

## **Klasifikasi Sentimen Ulasan Produk E-Commerce Menggunakan Naive Bayes**

**Anwar Musyaddad Rangkuti<sup>1</sup>, Hasbi Mustafa<sup>2</sup>, Adi Guna Marios Tarihoran<sup>3</sup> Andre Pandiangan<sup>4</sup>**

<sup>1</sup>Ilmu Komputer, Sistem Informasi, Universitas Budi Darma, Medan, Indonesia

Email: <sup>1</sup>[anwarmusyaddadr@email.com](mailto:anwarmusyaddadr@email.com), <sup>2</sup>[hasbi.mustafa05@email.com](mailto:hasbi.mustafa05@email.com),

<sup>3</sup>[adigunamariostarihoran@email.com](mailto:adigunamariostarihoran@email.com), <sup>4</sup>[andrepandiangan0304@email.com](mailto:andrepandiangan0304@email.com)

Email Penulis Korespondensi: [anwarmusyaddadr@email.com](mailto:anwarmusyaddadr@email.com)

**Abstrak**– Perkembangan e-commerce di Indonesia telah menghasilkan volume ulasan produk yang sangat besar, yang dapat dimanfaatkan untuk memahami persepsi dan kepuasan pelanggan. Namun, analisis manual terhadap ribuan komentar tersebut tidak efisien dan berpotensi bias. Penelitian ini bertujuan untuk mengklasifikasikan sentimen pada ulasan produk e-commerce berbahasa Indonesia menggunakan algoritma Naive Bayes Classifier (NBC) dengan metode pembobotan Term Frequency–Inverse Document Frequency (TF–IDF). Permasalahan utama yang dihadapi adalah bentuk data ulasan yang tidak terstruktur, bervariasi secara linguistik, dan sering kali ambigu dalam konteks makna. Untuk mengatasinya, penelitian ini menerapkan tahapan preprocessing teks seperti cleaning, tokenizing, stopword removal, dan stemming untuk menghasilkan data bersih sebelum dilakukan proses klasifikasi. Dataset yang digunakan merupakan kumpulan ulasan konsumen dari platform e-commerce yang telah diberi label sentimen positif dan negatif secara manual. Data kemudian dibagi menjadi tiga skenario pelatihan dan pengujian dengan rasio 70:30, 80:20, dan 90:10. Hasil pengujian menunjukkan bahwa model Naive Bayes mampu mencapai akurasi tertinggi sebesar 94,09%, dengan nilai presisi 95,17%, recall 98,52%, dan F1-score 96,81% pada rasio 90:10. Hasil tersebut membuktikan bahwa kombinasi TF–IDF dan Naive Bayes Classifier efektif dalam mengklasifikasikan opini publik terhadap produk e-commerce secara otomatis dan efisien. Temuan ini diharapkan dapat membantu pelaku bisnis dalam memahami persepsi pelanggan serta mendukung strategi pemasaran berbasis data yang lebih tepat sasaran.

**Kata Kunci:** Klasifikasi Sentimen, Ulasan Produk, E-Commerce, Naive Bayes

**Abstract**–The rapid growth of e-commerce in Indonesia has generated a massive volume of product reviews that can be utilized to understand customer perceptions and satisfaction levels. However, manual analysis of thousands of comments is inefficient and prone to bias. This study aims to classify sentiments in Indonesian-language e-commerce product reviews using the Naive Bayes Classifier (NBC) algorithm combined with the Term Frequency–Inverse Document Frequency (TF–IDF) weighting method. The main challenge addressed in this research is the unstructured nature of textual review data, which varies linguistically and often contains ambiguous meanings. To overcome this issue, several text preprocessing steps were applied, including cleaning, tokenizing, stopword removal, and stemming, to produce clean and structured data prior to classification. The dataset used in this study consists of consumer reviews from e-commerce platforms that were manually labeled as either positive or negative sentiments. The data were divided into three training and testing scenarios with ratios of 70:30, 80:20, and 90:10. The experimental results show that the Naive Bayes model achieved the highest accuracy of 94.09%, with a precision of 95.17%, recall of 98.52%, and F1-score of

96.81% at the 90:10 ratio. These findings demonstrate that the combination of TF-IDF and Naïve Bayes Classifier is highly effective in automatically and efficiently classifying public opinions toward e-commerce products. This research is expected to assist businesses in understanding customer perceptions and to support more accurate, data-driven marketing strategies

*Keywords: Sentiment Classification, Product Reviews, E-Commerce, Naïve Bayes.*

## **1. PENDAHULUAN**

Perkembangan teknologi informasi dan komunikasi dalam dua dekade terakhir telah mendorong perubahan signifikan dalam aktivitas bisnis, khususnya pada sektor electronic commerce (e-commerce). E-commerce memungkinkan transaksi jual beli dilakukan secara daring melalui berbagai platform digital. Di Indonesia, pertumbuhan e-commerce tergolong pesat dan menempatkan negara ini pada peringkat ke-10 dunia dengan tingkat pertumbuhan mencapai 78% [1]. Seiring dengan meningkatnya aktivitas transaksi, jumlah ulasan konsumen terhadap produk dan layanan juga terus bertambah. Ulasan tersebut menjadi sumber informasi penting bagi calon pembeli dan pelaku bisnis untuk memahami persepsi publik [2].

