

Analisis Sentimen Isu *Artificial Intelligence* di *Twitter* dengan SVM dan *Random Forest*

Abriel Navidkya¹, Mohamad Yusuf²

^{1,2}Teknik Informatika, fakultas ilmu komputer, Universitas Mercu Buana

¹41521010128@mercubuana.ac.id, ²mhd.yusuf@mercubuana.ac.id*

Abstract

Artificial Intelligence (AI) has become a widely discussed topic on social media, particularly Twitter, as public opinions about this technology grow. This study aims to analyze the sentiment of Twitter posts related to AI issues using two classification algorithms: Support Vector Machine (SVM) and Random Forest (RF). The research method involves data collection via the Twitter API, followed by text preprocessing steps including case folding, tokenization, stopword removal, and stemming. The data is then manually or semi-automatically labeled with sentiments (positive, negative, neutral) to support supervised learning. Vectorization using TF-IDF is applied before training and testing the SVM and RF models to compare their classification performance. Results indicate that SVM outperforms RF in accuracy and class balance across sentiments. The application of Synthetic Minority Oversampling Technique (SMOTE) enhances performance, especially in detecting the less frequent negative sentiment. Post-SMOTE, SVM achieves an accuracy of 89.12% and an F1-score of 0.7122 for the negative class, demonstrating its ability to handle data imbalance. Although RF also improves after SMOTE, its performance remains below SVM. This study is expected to contribute significantly to public opinion monitoring and serve as a foundation for decision-making regarding AI-based technology development.

Keywords: artificial intelligence, sentiment analysis, support vector machine, random forest, twitter

Abstrak

Kecerdasan Buatan (AI) semakin menjadi perbincangan hangat di media sosial, terutama *Twitter*, seiring bertambahnya opini publik tentang teknologi ini. Penelitian ini bertujuan menganalisis sentimen cuitan *Twitter* terkait isu AI menggunakan dua algoritma klasifikasi: *Support Vector Machine* (SVM) dan *Random Forest* (RF). Metode penelitian melibatkan pengumpulan data melalui *Twitter* API, diikuti pra-pemrosesan teks yang mencakup *case folding*, tokenisasi, penghapusan kata umum, dan stemming. Data selanjutnya diberi label sentimen (positif, negatif) secara manual atau semi-otomatis untuk mendukung pembelajaran terawasi. Proses vektorisasi menggunakan TF-IDF diterapkan sebelum model SVM dan RF dilatih serta diuji untuk membandingkan performa klasifikasi. Hasil penelitian menunjukkan SVM unggul dibandingkan RF dalam hal akurasi dan keseimbangan klasifikasi antar kelas. Penerapan *Synthetic Minority Oversampling Technique* (SMOTE) terbukti meningkatkan kinerja, terutama dalam mendeteksi sentimen negatif yang jumlahnya lebih sedikit dalam dataset. SVM setelah SMOTE mencapai akurasi 89,12% dengan f1-score kelas negatif sebesar 0,7122, menunjukkan kemampuan menangani ketidakseimbangan data. Meskipun RF juga menunjukkan peningkatan performa pasca-SMOTE, hasilnya tetap di bawah SVM. Penelitian ini diharapkan memberikan kontribusi signifikan dalam pemantauan opini publik serta menjadi dasar pengambilan keputusan terkait perkembangan teknologi berbasis AI.

Kata kunci: AI, sentimen, *support vector machine*, *random forest*, *twitter*

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

1. Pendahuluan

Perkembangan pesat teknologi informasi di era Revolusi Industri 4.0 melahirkan berbagai inovasi, salah satunya Kecerdasan Buatan (*Artificial Intelligence/AI*). AI kini menjadi elemen penting dalam kehidupan manusia, mencakup dunia industri, layanan publik, hingga sektor pendidikan. Dalam konteks akademik, AI membantu mahasiswa memahami materi, mengolah data, dan menyelesaikan tugas akhir seperti skripsi. Namun, kemudahan ini memunculkan dilema, terutama terkait etika, orisinalitas, dan ketergantungan pada teknologi. Banyak pihak khawatir bahwa penggunaan berlebihan AI dapat menurunkan kemampuan berpikir kritis mahasiswa dan meningkatkan risiko plagiarisme [1].

Sebaliknya, masyarakat luas menunjukkan beragam persepsi terhadap AI, yang tercermin dalam opini di media sosial seperti *Twitter* (X). Platform ini menjadi indikator penting untuk memahami penerimaan teknologi tersebut, dengan pengguna mengungkapkan pandangan positif, maupun negatif mengenai peran dan dampak AI. Oleh karena itu, analisis sentimen menjadi metode relevan untuk menggali opini masyarakat secara mendalam [2].

Penelitian sebelumnya menunjukkan AI dipandang sebagai teknologi masa depan yang menjanjikan, meski tetap ada kekhawatiran terhadap dampak negatifnya. Dengan teknik klasifikasi seperti *Decision Tree*, *Lexicon-Based* dengan VADER, dan *Random Forest*, analisis sentimen dapat mengevaluasi persepsi mahasiswa dan masyarakat terhadap AI. Temuan ini

diharapkan menjadi dasar bagi institusi pendidikan dan pembuat kebijakan untuk menetapkan regulasi serta etika penggunaan AI yang bijak dan bertanggung jawab [3].

2. Metode Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan komputasional, yang bersifat eksperimen komputasi (*computational experiment*). Penelitian ini melibatkan penerapan dan pengujian algoritma klasifikasi berbasis *machine learning* untuk menganalisis data teks dari media sosial Twitter terkait isu *Artificial Intelligence* (AI). Pendekatan yang digunakan mencakup *text mining* dan *natural language processing* (NLP) untuk mengolah data tidak terstruktur berupa tweet masyarakat.

Penelitian ini juga bersifat komparatif, membandingkan performa dua algoritma klasifikasi, yaitu *Support Vector Machine* (SVM) dan *Random Forest* (RF), guna menentukan metode yang lebih optimal dalam menganalisis sentimen publik terhadap isu AI. Evaluasi performa model dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *F1-score*.

