



Comparison of Support Vector Machine and Naïve Bayes for E-Commerce Review Sentiment Classification

Perbandingan Support Vector Machine dan Naïve Bayes untuk Klasifikasi Sentimen Ulasan E-Commerce

**Dita Nurmadewi^{1*}, Zakiul Fahmi Jailani², Haris Rafi³,
Dimas Aryo Anggoro⁴, Dewi Setiowati⁵**

^{1,2,3}Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Universitas Bakrie, Indonesia

⁴Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Bakrie, Indonesia

⁵Teknik Informatika, Fakultas Ilmu Komputer, Universitas Esa Unggul, Indonesia

E-Mail: ¹dita.nurmadewi@bakrie.ac.id, ²zakiul.jailani@bakrie.ac.id, ³haris.rafi@bakrie.ac.id,
⁴dimas.anggoro@bakrie.ac.id, ⁵dewi.setiowati@esaunggul.ac.id

Received Feb 15th 2026; Revised Mar 17th 2026; Accepted Apr 27th 2026; Available Online Apr 30th 2026

Corresponding Author: Dita Nurmadewi

Copyright ©2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Customer reviews on e-commerce platforms provide valuable insights into user experiences with products and services. However, the large volume of reviews makes manual analysis inefficient. Sentiment classification based on machine learning can automatically identify opinions from review texts. This study aims to compare the performance of Support Vector Machine (SVM) and Naïve Bayes for sentiment classification in e-commerce platform reviews. The dataset consists of 11,606 customer reviews obtained from a public dataset repository. Some of the tasks performed during the pre-processing stage include stemming, case folding, tokenization, and stopword removal. The Term Frequency-Inverse Document Frequency (TF-IDF) model is used to represent the characteristics of text. A 5-fold cross-validation strategy is used to assess model performance, with F1-score, recall, accuracy, and precision as assessment measures. The Support Vector Machine method achieved an accuracy score of 0.8717, while the Naïve Bayes method achieved an accuracy score of 0.8555, based on experimental data. These findings indicate that Support Vector Machine has better generalization capability in distinguishing sentiment classes in text-based e-commerce review data.

Keywords: E-Commerce Reviews, Naïve Bayes, Sentiment Classification, Support Vector Machine, TF-IDF

Abstrak

Ulasan pelanggan di platform e-commerce memuat informasi penting tentang pengalaman pengguna terhadap produk dan layanan. Namun, mengingat jumlahnya sangat besar, analisis manual tidak efisien. Klasifikasi sentimen berbasis machine learning dapat secara otomatis mengidentifikasi opini dari teks ulasan. Penelitian ini ingin melakukan perbandingan antara performa Support Vector Machine (SVM) dan Naïve Bayes dalam melakukan klasifikasi sentimen pada ulasan di platform e-commerce. Dataset terdiri atas 11.606 ulasan pelanggan yang bersumber dari repositori dataset publik. Tahap pra-pemrosesan mencakup case folding, tokenization, penghilangan stopword, serta stemming. Fitur teks ditampilkan memakai Term Frequency-Inverse Document Frequency (TF-IDF). Kinerja model dievaluasi berdasarkan skema 5-fold cross-validation menggunakan metrik accuracy, precision, dan recall, serta F1-score. Hasil eksperimen menemukan algoritma Support Vector Machine mempunyai performa lebih unggul jika dibandingkan dengan Naïve Bayes, di mana perolehan nilai accuracy masing-masing mencapai 0.8717 dan 0.8555. Temuan ini sekaligus menunjukkan Support Vector Machine mempunyai kemampuan generalisasi yang lebih baik dalam membedakan kelas sentimen pada data ulasan e-commerce berbasis teks.

Kata Kunci: Klasifikasi Sentimen, Naïve Bayes, Support Vector Machine, TF-IDF, Ulasan E-Commerce

1. PENDAHULUAN

Pola masyarakat berinteraksi dalam ekonomi telah berubah secara drastis sejalan dengan kemajuan dalam teknologi informasi dan komunikasi, khususnya melalui munculnya berbagai platform perdagangan



elektronik (*e-commerce*). Teknologi digital memungkinkan konsumen melakukan transaksi tanpa batasan waktu dan lokasi, sehingga aktivitas perdagangan menjadi lebih efisien dan fleksibel. Transformasi ini juga menghasilkan volume data yang sangat besar, salah satunya berupa ulasan pelanggan yang dipublikasikan pada platform *e-commerce* [1]. Ulasan pelanggan merupakan salah satu komponen penting dalam ekosistem *e-commerce* karena berfungsi sebagai sarana komunikasi antara konsumen dan penjual serta sebagai referensi bagi calon pembeli dalam mengambil keputusan pembelian [2]. Dalam penerapannya, tinjauan atau ulasan dari pelanggan berisi berbagai pandangan, penilaian, dan pengalaman pribadi pengguna terkait produk dan jasa yang mereka gunakan. Informasi ini memiliki arti penting bagi perusahaan karena bisa dipakai guna mengembangkan mutu produk, memperbaiki layanan, serta merancang strategi pemasaran yang berdasarkan informasi [3]. Namun, besarnya jumlah ulasan menjadikan analisis manual kurang efektif dan meningkatkan kemungkinan terjadinya bias *interpretative* [4]. Oleh sebab itu, diperlukan sebuah cara otomatis yang bisa mengategorikan dan mengevaluasi ulasan atau pendapat pelanggan dengan sistematis. Metode yang digunakan untuk menganalisis opini dalam teks, salah satunya adalah klasifikasi sentimen [5]. Klasifikasi sentimen dipahami sebagai metode untuk menentukan polaritas suatu teks dan mengklasifikasikan ke dalam beberapa kelas sentimen, misalnya positif, negatif, atau netral [6]. Dalam konteks *e-commerce*, klasifikasi sentimen membuka peluang bagi perusahaan memahami kecenderungan persepsi pelanggan secara lebih terstruktur dan kuantitatif. Secara umum, klasifikasi sentimen diterapkan melalui pendekatan supervised learning, yang mana model ini dikembangkan berdasarkan *dataset* yang sudah diberi label sebagai dasar proses pembelajaran [7].