Namun, tingginya volume ulasan yang dihasilkan setiap hari membuat analisis manual menjadi tidak efisien dan rentan terhadap bias subjektif [3]. Oleh karena itu, analisis sentimen diperlukan sebagai pendekatan berbasis komputasi untuk mengklasifikasikan opini ke dalam kategori positif, negatif, atau netral [4]. Melalui analisis sentimen, pelaku bisnis dapat memahami preferensi pelanggan secara lebih cepat dan akurat serta menyusun strategi pemasaran berbasis data [5].

Tantangan utama dalam analisis sentimen ulasan e-commerce terletak pada karakteristik data teks yang tidak terstruktur, beragam secara linguistik, serta mengandung unsur subjektivitas dan ambiguitas makna. Ulasan konsumen sering memadukan bahasa formal dan informal, emotikon, serta konteks tertentu yang sulit diproses oleh sistem konvensional. Kondisi ini menuntut adanya sistem analisis sentimen otomatis yang mampu menangani data teks berskala besar secara efisien dan akurat [6].

Salah satu metode yang banyak digunakan dalam analisis sentimen adalah algoritma Naive Bayes. Algoritma ini merupakan metode klasifikasi probabilistik berbasis Teorema Bayes dengan asumsi kemandirian antar fitur. Naive Bayes dikenal memiliki struktur sederhana, efisiensi komputasi tinggi, dan performa yang kompetitif pada data berbasis teks, termasuk ulasan e-commerce [7][8]. Dalam konteks analisis sentimen, algoritma ini mempelajari distribusi kata pada setiap kelas sentimen untuk mengklasifikasikan teks baru.

Berbagai penelitian menunjukkan efektivitas Naive Bayes dalam analisis sentimen e-commerce di Indonesia. Dakwah dan Firdaus [9] menemukan bahwa meskipun SVM memiliki akurasi lebih tinggi, Naive Bayes unggul dalam efisiensi dan interpretasi hasil. Aulia dan Hermawan [10] melaporkan akurasi 84% dengan presisi 96% pada ulasan Tokopedia. Widyandana dan Maskur [11] menunjukkan bahwa meskipun model berbasis transformer seperti IndoBERT unggul, Naive Bayes tetap kompetitif dan efisien. Penelitian lain juga menegaskan relevansi Naive Bayes dalam menganalisis opini publik terkait e-commerce dan platform digital [12–16].

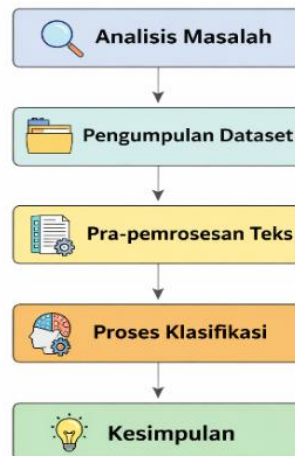
Berdasarkan kajian tersebut, penelitian ini bertujuan untuk mengklasifikasikan sentimen ulasan produk e-commerce menggunakan algoritma Naive Bayes Classifier serta mengevaluasi kemampuannya dalam membedakan sentimen positif dan negatif. Hasil penelitian diharapkan dapat memberikan gambaran kinerja Naive Bayes dalam analisis sentimen serta menjadi dasar

bagi pelaku bisnis dalam memahami opini pelanggan, meningkatkan kualitas layanan, dan menyusun strategi pemasaran berbasis data.

## 2. METODE

### 2.1 Tahapan Penelitian

Tahapan penelitian pada studi ini disusun secara sistematis untuk memastikan proses klasifikasi sentimen dapat berjalan secara terstruktur dan terukur. Alur penelitian dimulai dari tahap analisis masalah hingga penarikan kesimpulan akhir.



Gambar 1. Tahapan Penelitian

Berdasarkan gambar 1, berikut penjelasan yang dibuat oleh peneliti agar pembaca dapat lebih jelas dan lebih mudah memahami tahapan tersebut.

1. Analisis Masalah, Analisis permasalahan dilakukan untuk mengidentifikasi pemanfaatan ulasan produk e-commerce yang belum optimal, dengan fokus penelitian pada pengelompokan sentimen ulasan pelanggan guna memperoleh gambaran opini pengguna terhadap produk.
2. Pengumpulan dataset, Tahap berikutnya dilakukan dengan mengumpulkan dataset sekunder berupa ulasan produk e-commerce berbahasa Indonesia yang diperoleh dari Kaggle. Setiap ulasan disertai dengan nilai rating antara 1 sampai 5, yang selanjutnya dikelompokkan ke dalam tiga kategori sentimen, yaitu negatif untuk rating 1–2, netral untuk rating 3, dan positif untuk rating 4–5. Dataset tersebut digunakan sebagai sumber data utama dalam pelaksanaan analisis sentimen.
3. Pra-pemrosesan Teks, Setelah data terkumpul, teks ulasan diolah terlebih dahulu sebelum digunakan dalam proses klasifikasi. Pengolahan ini mencakup pembersihan teks dari karakter yang tidak diperlukan, penyesuaian kata agar lebih seragam, penghapusan kata-kata umum yang tidak memiliki makna penting, serta proses stemming. Langkah ini dilakukan untuk mengurangi gangguan pada data sehingga teks menjadi lebih rapi dan mudah dianalisis.
4. Proses Klasifikasi, Pada tahap ini dilakukan proses klasifikasi dengan memanfaatkan data yang telah melalui pra-pemrosesan untuk membangun model sentimen menggunakan metode Naive Bayes. Metode ini dipilih karena cukup efektif dalam mengelompokkan teks serta mampu menangani data dalam jumlah besar dengan baik. Model kemudian dilatih menggunakan data latih dan digunakan untuk memprediksi kelas sentimen pada data uji.