2.1 Tahapan Penelitian

Penelitian ini mengikuti alur pemrosesan data teks berbasis *sentiment analysis* dan *machine learning*. Studi ini bertujuan untuk menganalisis sentimen publik mengenai *Artificial Intelligence* (AI) dengan menggunakan algoritma klasifikasi *Support Vector Machine* (SVM) dan *Random Forest* (RF). Data diperoleh dari platform media sosial Twitter melalui API atau alat seperti Tweepy dan SNScrape, dengan kata kunci #ArtificialIntelligence, #AI, #ChatGPT, dan #MachineLearning untuk periode Januari hingga Maret 2025, yang kemudian disimpan dalam format CSV yang mencakup teks *tweet*, tanggal, dan metadata pengguna.

Sebelum pemodelan, tahap pra-pemrosesan data dilakukan, yang mencakup pembersihan teks (menghapus URL, tagar, mention, angka, dan tanda baca), case folding, tokenisasi, penghapusan stopword, serta stemming dengan menggunakan pustaka seperti Sastrawi, agar teks memiliki bentuk dasar yang konsisten. Setelahnya, data diberi label sentimen (positif, negatif) secara manual, semi-otomatis dengan kamus sentimen (seperti InSet atau SentiStrength), atau melalui anotator, dan kemudian direpresentasikan dalam bentuk numerik menggunakan TF-IDF, dengan opsi lain seperti *Count Vectorizer*, *Word2Vec*, atau *Doc2Vec*.

Dataset dibagi menjadi data latih (sekitar 80%) dan data uji (sekitar 20%), dan divalidasi menggunakan teknik *k-fold cross-validation* ($k=10$) untuk mendapatkan estimasi performa yang lebih akurat. Klasifikasi dilakukan menggunakan dua algoritma, yaitu SVM (dengan kernel linear dan RBF) dan *Random Forest*

dengan sekitar 100 pohon. Kinerja model dievaluasi dengan metrik akurasi, presisi, *recall*, dan *F1-score* yang ditampilkan dalam tabel dan grafik untuk mempermudah perbandingan. Berdasarkan hasil evaluasi dan distribusi prediksi sentimen, analisis dilakukan untuk menentukan algoritma yang paling optimal serta kecenderungan dominan sentimen publik terhadap isu AI.

3. Hasil dan Pembahasan

3.1 Dataset

Pengumpulan data dalam penelitian ini dilakukan dengan menggunakan tools *Tweet-Harvest*, yaitu sebuah alat bantu pengambil data (*scraper*) dari media sosial X/Twitter yang dibangun menggunakan bahasa pemrograman *Python*. Untuk menjalankan *Tweet-Harvest* di *Google Colab*, terlebih dahulu dilakukan konfigurasi lingkungan kerja. Langkah pertama adalah menyiapkan autentikasi ke API *Twitter* dengan memasukkan *bearer token* ke dalam variabel `twitter_auth_token`. Token ini bersifat pribadi dan diperoleh dari akun resmi *Twitter Developer* yang memiliki akses ke *endpoint* pencarian *tweet*.

Selanjutnya, dilakukan instalasi pustaka *Python* bernama *pandas* yang diperlukan dalam proses pengolahan data setelah berhasil dikumpulkan. *Pandas* akan digunakan untuk menyimpan dan mengelola *tweet* dalam bentuk tabel atau data *frame*. Setelah itu, dilakukan instalasi *Python* karena *Tweet-Harvest* membutuhkan lingkungan *runtime* tersebut agar dapat dijalankan. Instalasi *Node.js* mencakup proses pembaruan daftar paket (`apt-get update`), pemasangan dependensi seperti `curl`, `gnupg`, dan `ca-certificates`, serta penambahan repository resmi *Node.js* versi 20 dari *NodeSource* dengan sistem pengamanan menggunakan kunci *GPG*.

Program Twitter Auth Token

```
twitter_auth_token =  
'433dc2196859dcec5050111b0793bf26e458829'  
  
# Import required Python package  
!pip install pandas  
# Install Node.js (because tweet-harvest  
built using Node.js)  
  
!sudo apt-get update  
!sudo apt-get install -y ca-certificates  
curl gnupg  
!sudo mkdir -p /etc/apt/keyrings  
  
!curl -fsSL  
https://deb.nodesource.com/gpgkey/nodesourc  
e-repo.gpg.key | sudo gpg --dearmor -o  
/etc/apt/keyrings/nodesource.gpg  
  
!NODE_MAJOR=20 && echo "deb [signed-  
by=/etc/apt/keyrings/nodesource.gpg]  
https://deb.nodesource.com/node_${NODE_MAJOR  
.x nodistro main" | sudo tee  
/etc/apt/sources.list.d/nodesource.list  
  
!sudo apt-get update  
  
!sudo apt-get install nodejs -y  
  
!node -v
```

Setelah repositori ditambahkan, *Python* diinstal secara lengkap dan diverifikasi dengan menjalankan perintah *node -v* untuk memastikan versi yang terpasang. Proses ini penting agar *Tweet-Harvest* dapat dijalankan secara optimal di *Google Collab* atau *Jupyter Notebook*. Dengan langkah-langkah tersebut, lingkungan kerja telah siap digunakan untuk mengambil data *tweet* berdasarkan kata kunci tertentu melalui *Tweet-Harvest*.

