



The Impact of ChatGPT on Students' Academic Performance Using the Support Vector Machine Algorithm

Pengaruh ChatGPT Terhadap Peforma Akademik Mahasiswa Menggunakan Algoritma Support Vector Machine

Gita Aulia^{1*}, Sriani²

^{1,2}Program Studi Ilmu Komputer, Universitas Islam Negeri Sumatera Utara, Indonesia

E-Mail: ¹gitaaulia030320@gmail.com, ²sriani@uinsu.ac.id

Received Feb 09th 2026; Revised Mar 26th 2026; Accepted Mar 30th 2026; Available Online Apr 20th 2026

Corresponding Author: Gita Aulia

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

Abstract

The development of artificial intelligence technology, particularly ChatGPT, has influenced students' information-seeking and academic assignment completion. This technology provides convenience and efficiency in obtaining information, but also raises concerns about potential dependency that can affect students' academic performance. The purpose of this study is to analyze the effect of ChatGPT use on students' academic performance through sentiment classification. This study used a quantitative approach, using text mining techniques and the Support Vector Machine (SVM) algorithm to classify student opinions into negative and positive sentiments. The research data were obtained online and distributed to students of the Computer Science Study Program at the State Islamic University of North Sumatra, yielding 1,104 comments. The data were processed through several stages: text Preprocessing, TF-IDF weighting, dividing the training and test data, and model evaluation using a confusion matrix. The results showed that the SVM model classified 778 data points as positive sentiment and 326 as negative sentiment, with an accuracy of 79.44%. This finding indicates that most students have a positive perception of ChatGPT as a learning support tool. In addition, the results of this study have important implications for the need to use artificial intelligence technology wisely to support the learning process without reducing students' learning independence.

Keywords: Academic Performance, ChatGPT, Sentiment Analysis, Support Vector Machine, Text Mining

Abstrak

Perkembangan teknologi kecerdasan buatan, khususnya ChatGPT, telah memengaruhi pola pembelajaran mahasiswa dalam mencari informasi dan menyelesaikan tugas akademik. Teknologi ini memberikan kemudahan dan efisiensi dalam memperoleh informasi, namun juga menimbulkan kekhawatiran terhadap potensi ketergantungan yang dapat memengaruhi performa akademik mahasiswa. Tujuan dari studi adalah menganalisis pengaruh penggunaan ChatGPT terhadap performa akademik mahasiswa melalui klasifikasi sentimen. Kuantitatif merupakan pendekatan yang dipakai pada studi ini dengan teknik *text mining* dan algoritma *Support Vector Machine (SVM)* guna mengklasifikasikan pendapat mahasiswa dalam sentimen negatif maupun positif. Data penelitian diperoleh secara daring dan didistribusikan kepada mahasiswa Program Studi Ilmu Komputer Universitas Islam Negeri Sumatera Utara, menghasilkan 1.104 komentar. Data diproses melalui beberapa tahapan, yaitu *text preprocessing*, pembobotan TF-IDF, pembagian data latih dan uji, serta evaluasi model memakai *confusion matrix*. Hasil penelitian menampilkan bahwa model SVM mengklasifikasikan 778 data sebagai sentimen positif dan 326 data sebagai sentimen negatif dengan tingkat akurasi sebesar 79,44%. Temuan ini menunjukkan bahwa mayoritas mahasiswa mempunyai persepsi positif terhadap penggunaan ChatGPT sebagai sarana pendukung pembelajaran. Selain itu, hasil penelitian ini memberikan implikasi penting mengenai perlunya pemanfaatan teknologi kecerdasan buatan secara bijak dalam mendukung proses pembelajaran tanpa mengurangi kemandirian belajar mahasiswa.

Kata Kunci: Analisis Sentimen, ChatGPT, Performa Akademik, Support Vector Machine, Text Mining.

1. PENDAHULUAN

Kemajuan kecerdasan buatan (AI) telah menyebabkan transformasi yang besar di berbagai bidang, khususnya di bidang pendidikan. Teknologi ini memungkinkan manusia memperoleh dan mengolah



informasi secara lebih cepat sehingga dapat meningkatkan efisiensi dalam berbagai aktivitas akademik [1]. Perkembangan teknologi tersebut juga mendorong munculnya berbagai sistem berbasis AI yang dapat membantu manusia dalam menyelesaikan berbagai tugas secara otomatis [2]. Salah satu teknologi yang berkembang pesat yaitu *Generative Pre-trained Transformer (GPT)*, yang merupakan sistem pemrosesan bahasa alami yang dikembangkan oleh OpenAI guna menghasilkan respons berbasis teks secara kontekstual [3]. ChatGPT memanfaatkan pendekatan *deep learning* berbasis transformer sehingga dapat menghasilkan dan memahami teks secara alami dalam berbagai bahasa [4]. Teknologi ini juga dirancang untuk mensimulasikan percakapan dengan pengguna melalui interaksi berbasis teks sehingga dapat dimanfaatkan dalam berbagai bidang, termasuk pendidikan [5].

Dalam konteks pendidikan, pemanfaatan ChatGPT dapat membantu mahasiswa dalam memahami konsep pembelajaran, mencari referensi, serta menyelesaikan tugas akademik dengan lebih efisien [6]. Meskipun demikian, penggunaan teknologi ini juga menimbulkan berbagai pandangan di kalangan mahasiswa. Sebagian mahasiswa memanfaatkan ChatGPT sebagai alat bantu pembelajaran, sedangkan sebagian lainnya berpotensi menggunakannya sebagai solusi instan tanpa memahami materi secara mendalam [7]. Kondisi tersebut menunjukkan adanya potensi dampak positif maupun negatif terhadap pola pembelajaran mahasiswa. Untuk memahami kecenderungan persepsi tersebut, diperlukan suatu pendekatan dalam menganalisis, mengolah data opini secara sistematis. Diantara pendekatan yang banyak digunakan dalam mengkaji opini pengguna adalah analisis sentimen berbasis *text mining* [8]. Teknik ini memungkinkan proses klasifikasi sentimen terhadap data teks sehingga dapat diketahui kecenderungan opini pengguna terhadap suatu topik tertentu [9].

