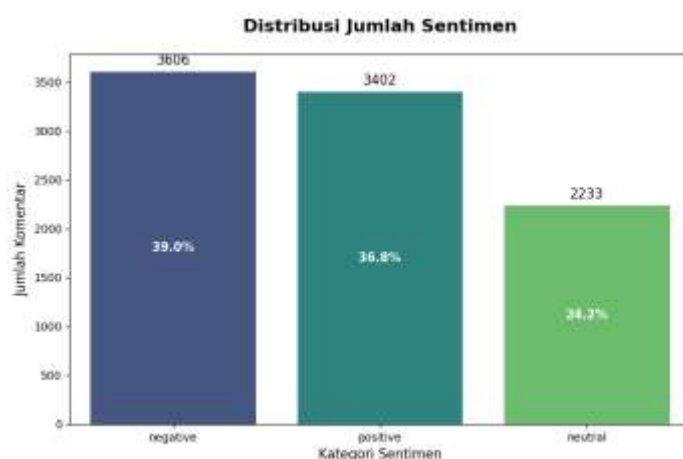
Tabel 3. Tabel Komentar yang Akan Dihitung TF-IDF

No.	Komentar
1.	pajak, mahal, iphone, rasa, jadul
2.	hp, mahal, fungsi, gaada

Tabel 4. Perhitungan TF-IDF

Kata	Kalimat 1 (TF)	Kalimat 2 (TF)	IDF	Kalimat 1 (TF-IDF)	Kalimat 2 (TF-IDF)
pajak	1/5 = 0.20	0	$\log(2/1) = 0.3010$	0.0602	0
mahal	1/5 = 0.20	1/4 = 0.25	$\log(2/2) = 0$	0	0
iphone	1/5 = 0.20	0	0.3010	0.0602	0
rasa	1/5 = 0.20	0	0.3010	0.0602	0
jadul	1/5 = 0.20	0	0.3010	0.0602	0
hp	0	1/4 = 0.25	0.3010	0	0.075
fungsi	0	1/4 = 0.25	0.3010	0	0.075
gada	0	1/4 = 0.25	0.3010	0	0.075

4.5. Model Klasifikasi



Gambar 2. Diagram Batang Distribusi Data Sentimen


Pada gambar 2 menunjukkan interpretasi terhadap reaksi masyarakat bahwa sebagian besar komentar yang diberikan pengguna lebih condong ke arah sentimen negatif. Berdasarkan hasil analisis, diperoleh sebanyak 3.606 komentar negatif, 3.402 komentar positif, dan 2.233 komentar netral. Dominasi sentimen negatif ini mengindikasikan bahwa perilisan iPhone 17 Series masih memunculkan banyak kritik atau ketidakpuasan dari pengguna, baik terkait fitur, harga, maupun perbandingan dengan produk sebelumnya. Analisis mendalam selanjutnya diperlukan untuk melihat faktor-faktor apa saja yang paling berpengaruh pada persebaran ketiga kategori sentimen tersebut.

Tabel 5. Akurasi *Naive Bayes*

	<i>precision</i>	<i>recall</i>	<i>f1 score</i>	<i>support</i>
<i>negative</i>	0.62	0.71	0.66	737
<i>neutral</i>	0.52	0.50	0.51	439
<i>positive</i>	0.64	0.57	0.60	673
<i>accuracy</i>			0.61	1849
<i>macro avg</i>	0.60	0.59	0.59	1849
<i>weighted avg</i>	0.61	0.61	0.60	1849

Tabel 5 memaparkan hasil implementasi algoritma *Naive Bayes* pada data uji. Untuk kelas negatif, sebesar 66% prediksi yang diberikan model sudah benar, dengan kemampuan menemukan kembali data negatif (*recall*) sebesar 71% dan *f1-score* 66%. Pada kelas netral, model mampu mengidentifikasi komentar dengan benar sebesar 51%, namun kemampuan model dalam menemukan seluruh data netral masih rendah, dengan nilai *recall* 50% dan *f1-score* 51%. Sementara itu, komentar positif diprediksi dengan tingkat ketepatan 60%, dan model berhasil

menangkap data positif dengan *recall* 57% serta *f1-score* 60%. Secara keseluruhan, model memperoleh akurasi sebesar 61%, dengan rata-rata *f1-score* (*macro average*) sebesar 59%.