A	B	C	D	E	F	G	H	I	J	K	L	M	N	
1	conversation_id	created_at	favorite_count	full_text	id_str	image_url	in_reply_to	lang	location	quote_count	reply_count	retweet_count	tweet_url	user_id
2	1.65E+18	Sat Apr 29	0	Pengaruh	1.65E+18			in		0	0	0	https://t.c.2.37E+09	
3	1.65E+18	Sat Apr 29	0	Kecerdasan	1.65E+18			in		1	0	0	https://t.c.1.58E+18	
4	1.65E+18	Sat Apr 29	0	Mengungkapkan	1.65E+18			in		0	0	0	https://t.c.1.53E+18	
5	1.65E+18	Sat Apr 29	0	@bakasda	1.65E+18		acrtite	in		0	0	0	https://t.c.1.38E+18	
6	1.65E+18	Sat Apr 29	1	Salah satu	1.65E+18			in		0	0	1	https://t.c.0.03E+17	
7	1.65E+18	Sat Apr 29	0	Kembali ke	1.65E+18			in		0	1	0	https://t.c.1.59E+08	
8	1.65E+18	Sat Apr 29	0	Tentunya	1.65E+18			in		0	1	0	https://t.c.1.59E+08	
9	1.65E+18	Sat Apr 29	0	Negeri luar	1.65E+18			in		0	1	0	https://t.c.5.36E+08	
10	1.65E+18	Sat Apr 29	0	Kecerdasan	1.65E+18			in		0	1	0	https://t.c.7.07716E	
11	1.65E+18	Sat Apr 29	0	Kecerdasan	1.65E+18			in		0	0	0	https://t.c.1.19E+09	
12	1.65E+18	Sat Apr 29	0	Italia men	1.65E+18			in		0	0	0	https://t.c.23343960	
13	1.65E+18	Sat Apr 29	0	5 Fakta Ch	1.65E+18			in		0	0	0	https://t.c.3.88E+08	
14	1.65E+18	Sat Apr 29	1	Kecerdasan	1.65E+18			in		1	0	0	https://t.c.41730943	
15	1.65E+18	Sat Apr 29	1	Artificial In	1.65E+18			in		0	0	0	https://t.c.1.36E+08	
16	1.65E+18	Sat Apr 29	0	TVOne Per	1.65E+18	https://pbs.twimg.co	in			0	0	1	https://t.c.1.03E+18	
17	1.65E+18	Sat Apr 29	3	Republika	1.65E+18			in		0	1	0	https://t.c.3.00716E	

Gambar 2. Dataset Hasil Twitter

Tahapan ini merupakan fondasi utama sebelum masuk ke proses pelabelan data dan analisis sentimen. Dengan berhasilnya proses *crawling*, seluruh *tweet* yang relevan dengan kata kunci penelitian akan disimpan dalam format file yang dapat diolah lebih lanjut, baik dalam bentuk .csv seperti pada gambar 2, untuk dianalisis pada tahap berikutnya

Kolom *full_text* pada dataset hasil *crawling* merupakan elemen utama yang digunakan dalam proses analisis sentimen. Kolom ini pada gambar 2 berisi isi lengkap dari setiap *tweet* yang ditulis oleh pengguna Twitter, yang umumnya mencerminkan opini, reaksi, atau pandangan terhadap topik tertentu, seperti *Artificial Intelligence* (AI). Karena *tweet* bersifat bebas dan tidak terstruktur, teks mentah dalam kolom ini perlu dibersihkan dan diproses terlebih dahulu agar dapat dianalisis secara akurat oleh model klasifikasi sentimen.

Proses pembersihan dan normalisasi teks atau yang dikenal sebagai *text preprocessing* dilakukan untuk menghilangkan elemen-elemen yang tidak relevan serta menyederhanakan struktur kalimat. Tahapan pertama yang umum dilakukan adalah mengubah seluruh huruf menjadi huruf kecil (*lowercasing*), agar kata seperti "AI" dan "ai" dianggap sama. Selanjutnya, tautan URL yang sering muncul dalam tweet dihapus karena tidak mengandung makna sentimen. Hal yang sama berlaku untuk mention (@username) dan tanda baca seperti titik, koma, dan tanda seru yang tidak diperlukan dalam analisis kata.

Melalui tahapan *preprocessing* ini, data dalam kolom *full_text* akan menjadi lebih bersih, terstruktur, dan relevan untuk dianalisis menggunakan metode seperti *lexicon-based*, *Naive Bayes*, atau *Random Forest*. Selain itu, data yang telah diproses juga lebih mudah divisualisasikan menggunakan teknik seperti *word cloud* atau *bag-of-words*, sehingga dapat memberikan pemahaman yang lebih dalam terhadap kata-kata dominan dalam opini publik.

3.2 Preprocessing Data

Setelah data berhasil dikumpulkan dari *platform* media sosial *X/Twitter* dan disimpan dalam kolom *full_text*, tahap selanjutnya adalah *preprocessing* atau pra-pemrosesan data. *Preprocessing* merupakan tahapan krusial dalam penelitian ini karena bertujuan untuk membersihkan, menyederhanakan, dan menstandarkan teks agar dapat diproses lebih efektif oleh model klasifikasi sentimen. Teks dari media sosial biasanya tidak terstruktur, mengandung banyak noise seperti simbol, singkatan, dan elemen tidak relevan. Oleh karena itu, serangkaian tahap *preprocessing* dilakukan secara berurutan agar makna sebenarnya dari teks dapat ditangkap dengan lebih baik oleh sistem.

Proses dimulai dengan *cleansing*, yaitu pembersihan teks dari unsur-unsur yang tidak diperlukan, seperti URL, mention (@username), hashtag (#), angka, tanda baca, dan emoji. Langkah ini bertujuan menghilangkan gangguan (*noise*) yang dapat mengganggu analisis. Contohnya, teks "@user1 AI itu keren! 🤖 #teknologi" akan dibersihkan menjadi "AI itu keren teknologi".

Selanjutnya dilakukan *case folding*, yaitu mengubah seluruh huruf menjadi huruf kecil (*lowercase*) untuk menyeragamkan data. Dengan demikian, kata "AI" dan "ai" akan diperlakukan sebagai kata yang sama.

Tahap berikutnya adalah normalisasi, yaitu mengganti kata-kata tidak baku, singkatan, dan bahasa gaul menjadi bentuk baku sesuai kaidah bahasa Indonesia. Contohnya, "gk" diubah menjadi "tidak" dan "bgt" menjadi "banget".

Setelah itu, dilakukan *tokenization* yang memecah teks menjadi unit kata-kata individu (*token*). Misalnya, kalimat "AI membantu tugas akhir" menjadi ["ai", "membantu", "tugas", "akhir"]. Proses ini memungkinkan setiap kata dapat dianalisis secara terpisah.

Kemudian dilakukan *stopword removal*, yaitu penghapusan kata-kata umum yang sering muncul namun tidak memiliki makna penting terhadap sentimen, seperti "yang", "di", "ke", "dan", serta "adalah". Penghapusan stopwords ini membantu mengurangi dimensi data dan fokus pada kata-kata yang lebih bermakna.