Dalam penelitian ini, analisis sentimen dilakukan menggunakan algoritma *Support Vector Machine (SVM)*. SVM digunakan karena memiliki kemampuan yang baik dalam melakukan klasifikasi data teks yang berdimensi tinggi, seperti data hasil pembobotan TF-IDF, serta mampu membentuk *hyperplane* optimal yang memaksimalkan pemisahan antara kelas sehingga menghasilkan tingkat generalisasi yang baik terhadap data baru. Dibandingkan dengan beberapa algoritma klasifikasi yang lain seperti *Naive Bayes* dan *K-Nearest Neighbor (KNN)*, SVM memiliki keunggulan dalam mengurangi risiko *overfitting* serta mampu menghasilkan akurasi yang lebih stabil pada proses analisis sentimen. Beberapa studi terdahulu juga mengatakan jika performa SVM lebih unggul, misalnya penelitian yang membandingkan SVM dan KNN dalam klasifikasi sentimen ulasan ChatGPT di Google Play Store menampilkan kalau SVM memperoleh akurasi sebesar 80% lebih tinggi dari pada KNN yang cuma sampai 71% [10]. Berlandaskan hal itu, tujuan studi ini untuk menganalisis pengaruh penggunaan ChatGPT terhadap performa akademik mahasiswa melalui klasifikasi sentimen.

2. BAHAN DAN METODE

Metode penelitian yang dimanfaatkan pada studi kali ini merupakan metode klasifikasi teks memakai algoritma SVM. Cara ini digunakan untuk mengklasifikasikan data teks berdasarkan fitur yang diperoleh dari langkah pembobotan kata memakai metode *Term Frequency-Inverse Document Frequency (TF-IDF)*. Secara umum tahapan penelitian meliputi proses pengumpulan *dataset*, *pre-processing*, pelabelan data, pembobotan TF-IDF, klasifikasi menggunakan SVM, serta evaluasi model menggunakan *confusion matrix* [15]. Alur metodologi penelitian dapat dilihat pada Gambar 1.


2.1. Dataset

Tahap awal penelitian yaitu pengumpulan *dataset* yang dipakai untuk bahan analisis. Data diperoleh melalui kuesioner daring yang berisi opini atau komentar mahasiswa mengenai penggunaan ChatGPT dalam kegiatan akademik. *Dataset* yang dipakai pada studi ini berjumlah 1.104 komentar mahasiswa Program Studi Ilmu Komputer Universitas Islam Negeri Sumatera Utara.

Data yang telah diperoleh kemudian dipakai sebagai bahan pokok pada proses analisis sentimen untuk mengetahui kecenderungan pendapat mahasiswa terhadap penggunaan teknologi ChatGPT pada tahapan pembelajaran. Perkembangan kecerdasan buatan seperti ChatGPT sudah membawa perubahan pada dunia pendidikan, terutama dalam membantu mahasiswa memperoleh informasi dan menyelesaikan tugas secara lebih cepat dan efisien [16].

2.2. Pre-processing Data

Tahap berikutnya adalah *pre-processing* atau pra-pemrosesan data teks. Fase ini berfokus pada pengorganisasian dan penyempurnaan data untuk memastikan data tersebut siap diproses oleh algoritma *machine learning*. Proses ini krusial lantaran data teks umumnya masih memiliki berbagai karakter yang tidak diperlukan seperti tanda baca, huruf kapital, maupun kata yang tidak memiliki makna penting dalam analisis [17].



Gambar 1. Tahapan Penelitian

Tahapan *pre-processing* yang dilaksanakan pada studi ini mencakup:

1. *Cleaning*

Cleaning merupakan langkah guna menghapus karakter yang tidak diperlukan, misalnya tanda baca, angka, URL, *mention*, dan tanda simbol. Pada penelitian ini, proses *cleaning* dikerjakan dengan memakai bahasa pemrograman Python dengan menggunakan *library regular expression (re)* guna menghilangkan pola teks spesifik seperti kata berulang, angka, *mention*, *hashtag*, dan URL. Selain itu, *library string* digunakan untuk menghapus tanda baca, sedangkan, *library pandas* digunakan untuk menerapkan fungsi pembersihan teks pada seluruh *dataset* melalui metode *.apply()*.

2. *Case Folding*

Case folding yaitu tahap mengonversi keseluruhan karakter pada teks jadi huruf kecil (*lowercase*) sehingga tidak terdapat kontras antara huruf kapital dengan huruf nonkapital dalam proses analisis [12]. Proses ini dilakukan menggunakan fungsi bawaan Python *.lower()* untuk mengonversi seluruh karakter huruf menjadi huruf nonkapital.

3. *Tokenizing*

Tokenizing yaitu tahapan memecah frasa menjadi potongan-potongan kata atau token sehingga masing-masing kata bisa dianalisis secara terpisah. Dalam studi ini, tokenizing dikerjakan dengan memakai *library Natural Language Toolkit (nltk)* dengan menggunakan fungsi *word_tokenize()* yang berfungsi untuk memisahkan kalimat menjadi kumpulan kata.

4. *Filtering*

Filtering yaitu tahapan guna menghapus istilah-istilah yang tidak mengandung makna krusial. Dalam penelitian ini, tahapan *filtering* dikerjakan dengan memanfaatkan *library Natural Language Toolkit (nltk)* dengan memanfaatkan daftar *stopwords* bahasa Indonesia dari *nltk.corpus.stopwords*.

5. Normalisasi

Normalisasi merupakan proses untuk mengonversi kata tidak standar atau kata gaul (*slang*) menjadi kata formal yang mengikuti aturan bahasa Indonesia. Pada studi ini, tahap normalisasi dilaksanakan menggunakan perbendaharaan kata *slangword* yang disimpan dalam *file Normalisasi.txt* yang berisi pasangan kata tidak baku dan kata bakunya. Proses pencocokan kata dilakukan menggunakan *Regular Expression (re)* pada Python, kemudian kata yang terdeteksi sebagai slang akan berubah menjadi wujud kata formal selaras dengan perbendaharaan kata yang digunakan.

6. *Stopword Removal*

Stopword removal yaitu tahap menghilangkan istilah-istilah biasaya yang kerap hadir namun tidak mengandung arti yang krusial pada kajian sentimen. Penelitian ini menggunakan *library (nltk)* dengan memanfaatkan kumpulan *stopwords* bahasa Indonesia dari *nltk.corpus.stopwords*. selain

menggunakan daftar *stopword* bawaan dari NLTK, penelitian ini juga menambahkan beberapa kata *stopword* secara manual seperti “aja”, “banget”, “nih”, “dong”. Dan kata umum lainnya agar proses penyaringan kata menjadi lebih optimal.