Beragam algoritma pembelajaran mesin sudah diterapkan pada studi klasifikasi sentimen, termasuk *Naïve Bayes* dan *Support Vector Machine* (SVM). Algoritma *Naïve Bayes* merupakan klasifikasi berdasarkan pada probabilitas yang beroperasi menurut Teorema Bayes dengan anggapan jika fitur-fitur bersifat bebas. Metode ini dikenal karena kesederhanaan modelnya dan efisiensi dalam penghitungan, sehingga sering diterapkan dalam penelitian-penelitian klasifikasi teks [8]. Adapun SVM adalah algoritma klasifikasi yang menggunakan pendekatan berdasarkan margin. Algoritma ini bertujuan untuk menemukan *hyperplane* terbaik yang bisa digunakan untuk membagi kelas data dengan margin terbesar. Metode ini memiliki keunggulan dalam melakukan generalisasi, khususnya pada data dengan dimensi tinggi seperti teks [9]. Sejumlah penelitian sebelumnya memperlihatkan bahwa SVM sering memberikan kinerja yang baik dalam mengerjakan berbagai tugas klasifikasi teks, termasuk analisis sentimen [10]. Namun demikian, performa model klasifikasi sangat dipengaruhi oleh karakteristik *dataset* serta metode representasi fitur yang digunakan [11]. Dalam beberapa kasus, *Naïve Bayes* masih mampu menunjukkan performa yang kompetitif karena struktur modelnya yang sederhana dapat bekerja dengan baik pada data yang relatif terbatas [12]. Oleh karena itu, perbandingan performa kedua algoritma tersebut masih menjadi topik yang relevan untuk diteliti dalam berbagai konteks aplikasi. Pada analisis sentimen berbasis teks, *Term Frequency-Inverse Document Frequency* atau TF-IDF adalah metode representasi fitur yang sering digunakan. Metode ini dapat menggambarkan seberapa pentingnya suatu kata dalam sekumpulan dokumen, sehingga memberikan dukungan kepada model pembelajaran mesin (*machine learning*) dalam mengidentifikasi pola distribusi kata yang berhubungan dengan polaritas sentimen [13]. Representasi fitur yang sesuai dapat meningkatkan kemampuan model untuk mengklasifikasikan pandangan pengguna dengan lebih tepat.

Berdasarkan uraian penelitian terdahulu tersebut, dapat diidentifikasi bahwa masih terdapat celah penelitian pada aspek perbandingan metode klasifikasi sentimen, khususnya antara SVM dan *Naïve Bayes* pada *dataset* ulasan *e-commerce* dengan skema pengolahan data yang seragam. Sebagian penelitian terdahulu lebih banyak berfokus pada penerapan salah satu algoritma secara terpisah, menggunakan domain data yang berbeda, atau belum menguji kedua metode tersebut dalam kerangka evaluasi yang konsisten. Atas dasar penelitian terdahulu, maka penelitian ini fokus mengkaji perbandingan langsung performa SVM dan *Naïve Bayes* untuk klasifikasi sentimen pada ulasan di *e-commerce* menggunakan tahapan preprocessing, representasi fitur TF-IDF, dan evaluasi *5-fold cross validation* yang sama. Penelitian ini juga memberikan kontribusi empiris dengan menunjukkan metode yang lebih baik untuk menganalisis opini atau pendapat pelanggan di platform *e-commerce*, sehingga dapat dijadikan acuan untuk pengembangan sistem analisis sentimen selanjutnya. Mengacu pada penjelasan tersebut, tujuan penelitian ini yaitu untuk melakukan perbandingan kinerja kedua algoritma dalam mengklasifikasikan sentimen pada ulasan di *e-commerce*. *Dataset* yang digunakan meliputi 11.606 ulasan pelanggan yang berasal dari repositori *dataset* publik. Proses klasifikasi dilakukan menggunakan representasi fitur TF-IDF dengan evaluasi model dengan metode *5-fold cross validation*. Penelitian ini juga menggunakan *paired t-test* untuk menguji signifikansi perbedaan performa antara kedua algoritma. Hasil penelitian ini diharapkan mampu memberikan penjelasan terkait metode klasifikasi yang lebih efisien untuk analisis ulasan pada sentimen *e-commerce*.

2. METODE PENELITIAN

Fokus dari penelitian ini, yaitu evaluasi dan perbandingan kinerja dari dua algoritma klasifikasi *machine learning*, yaitu *Naïve Bayes* dan *Support Vector Machine* (SVM) untuk mengklasifikasikan sentimen ulasan dari pelanggan di platform *e-commerce*. Proses penelitian dilaksanakan melalui beberapa

tahap utama yang mencakup persiapan *dataset*, pemrosesan teks, penyusunan representasi fitur memakai TF-IDF, dan pelatihan model klasifikasi, serta penilaian kinerja model. Alur metodologi studi ini ditampilkan pada Gambar 1.



Gambar 1. *Research Methodology*

2.1. Dataset

Dataset adalah sekumpulan ulasan pelanggan di platform *e-commerce* yang diambil dari repositori *dataset* yang tersedia untuk umum. *Dataset* tersebut memuat 11.606 ulasan pelanggan yang telah diberi label sentimen yang merepresentasikan opini pengguna terhadap produk atau layanan yang dibeli secara daring. Setiap entri data terdiri dari teks ulasan pelanggan yang digunakan sebagai sumber informasi pada proses klasifikasi sentimen. Tabel sentimen dalam *dataset* ini meliputi dua kategori, yaitu kategori positif dan kategori negatif. Penelitian ini memakai pendekatan klasifikasi sentimen biner, di mana setiap ulasan dikelompokkan menjadi sentimen positif atau negatif. Data yang ada selanjutnya dipakai sebagai data pelatihan dan data pengujian dalam proses pengembangan model klasifikasi. Agar dapat menghasilkan evaluasi model yang lebih objektif serta mengurangi potensi bias pada proses pembagian data digunakan metode *5-fold cross-validation*, di mana *dataset* dibagi menjadi 5 subset yang berukuran relatif sama. Pada masing-masing iterasi, 4 (empat) subset dimanfaatkan sebagai data pelatihan dan 1 subset sebagai data pengujian. Tabel 1 menyajikan beberapa contoh ulasan pelanggan *e-commerce*. Setiap data mencakup teks ulasan dan label sentimen yang mengindikasikan arah opini pengguna terhadap produk atau layanan.