5. Kesimpulan, Tahap terakhir adalah penarikan kesimpulan, yang dilakukan berdasarkan hasil evaluasi kinerja model klasifikasi. Pada tahap ini dianalisis tingkat keberhasilan model dalam mengklasifikasikan sentimen ulasan produk, serta disimpulkan efektivitas metode Naive Bayes dalam mendukung analisis sentimen pada data ulasan e-commerce.

## **2.2 Machine Learning**

Machine learning (pembelajaran mesin) adalah cabang dari kecerdasan buatan (Artificial Intelligence/AI) yang berfokus pada bagaimana komputer dapat belajar dari data dan membuat keputusan tanpa harus diprogram secara eksplisit. Secara sederhana, machine learning memungkinkan sistem untuk mengenali pola, membuat prediksi, atau mengklasifikasikan informasi berdasarkan pengalaman dari data yang telah dipelajari sebelumnya. Proses ini meniru cara manusia belajar melalui pengalaman, hanya saja dalam konteks komputasi, “pengalaman” tersebut berupa kumpulan data dalam jumlah besar.

Dalam konteks modern, machine learning telah menjadi fondasi bagi banyak teknologi yang kita gunakan sehari-hari, seperti sistem rekomendasi di e-commerce, pengenalan wajah di media sosial, dan algoritma deteksi spam di surat elektronik. Hal ini menunjukkan bahwa machine learning bukan sekadar teori ilmiah, tetapi sudah menjadi bagian dari kehidupan digital yang nyata dan berkelanjutan. Menurut Patil & Kolate [1], pembelajaran mesin telah berkembang pesat di berbagai sektor, termasuk sistem energi, transportasi, dan telekomunikasi, karena kemampuannya dalam menganalisis data kompleks dan memberikan solusi prediktif yang efisien.

Perkembangan machine learning juga sangat dipengaruhi oleh kemajuan dalam bidang matematika, statistik, dan optimisasi komputasional. Studi oleh Maquen & Cárdenas [2], menunjukkan bahwa optimisasi matematis berperan penting dalam meningkatkan efisiensi algoritma pembelajaran mesin. Melalui pendekatan optimisasi, model dapat menyesuaikan parameter secara adaptif sehingga kesalahan prediksi menjadi semakin kecil dan hasilnya lebih akurat. Di sisi lain, penelitian terbaru juga menunjukkan bahwa machine learning tidak hanya terbatas pada sektor teknologi informasi. Dalam bidang pendidikan, algoritma pembelajaran mesin digunakan untuk menganalisis performa mahasiswa dan membantu pengambilan keputusan akademik secara personal. Misalnya, algoritma dapat memprediksi mahasiswa yang berpotensi mengalami kesulitan belajar sehingga lembaga pendidikan dapat memberikan intervensi lebih awal. Hal ini dibuktikan oleh penelitian Munawar & Sayed [3], yang menunjukkan bahwa penerapan machine learning di bidang pendidikan mampu meningkatkan kualitas pembelajaran melalui sistem rekomendasi adaptif dan analisis kinerja akademik secara real time.

Selain itu, kemajuan teknologi open data turut mendorong perkembangan machine learning. Dengan ketersediaan data yang terbuka dan transparan, peneliti dapat mengembangkan model prediksi dan analisis dengan cakupan lebih luas. Menurut Amirah & Karimah [4], sinergi antara data terbuka dan algoritma machine learning membuka peluang besar dalam inovasi publik, seperti manajemen lalu lintas pintar, perencanaan kota berbasis data, dan analisis sosial ekonomi. Secara umum, machine learning dapat dipandang sebagai jembatan antara data dan pengetahuan. Ia memungkinkan manusia untuk memahami fenomena kompleks melalui pembelajaran otomatis yang terus berkembang seiring dengan ketersediaan data dan daya komputasi. Namun demikian, tantangan etis seperti privasi data, bias algoritma, dan transparansi keputusan masih menjadi isu penting yang perlu diperhatikan. Seperti yang diungkap oleh Zhai & Lu [5], keberhasilan machine learning tidak hanya diukur dari akurasi prediksi, tetapi juga dari sejauh mana teknologi ini dapat digunakan secara bertanggung jawab dan bermanfaat bagi

masyarakat luas. Dengan demikian, dapat disimpulkan bahwa machine learning bukan hanya teknologi masa depan, tetapi juga realitas masa kini yang telah mengubah cara manusia berpikir, bekerja, dan membuat keputusan. Ia menggabungkan kekuatan data, algoritma, dan komputasi dalam satu sistem cerdas yang terus belajar dan beradaptasi terhadap perubahan dunia nyata.

### 2.3 Naive Bayes

Naive Bayes merupakan salah satu algoritma machine learning yang sudah lama dikenal, tetapi hingga kini masih banyak digunakan, khususnya untuk tugas klasifikasi teks dan analisis sentimen. Algoritma ini bekerja dengan memanfaatkan konsep probabilitas untuk menentukan kelas suatu data berdasarkan karakteristik atau fitur yang dimilikinya. Istilah “naive” digunakan karena Naive Bayes menganggap setiap fitur saling berdiri sendiri dan tidak saling memengaruhi, meskipun pada praktiknya hubungan antar fitur sering kali ada. Walaupun asumsi tersebut terbilang sederhana, Naive Bayes mampu menghasilkan performa klasifikasi yang cukup baik, cepat, dan efisien, bahkan ketika diterapkan pada data yang kompleks.