7. Stemming

Stemming adalah tahapan mengonversi istilah berimbuhan jadi bentuk basis akibatnya istilah yang mengandung kemiripan arti bisa diidentifikasi sebagai suatu kata yang sama [18]. Pada dalam studi ini, tahap *stemming* dikerjakan dengan menggunakan *library* Sastrawi yang merupakan pustaka pemrosesan bahasa indonesia pada Python. Proses ini dilakukan dengan memanfaatkan *StemmerFactory* untuk membuat objek *stemmer*, kemudian setiap kata dalam dataset diproses menggunakan fungsi *stem()* untuk mendapatkan bentuk kata dasarnya.

Melalui tahapan ini, informasi berbasis teks yang awalnya masih tidak terorganisir akan berubah menjadi data yang semakin bersih dan siap digunakan dalam proses analisis selanjutnya.

2.3. Pelabelan Data

Usai tahap pengumpulan dan *preprocessing* data selesai dilakukan, tahap berikutnya yaitu pelabelan data. Pelabelan dilakukan secara otomatis menggunakan *TextBlob* untuk memberikan kategori sentimen pada setiap komentar mahasiswa sehingga dapat dimanfaatkan sebagai dataset pelatihan dalam tahap klasifikasi dengan memakai algoritma *Support Vector Machine* (SVM) tanpa melalui validasi manual. Pendekatan ini dipilih untuk meningkatkan efisiensi dan konsistensi pelabelan pada dataset berukuran besar. Library *Textblob* memanfaatkan nilai polaritas (*polarity*) yang dihasilkan dari setiap teks. Nilai polaritas tersebut berada pada rentang -1 hingga 1, di mana nilai mendekati -1 menunjukkan sentimen negatif, nilai mendekati 1 menunjukkan sentimen positif, dan nilai di sekitar 0 menunjukkan netral. *Textblob* pada dasarnya dikembangkan untuk pengolahan teks berbahasa Inggris, sehingga pada penelitian ini dilakukan penyesuaian terhadap data berbahasa Indonesia. Penyesuaian tersebut dilakukan dengan menerjemahkan teks ke dalam bahasa Inggris sebelum proses analisis sentimen, atau dengan asumsi bahwa beberapa kata dalam data tetap dapat dikenali oleh model bawaan *textblob*.

Dalam studi ini, proses pelabelan data dikelompokkan menjadi dua kategori, yaitu sentimen positif dan sentimen negatif. Sentimen positif diberikan pada komentar yang menunjukkan manfaat atau dukungan terhadap penggunaan ChatGPT dalam kegiatan akademik, sedangkan sentimen negatif diberikan pada komentar yang menunjukkan kekhawatiran atau dampak kurang baik dari penggunaan ChatGPT.

2.4. Split Data

Sehabis tahap pelabelan tuntas dilakukan, dataset kemudian dikelompokkan menjadi data latih (*training data*) dan data uji (*testing data*). Pembagian hal ini dimaksudkan untuk menyusun model klasifikasi sekaligus menilai performa model terhadap data yang sebelumnya belum pernah diolah. Pada studi ini, pemisahan dataset dilakukan dengan teknik *train-test split* menggunakan komposisi 80% sebagai data latih dan 20% sebagai data uji. Dari keseluruhan 1.104 data komentar, diperoleh 856 data latih dan 214 data uji.

2.5. Pembobotan TF-IDF

Dalam proses ini, pembobotan kata dilakukan dengan memakai cara *Term Frequency-Inverse Document Frequency* (TF-IDF) yang berguna dalam mengubah data teks yang sudah melalui tahap *preprocessing* dan pelabelan menjadi bentuk numerik agar bisa diolah oleh algoritma klasifikasi. Metode TF-IDF bekerja dengan menghitung tingkat kepentingan suatu kata dalam sebuah dokumen berlandaskan tingkat kemunculannya pada dokumen tersebut serta tingkat kelangkaannya pada semua kumpulan dokumen. Hasil dari proses pembobotan TF-IDF berupa matriks numerik yang merepresentasikan hubungan antara dokumen dan kata, yang berikutnya dipakai sebagai data input pada tahap pelatihan dan pengujian model SVM [19].

Adapun rumus tahap pembobotan memakai cara TF-IDF ditunjukkan pada Persamaan 1-3.

1. Term Frequency (TF)

$$TF = \frac{\text{jumlah kemunculan kata di dokumen}}{\text{total kata dalam dokumen}} \quad (1)$$

2. Inverse Document Frequency (IDF)

$$IDF = \log \left(\frac{D+1}{df+1} \right) + 1 \quad (2)$$

3. Term Frequency – Inverse Document Frequency (TF-IDF)

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

2.6. Normalisasi Data

Pada tahap ini dilaksanakan normalisasi kepada nilai TF-IDF yang telah dihasilkan. Normalisasi TF-IDF bertujuan untuk menyesuaikan skala nilai bobot setiap dokumen agar berada pada rentang yang sebanding, sehingga perbedaan panjang dokumen tidak memengaruhi hasil analisis. Proses ini membantu mencegah dominasi dokumen dengan jumlah kata yang lebih banyak serta memastikan bahwa setiap fitur memiliki peran yang proporsional pada tahap pembelajaran model. Dengan normalisasi TF-IDF, performa algoritma klasifikasi, khususnya *Support Vector Machine* (SVM), dapat menjadi lebih stabil dan akurat karena data masukan berada pada skala yang seragam. Rumus yang dipakai guna melaksanakan tahap normalisasi data dapat dijelaskan pada Persamaan 4.

$$TF_{norm}(t, d) = \frac{TF(t, d)}{\sqrt{\sum_i (TF(t, d))^2}} \quad (4)$$

Keterangan:

- d : dokumen ke-d
- t : kata ke-t dari kata kunci
- TF : jumlah kata dalam dokumen yang dicari

2.7. Klasifikasi Menggunakan SVM

Pada tahap klasifikasi menggunakan SVM, proses dimulai dengan menentukan kernel linear untuk memetakan data ke dalam ruang fitur dan menghubungkan secara linier antar data berdasarkan nilai bobot TF-IDF yang telah dinormalisasi. Selanjutnya, dilakukan perhitungan matriks Hessien yang berfungsi untuk merepresentasikan hasil perkalian antarvektor fitur dalam proses optimasi. Kemudian lanjut ke proses *Sequential Training SVM*, di mana metode ini melatih secara bertahap untuk memperoleh nilai parameter yang optimal. Proses ini bertujuan untuk menemukan *hyperplane* terbaik yang mampu membedakan data dari berbagai kategori dengan jarak maksimum [20].