Tabel 1. *Sample of E-commerce Review Dataset*

No	Review Text	Sentiment
1	Barang bagus dan pengiriman cepat	Positive
2	Produk sesuai dengan deskripsi dan kualitas memuaskan	Positive
3	Kualitas produk kurang baik dan tidak sesuai ekspektasi	Negative
4	Pengiriman sangat lambat dan kemasan rusak	Negative
5	Harga cukup terjangkau dan produk berfungsi dengan baik	Positive
6	Barang tidak sesuai gambar yang ditampilkan	Negative
7	Pelayanan penjual sangat responsif	Positive
8	Produk rusak saat diterima	Negative
9	Kualitas bagus dan packaging rapi	Positive
10	Pengiriman lama dan pelayanan kurang memuaskan	Negative

2.2. Text Preprocessing

Pada proses ini, data ulasan menjalani tahap preprocessing teks guna meningkatkan kualitas data serta mengurangi elemen-elemen yang dapat mengganggu proses pembelajaran model [14]. Tahap ini penting karena data ulasan yang diperoleh dari platform *e-commerce* umumnya masih mengandung variasi penulisan, istilah tidak standar atau tidak baku, serta elemen linguistik yang tidak sepenuhnya berkaitan dengan analisis sentimen. Proses preprocessing dimulai dari *case folding*, yakni mengubah semua karakter huruf pada teks ke dalam bentuk huruf kecil. Proses ini dilakukan guna menyeragamkan penulisan kata agar perbedaan penggunaan huruf kapital tidak menyebabkan kata yang bermakna sama dikenali sebagai token yang berbeda. Setelah itu, diterapkan *tokenization*, yakni proses memisahkan kalimat ulasan ke dalam unit-unit kata sebagai dasar analisis. Pada tahap ini, setiap ulasan yang awalnya berbentuk rangkaian kalimat diubah menjadi kumpulan token, sehingga teks dapat diproses lebih lanjut oleh algoritma klasifikasi. *Tokenization* berperan penting dalam mengidentifikasi kata-kata yang membentuk opini pengguna, karena model klasifikasi bekerja berdasarkan distribusi kata yang muncul pada dokumen [15]. Tahapan selanjutnya berupa penghapusan kata tidak bermakna, yaitu menyingkirkan atau menghilangkan kata-kata umum dengan frekuensi kemunculan tinggi tetapi mempunyai kontribusi yang rendah terhadap informasi sentimen. Misalnya kata depan, kata hubung, atau kata pelengkap yang seringkali muncul dalam teks, namun tidak mempunyai bobot yang signifikan dalam membedakan sentimen positif dan negatif [16]. Dengan menghilangkan kata-kata tersebut, representasi teks menjadi lebih fokus pada kata-kata yang lebih informatif.

Tahap selanjutnya adalah melakukan *stemming*, yakni proses mengembalikan kata ke bentuk dasarnya melalui penghilangan imbuhan kata. Proses ini dilakukan untuk meminimalkan variasi morfologis dari kata-

kata yang pada dasarnya mempunyai makna sejenis. Contohnya dari berbagai bentuk kata turunan dapat dikembalikan ke satu bentuk dasar sehingga jumlah fitur yang dihasilkan lebih ringkas dan konsisten. Oleh karena itu, *stemming* membantu model dalam mengenali pola kata yang serupa meskipun muncul dalam bentuk yang berbeda [17]. Secara umum, proses *preprocessing* dilaksanakan untuk menghasilkan data teks yang lebih teratur, lebih konsisten, dan lebih berkaitan dengan proses ekstraksi fitur. Melalui tahap ini, diharapkan representasi ulasan pelanggan menjadi lebih baik agar model klasifikasi dapat memahami pola sentimen dengan lebih efisien.

2.3. Representasi Fitur Menggunakan TF-IDF

Setelah proses *preprocessing* diselesaikan, teks ulasan yang sudah dibersihkan selanjutnya ditransformasikan ke dalam representasi numerik supaya bisa digunakan sebagai masukan untuk algoritma *machine learning*. Dalam hal ini, representasi fitur teks dibentuk dengan menerapkan metode *Term Frequency-Inverse Document Frequency* (TF-IDF) [18]. Metode ini merupakan salah satu teknik pembobotan kata yang sering kali diimplementasikan di dalam analisis teks, karena dapat menunjukkan tingkat kepentingan suatu kata dalam dokumen dibandingkan dengan kumpulan dokumen keseluruhan dalam *dataset* [19]. Metode ini terdiri dari dua bagian utama: TF, atau frekuensi istilah, dan IDF, atau frekuensi dokumen terbalik. Frekuensi istilah mengungkapkan seberapa sering sebuah kata muncul di semua dokumen. Keterkaitan sebuah kata dengan isi dokumen diperkuat seiring dengan meningkatnya frekuensi kemunculannya. Signifikansi kata tidak dapat ditentukan hanya dengan melihat seberapa sering sebuah kata muncul; lagipula, istilah-istilah tertentu dapat muncul di hampir setiap halaman. Masalah ini diatasi dengan menggunakan komponen frekuensi dokumen terbalik, yang berupaya mengurangi signifikansi istilah-istilah yang berulang di beberapa teks [20]. Kemudian, kata yang relatif jarang muncul pada keseluruhan kumpulan dokumen akan diberikan bobot yang lebih tinggi karena dinilai lebih representatif dalam membedakan isi antara satu dokumen dengan dokumen lainnya. Nilai bobot TF-IDF suatu kata pada dokumen secara matematis dirumuskan dalam Persamaan (1).

$$TFIDF(t, d) = TF(t, d) \times IDF(t) \quad (1)$$

dengan $TF(t, d)$ merepresentasikan frekuensi kemunculan dari kata t pada dokumen d , sementara nilai dari $IDF(t)$ ditentukan menggunakan Persamaan (2).

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

Pada Persamaan (2), N menunjukkan total dokumen pada *dataset*, sementara $df(t)$ mencerminkan jumlah dokumen yang memuat kata t . Berdasarkan mekanisme pembobotan tersebut, kata yang memiliki frekuensi tinggi pada dokumen tertentu namun jarang muncul pada dokumen lainnya akan diberikan bobot yang lebih besar [21]. Perhitungan TF-IDF menghasilkan representasi vektor fitur yang mencerminkan sebaran kata pada masing-masing dokumen ulasan. Selanjutnya, representasi ini digunakan sebagai input pada tahap pelatihan model klasifikasi berbasis algoritma *Naïve Bayes* dan SVM.