Dalam prosesnya, Naive Bayes menggunakan Teorema Bayes, yang secara matematis menghitung peluang suatu data termasuk dalam kategori tertentu berdasarkan data sebelumnya. Dengan kata lain, ia memprediksi kemungkinan suatu pernyataan benar berdasarkan bukti yang tersedia. Sebagai contoh, dalam analisis sentimen ulasan produk e-commerce, algoritma ini menghitung kemungkinan suatu ulasan termasuk kategori “positif” atau “negatif” berdasarkan frekuensi kata-kata tertentu dalam teks. Karena kemampuannya untuk bekerja cepat dan membutuhkan sumber daya komputasi rendah, metode ini banyak digunakan dalam pengolahan bahasa alami (Natural Language Processing / NLP), deteksi spam, serta analisis opini publik di media sosial [6]. Keunggulan utama dari Naive Bayes terletak pada efisiensi dan kesederhanaannya. Algoritma ini dapat bekerja dengan baik pada dataset besar tanpa memerlukan pelatihan yang lama. Dalam penelitian tentang klasifikasi teks di media sosial, Naive Bayes mampu mencapai tingkat presisi 87% dan kecepatan pemrosesan hanya 0,033 detik untuk 1.000 data komentar Sitepu & Wanayumini [6]. Kecepatan ini menjadikannya pilihan ideal dalam sistem yang membutuhkan analisis data secara real-time, seperti e-commerce atau layanan pelanggan digital.

Dalam konteks analisis sentimen, algoritma Naive Bayes terbukti efektif karena mampu mengklasifikasikan opini publik dengan tingkat kesalahan yang rendah. Studi oleh Sembiring [7], yang menggunakan dataset dari Wikipedia tentang COVID-19 menunjukkan akurasi sebesar 81% dalam menentukan sentimen positif, negatif, dan netral. Hal ini membuktikan bahwa algoritma Naive Bayes dapat memahami pola linguistik dan konteks kalimat dalam data teks besar, bahkan ketika data tersebut beragam secara semantik. Tidak hanya digunakan pada analisis opini, Naive Bayes juga diterapkan dalam keamanan siber dan deteksi serangan jaringan. Penelitian oleh Mutia & Irawan [8], menunjukkan bahwa metode ini efektif untuk mengklasifikasikan serangan siber seperti phishing, ransomware, dan DDoS attacks. Dengan akurasi tinggi, Naive Bayes membantu profesional keamanan dalam mengidentifikasi pola serangan berdasarkan data log jaringan, sekaligus mempercepat proses mitigasi ancaman.

Selain pada keamanan, Naive Bayes juga digunakan dalam konteks layanan publik dan industri. Sebagai contoh, penelitian oleh Anggraini & Ikhsan [9], membuktikan bahwa algoritma ini mampu mencapai tingkat akurasi 92% dalam mengidentifikasi pesan spam pada sistem komunikasi. Pendekatan ini membantu lembaga atau perusahaan telekomunikasi dalam memfilter pesan yang tidak diinginkan tanpa mengganggu pesan penting yang sah. Dalam bidang bisnis, penerapan Naive Bayes juga terus berkembang. Studi oleh Tanjung & Tampubolon [10], menggunakan kombinasi Naive Bayes Classifier dengan algoritma Genetic

Algorithm (GA) untuk mengklasifikasikan pelanggan berdasarkan tingkat kepuasan terhadap layanan. Hasilnya menunjukkan peningkatan akurasi dari 85,08% menjadi 89,31% setelah fitur yang relevan dipilih menggunakan GA. Ini membuktikan bahwa meskipun sederhana, Naive Bayes dapat dioptimalkan dengan teknik feature selection modern untuk meningkatkan kinerjanya.

Sementara itu, dalam bidang kesehatan, algoritma ini juga memiliki peran penting. Penelitian oleh Barus & Romindo [11], menggunakan Naive Bayes untuk mengklasifikasikan tingkat kehilangan pendengaran berdasarkan data pasien dari WHO. Dengan tingkat akurasi 94%, model ini mampu membantu proses diagnosis dini serta mendukung pengambilan keputusan medis berbasis data. Naive Bayes memiliki keunggulan utama pada kecepatan proses dan penggunaan sumber daya yang relatif ringan. Algoritma ini dapat bekerja dengan baik pada berbagai jenis data tanpa memerlukan perhitungan yang rumit. Walaupun pendekatannya sederhana, Naive Bayes masih sering digunakan, terutama pada tugas klasifikasi teks, karena mampu menangani data dalam jumlah besar dengan hasil yang cukup stabil. Selain mudah diterapkan, hasil yang dihasilkan juga lebih mudah dipahami, sehingga algoritma ini banyak dimanfaatkan dalam penelitian, pengembangan sistem di industri, hingga aplikasi yang membutuhkan pemrosesan cepat. Sampai saat ini, Naive Bayes tetap relevan dalam bidang machine learning karena fleksibel dan dapat disesuaikan dengan kebutuhan analisis serta karakteristik data yang berbeda.