1. Rumus Kernel Linear

$$K(x, y) = x \cdot y \quad (5)$$

2. Rumus Matrik Hessien

$$D_{ij} = y_i y_j (K(x_i, x_j) + \lambda^2) \quad (6)$$

3. Rumus Sequential Training

$$E_i = \sum_{j=1}^n \alpha_j D_{ij} \quad (7)$$

2.8. Evaluasi Model (*Confusion matrix*)

Fase terakhir dari studi ini melibatkan penilaian model klasifikasi. Hasil evaluasi sistem pengelompokan diperoleh dengan menggunakan *confusion matrix* guna menilai skor akurasi, presisi, recall, dan F1-score. *Confusion matrix* digunakan guna menilai performa model untuk mengelompokkan data ke dalam masing-masing kelas dengan membandingkan label prediksi dan label aktual. Selain itu, evaluasi model juga dilakukan menggunakan metode pembagian data (*train – test split*) dengan perbandingan 80:20, di mana data latih dipakai guna membangun model dan data uji dipakai untuk menilai kemampuan model dalam melakukan generalisasi pada data yang belum pernah digunakan sebelumnya. Adapun perhitungan metrik evaluasi dikerjakan dengan rumus sebagai berikut:

1. *True Positive* (TP)
2. *True Negative* (TN)
3. *False Positive* (FP)
4. *False Negative* (FN)

Matrix ini menampilkan performa pengelompokan untuk mengidentifikasi setiap kelas.

$$Akurasi = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data}} \times 100\% \quad (8)$$

$$Presisi = \frac{TP}{(TP + FP)} \quad (9)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (10)$$

$$F1 - Score = \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (11)$$

3. HASIL DAN PEMBAHASAN

3.1. Dataset Penelitian

Penelitian ini berguna dalam menganalisis sentimen mahasiswa terhadap penggunaan ChatGPT dalam proses pembelajaran menggunakan algoritma SVM. Data studi didapat lewat distribusi kuesioner daring kepada mahasiswa Program Studi Ilmu Komputer Universitas Islam Negeri Sumatera Utara (UINSU). Data yang dikumpulkan berupa komentar teks yang merepresentasikan pengalaman, pandangan, serta evaluasi mahasiswa terkait pemanfaatan ChatGPT dalam aktivitas akademik.

Berdasarkan proses pengumpulan data tersebut, diperoleh sebanyak 1.104 komentar mahasiswa yang digunakan sebagai dataset penelitian. Data tersebut mencerminkan berbagai pandangan mahasiswa mengenai manfaat maupun potensi dampak penggunaan ChatGPT dalam proses belajar. Beberapa contoh data komentar mahasiswa ditampilkan pada Tabel 1 guna menggambarkan ciri-ciri data secara umum yang dipakai pada studi ini.

Table 1. Dataset Contoh Komentar Mahasiswa

No	Komentar
1	ada kalanya saya termotivasi tapi dalam keadaan tertentu saya jadi ketergantungan
2	ya saya semakin semangat belajar karena merasa sangat terbantu tetapi di sisi lain ada ketergantungan juga
3	ya lebih termotivasi dan mempermudah belajar
4	chatgpt dapat membantu dalam proses pembelajaran tapi bisa bahaya kalau terlalu bergantung
5	sedikit bergantung
6	kalau kadang melenceng chatgpt perlu dibandingkan dengan sumber lain
7	chatgpt lebih jelas saat mencari ringkasan cepat tetapi tidak boleh bergantung terlalu banyak

Contoh komentar tersebut menunjukkan bahwa tanggapan mahasiswa terhadap penggunaan ChatGPT memiliki variasi sentimen, baik positif maupun negatif. Sebagian mahasiswa menilai ChatGPT bisa menunjang pemahaman materi serta merampungkan tugas secara lebih cepat, sementara sebagian lainnya menyampaikan kekhawatiran terkait potensi ketergantungan terhadap teknologi tersebut. Distribusi dataset dapat dilihat pada Tabel 2.

Tabel 2. Distribusi Dataset

Sentimen	Jumlah Data
Positif	778
Negatif	326
Total	1104

Berdasarkan distribusi tersebut, dapat diketahui bahwa mayoritas mahasiswa menunjukkan respons yang baik dalam pemanfaatan ChatGPT guna mendukung aktivitas akademik.

3.2. Preprocessing Data Teks

Sebelum tahapan klasifikasi dikerjakan, data komentar diawali dengan tahapan *text Preprocessing* guna menghilangkan data dari unsur yang tidak sesuai serta menyeragamkan struktur teks [21]. Tahapan ini penting karena data komentar yang diperoleh masih bersifat tidak terstruktur dan memiliki variasi bahasa yang beragam.

Dalam studi ini, *preprocessing* dilakukan melalui sejumlah tahapan utama seperti *cleaning data*, *case folding*, *tokenizing*, *filtering*, normalisasi, *stopword removal*, dan *stemming*. Tahapan tersebut berguna dalam mengoptimalkan kualitas representasi data teks. Dengan demikian, proses klasifikasi dapat dilakukan dengan lebih optimal memakai algoritma *Support Vector Machine* (SVM). Contoh tahap *preprocessing* bisa diperhatikan di Tabel 3.

Table 3. Preprocessing Data Teks


Tahapan	Hasil
Teks Asli	chatgpt dapat membantu dalam proses pembelajaran tapi bisa bahaya kalau terlalu bergantung
<i>Cleaning</i>	chatgpt dapat membantu dalam proses pembelajaran tapi bisa bahaya kalo terlalu bergantung
<i>Case Folding</i>	chatgpt dapat membantu dalam proses pembelajaran tapi bisa bahaya kalau terlalu bergantung
<i>Tokenizing</i>	['chatgpt', 'dapat', 'membantu', 'proses', 'pembelajaran', 'bahaya', 'bergantung']

Tahapan	Hasil
<i>Filtering</i>	['chatgpt', 'membantu', 'proses', 'pembelajaran', 'bahaya', 'bergantung']
Normalisasi	['chatgpt', 'membantu', 'proses', 'pembelajaran', 'bahaya', 'terlalu', 'bergantung']
<i>Stopword Removal</i>	['chatgpt', 'membantu', 'proses', 'pembelajaran', 'bahaya', 'terlalu', 'bergantung']
<i>Stemming</i>	['chatgpt', 'bantu', 'proses', 'ajar', 'bahaya', 'gantung']

Proses *preprocessing* tersebut bertujuan untuk mengurangi pilihan istilah yang tidak diperlukan serta menciptakan gambaran teks yang semakin konsisten. Dengan demikian, data yang digunakan dalam proses klasifikasi menjadi lebih terstruktur dan dapat meningkatkan performa model analisis sentimen.

