JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.92-105

KOMPARASI MODEL SVM, NAÏVE BAYES, DAN RANDOM FOREST DALAM ANALISIS SENTIMEN TERHADAP PERCAKAPAN PUBLIK TENTANG PERTAMINA

Hazlan Vazli[1)], Ryan Randy Suryono*[2)].
1. Sistem Informasi, Fakultas Teknik dan Ilmu Komputer, Univeristas Teknokrat Indonesia, Indonesia
2. Magister Ilmu Komputer, Fakultas Teknik dan Ilmu Komputer, Universitas Teknokrat Indonesia, Indonesia

Article Info
Kata Kunci: Analisis Sentimen, Pertamina, Random Forest, SVM, Naive Bayes, SMOTE

Keywords: *Sentiment Analysis, Pertamina, Random Forest, SVM, Naive Bayes, SMOTE*

Article history:
Received 21 April 2025
Revised 2 May 2025
Accepted 15 May 2025
Available online 1 March 2026

DOI :
https://doi.org/10.29100/jipi.v11i1.7699

* Corresponding author.
Corresponding Author
E-mail address:
ryan@teknokrat.ac.id

ABSTRAK
Penelitian ini memiliki tujuan untuk melakukan komparasi tiga perhitungan klasifikasi, yakni Naïve Bayes, Random Forest, dan Support Vector Machine (SVM), dalam melakukan Analisis Sentimen terkait opini masyarakat pada Pertamina di media Twitter. Data diperoleh melalui proses crawling menggunakan pustaka Tweepy pada rentang waktu 1 Januari 2025 hingga 17 Maret 2025, dengan jumlah total sebanyak 7.224 tweet. Setelah melalui tahap preprocessing dan pelabelan, ditemukan bahwa sebagian besar percakapan didominasi oleh sentimen negatif. Salah satu tantangan yang dihadapi dalam penelitian ini adalah ketidakseimbangan distribusi data antar kelas sentimen. Untuk mengatasi permasalahan tersebut, digunakan teknik SMOTE (Synthetic Minority Over-sampling Technique) guna meneysuaikan jumlah data pada setiap kelasPenilaian dilakukan dengan menggunakan pengukuran presisi, akurasi, recall, dan skor F1-Score, serta dianalisis melalui confusion matrix. Hasil akhir menunjukkan bahwa penerapan SMOTE berdampak positif terhadap peningkatan kinerja model. Akurasi Naïve Bayes meningkat dari enam puluh menjadi tujuh puluh delapan, Random Forest dari tujuh puluh menjadi delapan puluh delapan, dan SVM mengalami peningkatan paling tinggi dari tujuh puluh lima menjadi sembilan puluh satu. Berdasarkan hasil tersebut, SVM dinilai sebagai model yang paling optimal dalam mengklasifikasikan sentimen publik terhadap Pertamina setelah dilakukan penyeimbangan data.

ABSTRACT
This study aims to compare three classification calculations, namely Naïve Bayes, Random Forest, and Support Vector Machine (SVM), in conducting Sentiment Analysis related to public opinion on Pertamina on Twitter. Data was obtained through a crawling process using the Tweepy library in the period from January 1, 2025 to March 17, 2025, with a total of 7,224 tweets. After going through the preprocessing and labeling stages, it was found that most of the conversations were dominated by negative sentiment. One of the challenges faced in this study is the imbalance in data distribution between sentiment classes. To overcome this problem, the SMOTE (Synthetic Minority Over-sampling Technique) technique is used to adjust the amount of data in each class. The assessment was carried out using precision, accuracy, recall, and F1-Score measurements, and analyzed through a confusion matrix. The final results show that the application of SMOTE has a positive impact on improving model performance. The accuracy of Naïve Bayes increased from sixty to seventy-eight, Random Forest from seventy to eighty-eight, and SVM experienced the highest increase from seventy-five to ninety-one. Based on these results, SVM is considered the most optimal model in classifying public sentiment towards Pertamina after data balancing.

I. PENDAHULUAN

PERTAMINA merupakan salah satu Badan Usaha Milik Negara (BUMN) strategis yang berperan penting dalam penyediaan energi nasional, khususnya bahan bakar minyak (BBM)[1]. Sebagai perusahaan energi terbesar di Indonesia, Pertamina memegang peranan vital dalam mendukung ketahanan energi nasional.

Setiap kebijakan dan pelayanan yang diberikan oleh perusahaan ini tidak hanya berdampak langsung pada masyarakat, tetapi juga menjadi bahan perbincangan yang luas di ruang publik, terutama di media sosial[2].