### 2.4 Evaluasi Kinerja Model

Evaluasi kinerja model adalah tahap penting untuk mengetahui seberapa baik algoritma mampu memprediksi hasil dengan benar. Dalam konteks klasifikasi sentimen, tahap ini bertujuan untuk menilai kemampuan model dalam membedakan antara sentimen positif dan negatif secara akurat. Evaluasi yang baik memastikan bahwa model tidak hanya bekerja dengan baik pada data pelatihan, tetapi juga dapat beradaptasi dengan data baru. Beberapa metrik umum yang digunakan dalam evaluasi model klasifikasi adalah akurasi (accuracy), presisi (precision), recall (sensitivitas), F1-score, dan confusion matrix. Akurasi mengukur proporsi prediksi yang benar terhadap seluruh data uji. Presisi menunjukkan sejauh mana model mampu menghindari kesalahan prediksi positif palsu, sedangkan recall mengukur kemampuan model dalam menemukan semua data yang benar-benar positif. F1-score digunakan sebagai ukuran keseimbangan antara presisi dan recall. Sementara itu, confusion matrix membantu melihat distribusi kesalahan klasifikasi dengan menunjukkan berapa banyak data yang diklasifikasikan dengan benar maupun salah [12].

Menurut penelitian Siregar & Ruslan, penggunaan kombinasi beberapa metrik evaluasi seperti akurasi, presisi, recall, dan F1-score memberikan gambaran yang lebih menyeluruh terhadap performa model. Metrik-metrik tersebut dapat membantu peneliti mengetahui apakah model memiliki masalah seperti overfitting atau bias terhadap kelas tertentu [13]. Selain itu, studi oleh Adiputra [14], juga menekankan pentingnya penggunaan metrik F1-score dan precision dalam memastikan bahwa model tidak hanya akurat tetapi juga efisien dalam menangani data yang tidak seimbang. Dengan menggunakan metrik ini, model dapat dievaluasi secara objektif berdasarkan keseimbangan antara kemampuan mengenali data benar dan menghindari kesalahan prediksi. Dari berbagai penelitian tersebut dapat disimpulkan bahwa proses evaluasi tidak boleh hanya berfokus pada satu metrik saja. Kombinasi beberapa ukuran performa akan memberikan gambaran yang lebih akurat mengenai kemampuan model. Dengan demikian, model seperti Naive Bayes dapat dinilai secara komprehensif dalam mengklasifikasikan sentimen ulasan produk e-commerce.

### 3. HASIL DAN PEMBAHASAN

Data yang digunakan pada penelitian ini diperoleh dari kumpulan ulasan teks yang telah dilabeli sentimen positif dan negatif secara manual. Dataset terdiri atas dua file utama, yaitu `sentimen_labeled.csv` sebagai data mentah dan `sentimen_preprocessed.csv` sebagai hasil preprocessing. Total data yang digunakan sebanyak  $n$  ulasan, dengan dua kategori sentimen: positif dan negatif. Data tersebut selanjutnya digunakan untuk proses pembobotan TF-IDF dan pelatihan model klasifikasi menggunakan algoritma Naïve Bayes Classifier (NBC). Tahap pelabelan data dilakukan secara manual (supervised labeling) untuk menentukan kelas sentimen setiap ulasan.

Setiap teks ulasan dibaca dan diberikan label berdasarkan polaritas emosinya:

1. Positif, jika teks mengandung kata atau ekspresi kepuasan, pujian, atau penilaian baik.
2. Negatif, jika teks mengandung kata atau ekspresi kekecewaan, keluhan, atau penilaian buruk.

Proses ini menghasilkan dua kelas sentimen:

1. Sentimen positif: mayoritas data ulasan menunjukkan kepuasan terhadap layanan atau produk.
2. Sentimen negatif: sebagian kecil ulasan berisi ketidakpuasan atau pengalaman buruk.

Hasil pelabelan ini disimpan dalam kolom `sentiment` pada file `sentimen_labeled.csv`, dan digunakan sebagai ground truth pada proses pelatihan model Naïve Bayes.

Tahapan preprocessing dilakukan untuk membersihkan dan menormalkan data teks agar siap diolah. Proses ini meliputi:

1. Cleaning – menghapus simbol, tanda baca, URL, angka, dan karakter khusus.
2. Case Folding – mengubah seluruh teks menjadi huruf kecil.
3. Tokenizing – memecah kalimat menjadi kata-kata (token).
4. Normalization – mengubah kata tidak baku menjadi kata baku.
5. Stopword Removal – menghapus kata yang tidak memiliki makna penting.
6. Stemming – mengubah kata menjadi bentuk dasar.

Hasil akhir preprocessing disimpan pada kolom `clean_text` di file `sentimen_preprocessed.csv`.

Pembobotan teks dilakukan menggunakan metode TF-IDF (Term Frequency–Inverse Document Frequency) untuk menghitung tingkat kepentingan setiap kata dalam korpus.

Rumus perhitungan ditunjukkan pada persamaan berikut:

$$\text{TF-IDF}(t, d) = \text{TF}(t, d) \times \log\left(\frac{N}{\text{DF}(t)}\right)$$

Keterangan :

$t$  = term atau kata

$d$  = dokumen

$N$  = jumlah total dokumen dalam korpus

$\text{DF}(t)$  = jumlah dokumen yang mengandung term  $t$

Proses klasifikasi dilakukan menggunakan algoritma Naïve Bayes Classifier (MultinomialNB) yang banyak digunakan dalam analisis sentimen karena efisien dan memiliki performa tinggi pada data teks.