3.3. Pelabelan data

Pada langkah ini dijalankan pelabelan data, yaitu tahap penandaan label sentimen pada setiap data teks yang telah melalui seluruh tahapan *preprocessing*. Pelabelan data pada studi ini dikerjakan secara otomatis dengan memakai *library TextBlob* yang digunakan dalam rangka mengkaji opini terhadap teks komentar mahasiswa. *Textblob* menghasilkan nilai *polarity* yang terletak berkisar -1 hingga +1. Nilai *polarity* tersebut digunakan untuk menentukan kategori sentimen dari setiap komentar. Jika nilai *polarity* lebih besar dari 0, maka komentar dilabelkan sebagai sentimen positif, sedangkan apabila skor *polarity* kurang dari 0, komentar dilabelkan sebagai sentimen negatif. Tahap pelabelan otomatis ini dilaksanakan untuk mempermudah pengolahan data dalam jumlah besar serta mempercepat proses klasifikasi.



Gambar 2. Hasil Pelabelan

Pada Gambar 2 terlihat bahwa setelah dilakukan pelabelan maka didapatkan hasil sebanyak 1.104 komentar terbagi menjadi komentar positif dan negatif, yaitu dengan 778 komentar positif dan 326 komentar negatif.

3.4. Split Data

Hasil dari *split* data bisa diamati dari Tabel 4.

Tabel 4. *Split* Data

Data Latih	
Sentimen	Komentar
Positif	['kala', 'motivasi', 'ada', 'tentu', 'gantung'],
Positif	['semangat', 'ajar', 'bantu', 'gantung'],
Positif	['motivasi', 'mudah', 'ajar'],
Negatif	['chatgpt', 'bantu', 'proses', 'ajar', 'bahaya', 'lalu', 'gantung', 'buat', 'malas', 'cari', 'jawab', 'sendiri', 'kurang', 'latih', 'pikir', 'kritis'],
Negatif	['sedikit', 'gantung']
Data Uji	
?	['lenceng', 'chatgpt', 'ajar', 'malam', 'banding', 'sumber'],
?	['belakang', 'chatgpt', 'jelas', 'cari', 'ringkas', 'cepat', 'gantung']

Tabel 4 menunjukkan hasil pembagian dataset yang diperoleh dari 7 data sebagai gambaran dari kumpulan dataset. Pembagian data dilakukan guna memisahkan tahap pelatihan dan pengujian model SVM.

3.5. Hasil Pembobotan TF-IDF

Setelah tahap *preprocessing* tuntas dilakukan, tahap berikutnya adalah menjalankan pembobotan kata memakai metode TF-IDF. Metode TF-IDF dipakai guna mengonversi data teks menjadi *representasi numerik* sehingga bisa diproses melalui algoritma *machine learning*. Seluruh kata pada dokumen akan diberikan bobot mengacu pada banyaknya munculnya pada dokumen dan tingkat kepentingannya pada keseluruhan dokumen.

Output dari tahap pembobotan ini menghasilkan matriks fitur yang selanjutnya dipakai sebagai data masukan pada proses pengelompokan memakai algoritma *Support Vector Machine* (SVM). Adapun perhitungannya sebagaimana berikut ini:

$$IDF \text{ kala} = \log\left(\frac{D+1}{df+1}\right) + 1 = \log\left(\frac{5+1}{1+1}\right) + 1 = \log(3) + 1 = 1,477$$

Setelah perhitungan *IDF* maka dilanjutkan menghitung TF-IDF dengan perhitungan di bawah ini:

$$W \text{ kala} = TF \times IDF = 1 \times 1,477 = 1,477$$

Hasil dari pembobotan TF-IDF pada beberapa kata bisa ditinjau berdasarkan Tabel 5.

Tabel 5. Nilai TF-IDF

Term	TF-IDF				
	D1	D2	D3	D4	D5
kala	1,477	0,000	0,000	0,000	0,000
motivasi	1,301	0,000	1,301	0,000	0,000
ada	1,477	0,000	0,000	0,000	0,000
tentu	1,477	0,000	0,000	0,000	0,000
gantung	1,079	1,079	0,000	1,079	1,079

3.6. Normalisasi Data

Pada langkah ini dilaksanakan normalisasi terhadap nilai TF-IDF yang sudah dihasilkan, melalui penerapan rumus sebagai berikut:

$$TF_{norm}(t, d) = \frac{TF(t, d)}{\sqrt{\sum_i (TF(t, d))^2}} = \frac{1,477}{\sqrt{(1,477)^2 + (1,301)^2 + \dots + (1,477)^2}} = \frac{1,477}{\sqrt{57,035}} = 0,19559$$

Sehingga hasil dari normalisasi pada beberapa data sebagaimana pada Tabel 6.

Tabel 6. Normalisasi Data

No	D1	D2	D3	D4	D5
1	0,19559	0,000	0,000	0,000	0,000
2	0,17227	0,000	0,172	0,000	0,000
3	0,19559	0,000	0,000	0,000	0,000
4	0,19559	0,000	0,000	0,000	0,000
5	0,14290	0,142	0,000	0,142	0,142

3.7. Hasil Klasifikasi SVM

Parameter yang dipakai pada algoritma SVM pada kajian ini meliputi nilai α sebesar 0 sebagai nilai awal parameter, parameter *regularisasi C* sebesar 1, nilai gamma (γ) sebesar 0,1, parameter λ sebesar 0,5 serta batas maksimum iterasi sebanyak 3 kali. Parameter-parameter tersebut digunakan dalam proses perhitungan matriks Hessian dan pelatihan model untuk memperoleh nilai parameter optimal sehingga model SVM dapat membantu menentukan *hyperplane* pemisah yang optimal dalam proses klasifikasi sentimen.

Sesudah langkah ekstraksi fitur dikerjakan, langkah berikutnya yaitu proses klasifikasi memakai algoritma SVM. Pada langkah ini, dataset dipecah menjadi *data training* dan *data testing* berdasarkan rasio 80% data latih serta 20% data uji. Jumlah data uji yang dipakai pada tahap pengujian yaitu sejumlah 214 data, yang terdiri dari:

1. 70 data sentimen negatif
2. 144 data sentimen positif

Hasil klasifikasi model kemudian dievaluasi menggunakan *confusion matrix* untuk mengetahui tingkat kinerja model.