2.4. Naïve Bayes Classification

Teorema Bayes adalah dasar dari *Naïve Bayes*, sebuah pendekatan klasifikasi yang bergantung pada probabilitas. Berdasarkan distribusi karakteristik dokumen, algoritma ini menghitung kemungkinan dokumen tersebut berada dalam kelas tertentu [22]. Dalam konteks klasifikasi teks, fitur yang digunakan diperoleh dari bobot kata hasil representasi TF-IDF. Metode *Naïve Bayes* bertumpu pada asumsi bahwa masing-masing fitur saling independen. Meskipun asumsi independensi tersebut jarang sepenuhnya terpenuhi pada data nyata, pendekatan tersebut sering memberikan performa yang cukup baik untuk mengatasi permasalahan yang menyangkut klasifikasi teks karena mampu menyederhanakan proses perhitungan probabilitas [23]. Secara matematis, probabilitas suatu dokumen d termasuk ke dalam kelas c dihitung menggunakan Teorema Bayes yang dinyatakan dalam Persamaan (3).

$$P(c|d) = \frac{P(d|c)P(c)}{P(d)} \quad (3)$$

Pada Persamaan (3), $P(c|d)$ merepresentasikan probabilitas posterior bahwa dokumen d termasuk dalam kelas c , $P(d|c)$ menampilkan kemungkinan kemunculan dokumen d dengan asumsi bahwa kelas c diketahui memuatnya, di mana $P(c)$ adalah probabilitas awal dari $P(d)$ merepresentasikan probabilitas kemunculan dokumen secara keseluruhan. Dalam proses klasifikasi, model akan menghitung probabilitas posterior untuk setiap kelas sesuai fitur yang terdapat pada dokumen [24]. Dokumen kemudian diklasifikasikan ke dalam kelas yang memiliki nilai probabilitas terbesar. Pendekatan ini memungkinkan

model untuk menentukan polaritas sentimen suatu ulasan berdasarkan distribusi kata yang muncul pada dokumen tersebut. Keunggulan utama dari *Naïve Bayes*, salah satunya adalah kesederhanaan model serta efisiensi komputasi yang tinggi. Metode ini juga dipandang mampu bekerja secara baik pada *dataset* teks yang mempunyai jumlah fitur yang besar, seperti representasi dokumen berbasis TF-IDF.

2.5. Support Vector Machine

Support Vector Machine (SVM) sebagai metode klasifikasi pembandingan yang juga merupakan algoritma yang dirancang untuk membentuk batas keputusan optimal dengan membagi data ke dalam kelas yang berbeda. Fungsinya untuk membangun batas keputusan atau *hyperplane* yang memisahkan data menjadi 2 (dua) kelas yang berbeda. Tujuannya untuk menemukan *hyperplane* yang dapat memaksimalkan jarak atau margin antara kedua kelompok data, sehingga proses pemisahan kelas menjadi lebih efisien. Dalam ruang fitur berdimensi tinggi seperti pada data teks, SVM memiliki kemampuan yang baik untuk membedakan pola data [25]. Hal ini karena algoritma SVM bergantung pada sejumlah titik data tertentu yang disebut *support vectors*, yaitu titik data yang paling dekat dengan batas keputusan. *Support vectors* berperan sangat penting dalam menentukan letak *hyperplane* sebagai batas pemisah antar kelas data [26]. Secara matematis, fungsi keputusan dalam SVM dapat dinyatakan sebagaimana tercantum dalam Persamaan (4).

$$f(x) = w \cdot x + b \quad (4)$$

Persamaan (4) mengambil vektor fitur data masukan x , orientasi *hyperplane* yang ditentukan oleh vektor bobot w , dan lokasi *hyperplane* di ruang fitur yang digeser oleh bias b . Berdasarkan fungsi keputusan tersebut, data akan diklasifikasikan ke dalam kelas tertentu sesuai dengan posisi relatifnya terhadap *hyperplane* yang terbentuk [27]. Penggunaan SVM dalam klasifikasi teks sering memberikan performa yang baik, sebab algoritma ini memiliki kemampuan menangani data dengan jumlah fitur yang besar serta memiliki kemampuan generalisasi yang kuat. Dengan memanfaatkan representasi fitur yang dihasilkan oleh TF-IDF, SVM dapat mempelajari pola distribusi kata yang berkaitan dengan polaritas sentimen sehingga mampu mengklasifikasikan ulasan pelanggan secara lebih akurat.

2.6. Model Evaluation

Untuk menilai kinerja model klasifikasi dipakai metode *5-fold cross validation*. Dalam metode ini, *dataset* dibagi menjadi 5 (lima) subset berdasarkan ukuran yang relatif sama. Proses pelatihan maupun pengujian dijalankan bergantian untuk setiap subset, sehingga setiap bagian data mempunyai peluang yang sama untuk digunakan sebagai data pelatihan ataupun data pengujian [28]. Pendekatan ini digunakan guna memperoleh estimasi kinerja model yang lebih stabil serta untuk mengurangi kemungkinan bias yang disebabkan oleh pembagian data [29]. Selanjutnya, ukuran akurasi, presisi, *recall*, dan *F1-score* yang sering digunakan dalam masalah klasifikasi digunakan untuk menilai kinerja model. Metrik akurasi digunakan untuk memastikan rasio prediksi akurat terhadap seluruh data uji. Untuk menentukan presisi secara matematis, seseorang dapat menggunakan rumus (5).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

Sehubungan dengan Persamaan (5), variabel TP (*True Positive*) dan TN (*True Negative*) mewakili data positif dan negatif yang diprediksi benar. Di sisi lain, FP (*False Positive*) dan FN (*False Negative*) menampakkan jumlah data negatif dan positif yang diprediksi secara salah [30]. Untuk mengevaluasi kinerja model dalam memprediksi kelas positif, penelitian ini menggunakan metrik akurasi dan presisi. Dengan menggunakan rumus pada Persamaan (6), kita dapat memperoleh nilai presisi.

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

Metrik berikutnya adalah *recall*, yaitu mengukur kemampuan model mengidentifikasi keseluruhan data yang termasuk kelas positif. Nilai *recall* dihitung berdasarkan rumus Persamaan (7).

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

Untuk memberikan penilaian yang lebih adil antara ketepatan dan pengingat, digunakan metrik *F1-score* yaitu rata-rata harmonis dari kedua metrik itu. Nilai *F1-score* dirumuskan pada Persamaan (8).