Media sosial seperti Twitter menjadi wadah yang banyak digunakan oleh masyarakat untuk mengekspresikan opini, keluhan, maupun dukungan terhadap berbagai isu, termasuk kebijakan dan layanan Pertamina. Opini-opini tersebut membentuk sentimen publik yang dapat dimanfaatkan sebagai sumber informasi strategis dalam pengambilan keputusan. Untuk mengelola dan menganalisis opini dalam jumlah besar tersebut, diperlukan pendekatan berbasis teknologi seperti analisis sentimen[3].

Analisis sentimen merupakan tahapan yang akan digunakan untuk mengolah dan memahami data teks yang tidak terstruktur, dengan tujuan mengidentifikasi dan menilai emosi atau opini yang terkandung dalam sebuah pernyataan, komentar, atau pandangan.[4]. Tujuan dari analisis ini adalah untuk mengidentifikasi sikap atau kecenderungan opini terhadap suatu isu, apakah bernuansa positif, negatif, atau netral. Dalam praktiknya yang melibatkan teknik *text mining*, metode yang sering diterapkan meliputi Naïve Bayes, Random Forest, dan Support Vector Machine (SVM)[5].

Naive Bayes merupakan algoritma klasifikasi berbasis probabilistik yang dikenal karena kesederhanaannya serta kemampuannya dalam memberikan performa yang cukup baik, terutama pada permasalahan dengan data teks seperti analisis sentimen. SVM merupakan algoritma yang sangat baik dalam menangani data berdimensi tinggi dan mampu membedakan kelas secara optimal. Sementara itu, Random Forest merupakan metode ensemble yang menggabungkan beberapa pohon keputusan untuk menghasilkan klasifikasi yang lebih stabil dan akurat[6].

Meskipun banyak penelitian telah mengeksplorasi analisis sentimen mengenai isu-isu terkait bahan bakar di Indonesia, khususnya mengenai kenaikan harga dan reformasi subsidi, masih terdapat kesenjangan yang signifikan dalam pemeriksaan sentimen publik terhadap praktik pencampuran bahan bakar. Tidak seperti negara-negara lain, Indonesia menyajikan konteks sosial, ekonomi, dan peraturan yang unik seputar isu ini. Penelitian yang ada sebagian besar membahas reaksi publik terhadap kenaikan biaya bahan bakar atau penyesuaian subsidi, tetapi jarang berfokus pada topik pencampuran bahan bakar — suatu area yang sering memicu perdebatan di Indonesia, khususnya yang berkaitan dengan kualitas bahan bakar, persepsi keselamatan, dan kepercayaan publik terhadap perusahaan milik negara seperti PT. Mengingat bahwa praktik pencampuran bahan bakar di Indonesia dipengaruhi oleh faktor-faktor yang berbeda dibandingkan dengan negara-negara lain, eksplorasi yang lebih mendalam terhadap analisis sentimen dalam konteks khusus ini masih kurang[7].

Menganalisis sentimen publik terkait pencampuran bahan bakar memiliki signifikansi strategis bagi pengambilan keputusan dalam sektor energi nasional. Wawasan yang diperoleh dari analisis ini dapat menjadi referensi penting bagi para pembuat kebijakan, khususnya dalam konteks upaya transisi energi dan perumusan ulang kebijakan bahan bakar bersubsidi. Dengan memahami persepsi, kekhawatiran, dan harapan publik, baik pemerintah maupun pemangku kepentingan industri lebih siap untuk mengembangkan kebijakan yang lebih responsif dan efektif sekaligus mengurangi potensi penolakan publik terhadap perubahan kebijakan energi. Selain itu, hasil analisis sentimen dapat membantu mengidentifikasi isu-isu mendesak yang memerlukan perhatian segera dan memperkuat upaya untuk membina komunikasi yang transparan dan bertanggung jawab dengan publik[8].

Memposisikan penelitian ini dalam konteks regional, khususnya di kawasan ASEAN, sama pentingnya. Negara-negara seperti Malaysia dan Thailand juga menghadapi tantangan serupa terkait kebijakan subsidi bahan bakar, praktik pencampuran bahan bakar, dan transisi energi yang lebih luas. Namun, karakteristik sosial, ekonomi, dan kebijakan Indonesia yang unik seperti perbedaan volume konsumsi bahan bakar, persepsi publik, dan struktur subsidi menciptakan dinamika yang berbeda. Dengan membandingkan temuan analisis sentimen dari Indonesia dengan temuan dari negara-negara ASEAN lainnya, penelitian ini menawarkan perspektif yang lebih holistik tentang sikap dan kesiapan Indonesia dalam menghadapi tantangan transisi energi regional[9].