Tabel 7. *Confusion Matrix*

<i>Actual / Predicted</i>	Negatif	Positif
Negatif	41	29
Positif	15	129

Berdasarkan *confusion matrix* pada Tabel 7 dapat dijelaskan bahwa:

1. *True Negative* (TN) = 41
2. *False Positive* (FP) = 29
3. *False Negative* (FN) = 15
4. *True Positive* (TP) = 129

Visualisasi *confusion matrix* bisa diperhatikan pada Gambar 3.

**Gambar 3.** *Confusion Matrix*

Hasil visualisasi *confusion matrix* menunjukkan performa model SVM saat proses penentuan sentimen negatif dan positif. Berdasarkan hasil tersebut, terdapat 41 data negatif yang berhasil diprediksi dengan benar sebagai negatif, sementara 29 data negatif salah diprediksi sebagai positif. Pada kelas positif, model bisa mengklasifikasikan dengan benar sejumlah 129 data positif, sedangkan 15 data positif lainnya salah diprediksi sebagai negatif. Temuan ini mengindikasikan bahwa model mempunyai keahlian yang relatif baik saat mengidentifikasi sentimen dilihat dari hasil prediksi yang lebih banyak benar daripada salah.

3.8. Evaluasi Kinerja Model

Evaluasi model dijalankan guna mengukur performa algoritma SVM guna mengkategorikan sentimen mahasiswa terhadap penggunaan ChatGPT. Proses evaluasi dilakukan dengan membandingkan label sentimen sebenarnya dengan hasil prediksi yang diproduksi oleh model. Metode yang dipakai pada studi ini adalah *confusion matrix*, yang mampu memperlihatkan skor klasifikasi yang benar maupun kesalahan klasifikasi di setiap kelas. Berdasarkan hasil pengujian terhadap 214 data uji, diperoleh nilai *True Negative* (TN) = 41, *False Positive* (FP) = 29, *False Negative* (FN) = 15, dan *True Positive* (TP) = 129. Nilai tersebut menunjukkan jumlah data yang berhasil maupun gagal diklasifikasikan oleh model.

Tahap berikutnya yaitu menghitung secara manual nilai akurasi, presisi, *recall*, dan *F1-Score* sebagai langkah evaluasi terhadap kinerja model.

1. Akurasi

Accuracy dipakai guna menilai keakuratan model saat menjalankan pengelompokan data.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data}} \times 100\% = \frac{129 + 41}{214} \times 100\% = \frac{170}{214} \times 100\% = 79,44\%$$

Nilai akurasi model sebesar 79,44% menunjukkan bahwa algoritma SVM mempunyai kinerja yang tergolong cukup baik guna mengklasifikasikan sentimen mahasiswa dalam penggunaan Chatgpt. Hal ini bisa diperhatikan dari perbandingan pada penelitian sebelumnya oleh Muadin (2023) yang memperoleh akurasi sebesar 70% serta penelitian oleh Pamungkas dan Cahyono (2024) yang mencapai sekitar 80%. Dengan demikian, hasil penelitian ini berada pada rentang yang kompetitif dan mendekati performa optimal dari model SVM dalam analisis berbasis teks. Performa ini dipengaruhi oleh beberapa faktor, seperti kualitas dan keragaman data kuesioner, tahapan *preprocessing* yang membantu membersihkan teks, serta penggunaan TF-IDF dalam merepresentasikan fitur. Selain itu,

pelabelan otomatis menggunakan TextBlob yang memiliki keterbatasan dalam memahami bahasa Indonesia dan penggunaan kernel linear pada SVM juga turut memengaruhi hasil akurasi.

2. Presisi

Precision digunakan untuk mengukur ketepatan prediksi model terhadap data yang diprediksi sebagai kelas tertentu.

Negatif

$$Presisi = \frac{TN}{(TN + FN)} = \frac{41}{(41 + 15)} = 73,21\%$$

Positif

$$Presisi = \frac{TP}{(TP + FP)} = \frac{129}{(129 + 29)} = 81,65\%$$

Nilai ketepatan pada kelas negatif senilai 73,21% mengindikasikan bahwa tetap terdapat sejumlah kekeliruan saat memprediksi data negatif memperlihatkan jikalau model terdapat sejumlah kekeliruan saat memprediksi data negatif, sementara itu, ketepatan pada kelas positif senilai 81,65% memperlihatkan bahwa sebagian besar data yang diprediksi sebagai sentimen positif memang benar positif, sehingga model cukup akurat dalam mengidentifikasi komentar positif

3. Recall

Recall digunakan untuk menilai keahlian model guna menentukan semua data pada kelas tertentu.

Negatif

$$Recall = \frac{TN}{(TN + FP)} = \frac{41}{(41 + 29)} = 58,57\%$$

Positif

$$Presisi = \frac{TP}{(TP + FN)} = \frac{129}{(129 + 15)} = 89,58\%$$

Nilai *recall* pada kelas negatif senilai 58,57% mengindikasikan bahwa model masih kurang optimal untuk mendeteksi seluruh data sentimen negatif, sehingga masih terdapat cukup banyak data negatif yang salah diklasifikasikan sebagai positif. Sebaliknya, nilai *recall* pada kelas positif senilai 89,58% mengindikasikan bahwa model mempunyai keahlian yang sangat baik serta mengenali sebagian besar data sentimen positif secara benar. Hal ini mengindikasikan bahwa model semakin tepat saat mendeteksi sentimen positif daripada sentimen negatif.

4. F1-Score

F1-Score yaitu rata-rata harmonik dari *Precision* dan *recall* yang dipakai guna mengetahui keseimbangan performa model.

Negatif

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} = 2 \times \frac{(0,7321 \times 0,5857)}{(0,7321 + 0,5857)} = 65,05\%$$

Positif

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} = 2 \times \frac{(0,8165 \times 0,8958)}{(0,8165 + 0,8958)} = 85,45\%$$

Nilai *F1-Score* menunjukkan bahwa model mempunyai performa yang baik saat mengelompokkan sentimen, khususnya pada kelas positif yang memiliki nilai sebesar 85,45% yang menggambarkan keselarasan yang optimal antara *Precision* dan *Recall*. Selain itu, nilai *F1-Score* pada kelas negatif sebesar 65,05% tetap mengindikasikan bahwa model dapat mengidentifikasi pola sentimen positif dengan cukup baik.

Ringkasan hasil evaluasi model bisa ditinjau di Tabel 8.