Tahap selanjutnya adalah *stemming*, yaitu proses mengembalikan kata ke bentuk dasarnya (*root word*). Contohnya, kata "membantu", "dibantu", dan "membantunya" akan disederhanakan menjadi "bantu". Dalam penelitian ini, *stemming* dilakukan menggunakan library Sastrawi untuk bahasa Indonesia.


Setelah seluruh proses *preprocessing* selesai, tahap terakhir adalah visualisasi data menggunakan *WordCloud*. *WordCloud* merupakan representasi visual berupa gambar di mana ukuran kata menunjukkan frekuensi kemunculannya. Kata yang muncul lebih besar menandakan frekuensi yang lebih tinggi. Visualisasi ini membantu peneliti untuk

mengidentifikasi topik dan istilah dominan dalam opini publik mengenai kecerdasan buatan (AI) di *Twitter* secara intuitif, sekaligus memberikan pemahaman awal sebelum memasuki tahap klasifikasi sentimen.



Gambar 3. Visualisasi *WordCloud*

Pada gambar 3. *Wordcloud* tersebut menunjukkan bahwa teks sangat menekankan konsep kecerdasan buatan dan teknologi yang dibuat untuk membantu manusia. Kata dominan seperti “cerdas”, “buat”, “ai”, “teknologi”, dan “manusia” mengindikasikan fokus pada pemanfaatan AI untuk memudahkan tugas, kerja, dan kehidupan masyarakat, dengan nada yang cenderung positif terhadap inovasi teknologi.



Gambar 4. Visualisasi Frekuensi Kata pada *Tweet*

Gambar 4. di atas menunjukkan hasil visualisasi berupa diagram batang (*bar chart*) yang menggambarkan frekuensi kemunculan kata-kata yang paling dominan dalam kumpulan data *tweet* setelah melalui proses *preprocessing*. Visualisasi ini dilakukan sebagai bagian dari tahap eksplorasi awal sebelum analisis sentimen. Grafik ini diberi judul “Frekuensi Kata” dan menunjukkan sepuluh kata yang paling sering muncul dalam data. Setiap batang pada grafik mewakili sebuah kata, sedangkan tinggi batang menunjukkan seberapa sering kata tersebut muncul dalam keseluruhan dataset.

Berdasarkan grafik tersebut, kata yang paling sering muncul adalah “cerdas” dengan frekuensi sebanyak 11.682 kali, diikuti oleh “buat” sebanyak 11.394 kali, dan “ai” sebanyak 5.407 kali. Kemunculan tinggi dari kata “cerdas” dan “buat” sangat mungkin berasal dari frasa “kecerdasan buatan” yang telah melalui tahap tokenization dan *stemming*, sehingga kata tersebut terpecah menjadi dua kata dasar. Sementara itu, kata “teknologi” dan “manusia” yang muncul dengan frekuensi cukup tinggi menunjukkan bahwa percakapan publik di *Twitter* banyak membahas aspek teknologi serta dampaknya terhadap manusia.

Selain itu, munculnya kata seperti “kembang” (dari “perkembangan”), “data”, dan “digital” menegaskan bahwa topik AI sering dikaitkan dengan kemajuan teknologi informasi dan transformasi digital. Menariknya, kata-kata berbahasa Inggris seperti “artificial” dan “intelligence” juga masih muncul dalam daftar, yang menunjukkan bahwa sebagian pengguna tetap menggunakan istilah internasional saat membahas AI, meskipun percakapan secara umum menggunakan Bahasa Indonesia.

Secara keseluruhan, grafik ini memberikan gambaran awal yang bermanfaat dalam memahami tema-tema utama dalam opini publik terkait AI. Visualisasi frekuensi kata seperti ini berguna untuk mengidentifikasi kata kunci, membangun lexicon awal, dan mendukung proses analisis lanjutan seperti *word cloud* atau pembobotan kata menggunakan TF-IDF. Dengan mengetahui kata-kata yang paling sering muncul, peneliti dapat lebih mudah mengarahkan analisis sentimen secara kontekstual dan relevan terhadap data yang dianalisis.

3.3 Kelabelan

Program Kelabelan

```
import pandas as pd
def determine_sentiment(text):
    positive_count = sum(1 for word in
        text.split() if word in
            positive_lexicon)
    negative_count = sum(1 for word in
        text.split() if word in
            negative_lexicon)
    if positive_count > negative_count:
        return "Positif"
    elif positive_count < negative_count:
        return "Negatif"

positive_lexicon =
set(pd.read_csv('/content/drive/MyDrive/TA/da
taset/positive.tsv', sep="\t",
header=None)[0])
negative_lexicon = set(pd.read_csv(
content/drive/MyDrive/TA/dataset/negative.tsv
', sep="\t", header=None)[0])

def replace_none_sentiment(sentiments):
    replace_flag = "Positif"
    for i in range(len(sentiments)):
        if sentiments[i] is None:
            sentiments[i] = replace_flag
            replace_flag = "Negatif" if
                replace_flag == "Positif" else
                    "Positif"
    return sentiments

df['Sentiment'] =
df['stemming_data'].apply(determine_sentiment)
df['Sentiment'] =
replace_none_sentiment(df['Sentiment']).tolist
())
df.head()
```

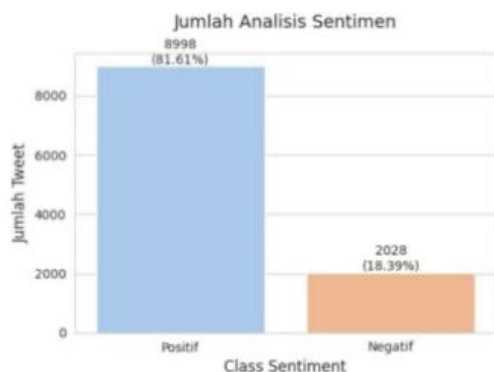
Tahap kelabelan dalam penelitian ini dilakukan untuk menentukan kategori sentimen dari setiap data teks (*tweet*) yang telah diproses sebelumnya. Proses ini menggunakan pendekatan *lexicon-based*, yaitu membandingkan kata-kata dalam teks dengan daftar kata positif dan negatif (kamus leksikon) yang telah disiapkan. Jika jumlah kata positif lebih banyak dari

kata negatif, maka *tweet* dikategorikan sebagai "Positif". Sebaliknya, jika kata negatif lebih banyak, maka *tweet* diberi label "Negatif". Jika jumlahnya sama atau tidak ditemukan dalam leksikon, maka label akan digantikan secara bergantian antara "Positif" dan "Negatif" untuk menghindari nilai *None*.