Penelitian ini juga sejalan dengan upaya untuk memajukan Tujuan Pembangunan Berkelanjutan (SDGs), khususnya Tujuan 7 (Energi Terjangkau dan Bersih) dan Tujuan 12 (Konsumsi dan Produksi yang Bertanggung Jawab). Analisis sentimen terhadap isu pencampuran bahan bakar dapat memberikan wawasan berharga untuk membentuk kebijakan yang mempromosikan penggunaan energi yang lebih bersih dan lebih efisien, sekaligus mendorong praktik konsumsi yang bertanggung jawab dalam masyarakat. Oleh karena itu, temuan penelitian ini dapat memberikan kontribusi yang berarti bagi inisiatif Indonesia dalam mendukung agenda pembangunan berkelanjutan dalam sektor energi[9].

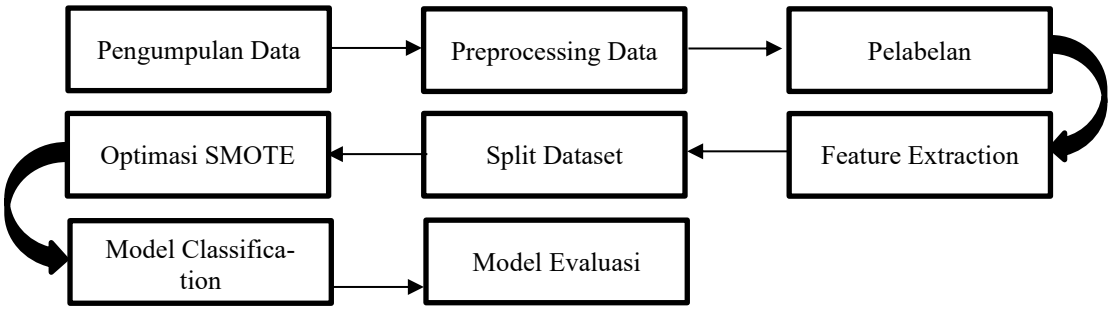
Namun, Salah satu tantangan umum dalam pengolahan data dari media sosial adalah adanya ketimpangan distribusi antar kelas sentimen. Untuk mengatasi permasalahan ini, penelitian ini turut menerapkan metode Synthetic Minority Oversampling Technique (SMOTE) sebagai upaya penyeimbangan data. SMOTE (Synthetic

Minority Over-sampling Technique) Beroperasi dengan menghasilkan sampel sintetis dari kelas yang kurang terwakili, berdasarkan data yang telah ada, sehingga membantu menyeimbangkan distribusi kelas dalam dataset dan meningkatkan performa model klasifikasi, khususnya pada data yang tidak seimbang[10].

Penelitian ini memiliki tujuan untuk membandingkan kinerja tiga algoritma, yakni Support Vector Machine (SVM), Naïve Bayes, dan Logistic Regression, dalam upaya meningkatkan tingkat akurasi analisis sentimen terhadap opini publik terkait topik pencampuran bahan bakar. Melalui perbandingan berbagai metode tersebut, diharapkan dapat ditemukan metode klasifikasi yang paling efektif. Setiap algoritma memiliki kelebihan dan keterbatasannya sendiri dalam mengklasifikasikan sentimen positif, negatif, maupun netral. Faktor seperti karakteristik data, kompleksitas model, serta sensitivitas terhadap ketidakseimbangan kelas dapat memengaruhi akurasi dan efektivitas masing-masing algoritma dalam melakukan klasifikasi sentimen.[11]. Temuan dari penelitian ini diharapkan dapat membantu PT Pertamina dalam memantau keluhan dari pengguna bahan bakar terkait pencampuran, serta memperbaiki sistem penjualan agar tidak menimbulkan permasalahan di kemudian hari.

II. METODOLOGI PENELITIAN

Pada bagian berikut, akan diuraikan pendekatan dan langkah-langkah metodologis yang diterapkan dalam studi ini, yang terdiri dari beberapa tahapan sistematis untuk mendukung proses analisis secara menyeluruh, dimulai dengan pengumpulan data melalui proses *scraping* data dari Twitter serta pemanfaatan sumber pustaka sebagai bahan referensi. Tahapan selanjutnya adalah pemrosesan data melalui tahap *preprocessing*, Hal ini melibatkan proses seperti *cleansing*, *case folding*, normalisasi, *tokenizing*, penghilangan *stopwords*, dan *stemming*. Setelah langkah-langkah ini, klasifikasi teks dilakukan, dan hasilnya dianalisis. Alur kerja penelitian ini ditunjukkan pada Gambar 1.