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (8)$$

Penggunaan berbagai metrik evaluasi di atas memungkinkan performa model klasifikasi dianalisis secara menyeluruh dan komprehensif. Akurasi menyajikan pandangan umum tentang seberapa tepat prediksi yang dihasilkan oleh model, sementara presisi dan *recall* menyajikan data yang lebih rinci tentang kemampuan model dalam mendeteksi kelas positif secara akurat [31]. Sementara itu, *F1-score* menyajikan ukuran evaluasi yang lebih seimbang dengan mempertimbangkan kedua metrik tersebut secara bersamaan [32]. Dengan memanfaatkan serangkaian metrik penilaian ini, penelitian ini bisa memberikan pemahaman secara mendalam mengenai kinerja algoritma *Naïve Bayes* dan *SVM* di dalam mengklasifikasikan sentimen pada ulasan *e-commerce*.

3. HASIL DAN DISKUSI

Temuan dari penelitian yang mengklasifikasikan ulasan menggunakan algoritma *Naive Bayes* dan *Support Vector Machine* dengan menggunakan validasi silang 5-fold. Selain itu, beberapa ukuran penilaian, termasuk akurasi, presisi, *recall*, dan skor F1, digunakan untuk menganalisis eksperimen. juga menggunakan matriks kebingungan untuk analisis ini.

3.1. Dataset Distribution

Sebelum proses klasifikasi dilakukan, analisis awal terhadap *dataset* dilakukan untuk mengetahui distribusi data berdasarkan label sentimen. *Dataset* yang dipakai dalam penelitian ini mencakup 11.606 ulasan pelanggan yang telah diklasifikasikan sesuai label sentimen positif dan negatif. Sebaran data masing-masing label sentimen dijelaskan pada Tabel 2.

Tabel 2. *Dataset Distribution*

<i>Sentiment</i>	<i>Number of Reviews</i>
<i>Positive</i>	5803
<i>Negative</i>	5803
<i>Total</i>	11606

Berdasarkan Tabel 2, *dataset* memiliki proporsi yang seimbang pada kategori positif dan negatif. Keseimbangan dalam distribusi data dapat mendukung model klasifikasi untuk memahami pola data dengan lebih efektif serta meminimalkan kemungkinan adanya bias terhadap salah satu kelas sentimen.

3.2. Cross Validation Results

Evaluasi dari model dilaksanakan dengan pendekatan *5-fold cross validation* untuk mendapatkan estimasi kinerja yang lebih konsisten. Dalam setiap *fold*, model dilatih dengan sekelompok data dan diuji pada subset data yang lain. Nilai akurasi di setiap *fold* terlihat pada Tabel 3.

Tabel 3. *Cross Validation Accuracy*

<i>Fold</i>	<i>Naïve Bayes</i>	<i>SVM</i>
1	0.846	0.867
2	0.852	0.872
3	0.859	0.875
4	0.861	0.873
5	0.860	0.871
Average	0.8555	0.8717

Mengacu pada Tabel 3, algoritma *SVM* memperlihatkan lebih unggul jika daripada *Naïve Bayes* pada seluruh fold pengujian. Rata-rata *accuracy* yang dicapai oleh *SVM* sebesar 0.8717, sedangkan *Naïve Bayes* memperoleh nilai *accuracy* sebesar 0.8555.


3.3. Performance Comparison

Di samping *accuracy*, kinerja model juga dianalisis memakai metrik *precision*, *recall*, dan *F1-score* untuk memperoleh gambaran secara menyeluruh terkait kemampuan model dalam mengklasifikasikan sentimen.

Tabel 4. *Performance Comparison of Classification Models*

<i>Model</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
<i>Naïve Bayes</i>	0.8555	0.8677	0.8389	0.8531
<i>SVM</i>	0.8717	0.8670	0.8782	0.8725

Merujuk pada Tabel 4, SVM memperlihatkan performa atau hasil yang unggul atau lebih baik, jika dibandingkan dengan *Naïve Bayes* pada sebagian besar metrik evaluasi. Perbandingan performa kedua algoritma juga dapat diamati melalui nilai *accuracy* yang dihasilkan oleh masing-masing model.



Gambar 2. Accuracy Comparison of Naïve Bayes and SVM

Keunggulan tersebut terutama tampak pada nilai *accuracy* yang divisualisasikan pada Gambar 2. Berdasarkan visualisasi tersebut, SVM memperoleh nilai *accuracy* lebih tinggi dibandingkan *Naïve Bayes*. Hal ini menunjukkan metode berbasis margin yang diterapkan oleh SVM dapat membedakan kelas sentimen dengan lebih efektif dalam ruang fitur berdimensi tinggi yang dihasilkan oleh representasi TF-IDF.

3.4. Confusion Matrix Analysis

Untuk studi ini, peneliti memanfaatkan matriks kebingungan (*confusion matrix*) untuk mencari tren dalam kesalahan klasifikasi model. Matriks kebingungan menunjukkan berapa kali setiap kelas sentimen benar atau salah, yang berguna untuk mengukur kinerja model dalam membedakan antara evaluasi yang baik dan buruk. Tabel 5 mengindikasikan bahwa mayoritas data dapat diklasifikasikan dengan benar oleh model *Naïve Bayes*. Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi pada kedua kelas sentimen. Kesalahan tersebut disebabkan oleh kata atau frasa dalam ulasan yang memiliki makna sentimen yang ambigu sehingga menyulitkan model dalam melakukan klasifikasi.

Tabel 5. Confusion Matrix of Naïve Bayes

	Predicted Positive	Predicted Negative
Actual Positive	4978	825
Actual Negative	853	4950


Confusion matrix untuk algoritma SVM ditunjukkan oleh Tabel 6 untuk menggambarkan performa model di dalam mengklasifikasikan ulasan positif dan negatif.

Tabel 5. Confusion Matrix of SVM

	Predicted Positive	Predicted Negative
Actual Positive	5090	713
Actual Negative	778	5025

Untuk menunjukkan gambaran yang lebih jelas mengenai penyebaran prediksi model, *confusion matrix* dari algoritma SVM ditampilkan dalam bentuk *heatmap* yang terlihat pada Gambar 3.