Sebelum pelatihan, data ulasan yang telah melalui proses pembobotan TF-IDF dibagi menjadi dua bagian, yaitu data latih (training set) dan data uji (testing set).

## Klasifikasi Sentimen Ulasan Produk E-Commerce Menggunakan Naive Bayes

Pembagian data dilakukan secara acak dengan seed konstan (`random_state = 42`) untuk memastikan hasil dapat direproduksi (`reproducible`). Tiga rasio pembagian yang digunakan adalah:

- 70% data latih dan 30% data uji,
- 80% data latih dan 20% data uji,
- 90% data latih dan 10% data uji.

Model dilatih menggunakan data latih dan diuji menggunakan data uji untuk mengukur performa klasifikasi berdasarkan metrik-metrik berikut:

1. Accuracy (Akurasi), yaitu proporsi prediksi yang benar terhadap seluruh data.
2. Precision (Presisi), yaitu tingkat ketepatan model dalam memprediksi kelas positif.
3. Recall (Sensitivitas), yaitu kemampuan model dalam mengenali seluruh data positif.
4. F1-Score, yaitu rata-rata harmonik antara presisi dan recall.

Keempat metrik tersebut dihitung berdasarkan hasil Confusion Matrix, menggunakan pustaka `scikit-learn` pada bahasa pemrograman Python.

Hasil pengujian dengan tiga rasio pembagian data ditunjukkan pada Tabel 1 berikut.

Tabel. 1 Hasil Pengujian

Rasio Data Latih:Uji	Akurasi	Presisi	Recall	F1-Score
70:30	94.02 %	94.96 %	98.67 %	96.78 %
80:20	93.89 %	94.95 %	98.53 %	96.70 %
90:10	94.09 %	95.17 %	98.52 %	96.81 %

Model menunjukkan performa yang stabil pada seluruh rasio, dengan akurasi tertinggi sebesar 94.09% pada rasio 90:10.

Untuk menilai performa klasifikasi secara lebih rinci, digunakan Confusion Matrix, yang menggambarkan distribusi prediksi model terhadap data aktual. Berdasarkan hasil pengujian, metode Naïve Bayes Classifier terbukti efektif dalam mengklasifikasikan sentimen teks berbahasa Indonesia. Dengan akurasi di atas 93% pada semua rasio, model ini menunjukkan kemampuan yang konsisten serta efisiensi tinggi dalam menangani data teks sederhana.

Namun, hasil confusion matrix juga memperlihatkan adanya ketidakseimbangan minor pada kelas negatif, yang dapat diatasi pada penelitian selanjutnya dengan pendekatan resampling seperti SMOTE atau penambahan data negatif.

Secara keseluruhan, hasil ini mendukung bahwa metode TF-IDF + Naïve Bayes Classifier merupakan kombinasi yang kuat untuk analisis sentimen teks dalam bahasa Indonesia.

## 4. PENUTUP

### 4.1 Kesimpulan

Berdasarkan hasil penelitian dan analisis yang telah dilakukan, dapat disimpulkan :

1. Metode Naïve Bayes Classifier (NBC) terbukti efektif dalam melakukan klasifikasi sentimen ulasan produk e-commerce berbahasa Indonesia. Dengan pendekatan TF-IDF sebagai metode pembobotan kata, sistem mampu mengenali perbedaan antara sentimen positif dan negatif secara akurat. Proses preprocessing teks seperti cleaning, tokenizing, stopword removal, dan stemming berperan penting dalam meningkatkan kualitas data sehingga model dapat bekerja secara efisien dan menghasilkan hasil klasifikasi yang stabil pada seluruh rasio pembagian data.
2. Hasil pengujian menunjukkan bahwa model Naïve Bayes memiliki performa yang tinggi dengan rata-rata akurasi di atas 93%, serta akurasi tertinggi sebesar 94,09% pada rasio data

90:10. Nilai presisi 95,17%, recall 98,52%, dan F1-score 96,81% menegaskan bahwa model ini mampu mengidentifikasi opini positif dan negatif dengan sangat baik. Confusion Matrix memperlihatkan bahwa sebagian besar prediksi model benar, dengan sedikit kesalahan klasifikasi pada kelas negatif akibat ketidakseimbangan data, sedangkan visualisasi wordcloud memperkuat hasil dengan dominasi kata-kata positif seperti “bagus”, “mantap”, dan “puas”. Secara keseluruhan, kombinasi TF-IDF dan Naïve Bayes Classifier merupakan pendekatan sederhana namun efektif untuk analisis sentimen ulasan e-commerce.

### 4.2 Saran

Berdasarkan hasil dari penelitian diatas, maka dapat disarankan untuk mengembangkan penelitian ini lebih baik, yaitu sebagai berikut:

1. Penelitian selanjutnya disarankan untuk menggunakan dataset ulasan yang lebih besar dan beragam dari berbagai platform e-commerce agar hasil klasifikasi sentimen menjadi lebih akurat dan representatif.
2. Proses pra-pemrosesan teks seperti *tokenizing*, *stopword removal*, *stemming*, dan *normalisasi kata* dapat dikembangkan lebih lanjut untuk meningkatkan kualitas data dan performa algoritma Naive Bayes.
3. Untuk mengetahui tingkat efektivitas metode yang digunakan, disarankan agar dilakukan perbandingan dengan algoritma klasifikasi lain seperti Support Vector Machine (SVM), K-Nearest Neighbor (KNN), atau metode berbasis *deep learning*.
4. Penelitian selanjutnya disarankan menggunakan teknik resampling seperti SMOTE untuk menyeimbangkan distribusi data, serta membandingkan hasilnya dengan model berbasis *deep learning* seperti LSTM atau BERT guna memperoleh hasil yang lebih optimal.