Langkah pertama yang dilakukan adalah membaca kamus leksikon dari dua file eksternal, yaitu *positive.tsv* dan *negative.tsv*, yang masing-masing berisi daftar kata-kata bernada positif dan negatif. File tersebut dibaca menggunakan pustaka *pandas* dan diubah menjadi struktur set agar proses pencocokan kata menjadi lebih efisien. Kemudian, dibuat fungsi *determine_sentiment(text)* untuk menghitung jumlah kata positif dan negatif dalam setiap *tweet*. Fungsi ini memecah teks menjadi kata-kata (menggunakan *text.split()*) dan menghitung kemunculannya dalam kamus leksikon.

Setelah itu, fungsi *determine_sentiment()* diterapkan pada setiap baris kolom *stemming_data* (hasil *stemming* dari *preprocessing*) menggunakan *apply()*. Hasilnya dimasukkan ke dalam kolom baru bernama *Sentiment*. Namun, karena mungkin saja ada data yang tidak mengandung kata dari kedua leksikon (positif maupun negatif), maka nilai *None* bisa muncul. Untuk mengatasi hal ini, digunakan fungsi *replace_none_sentiment()*, yaitu fungsi yang menggantikan nilai *None* secara bergantian dengan label "Positif" dan "Negatif" agar seluruh data tetap memiliki label.

Dengan pendekatan ini, setiap *tweet* berhasil diklasifikasikan ke dalam salah satu kategori sentimen yang diperlukan untuk proses analisis lebih lanjut. Proses kelabelan ini sangat penting karena menjadi dasar dalam mengevaluasi persepsi publik secara kuantitatif terhadap topik yang sedang diteliti, yakni kecerdasan buatan (*Artificial Intelligence*). Label sentimen yang dihasilkan akan digunakan dalam visualisasi, perhitungan distribusi sentimen, serta validasi model klasifikasi jika dilanjutkan ke tahap pembelajaran mesin.



Gambar 5. Visualisasi Jumlah *Tweet*

Gambar 5. di atas adalah visualisasi hasil distribusi sentimen dari data *tweet* yang telah dianalisis dan dilabeli menggunakan metode *lexicon-based* pada tahap sebelumnya. Grafik berbentuk diagram batang

(*bar chart*) ini menggambarkan jumlah *tweet* yang termasuk ke dalam dua kategori sentimen, yaitu Positif dan Negatif, berdasarkan hasil dari fungsi *determine_sentiment()*.

Pada grafik tersebut, terlihat bahwa sebanyak 8.998 *tweet* (81,61%) dikategorikan sebagai sentimen positif, sedangkan 2.028 *tweet* (18,39%) dikategorikan sebagai sentimen negatif. Perbedaan ini cukup mencolok, menunjukkan bahwa opini publik terhadap topik yang diteliti—dalam hal ini kemungkinan besar berkaitan dengan *Artificial Intelligence* (AI)—cenderung sangat positif. Mayoritas pengguna *Twitter* mengekspresikan sikap yang mendukung, optimistis, atau mengapresiasi terhadap perkembangan teknologi AI.

Proporsi sentimen yang dominan positif ini dapat mencerminkan bahwa masyarakat melihat AI sebagai inovasi yang bermanfaat, membantu kehidupan sehari-hari, atau membuka peluang baru, misalnya dalam bidang pendidikan, pekerjaan, maupun efisiensi proses kerja. Di sisi lain, meskipun jumlahnya lebih kecil, keberadaan 18,39% *tweet* negatif tetap penting untuk diperhatikan. *Tweet-tweet* ini kemungkinan berisi kekhawatiran terhadap dampak AI, seperti penggantian tenaga kerja manusia, penyalahgunaan teknologi, atau risiko privasi dan keamanan.

Dengan demikian, grafik ini tidak hanya menyajikan perbandingan kuantitatif, tetapi juga memberi gambaran umum mengenai persepsi publik secara keseluruhan terhadap AI berdasarkan data yang diperoleh dari media sosial. Informasi ini sangat penting sebagai bahan pertimbangan dalam pengambilan kebijakan, penyusunan strategi komunikasi publik, atau pengembangan teknologi yang lebih etis dan inklusif.

3.4 Pembuatan Model

Setelah proses *preprocessing* dan pelabelan data selesai dilakukan, tahap selanjutnya adalah membangun dan mengembangkan model klasifikasi untuk mengelompokkan *tweet* menjadi dua kategori sentimen, yaitu positif dan negatif. Pada penelitian ini, digunakan dua algoritma pembelajaran mesin yang banyak digunakan untuk tugas klasifikasi teks, yaitu *Support Vector Machine* (SVM) dan *Random Forest* (RF). Masing-masing model diuji pada dua skenario, yaitu sebelum dan sesudah diterapkan teknik SMOTE (*Synthetic Minority Over-sampling Technique*), yang berfungsi untuk menangani ketidakseimbangan jumlah data antar kelas.

Langkah awal dalam pembuatan model adalah memisahkan data latih dan data uji dengan perbandingan 80:20, kemudian melakukan ekstraksi fitur teks menggunakan metode TF-IDF (*Term Frequency-Inverse Document Frequency*). Metode ini mengubah data teks dari kolom *stemming_data* menjadi representasi numerik yang mencerminkan pentingnya kata dalam dokumen. Hasil transformasi TF-IDF digunakan sebagai input untuk kedua model yang diuji.