Berlandaskan visualisasi pada Gambar 3, sebagian besar data telah berhasil diklasifikasikan secara tepat oleh model *Support Vector Machine (SVM)*. Area dengan tigtat warna yang lebih tinggi mengindikasikan jumlah prediksi yang lebih besar pada kategori tersebut. Terlihat bahwa jumlah prediksi yang benar pada kelas positif dan negatif cukup dominan jika dibandingkan dengan kesalahan klasifikasi. Hal ini memperlihatkan model SVM mampu mempelajari pola distribusi kata pada *dataset* ulasan dengan cukup baik, sehingga menghasilkan performa klasifikasi yang lebih akurat. Temuan visual tersebut selaras dengan hasil evaluasi kuantitatif yang telah diperoleh sebelumnya, sehingga perlu dibahas lebih dalam terkait faktor-faktor yang menyebabkan kinerja SVM unggul daripada *Naïve Bayes*, keterkaitannya dengan penelitian terdahulu, serta implikasi dari hasil penelitian ini.



Gambar 3. Confusion Matrix of Support Vector Machine

Hasil analisis menemukan *Support Vector Machine* mempunyai performa lebih baik daripada *Naïve Bayes*, dengan nilai *accuracy* sebesar 0,8717 berbanding 0,8555 serta *F1-score* sebesar 0,8725 dibandingkan 0,8531. Temuan ini menunjukkan SVM lebih efektif dalam membangun batas keputusan yang optimal pada representasi fitur TF-IDF yang memiliki dimensi tinggi [33]. Dalam teks yang dianalisis, setiap dokumen digambarkan sebagai vektor jarang dengan banyak fitur [34]. Kondisi tersebut menjadikan algoritma berbasis margin seperti SVM lebih mampu memisahkan kelas positif dan negatif secara tegas [35]. Sebaliknya, *Naïve Bayes* didasarkan pada asumsi bahwa setiap fitur saling independen namun dalam teks ulasan, banyak kata saling terkait baik secara semantik maupun kontekstual, sehingga asumsi ini tidak selalu terpenuhi dengan sempurna [36].

Keunggulan SVM pada studi ini senada dengan studi terdahulu yang mendapati model konvensional berbasis vektor, khususnya SVM, sering kali menghasilkan performa yang baik dalam klasifikasi emosi dan pengelompokan teks, terutama saat digabungkan dengan TF-IDF [37]. Di sisi lain, kajian lain di bidang *e-commerce* menunjukkan bahwa *Naïve Bayes* tetap memiliki relevansi karena sifatnya yang sederhana, efisien, dan mampu bersaing dalam situasi tertentu, terutama ketika struktur data relatif lebih simpel atau tuntutan komputasi menjadi hal yang sangat dipertimbangkan [38]. Namun hasil dari penelitian ini tidak menyatakan bahwa *Naïve Bayes* selalu kurang baik, melainkan menunjukkan bahwa dalam kumpulan data ulasan *e-commerce* yang dianalisis, SVM menunjukkan kemampuan generalisasi yang lebih unggul.

Berdasarkan analisis confusion matrix, algoritma SVM menunjukkan jumlah kesalahan klasifikasi lebih rendah daripada *Naïve Bayes*, baik untuk kelas positif maupun negatif. Temuan ini menunjukkan SVM lebih baik dalam metrik keseluruhan dan lebih konsisten dalam membedakan sentiment positif dan negatif [39]. Walaupun demikian, masih ada kesalahan dalam prediksi dari kedua model, yang menunjukkan adanya ulasan dengan ambiguitas dalam penggunaan kata, pandangan yang campur aduk, atau ungkapan sentimen yang tidak langsung yang sulit diidentifikasi hanya dengan fitur TF-IDF. Temuan ini memiliki implikasi praktis yang menunjukkan bahwa SVM dapat menjadi pilihan yang baik sebagai model dasar untuk sistem pemantauan opini pelanggan di platform *e-commerce*. Namun, penelitian ini tetap memiliki batasan karena hanya melakukan perbandingan antara dua algoritma klasik, menerapkan representasi fitur tunggal, serta belum menyelidiki aspek seperti pemilihan fitur, penyetelan hyperparameter yang lebih mendalam, atau perbandingan dengan model-model pembelajaran dalam atau transformer. Oleh karena itu, penelitian di masa mendatang sebaiknya difokuskan pada pengoptimalan parameter, penggunaan pengembedding kata atau pengembedding kontekstual, serta pengujian pada *dataset* multi-domain agar evaluasi generalisasi model menjadi lebih menyeluruh.

4. KESIMPULAN

Penelitian ini membandingkan *Naive Bayes* dengan *Support Vector Machine* (SVM). Pelatihan model klasifikasi dengan salah satu pendekatan tersebut merupakan bagian dari prosedur penelitian, begitu pula persiapan teks dan pembuatan representasi fitur dengan TF-IDF. Evaluasi terhadap model menggunakan metode *5-fold cross-validation* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Berdasarkan hasil penelitian, algoritma SVM berkinerja lebih baik jika dibandingkan *Naïve Bayes*. SVM mencapai *accuracy* 0.8717, sementara *Naïve Bayes* mencapai 0.8555. Analisis *confusion matrix* juga memperlihatkan bahwa SVM menghasilkan lebih sedikit kesalahan klasifikasi dibanding *Naïve Bayes*. Temuan ini menunjukkan bahwa SVM lebih efektif dalam memanfaatkan representasi fitur TF-IDF untuk klasifikasi sentimen pada *dataset* ulasan *e-commerce*. Pada penelitian selanjutnya, pengembangan metode dapat dilakukan dengan

menggunakan *dataset* yang lebih besar, eksplorasi teknik *preprocessing* tambahan, maupun penerapan algoritma klasifikasi lainnya untuk meningkatkan performa model.