## REFERENCES

- [1] A. T. Rizkya, R. Rianto, and A. I. Gufroni, “Implementation of the Naive Bayes Classifier for Sentiment Analysis of Shopee E-Commerce Application Review Data on the Google Play Store,” *Int. J. Appl. Inf. Syst. Informatics*, vol. 1, no. 1, pp. 31–37, 2023, doi: 10.37058/jaisi.v1i1.8993.
- [2] F. Akmal, A. D. Riyanto, and I. Darmayanti, “Optimization Naïve Bayes Algorithm in Sentiment Analysis of Bukalapak App Reviews,” *Sinkron*, vol. 9, no. 1, pp. 145–151, 2024, doi: 10.33395/sinkron.v9i1.13132.
- [3] V. Oktaviani, B. Warsito, H. Yasin, R. Santoso, and Suparti, “Sentiment analysis of e-commerce application in Traveloka data review on Google Play site using Naïve Bayes classifier and association method,” *J. Phys. Conf. Ser.*, vol. 1943, no. 1, 2021, doi: 10.1088/1742-6596/1943/1/012147.
- [4] A. Lestari, A. Irma Purnamasari, A. Bahtiar, and E. Tohidi, “Journal of Artificial Intelligence and Engineering Applications Sentiment Analysis to Classify Tiktok Shop Users on Twitter with Naïve Bayes Classifier Algorithm,” vol. 4, no. 2, pp. 2808–4519, 2025, doi: 10.59934/jaiea.v4i2.748.
- [5] C. R. Hassolthine, T. Haryanto, F. Adline Twince Tobing, and M. Ikhwan Saputra, “E-Commerce Product Review Sentiment Analysis: A Comparative Study of Naïve Bayes Classifier and Random Forest Algorithms on Marketplace Platforms,” *IJNMT (International J. New Media Technol.)*, vol. 12, no. 1, pp. 55–60, 2025, doi: 10.31937/ijnmt.v12i1.4246.
- [6] A. S. Stone and F. Fathoni, “Analisis Sentiment Pelanggan Terhadap Penilaian Produk

- Pada Toko Online Shop Amreta Menggunakan Metode Naïve Bayes Classification,” *J. Media Inform. Budidarma*, vol. 6, no. 3, p. 1590, 2022, doi: 10.30865/mib.v6i3.4436.
- [7] S. N. Fadhilah and F. S. Utomo, “Algoritma Naïve Bayes untuk Analisis Sentiment Review Blibli.com di Google Play Store,” *Sist. J. Sist. Inf.*, vol. 13, no. 2, pp. 834–4, 2024, doi: 10.32520/stmsi.v13i2.
- [8] R. Kosasih and A. Alberto, “Sentiment analysis of game product on shopee using the TF-IDF method and naive bayes classifier,” *Ilk. J. Ilm.*, vol. 13, no. 2, pp. 101–109, 2021, doi: 10.33096/ilkom.v13i2.721.101-109.
- [9] M. M. Dakwah, A. A. Firdaus, F. Furizal, and R. Faresta, “Sentiment Analysis on Marketplace in Indonesia using Support Vector Machine and Naïve Bayes Method,” *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 10, no. 1, p. 39, 2024, doi: 10.26555/jiteki.v10i1.28070.
- [10] M. Aulia and A. Hermawan, “Analisis Perbandingan Algoritma SVM, Naïve Bayes, dan Perceptron untuk Analisis Sentimen Ulasan Produk Tokopedia,” *J. Media Inform. Budidarma*, vol. 7, no. 4, p. 1850, 2023, doi: 10.30865/mib.v7i4.6839.
- [11] N. M. Farhan and B. Setiaji, “Indonesian Journal of Computer Science,” *Indones. J. Comput. Sci.*, vol. 12, no. 2, pp. 284–301, 2023, doi: 10.33022/ijcs.v14i4.4980.
- [12] S. Jafar Sidiq and A. Nur Rachman, “Analysis Of Twitter User Sentiment To Tiktok Shop Using Naïve Bayes And Decision Tree Algorithms,” *Int. J. Appl. Inf. Syst. Informatics*, vol. 1, no. 1, pp. 8–14, 2023, doi: 10.37058/jaisi.v1i1.8990.
- [13] I. R. Hendrawan, “‘Jurnal TRANSFORMASI (Informasi & Pengembangan Iptek)’ (STMIK BINA PATRIA) PERBANDINGAN ALGORITMA NAÏVE BAYES, SVM DAN XGBOOST DALAM KLASIFIKASI TEKS SENTIMEN MASYARAKAT TERHADAP PRODUK LOKAL DI INDONESIA,” *J. Transform.*, vol. 18, no. 1, pp. 1–8, 2022, doi: 10.56357/jt.v18i1.295.
- [14] N. F. Zakaria, M. Wibowo, and N. A. Setya Nugraha, “Analisis Sentimen Terhadap Isu Resesi Tahun 2023 di Indonesia menggunakan Metode Naïve Bayes,” *J. Media Inform. Budidarma*, vol. 7, no. 3, p. 1171, 2023, doi: 10.30865/mib.v7i3.6386.
- [15] B. Setiawan, “A Review of Sentiment Analysis Applications in Indonesia Between 2023-2024,” *J. Inf. Eng. Educ. Technol.*, vol. 8, no. 2, pp. 71–83, 2025, doi: 10.26740/jieet.v8n2.p71-83.
- [16] A. A. Lestari, Ahmad Faqih, and Gifthera Dwilestari, “Improving Sentiment Analysis Performance of Tokopedia Reviews Using Principal Component Analysis and Naïve Bayes Algorithm,” *J. Artif. Intell. Eng. Appl.*, vol. 4, no. 2, pp. 758–763, 2025, doi: 10.59934/jaiea.v4i2.743.
- [17] Jayesh Nana Patil, Ashvini Sunil Kolate, and Prayag Satish Patil, “Recent Advances in Machine Learning Applications in Electrical Utility Systems,” *Open Access Res. J. Eng. Technol.*, vol. 9, no. 1, pp. 056–064, 2025, doi: 10.53022/oarjet.2025.9.1.0077.
- [18] G. L. E. Maquen-niño and D. S. García, “Impact of Mathematical Optimization on Machine Learning: A Bibliometric Review Diana Mercedes Castro Cárdenas Carmen Margarita Guzmán Roldán Adelmo Pérez Herrera Yessica del Milagro Chunga More,” vol. 15, no. 5, pp. 208–227, 2025, doi: 10.36941/jesr-2025-0172.
- [19] Munawar Y. Sayed, “Enhancing Education Quality and Student Knowledge in Higher Education Using Machine Learning to Meet Societal Needs,” *J. Informatics Educ. Res.*, vol. 5, no. 2, pp. 1112–1121, 2025, doi: 10.52783/jier.v5i2.2549.
- [20] Amirah and F. Karimah, “Leveraging Open Data with Machine Learning Algorithms,” *J. Sist. Inf. dan Tek. Inform.*, vol. 1, no. 2, pp. 62–69, 2023, doi: 10.70356/jafotik.v1i2.19.
- [21] X. Zhai and M. Lu, “Editorial: Machine learning applications in educational studies,”