Pada tahap pertama, model SVM dan *Random Forest* dilatih menggunakan data asli (tanpa SMOTE). Berdasarkan hasil pengujian awal, SVM (Before SMOTE) menunjukkan akurasi sebesar 88.53%, sedangkan *Random Forest* (Before SMOTE) menghasilkan akurasi sebesar 83.64%. Meskipun akurasi terlihat tinggi, ketidakseimbangan kelas dalam dataset menyebabkan rendahnya kemampuan model dalam mengenali sentimen negatif, yang terlihat dari nilai recall dan f1-score kelas negatif yang rendah, terutama pada *Random Forest*.

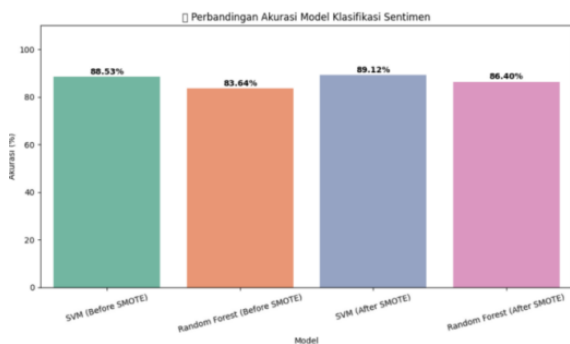
Perbandingan Performa Model:

Model	Accuracy	Precision_Pos	Recall_Pos	F1_Pos	Precision_Neg	Recall_Neg	F1_Neg
0 SVM (Before SMOTE)	0.8853	0.8862	0.9695	0.9325	0.7893	0.5099	0.6195
1 Random Forest (Before SMOTE)	0.8364	0.8439	0.9811	0.9074	0.6837	0.1906	0.2990
2 SVM (After SMOTE)	0.8912	0.9398	0.9262	0.9329	0.6907	0.7351	0.7122
3 Random Forest (After SMOTE)	0.8640	0.8816	0.9628	0.9204	0.7185	0.4233	0.5327

Gambar 6. Tabel Perbandingan Performa Model SVM dan *Random Forest* Sebelum dan Sesudah SMOTE

Untuk memperbaiki kinerja model dalam mengenali kelas minoritas (negatif), dilakukan pelatihan ulang model menggunakan data latih yang telah disintesis dengan SMOTE. Hasilnya menunjukkan peningkatan performa, terutama pada SVM (*After SMOTE*), yang memperoleh akurasi tertinggi sebesar 89.12% dan nilai F1-score tertinggi untuk kelas negatif (0.7122). Sementara itu, *Random Forest* (*After SMOTE*) juga menunjukkan peningkatan akurasi menjadi 86.40%, dan nilai F1-score kelas negatif naik dari 0.2990 menjadi 0.5327.

Untuk memperjelas perbandingan performa antar model, dibuat grafik batang perbandingan akurasi. Grafik tersebut menunjukkan bahwa SVM setelah SMOTE merupakan model terbaik dari segi akurasi dan keseimbangan performa antar kelas. Model ini tidak hanya unggul dalam mengenali sentimen positif yang dominan, tetapi juga menunjukkan peningkatan signifikan dalam mengenali sentimen negatif setelah dilakukan penyeimbangan data dengan SMOTE.



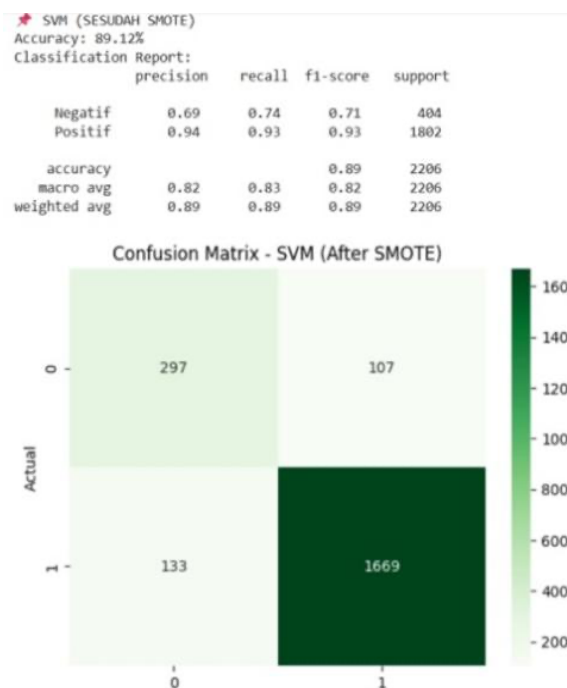
Gambar 7. Perbandingan Akurasi Model Klasifikasi

Dengan demikian, proses pembuatan model klasifikasi dalam penelitian ini menunjukkan bahwa pemilihan algoritma dan penanganan ketidakseimbangan data sangat memengaruhi kualitas prediksi. Model SVM dengan SMOTE dinyatakan sebagai model paling optimal untuk digunakan dalam klasifikasi sentimen pada data *tweet* yang dianalisis.


3.5 Evaluasi Model

Tahap evaluasi model dilakukan untuk mengukur kinerja dari algoritma klasifikasi yang digunakan dalam penelitian ini, yaitu *Support Vector Machine* (SVM) dan *Random Forest*, dalam mengelompokkan tweet ke dalam dua kategori sentimen: positif dan negatif. Evaluasi dilakukan dalam dua kondisi, yakni sebelum dan sesudah dilakukan penyeimbangan data menggunakan teknik SMOTE (*Synthetic Minority Over-sampling Technique*). Tujuan evaluasi ini adalah untuk mengetahui seberapa baik model mampu mengenali masing-masing kelas, terutama kelas minoritas (sentimen negatif) yang jumlahnya lebih sedikit dalam dataset.


Hasil evaluasi pada gambar 8. menunjukkan bahwa SVM setelah SMOTE memberikan performa terbaik dengan akurasi mencapai 89,12%, diikuti oleh SVM sebelum SMOTE dengan akurasi 88,53%. Penerapan SMOTE juga memberikan dampak positif terhadap *Random Forest*, di mana akurasi meningkat dari 83,64% menjadi 86,40%. Namun, peningkatan performa yang paling signifikan tidak hanya terlihat dari akurasi, tetapi dari kemampuan model dalam mengenali kelas negatif, yang tercermin pada metrik recall dan f1-score untuk kelas negatif. Pada SVM, f1-score kelas negatif naik dari 0,6195 sebelum SMOTE menjadi 0,7122 sesudah SMOTE, menunjukkan peningkatan kualitas klasifikasi terhadap opini yang lebih jarang muncul.