Gambar 3. Confusion Matrix Data

Gambar 3 merupakan *confusion matrix* untuk mengevaluasi kinerja model *Naive Bayes* pada proses klasifikasi sentimen data uji. Berdasarkan hasil pengujian, model berhasil mengklasifikasikan 520 komentar negatif dengan benar sebagai negatif (*True Negative*). Namun, terdapat 111 komentar negatif yang salah diklasifikasikan sebagai netral (*False Neutral*) dan 106 komentar negatif yang keliru diprediksi sebagai positif (*False Positive*). Pada kategori sentimen netral, sebanyak 220 komentar berhasil diidentifikasi dengan benar (*True Neutral*), sementara 115 komentar netral salah diklasifikasikan sebagai negatif dan 104 komentar lainnya diprediksi sebagai positif. Di sisi lain, model mampu mengklasifikasikan 381 komentar positif dengan benar sebagai positif (*True Positive*), tetapi masih terdapat kesalahan prediksi berupa 199 komentar positif yang diklasifikasikan sebagai negatif serta 93 komentar positif yang diprediksi sebagai netral. Secara keseluruhan, hasil ini menyimpulkan bahwa model memiliki kinerja yang lebih baik dalam mengenali sentimen positif dibanding sentimen lainnya, meskipun tingkat akurasi keseluruhan sebesar 60,63% masih mengindikasikan adanya tantangan dalam membedakan kategori sentimen yang mirip secara konteks, terutama antara komentar negatif dan positif.

4.6. Visualisasi

Metode ini membantu mengidentifikasi kata-kata yang lebih relevan untuk analisis sentimen. Kata-kata yang memiliki bobot lebih tinggi dalam perhitungan TF-IDF sering kali mencerminkan opini atau sentimen pengguna yang lebih signifikan, sehingga memberikan informasi tambahan yang berguna pada proses analisis. Visualisasi *wordcloud* menampilkan kata-kata yang paling sering muncul dalam kumpulan ulasan sehingga pola umum dalam teks dapat terlihat dengan lebih jelas.



Gambar 4. Wordcloud Ulasan Positif

Pada Gambar 4 ditampilkan *Wordcloud* yang menggambarkan kata-kata dominan pada data sentimen positif, di mana istilah seperti “lebih,” “harga,” “beli,” “bagus,” dan “suka” tampak dengan ukuran lebih besar, menandakan tingginya frekuensi kemunculan kata-kata tersebut dalam ulasan positif. Hal ini menunjukkan bahwa pengguna banyak menyoroti aspek kualitas produk, kesesuaian harga, serta pengalaman membeli yang memuaskan. Kata lain seperti “suka,” “warna,” “keren,” “paling,” dan “baru” turut mencerminkan bahwa desain, pilihan warna, dan fitur terbaru menjadi faktor penting yang mendorong terbentuknya sentimen positif. Secara keseluruhan, *Wordcloud* ini memberikan wawasan visual mengenai aspek-aspek yang paling dihargai pengguna, sehingga pihak pengembang atau penjual dapat memprioritaskan peningkatan kualitas produk, inovasi fitur, serta penawaran harga yang kompetitif untuk mempertahankan kepuasan pelanggan.



Gambar 5. Wordcloud Ulasan Netral

Pada Gambar 5 ditampilkan *Wordcloud* yang menggambarkan kata-kata yang paling sering muncul pada data sentimen netral. Kata-kata seperti “kamera,” “warna,” “baru,” “harga,” “apa,” dan “beli” tampak dengan ukuran yang lebih besar, menandakan bahwa istilah-istilah tersebut sering muncul dalam komentar netral yang umumnya berisi deskripsi, pertanyaan, atau pernyataan informatif tanpa menunjukkan emosi yang kuat. Selain itu, kata-kata seperti “air,” “coba,” “model,” “pakai,” “seri,” serta “rilis” menunjukkan bahwa banyak pengguna sekadar membahas fitur, spesifikasi, atau perkembangan produk tanpa memberikan penilaian positif maupun negatif. Pola ini mengindikasikan bahwa komentar netral cenderung berfokus pada informasi faktual, perbandingan produk, atau rasa ingin tahu pengguna terhadap fitur dan teknologi terbaru. Secara keseluruhan, *Wordcloud* ini memberikan gambaran visual yang membantu dalam memahami topik-topik yang paling banyak dibicarakan dalam ulasan netral, sehingga dapat menjadi acuan bagi pihak pengembang atau penjual untuk mengetahui aspek mana yang sering ditanyakan atau diperhatikan oleh pengguna.



minoritas (positif dan netral) agar model tidak bias ke kelas mayoritas dan dapat meningkatkan nilai *recall* pada sentimen positif.

Meskipun *Naive Bayes* efisien dari segi komputasi, disarankan untuk membandingkan performanya dengan algoritma berbasis *Ensemble Learning* seperti *Random Forest* atau *XGBoost*, yang sering kali lebih tangguh terhadap *noise*. Selain itu, eksplorasi metode *Deep Learning* seperti LSTM (*Long Short-Term Memory*) atau melakukan *fine-tuning* langsung pada model BERT (*Background Equivalent Radiation Time*) juga direkomendasikan untuk menangkap konteks kalimat yang lebih kompleks.