- Front. Educ.*, vol. 8, 2023, doi: 10.3389/educ.2023.1225802.
- [22] A. C. Sitepu, W. Wanayumini, and Z. Situmorang, "Determining Bullying Text Classification Using Naive Bayes Classification on Social Media," *J. Varian*, vol. 4, no. 2, pp. 133–140, 2021, doi: 10.30812/varian.v4i2.1086.
- [23] J. M. Br Sembiring and H. H, "Naïve Bayes Algorithm Classification in Sentiment Analysis Covid-19 Wikipedia," *J. Tek. Inform.*, vol. 3, no. 4, pp. 869–875, 2022, doi: 10.20884/1.jutif.2022.3.4.311.
- [24] A. Sandi Mutia, I. Irawan, and C. Juliane, "Global Network Cyberattack Classification Using Naive Bayes Method Time Range 2020 – 2023," *Astonjadro*, vol. 13, no. 2, pp. 587–596, 2024, doi: 10.32832/astonjadro.v13i2.15683.
- [25] D. R. Retail and M. Safri, "Journal of Computer Networks , Architecture and High Performance Computing Implementation of The Apriori Algorithm in Managing Stock Items at Journal of Computer Networks , Architecture and High Performance Computing," *J. Comput. Networks Archit. High Perform. Comput.*, vol. 6, no. 3, pp. 838–849, 2024, doi: 10.47709/cnahpc.v6i2.3875.
- [26] J. P. Tanjung, F. C. Tampubolon, A. W. Panggabean, and M. A. A. Nandrawan, "Customer Classification Using Naive Bayes Classifier With Genetic Algorithm Feature Selection," *Sinkron*, vol. 8, no. 1, pp. 584–589, 2023, doi: 10.33395/sinkron.v8i1.12182.
- [27] O. P. Barus, Romindo, and J. J. Pangaribuan, "Classification of Hearing Loss Degrees with Naive Bayes Algorithm," *J. RESTI*, vol. 7, no. 4, pp. 751–757, 2023, doi: 10.29207/resti.v7i4.4683.
- [28] N. Van Thieu, "PerMetrics: A Framework of Performance Metrics for Machine Learning Models," *J. Open Source Softw.*, vol. 9, no. 95, p. 6143, 2024, doi: 10.21105/joss.06143.
- [29] K. H. Siregar, D. Ruslan, A. I. Faried, and R. Sembiring, "Implementation of Machine Learning Algorithm for Credit Scoring Prediction in Islamic Microfinance," *J. Intell. Syst. Inf. Technol.*, vol. 2, no. 2, pp. 88–98, 2025, doi: 10.61971/jisit.v2i2.156.
- [30] T. T. H. Le, A. A. Adiputra, J. Yun, and H. Kim, "Anomaly Detection in Industrial Machine Sounds Using High-Frequency Features and Gate Recurrent Unit Networks," *IEEE Access*, vol. 13, no. 2024, pp. 77165–77186, 2025, doi: 10.1109/ACCESS.2025.3565812.