3.9. Analisis Kata dalam Komentar Mahasiswa

Untuk memahami konteks opini mahasiswa secara lebih mendalam, penelitian ini juga melakukan analisis terhadap kata-kata yang dominan kemunculannya dalam komentar mahasiswa menggunakan visualisasi *word cloud*.

Visualisasi pada Gambar 4 menunjukkan istilah-istilah yang dominan ada dalam komentar mahasiswa terkait penggunaan ChatGPT dalam pembelajaran. Pada sentimen positif, istilah-istilah yang dominan berkaitan dengan kemudahan penggunaan, bantuan dalam memahami materi, serta kecepatan dalam memperoleh informasi. Hal ini menunjukkan bahwa mahasiswa merasakan manfaat langsung dari penggunaan teknologi tersebut.

Table 8. Hasil Evaluasi Model (Classification Report)

Kelas	Precision	Recall	F1-Score	Support
Negatif	0.73	0.59	0.65	70
Positif	0.82	0.9	0.85	144
Accuracy			0.79	214
Macro Avg	0.77	0.74	0.75	214
Weighted Avg	0.79	0.79	0.79	214

Sementara itu, pada sentimen negatif muncul kata-kata yang berkaitan dengan kekhawatiran terhadap potensi ketergantungan terhadap teknologi serta perlunya melakukan verifikasi terhadap informasi yang dihasilkan. Hal ini menunjukkan bahwa meskipun ChatGPT memberikan berbagai kemudahan, penggunaannya tetap perlu disertai dengan kemampuan berpikir kritis dalam mengevaluasi informasi.

Secara keseluruhan, temuan studi ini mengindikasikan bahwa pemanfaatan teknologi kecerdasan buatan seperti ChatGPT mempunyai peluang yang besar untuk menunjang proses pembelajaran di perguruan tinggi. Walaupun demikian, penggunaannya perlu diarahkan dengan bijak agar tidak mengurangi keahlian *critical thinking* mahasiswa saat memperoleh dan mengevaluasi informasi. Temuan studi ini juga konsisten dengan studi terdahulu, seperti Muadin (2023) yang menunjukkan bahwa ChatGPT menjadi peluang sekaligus tantangan dalam dunia akademik, serta Pamungkas dan Cahyono (2024) yang mengonfirmasi bahwa algoritma SVM memiliki keahlian yang baik saat melakukan analisis sentimen dengan tingkat akurasi yang cukup tinggi. Selain itu, penelitian oleh Septini (2025) juga menunjukkan bahwa SVM mampu menghasilkan performa klasifikasi yang baik dalam memahami opini publik terhadap Chatgpt. Dengan demikian, hasil penelitian ini memperkuat temuan sebelumnya bahwa penggunaan Chatgpt dalam pembelajaran memiliki dampak yang signifikan dan perlu dikelola secara tepat agar memberikan manfaat yang optimal.



Gambar 5. Word Cloud Komentar Mahasiswa Berdasarkan Sentimen

4. KESIMPULAN

Berlandaskan temuan penelitian yang sudah dilaksanakan, penerapan algoritma *Support Vector Machine* (SVM) untuk mengklasifikasikan sentimen mahasiswa Program Studi Ilmu Komputer UIN Sumatera Utara Medan terhadap pengaruh penggunaan ChatGPT dilakukan melalui beberapa tahapan, yaitu pengumpulan data sebanyak 1.104 komentar, pelabelan sentimen, proses *preprocessing* teks yang mencakup *cleaning*, *case folding*, *tokenizing*, *filtering*, *stopword removal*, *stemming*, serta normalisasi, kemudian diikuti dengan tahapan pembobotan kata memakai metode TF-IDF. Temuan studi memperlihatkan bahwa algoritma *Support Vector Machine* bisa diterapkan dengan tingkat keberhasilan yang baik dalam mengklasifikasikan sentimen mahasiswa berdasarkan data teks yang telah diproses.

Model klasifikasi yang dibentuk memakai algoritma SVM menghasilkan tingkat akurasi senilai 79,44% dalam mengklasifikasikan sentimen mahasiswa mengenai pengaruh penggunaan ChatGPT terhadap performa akademik. Nilai akurasi tersebut memperlihatkan bahwa model mempunyai kinerja yang cukup baik saat membedakan sentimen positif dan negatif pada data yang dianalisis.

Temuan analisis sentimen juga memperlihatkan bahwa dari 1.104 komentar yang dianalisis, ditemukan 778 komentar dengan sentimen positif serta 326 komentar dengan sentimen negatif. Temuan ini

menunjukkan bahwa mayoritas mahasiswa mempunyai opini yang positif terhadap penggunaan ChatGPT sebagai sarana pendukung pada proses pembelajaran. Meskipun demikian, masih terdapat sebagian mahasiswa yang memberikan tanggapan negatif yang menyoroti potensi dampak penggunaan ChatGPT, seperti kemungkinan ketergantungan terhadap teknologi serta penurunan kemandirian dalam belajar.

Berdasarkan hasil penelitian tersebut, penelitian selanjutnya direkomendasikan agar memakai jumlah data yang lebih banyak serta lebih bervariasi, baik dari sisi latar belakang responden maupun konteks pertanyaan, sehingga hasil klasifikasi sentimen yang diperoleh menjadi lebih representatif dan mampu mengoptimalkan daya generalisasi model. Di samping itu, peningkatan kinerja model *Support Vector Machine* juga dapat dilakukan melalui optimasi parameter, misalnya pengaturan nilai *C*, *gamma*, dan penentuan jenis kernel yang tepat. Proses optimasi tersebut dapat dilakukan melalui teknik *hyperparameter tuning*, seperti *Grid Search* atau *Cross Validation*, sehingga harapannya dapat memberikan performa model klasifikasi yang semakin efektif pada penelitian selanjutnya.