REFERENSI

- [1] K. Kowsari, K. J. Meimandi, M. Heidarysafa, S. Mendu, L. Barnes and D. Brown, "Text Classification Algorithms: A Survey," *Information*, vol. 10, no. 4, pp. 1-68, 2019, doi: 10.3390/info10040150
- [2] S. Minaee, N. Kalchbrenner, E. Cambria, N. Nikzad, M. Chaenaghlu and J. Gao, "Deep Learning--based Text Classification: A Comprehensive Review," *ACM Computing Surveys*, vol. 54, no. 3, pp. 1-40, 2021, doi: 10.1145/3439726
- [3] N. C. Dang, M. N. Moreno-Garcia and F. D. I. Prieta, "Sentiment Analysis Based on Deep Learning: A Comparative Study," *Electronics*, vol. 9, no. 3, pp. 1-29, 2020, doi : 10.3390/electronics9030483.
- [4] D. Nurmadewi, Z. F. Jailani and N. K. S. Manik, "Comparison of the Performance of the VADER and RoBERTa Algorithms on Twitter," *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 4, pp. 1547-1557, 2024, doi: 10.32520/stmsi.v13i4.4198
- [5] D. Nurmadewi, C. P. Gusti, E. C. Hernanto, F. Ananda, M. A. Hutagalung and N. Hikmah, "Analisis Sentimen untuk Melihat Respon Masyarakat Terhadap Vaksin Pfizer," *Journal of Technology and Informatics (JoTI)*, vol. 4, no. 2, pp. 77-80, 2023, doi: 10.37802/joti.v4i2.322
- [6] R. Illahi , S. Agustian and F. Yanto, "Klasifikasi Sentimen Menggunakan Bidirectional LSTM dan INDOBERT dengan *Dataset* Terbatas," *ZONasi : Jurnal Sistem Informasi*, vol. 7, no. 1, pp. 74-84, 2025, doi: 10.31849/zn.v7i1.25091.
- [7] H. Abijono, P. Puput and N. L. Anggreini, "Supervised Learning and Unsupervised Learning Algorithm in Data Processing," *G-Tech: Jurnal Teknologi Terapan*, vol. 4, no. 2, pp. 315-318, 2021, doi: 10.33379/gtech.v4i2.635
- [8] D. Nurmadewi, S. Yuniati, M. Amaliah, H. Hanifah, U. B. Purwanti, M. S. Arum and N. W. Kusuma, "Sentiment Analysis of Jokowi's Candidate Discourse in Three Periods using the *Naïve Bayes* Method," *Sistemasi: Jurnal Sistem Informasi*, vol. 12, no. 1, pp. 166-177, 2023, doi: 10.32520/stmsi.v12i1.2413
- [9] E. I. Saputra, M. K. Anam, H. Hamdani and A. Zamsuri, "Optimalisasi Algoritma *Support Vector Machine* pada Aspect-Based Sentiment Analysis Menggunakan Gridsearchcv," *ZONasi: Jurnal Sistem Informasi*, vol. 7, no. 1, pp. 271-279, 2025, doi: 10.31849/zn.v7i1.17800.
- [10] G. P. Permana, D. A. Nugraha and H. Santoso, "Perbandingan Performa SVM dan *Naïve Bayes* Pada Analisis Sentimen Aplikasi Game Online," *JOINTECS (Journal of Information Technology and Computer Science)*, vol. 9, no. 1, pp. 21-30, 2024, doi: 10.31328/jointecs.v8i1.4854
- [11] T. T. Khoei, S. Ismail, K. A. Shamaileh, V. K. Devabhaktuni and N. Kaabouch, "Pengaruh Parameter *Dataset* dan Model terhadap Kinerja Pembelajaran Mesin untuk Deteksi Serangan Pemalsuan GPS pada Pesawat Tanpa Awak," *Ilmu Terapan*, vol. 13, no. 1, pp. 1-15, 2023, doi: 10.3390/app13010383.
- [12] N. Mirantika, R. Trisudarmo and T. S. Syamfithriani, "Implementation of *Naïve Bayes* Algorithm for Early Detection of Stunting Risk," *Journal of Applied Informatics and Computing*, vol. 9, no. 2, pp. 356-363, 2025, doi: 10.30871/jaic.v9i2.9144.
- [13] D. S. A. Rizki, M. S. Khabib, N. Rahmayuna and V. G. Utomo, "Klasifikasi Sentimen Ulasan Pengguna Aplikasi Layanan Publik Google Play Store Menggunakan NLP dan ML," *Jurnal Tekno Kompak*, vol. 20, no. 1, pp. 51-64, 2025, doi: 10.33365/jtk.v20i1.586.
- [14] S. Khairunnisa, A. Adiwijaya and S. A. Faraby, "Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19)," *Jurnal Media Informatika Budidarma*, vol. 5, no. 2, pp. 406-414, 2021, doi: 10.30865/mib.v5i2.2835.
- [15] A. E. Budiman and A. Widjaja, "Analisis Pengaruh Teks Preprocessing Terhadap Deteksi Plagiarisme Pada Dokumen Tugas Akhir," *Jutisi : Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 3, pp. 475-488, 2020, doi: 10.28932/jutisi.v6i3.2892.
- [16] R. Rinandyaswara, Y. A. Sari and M. T. Furqon, "Pembentukan Daftar *Stopword* Menggunakan Term Based Random Sampling Pada Analisis Sentimen Dengan Metode *Naïve Bayes* (Studi Kasus: Kuliah Daring Di Masa Pandemi)," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 9, no. 4, pp. 717-724, 2022, doi: 10.25126/jtiik.2022934707.
- [17] M. U. Albab, Y. K. P. and M. N. Fawaiq, "Optimization of the *Stemming* Technique on Text Preprocessing President 3 Periods Topic," *Jurnal Transformatika*, vol. 20, no. 2, pp. 1-10, 2023, doi: 10.26623/transformatika.v20i2.5374.
- [18] V. M. Hersianty, E. L. Amalia, D. Puspitasari and D. W. Wibowo, "Penerapan Algoritma TF-IDF dan Cosine Similarity dalam Sistem Rekomendasi Lowongan Pekerjaan," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 1619-1625, 2025, doi: 10.36040/jati.v9i1.12406.