Menambah dan memperbarui kamus normalisasi teks (*slang dictionary*) yang spesifik pada domain *gadget* sangat diperlukan. Hal ini bertujuan untuk meminimalkan data yang terbuang saat proses *cleaning data* dan meningkatkan akurasi model dalam memahami singkatan atau istilah teknis yang sering muncul di kolom komentar YouTube.

REFERENSI

- [1] N. Hidayati dan Ali, "Modeling Dan Analisis Menggunakan Sentiment Analysis Mengenai Konten Youtube Pada Channel Gadgetin Dengan Metode Fine-Tune Menggunakan Pre-Trained Model," *THEMATIC : InnovaTive Research SciEnce inforMATION teChnology*, vol. 1, no. 1, hlm. 1–10, 2024, [Daring]. Tersedia pada: <https://e-journal.uncip.ac.id/index.php/thematic>
- [2] A. S. Cahyani, D. A. Fauzan, K. Padmavati, dan R. S. Ekohandito, "Pengaruh Konten Review Channel Youtube Gadgetin Terhadap Minat Beli Smartphone di Kalangan Gen Z," *Journal of Scientific Communication*, vol. 7, no. 1, Apr 2025, doi: 10.62870/jsc.v7i1.30709.
- [3] G. Arum Prabowo, B. Rahmat, dan H. Endah Wahanani, "Aspect-Based Sentiment Analysis Iphone 14 Pro Menggunakan Algoritma XGBoost," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 6, hlm. 3947–3952, Jan 2024, doi: 10.36040/jati.v7i6.7831.
- [4] J. W. Iskandar dan Y. Nataliani, "Comparison of Naïve Bayes, SVM, and k-NN for Aspect-Based Gadget Sentiment Analysis," *Jurnal RESTI*, vol. 5, no. 6, hlm. 1120–1126, Des 2021, doi: 10.29207/resti.v5i6.3588.
- [5] M. D. Bimantara dan I. Zufria, "Text Mining Sentiment Analysis on Mobile Banking Application Reviews using TF-IDF Method with Natural Language Processing Approach," *JINAV: Journal of Information and Visualization*, vol. 5, no. 1, hlm. 115–123, Jul 2024, doi: 10.35877/454ri.jinav2772.
- [6] Rahel Lina Simanjuntak, Theresia Romauli Siagian, Vina Anggriani, dan Arnita Arnita, "Analisis Sentimen Ulasan Pada Aplikasi E-Commerce Shopee Dengan Menggunakan Algoritma Naïve Bayes," *Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, vol. 3, no. 3, hlm. 23–39, Nov 2023, doi: 10.55606/teknik.v3i3.2411.
- [7] N. Arif Maulana dan Z. Fatah, "Penerapan Metode Naïve Bayes untuk Analisis Sentimen Ulasan Produk di Platform E-Commerce," *Gudang Jurnal Multidisiplin Ilmu*, vol. 2, no. 10, hlm. 433–439, Nov 2024, doi: 10.59435/gjmi.v2i11.1103.
- [8] V. G. Shintarani, R. Mayasari, dan M. Jajuli, "Analisis Sentimen Ulasan Konsumen pada Produk Ponsel Pintar Menggunakan Metode Naïve Bayes," *Jurnal Cahaya Mandalika*, vol. 4, no. 1, Agu 2023, doi: 10.36312/jcm.v4i1.2101.
- [9] R. A. E. V. T. Sapanji, D. Hamdani, dan P. Harahap, "Sentiment Analysis of the Top 5 E-commerce Platforms in Indonesia using Text Mining and Natural Language Processing (NLP)," *Journal of Applied Informatics and Computing*, vol. 7, no. 2, hlm. 202–211, Nov 2023, doi: 10.30871/jaic.v7i2.6517.
- [10] P. Primadona dan R. Fauzi, "Penerapan Data Mining pada Penjualan Produk Elektronik," *Computer and Science Industrial Engineering (COMASIE)*, vol. 9, no. 4, Okt 2023, doi: 10.33884/comasiejournal.v9i4.7712.
- [11] M. A. Palomino dan F. Aider, "Evaluating the Effectiveness of Text Pre-Processing in Sentiment Analysis," *Applied Sciences (Switzerland)*, vol. 12, no. 17, Sep 2022, doi: 10.3390/app12178765.