REFERENSI

- [1] A. W. Budiman, A. Setiawan, and S. Nugroho, "Pengembangan Sistem Layanan Informasi Berbasis Web dengan Memanfaatkan AI Pada ChatGPT," *J. Teknol. Dan Sist. Inf. Bisnis-JTEKSIS*, vol. 5, no. 4, p. 592, 2023, [Online]. Available: <http://jurnal.unidha.ac.id/index.php/jteksishttps://doi.org/10.47233/jteksis.v5i4.1068>
- [2] A. Zein, "Dampak Penggunaan ChatGPT pada Dunia Pendidikan," *JITU J. Inform. Utama*, vol. 1, no. 2, pp. 19–24, 2023, [Online]. Available: <https://jurnal.astinamandiri.com/index.php/jitu/article/view/151>
- [3] T. U. S. H. Wibowo, F. Akbar, S. R. Ilham, and M. S. Fauzan, "Tantangan dan Peluang Penggunaan Aplikasi Chat GPT Dalam Pelaksanaan Pembelajaran Sejarah Berbasis Dimensi 5.0," *J. PETISI (Pendidikan Teknol. Informasi)*, vol. 4, no. 2, pp. 69–76, 2023, doi: 10.36232/jurnalpetisi.v4i2.4226.
- [4] D. Setiawan, E. A. D. Karuniawati, and S. I. Janty, "Peran Chat Gpt (Generative Pre-Training Transformer) Dalam Implementasi Ditinjau Dari Dataset," *Innov. J. Soc. Sci. Res.*, vol. 3, no. 3, pp. 9527–9539, 2023, [Online]. Available: <https://j-innovative.org/index.php/Innovative/article/view/3286>
- [5] E. S. Priowirjanto *et al.*, "Sosialisasi Mengenai Aspek Hukum Dari Penggunaan Chatgpt Dalam Dunia Pendidikan Di Smk Al-Wafa Kabupaten Bandung," *Kabuyutan*, vol. 2, no. 2, pp. 92–99, 2023, doi: 10.61296/kabuyutan.v2i2.161.
- [6] K. L. Panjaitan, J. M. Sinurat, Y. Tarigan, and U. S. Utara, "Pengaruh chatgpt terhadap pengerjaan tugas kuliah pada mahasiswa di era society 5.0," vol. 6, no. 1, pp. 1–19, 2024.
- [7] M. Muadin and H. Asnal, "Implementasi Metode *Support Vector Machine* Pada Opinion Mining Masyarakat Terkait Chatgpt," *JOISIE J. Inf. Syst. Informatics Eng.*, vol. 7, no. 1, pp. 78–84, 2023.
- [8] D. A. Agustina, S. Subanti, and E. Zukhronah, "Implementasi Text Mining Pada Analisis Sentimen Pengguna Twitter Terhadap Marketplace di Indonesia Menggunakan Algoritma *Support Vector Machine*," *Indones. J. Appl. Stat.*, vol. 3, no. 2, p. 109, 2021, doi: 10.13057/ijas.v3i2.44337.
- [9] N. Arifin, U. Enri, and N. Sulistiyowati, "Penerapan Algoritma *Support Vector Machine* (SVM) dengan TF-IDF N-Gram untuk Text Classification," *STRING (Satuan Tulisan Ris. dan Inov. Teknol.*, vol. 6, no. 2, p. 129, 2021, doi: 10.30998/string.v6i2.10133.
- [10] A. S. Pamungkas and N. Cahyono, "Analisis Sentimen Review ChatGPT di Play Store menggunakan *Support Vector Machine* dan K-Nearest Neighbor," *Edumatic J. Pendidik. Inform.*, vol. 8, no. 1, pp. 1–10, 2024, doi: 10.29408/edumatic.v8i1.24114.
- [11] A. Baita, Y. Pristyanto, N. Cahyono, P. Covid-, K. N. N. Akurasi, and K. Kunci, "Analisis Sentimen Mengenai Vaksin Sinovac Menggunakan Algoritma *Support Vector Machine* (SVM) Dan K-Nearest Neighbor (KNN) Abstraksi Keywords :," vol. 4, no. 2, pp. 42–46, 2021.
- [12] H. C. Husada and A. S. Paramita, "Analisis Sentimen Pada Maskapai Penerbangan di Platform Twitter Menggunakan Algoritma *Support Vector Machine* (SVM)," *Teknika*, vol. 10, no. 1, pp. 18–26, 2021, doi: 10.34148/teknika.v10i1.311.
- [13] Hermanto, A. Mustopa, and A. Y. Kuntoro, "Algoritma Klasifikasi Naive Bayes Dan *Support Vector*," *J. Ilmu Pengetah. dan Teknol. Komput.*, vol. 5, no. 2, pp. 211–220, 2020.
- [14] Y. Bambang Seran and S. Supatman, "Analisis Sentimen Masyarakat Terhadap Kinerja Kerja Presiden Joko Widodo Enggunakan Algoritma *Support Vector Machine*," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 8, no. 4, pp. 7190–7195, 2024, doi: 10.36040/jati.v8i4.10171.
- [15] Oryza Habibie Rahman, Gunawan Abdillah, and Agus Komarudin, "Klasifikasi Ujaran Kebencian pada Media Sosial Twitter Menggunakan *Support Vector Machine*," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 17–23, 2021, doi: 10.29207/resti.v5i1.2700.
- [16] V. Muslimah *et al.*, "Kemajuan dalam Ilmu Informatika Dari Decision Support System Menuju Artificial Intelligence," 2024.
- [17] R. Tjuet Adek, Z. Fitri, and S. Chairani Siegar, "Analisis Sentimen Komentar Pada Saluran Youtube Beauty Vlogger Berbahasa Indonesia Menggunakan Metode *Support Vector Machine*," vol. 5, no. 2,

- pp. 164–175, 2025, doi: 10.35957/algorithm.v5i2.9692.
- [18] A. R. Iqbal and Y. Miftahuddin, “Implementasi SVM Untuk Deteksi Komentar Negatif Berbahasa Indonesia di Twitter,” *Fti*, vol. X, no. X, 2022, [Online]. Available: <https://eproceeding.itenas.ac.id/index.php/fti/article/view/966%0Ahttps://eproceeding.itenas.ac.id/index.php/fti/article/download/966/942>
- [19] F. Putrawansyah, “Penerapan Metode *Support Vector Machine* Terhadap Klasifikasi Jenis Jambu Biji,” *JIKO (Jurnal Inform. dan Komputer)*, vol. 8, no. 1, p. 193, 2024, doi: 10.26798/jiko.v8i1.988.
- [20] I. Frianda Gultom, Sriani, and Suhardi, “Analisis Sentimen Kebijakan Pemberian Subsidi Motor Listrik Menggunakan Metode *Support Vector Machine*,” *J. Fasilkom*, vol. 13, no. 3, pp. 511–517, 2023, doi: 10.37859/jf.v13i3.6225.
- [21] A. Septini, “Bulletin Of Computer Science Research Analisis Sentimen Masyarakat di Twitter Mengenai Open AI CHATGPT Menggunakan Metode *Support Vector Machine* (SVM),” vol. 5, no. 2, pp. 138–149, 2025, doi: 10.47065/bulletincsr.v5i2.475.