- [19] M. S. Maulana, Y. Anshori, R. Azhar, R. Laila and N. T. Lapatta, "Implementasi Pembobotan TF-IDF pada Chatbot Telegram untuk Sistem Layanan Informasi," *JIPI : Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*, vol. 10, no. 3, pp. 1869-1877, 2025, doi: 10.29100/jipi.v10i3.6314.
- [20] M. P. Syah, A. P. Wardani, M. Idhom and T. Trimono, "Perbandingan Representasi Teks Tf-Idf Dan Bert Terhadap Akurasi Cosine Similarity Dalam Penilaian Otomatis Jawaban Berbasis Teks," *Jurnal Data Science Indonesia*, vol. 5, no. 1, pp. 47-59, 2025, doi: 10.47709/dsi.v5i1.6021.
- [21] K. Huda, S. D. Pohan and Y. Herlina, "Penerapan Pembobotan Term Frequency-Invers Document Frequency dan Algoritma K-Nearest Neighbor untuk Analisis Ulasan Hotel di Situs Tripadvisor," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 2536-2546, 2024, doi: 10.23960/jitet.v12i3.4800.
- [22] D. E. R. Purba, "Analisa Data Mining Dengan *Naïve Bayes* Untuk Klasifikasi Kelayakan Penerima Bantuan Iuran Jaminan Kesehatan Pada Desa Durian," *Jurnal Multimedia Dan Teknologi Informasi (Jatilima)*, vol. 7, no. 2, pp. 11-23, 2025, doi: 10.54209/jatilima.v7i02.1279.
- [23] C. W. Nugroho, S. Tamriesfatno and S. Sulkifli, "Implementasi Algoritma *Naive Bayes* untuk Sistem Pendukung Keputusan Penerima Bantuan Pendidikan," *Jurnal Publikasi Ilmu Komputer Dan Multimedia*, vol. 4, no. 1, pp. 1-10, 2025, doi: 10.55606/jupikom.v4i1.4276.
- [24] R. Rachman and R. N. Handayani, "Klasifikasi Algoritma *Naive Bayes* Dalam Memprediksi Tingkat Kelancaran Pembayaran Sewa Teras UMKM," *Jurnal Informatika*, vol. 8, no. 2, pp. 111-122, 2021, doi: 10.31294/ji.v8i2.10494, doi: 10.31294/ji.v8i2.10494.
- [25] A. W. Nugroho and N. Norhikmah, "Sentiment Analysis using the *Support Vector Machine* Algorithm on Covid_19," *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 4, pp. 1758-1772, 2024, doi: 10.32520/stmsi.v13i4.3778.
- [26] S. Rahayu and Y. Yamasari, "Klasifikasi Penyakit Stroke dengan Metode *Support Vector Machine* (SVM)," *Journal of Informatics and Computer Science (JINACS)*, vol. 5, no. 3, pp. 440-446, 2024, doi: 10.26740/jinacs.v5n03.p440-446.
- [27] F. Putrawansyah and T. Susanti, "Application of the *Support Vector Machine* Method to the Classification of Guava Types," *JIKO (Jurnal Informatika dan Komputer)*, vol. 8, no. 1, pp. 193-204, 2024, doi: 10.26798/jiko.v8i1.988.
- [28] R. N. Irawan, K. M. Hindrayani and M. Idhom, "Penerapan Cross Validation sebagai Analisis Sentimen Pelayanan Publik Kereta Api Lokal Daop 8 Menggunakan Metode Multinomial *Naïve Bayes*," *G-Tech: Jurnal Teknologi Terapan*, vol. 8, no. 2, pp. 954-963, 2024, doi: 10.33379/gtech.v8i2.4117.
- [29] N. Blesyova and F. N. Hasan, "Analisis Snetimen Terhadap Bea Cukai Menggunakan *Support Vector Machine* dan K-Fold Cross Validation," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 6, pp. 12051-12056, 2024, doi: 10.36040/jati.v8i6.11774.
- [30] M. Z. Sarwani, M. Khoiron and M. Udin, "Optimization of the *Naïve Bayes* Classifier Algorithm Using Cost-Sensitive Learning to Detect Lung Diseases with an Imbalanced *Dataset*," *Journal of Artificial Intelligence and Software Engineering*, vol. 5, no. 1, pp. 332-338, 2025, doi: 10.30811/jaise.v5i1.6474.
- [31] W. Auwiyah and G. Erlianti, "*Recall* and *Precision* Temu Kembali Informasi Pada Repository Universitas Negeri Padang," *Innovative: Journal Of Social Science Research*, vol. 5, no. 4, pp. 1796-1804, 2025, doi : 10.31004/innovative.v5i4.20311.
- [32] M. K. Suryadewiansyah and T. E. E. Tju, "*Naïve Bayes* dan Confusion Matrix untuk Efisiensi Analisa Intrusion Detection System Alert," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 8, no. 2, pp. 81-88, 2022, doi: 10.25077/TEKNOSI.v8i2.2022.81-88.
- [33] F. Farahdinna and P. Prabawati, "Perbandingan Algoritma *Support Vector Machine* dan K-Nearest Neighbor terhadap Efektivitas Program Makan Siang Gratis," *Sistemasi: Jurnal Sistem Informasi*, vol. 15, no. 2, pp. 699-709, 2026, doi: 10.36040/jati.v9i4.14084.
- [34] N. Maulana, M. R. Handayani, W. D. Yuniarti and K. Umam, "Penerapan Metode *Support Vector Machine* Dalam Mengklasifikasikan Berita Politik : Fakta Vs Hoaks," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 10, no. 3, pp. 2679-2688, 2025, doi: 10.29100/jipi.v10i3.8077.
- [35] K. H. Hanif, N. R. Muntiri, D. Harto and D. S. Wiranata, "Perbandingan Analisis Sentimen Komentar Mahasiswa Prodi Teknik Komputer Menggunakan Algoritma Decision Tree, *Support Vector Machine* (SVM) dan Random Forest," *Insect (Informatics and Security): Jurnal Teknik Informatika*, vol. 12, no. 1, pp. 24-33, 2026, doi: 10.33506/insect.v12i01.5144.
- [36] N. Aditiya, P. Setiaji and Supriyono, "Analisis Sentimen Kepuasan Masyarakat terhadap Aplikasi "INFO BMKG" menggunakan *Naive Bayes*, SVM, dan KNN," *Sistemasi: Jurnal Sistem Informasi*, vol. 14, no. 3, pp. 1418-1432, 2025.
- [37] N. F. Mahing, A. L. Gunawan, A. F. A. Zen, F. A. Bachtiar and S. A. Wicaksono, "Klasifikasi Tingkat Stress dari Data Berbentuk Teks dengan Menggunakan Algoritma *Support Vector Machine* (SVM)

- dan Random Forest," Jurnal Teknologi Informasi dan Ilmu Komputer, vol. 11, no. 5, pp. 1067-1076, 2024, doi: 10.25126/jtiik.2024118010.
- [38] S. N. Halizah and S. Yunita, "Analisis Sentimen Jasa Pengiriman *E-commerce* Menggunakan *Naïve Bayes*," Riwayat: Educational Journal of History and Humanities, vol. 9, no. 2, pp. 3773-3793, 2026, doi: 10.24815/riwayat.v9i1.786.
- [39] S. A. Salsabila, B. Priyatna, A. Hananto and T. Tukino, "Komparasi Kinerja Model Naive Bayes, SVM, dan BERT dalam Klasifikasi Sentimen Ulasan Pada Aplikasi YUMMY," Storage: Jurnal Ilmiah Teknik dan Ilmu Komputer, vol. 4, no. 2, pp. 42-47, 2025, doi: 10.55123/storage.v4i2.5120.