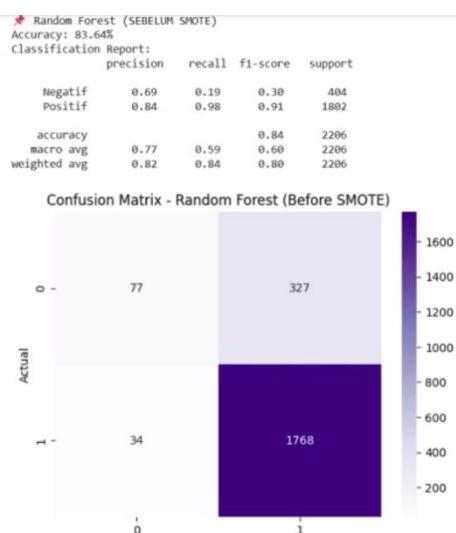
Gambar 8. Visualisasi *Confusion Matrix* – SVM(After SMOTE)



Gambar 9. Visualisasi Confusion Matrix – SVM (Before SMOTE)



Gambar 10. Visualisasi Confusion Matrix – Random Forest (After SMOTE)



Gambar 11. Visualisasi Confusion Matrix – Random Forest (Before SMOTE)

Analisis lebih dalam melalui *confusion matrix* mendukung temuan ini. Sebelum SMOTE pada gambar 9, SVM hanya mampu mengklasifikasikan 206 tweet negatif dengan benar dan salah memprediksi 198 lainnya. Setelah SMOTE gambar 10 diterapkan, prediksi benar terhadap tweet negatif meningkat

menjadi 297, dan kesalahan turun menjadi 107. Peningkatan serupa terlihat pada Random Forest yang awalnya hanya memprediksi 77 tweet negatif secara benar (dengan 327 kesalahan), dan setelah SMOTE, prediksi benar naik menjadi 171, sementara kesalahan menurun menjadi 233. Hal ini menegaskan bahwa SMOTE tidak hanya membantu dalam distribusi data, tetapi juga dalam menyeimbangkan kemampuan model dalam mengenali kedua kelas.

Visualisasi berupa grafik batang perbandingan akurasi memperlihatkan bahwa meskipun semua model memiliki akurasi di atas 83%, hanya SVM sesudah SMOTE yang mampu mempertahankan akurasi tinggi sembari memberikan hasil yang seimbang antar kelas. Berdasarkan keseluruhan hasil evaluasi, dapat disimpulkan bahwa model SVM dengan SMOTE merupakan model paling optimal dalam penelitian ini karena mampu menangani ketidakseimbangan kelas secara efektif dan menghasilkan klasifikasi yang akurat dan adil terhadap kedua jenis sentimen.

4. Kesimpulan

Penelitian ini bertujuan untuk menganalisis sentimen pengguna Twitter terhadap isu *Artificial Intelligence* (AI) menggunakan algoritma Support Vector Machine (SVM) dan *Random Forest* (RF). Berdasarkan hasil analisis dan evaluasi, berikut adalah kesimpulan penelitian:

Tahapan *preprocessing* data, meliputi pembersihan teks, normalisasi, tokenisasi, dan *stemming*, berhasil menghasilkan dataset yang berkualitas dan siap untuk proses klasifikasi. Penggunaan metode TF-IDF untuk vektorisasi teks mendukung pembangunan model machine learning yang andal. Pembagian data latihan dan uji dengan rasio 80:20 terbukti efektif sebagai dasar pembentukan model.

Algoritma SVM menunjukkan performa yang lebih unggul dibandingkan *Random Forest* dalam hal akurasi dan keseimbangan klasifikasi antar kelas. Penerapan teknik SMOTE secara signifikan meningkatkan kinerja model, khususnya dalam mengidentifikasi sentimen negatif yang memiliki jumlah data lebih sedikit. Model SVM yang dilatih dengan data setelah SMOTE mencapai akurasi sebesar 89,12% dan F1-score untuk kelas negatif sebesar 0,7122, menunjukkan kemampuan yang baik dalam menangani ketidakseimbangan data.

Meskipun Random Forest juga mengalami peningkatan performa pasca-SMOTE, hasilnya masih di bawah SVM.

Kombinasi algoritma *Support Vector Machine* dan teknik SMOTE terbukti sebagai pendekatan paling optimal untuk menganalisis sentimen terhadap isu AI di Twitter. Model ini menghasilkan klasifikasi yang akurat, adil, dan seimbang dalam mengenali sentimen positif maupun negatif dari pengguna.

Temuan ini dapat menjadi dasar bagi pengembangan sistem pemantauan opini publik secara otomatis terhadap isu-isu teknologi di masa mendatang, khususnya dalam konteks analisis sentimen berbasis media sosial.