- [12] A. F. Aufar, Mochamad Alfian Rosid, A. Eviyanti, dan I. R. I. Astutik, "Optimizing Text Preprocessing for Accurate Sentiment Analysis on E-Wallet Reviews," *JICTE (Journal of Information and Computer Technology Education)*, vol. 7, no. 2, hlm. 42–50, Okt 2023, doi: 10.21070/jicte.v7i2.1650.
- [13] L. M. Gandy, L. V Ivanitskaya, L. L. Bacon, dan R. Bizri-Baryak, "Public Health Discussions on Social Media: Evaluating Automated Sentiment Analysis Methods," *JMIR Form Res*, vol. 9, hlm. e57395, Jan 2025, doi: 10.2196/57395.
- [14] D. Septiani dan I. Isabela, "Analisis Term Frequency Inverse Document Frequency (TF-IDF) dalam Temu Kembali Informasi pada Dokumen Teks," *SINTESIA : Jurnal Sistem dan Teknologi Informasi Indonesia*, vol. 1, no. 2, Mar 2022.
- [15] M. I. Alfarizi, L. Syafaah, dan M. Lestandy, "Emotional Text Classification Using TF-IDF (Term Frequency-Inverse Document Frequency) And LSTM (Long Short-Term Memory)," *JUITA : Jurnal Informatika*, vol. 10, no. 2, hlm. 225, Nov 2022, doi: 10.30595/juita.v10i2.13262.
- [16] Q. A. N. Prakoso, A. Muliawati, dan I. N. Isnainiyah, "Analisis Sentimen terhadap Produk Skin Game di Forum Review Female Daily Menggunakan Metode Multinomial Naïve Bayes dan TF-IDF," *Informatik : Jurnal Ilmu Komputer*, vol. 18, no. 3, hlm. 198, Des 2022, doi: 10.52958/iftk.v18i3.4679.
- [17] R. F. Triana, A. I. P. Sari, A. Bahtiar, dan E. Wahyudin, "Implementasi Algoritma Naïve Bayes Untuk Klasifikasi Sentimen Ulasan Pengguna KAI Access," *Jutisi : Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 14, no. 1, hlm. 12, Apr 2025, doi: 10.35889/jutisi.v14i1.2437.
- [18] Z. Firmansyah dan N. F. Puspitasari, "Analisis Sentimen Masyarakat Terhadap Vaksinasi Covid-19 Berdasarkan Opini pada Twitter Menggunakan Algoritma Naive Bayes," *JTI : Jurnal Teknik Informatika*, vol. 14, no. 2, Okt 2021, doi: 10.15408/jti.v14i2.24024.
- [19] R. Metivianis, D. E. Ratnawati, dan B. Rahayudi, "Analisis Sentimen pengguna Twitter terhadap Vaksinasi Sinovac dan AstraZeneca menggunakan Algoritma CART," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 6, no. 4, hlm. 2548–964, Apr 2022, [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>
- [20] P. Pasek, O. Mahawardana, G. A. Sasmita, P. Agus, dan E. Pratama, "Analisis Sentimen Berdasarkan Opini dari Media Sosial Twitter terhadap 'Figure Pemimpin' Menggunakan Python," *JITTER-Jurnal Ilmiah Teknologi dan Komputer*, vol. 3, no. 1, Apr 2022, doi: <https://doi.org/10.5281/zenodo.7934336>.
- [21] R. Rinandyaswara, Y. A. Sari, dan M. T. Furqon, "Pembentukan Daftar Stopword Menggunakan Term Based Random Sampling pada Analisis Sentimen dengan Metode Naive Bayes (Studi Kasus : Kuliah Daring di Masa Pandemi)," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 9, no. 4, 2022, doi: 10.25126/jtiik.202294707.
- [22] M. U. Albab, Y. K. P., dan M. N. Fawaiq, "Optimization of the Stemming Technique on Text Preprocessing President 3 Periods Topic," *Jurnal Transformatika*, vol. 20, no. 2, hlm. 1–12, Jan 2023, doi: 10.26623/transformatika.v20i2.5374.
- [23] N. Mahfudza dan M. Ihksan, "Sentiment Analysis of Youtube Comments on Indonesian Presidential Candidates in 2024 using Naïve Bayes Classifier," *JURIKOM (Jurnal Riset Komputer)*, vol. 12, no. 2, hlm. 140–148, Apr 2025, doi: 10.30865/jurikom.v12i2.8538.
- [24] O. M. Wulandari, I. Maulana, F. Syamsudin, dan R. Waluyo, "Perbandingan Algoritma Naive Bayes dan SVM dalam Analisis Sentimen Twitter terhadap Isu Ijazah Jokowi Palsu," *Jurnal Manajemen Informatika, Sistem Informasi dan Teknologi Komputer (JUMISTIK)*, vol. 4, no. 1, hlm. 392–400, Jun 2025, doi: 10.70247/jumistik.v4i1.145.