Daftar Rujukan

- [1] I. A. Putri *et al.*, “ANALISIS SENTIMEN PERAN ARTIFICIAL INTELLIGENCE TERHADAP,” vol. 9, no. 3, pp. 4909–4916, 2025.
- [2] R. Wijanarko, D. E. Ratnawati, and P. P. Adikara, “Analisis Sentimen Dampak Perkembangan Artificial Intelligence (AI) pada Media Sosial X/Twitter Menggunakan Metode Random Forest,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 1, pp. 2548–964, 2017, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [3] S. A. Putra and A. Wijaya, “Analisis Sentimen Artificial Intelligence (Ai) Pada Media Sosial Twitter Menggunakan Metode Lexicon Based,” *JuSiTik J. Sist. dan Teknol. Inf. Komun.*, vol. 7, no. 1, pp. 21–28, 2023, doi: 10.32524/jusitik.v7i1.1042.
- [4] M.S. Afiyati and M. Samantri, “Perbandingan Algoritma Support Vector Machine dan Random Forest untuk Analisis Sentimen Terhadap Kebijakan Pemerintah Indonesia Terkait Kenaikan Harga BBM Tahun 2022,” *Jurnal JTik(Jurnal Teknologi Informasi dan Komunikasi)*, vol. 8, no. 1, pp. 1–9, 2024, doi: 10.35870/jtik.v8i1.1202.
- [5] P. Yang, S. Untuk, and P. Mahasiswa, “Pemanfaatan Kecerdasan Buatan Pada Algoritma K-Means Klustering Dan Sentiment Analysis Terhadap Strategi Promosi Yang Sukses Untuk Penerimaan Mahasiswa Baru,” *J. Sist. Inf. Univ. Suryadarma*, vol. 11, no. 1, pp. 1–6, 2014, doi: 10.35968/jsi.v11i1.1120.
- [6] Y. Akbar and T. Sugiharto, “Analisis Sentimen Pengguna Twitter di Indonesia Terhadap ChatGPT Menggunakan Algoritma C4.5 dan Naïve Bayes (Yuma Akbar 1*, Tri Sugiharto 2) Analisis Sentimen Pengguna Twitter di Indonesia Terhadap ChatGPT Menggunakan Algoritma C4.5 dan Naïve Bayes,” *J. Sains dan Teknol.*, vol. 5, no. 1, pp. 115–122, 2023, [Online]. Available: <https://doi.org/10.55338/saintek.v4i3.1368>
- [7] A. Cahya Kamilla, N. Priyani, R. Priskila, and V. Handrianus Pranatawijaya, “Analisis Sentimen Film Agak Laen Dengan Kecerdasan Buatan: Text Mining Metode Naïve Bayes Classifier,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 3, pp. 2923–2928, 2024, doi: 10.36040/jati.v8i3.9587.
- [8] Y. Jumaryadi, R. Meiyanti, R. Fajriah, and A. N. Mahsyar, “Implementasi Algoritma Random Forest Untuk Analisis Sentimen Ulasan Pengguna Aplikasi Merdeka Mengajar,” *Bulletin of Computer Science Research.*, vol. 5, no. 4, pp. 1–10, 2025, doi: 10.47065/bulletincsr.v5i4.530.
- [9] V. No, I. K. Najibulloh, D. Intan, and S. Saputra, “Edumatic : Jurnal Pendidikan Informatika Analisis Sentimen Ulasan Co-Pilot Google Play dengan SVM , Neural Network , dan Decision Tree,” vol. 9, no. 1, pp. 275–283, 2025, doi: 10.29408/edumatic.v9i1.29673.
- [10] P. H. Febryan, A. K. Negara, M. Farell, A. Ramadhan, and S. Informasi, “ANALISIS PENGGUNAAN AI DALAM ALGORITMA SOSIAL MEDIA :,” vol. 9, no. 1, pp. 1095–1102, 2025.
- [11] R. Mubarak, S. Maesaroh, M. Yusuf, K. Budiana, and M. R. Fahreza “Visualisasi Prediksi Prevalensi Balita Menggunakan Algoritma Random Forest Pada Lembaga Bidang Pangan,” *Journal CERITA:Creative Education of Research in Information Technology and Artificial Informatics.*, vol. 10, no. 2, pp. 164–171, Aug. 2024, doi:10.33050/cerita.v10i2.3176.
- [12] L. Tan, O. K. Tan, C. C. Sze, and W. W. Bin Goh, “Emotional Variance Analysis: A new sentiment analysis feature set for Artificial Intelligence and Machine Learning applications,” *PLoS One*, vol. 18, no. 1 January, pp. 1–22, 2023, doi: 10.1371/journal.pone.0274299.
- [13] T. H. J. Hidayat, Y. Ruldeviyani, A. R. Aditama, G. R. Madya, A. W. Nugraha, and M. W. Adisaputra, “Sentiment analysis of twitter data related to Rinca Island development using Doc2Vec and SVM and logistic regression as classifier,” *Procedia Comput. Sci.*, vol. 197, no. 2021, pp. 660–667, 2021, doi: 10.1016/j.procs.2021.12.187.
- [14] F. Iqbal *et al.*, “A Hybrid Framework for Sentiment Analysis Using Genetic Algorithm Based Feature Reduction,” *IEEE Access*, vol. 7, pp. 14637–14652, 2019, doi: 10.1109/ACCESS.2019.2892852.
- [15] Y. Kirelli and S. Arslankaya, “Sentiment Analysis of Shared Tweets on Global Warming on Twitter with Data Mining Methods: A Case Study on Turkish Language,” *Comput. Intell. Neurosci.*, vol. 2020, 2020, doi: 10.1155/2020/1904172.
- [16] H. Wisnu, M. Afif, and Y. Ruldeviyani, “Sentiment analysis on customer satisfaction of digital payment in Indonesia: A comparative study using KNN and Naïve Bayes,” *J. Phys. Conf. Ser.*, vol. 1444, no. 1, 2020, doi: 10.1088/1742-6596/1444/1/012034.
- [17] D. Pratmanto, R. Rousyati, F. F. Wati, A. E. Widodo, S. Suleman, and R. Wijianto, “App Review Sentiment Analysis Shopee Application in Google Play Store Using Naive Bayes Algorithm,” *J. Phys. Conf. Ser.*, vol. 1641, no. 1, 2020, doi: 10.1088/1742-6596/1641/1/012043.
- [18] L. Kurniasari and A. Setyanto, “Sentiment Analysis using Recurrent Neural Network,” *J. Phys. Conf. Ser.*, vol. 1471, no. 1, 2020, doi: 10.1088/1742-6596/1471/1/012018.
- [19] R. Novendri, A. S. Callista, D. N. Pratama, and C. E. Puspita, “Sentiment Analysis of YouTube Movie Trailer Comments Using Naïve Bayes,” *Bull. Comput. Sci. Electr. Eng.*, vol. 1, no. 1, pp. 26–32, 2020, doi: 10.25008/bcsee.v1i1.5.
- [20] S. Styawati, A. R. Isnain, N. Hendrastuty, and L. Andraini, “Comparison of Support Vector Machine and Naïve Bayes on Twitter Data Sentiment Analysis,” *J. Inform. J. Pengemb. IT*, vol. 6, no. 1, pp. 56–60, 2021, doi: 10.30591/jpit.v6i1.3245.