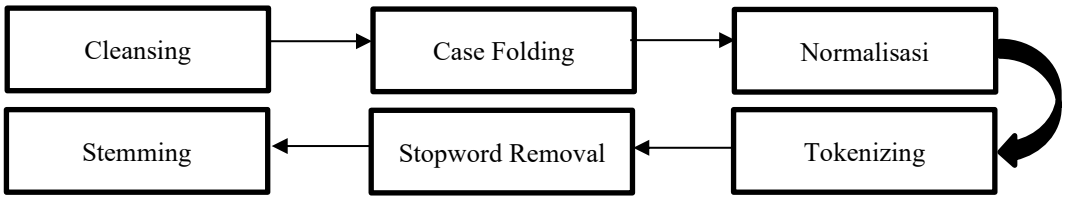
Gambar 1. Tahapan Penelitian

2.1 Metode Pengumpulan Data

Tahap ini dilakukan untuk mengumpulkan data berupa *tweet* dan komentar dari pengguna aplikasi media sosial Twitter. Pengambilan data dilakukan melalui proses *crawling* pada platform Twitter. Data yang diperoleh berasal dari rentang waktu 1 Januari 2025 hingga 17 Maret 2025, dengan total sebanyak 7.224 *tweet* yang mengandung kata kunci "Pertamina", "Pertamax", dan "Oplosan". Pengambilan data dilakukan melalui metode *data crawling* dengan memanfaatkan pustaka (*library*) Python, yang memungkinkan penelusuran dan pengambilan informasi secara otomatis dari sumber tertentu.

2.2 Tahap Preprocessing

Preprocessing merupakan serangkaian tahapan atau teknik yang diterapkan pada data mentah sebelum memasuki proses analisis atau pemodelan. Tahap *preprocessing* diperlukan agar data yang dianalisis dapat diprediksi secara akurat[12]. Metode koreksi pada setiap tahap *preprocessing* dapat menghilangkan jenis artefak tertentu, meskipun masih mungkin meninggalkan efek tertentu, namun tetap berkontribusi dalam meningkatkan kualitas data. Tahapan-tahapan dalam proses *preprocessing* dapat dilihat pada Gambar 2.



Gambar 2. Tahapan Preprocessing Data

A. Cleansing

Cleansing merupakan salah satu tahapan dalam preprocessing data teks yang bertujuan untuk membersihkan informasi dari komponen-komponen yang tidak penting. Strategi ini menggabungkan penghilangan aksentuasi seperti titik (.), koma (,), tanda seru (!), tanda alamat (?), dan tanda kurung (()) untuk mengatur ulang konten dan mendorong penyelidikan lebih awal. Selain itu, proses ini juga mencakup penghapusan data duplikat serta simbol-simbol seperti nama pengguna (*username*), simbol *retweet*, dan tautan (*URL*).[13] Dari total 7.224 *tweet* yang terdapat dalam *dataset*, setelah melalui proses *cleansing*, jumlah data berkurang menjadi 6.686 *tweet*.

B. Case Folding

Case folding merupakan merupakan suatu pengaturan dalam *preprocessing* informasi konten yang bertujuan untuk mengubah semua huruf dalam konten menjadi huruf kecil. Tujuan dari tahap ini adalah untuk menyamakan format penulisan sehingga mempermudah proses analisis data teks secara konsisten. Proses ini penting dilakukan karena bahasa pemrograman seperti Python bersifat *case sensitive*, sehingga penerapan *case folding* berfungsi untuk menyeragamkan penulisan kata agar dapat dikelompokkan dengan lebih akurat dalam proses analisis selanjutnya[13].

C. Normalisasi

Normalisasi adalah proses perubahan kata-kata yang nonbaku atau tidak standar menjadi bentuk yang sesuai dengan Struktur bahasa, dengan merujuk pada kamus kata baku dalam bahasa Indonesia[14].

D. Tokenizing

Tokenizing merupakan proses untuk membagi kalimat atau paragraf menjadi unit-unit kata atau token secara terpisah. Proses ini umumnya mengandalkan karakter spasi sebagai pemisah untuk memotong setiap kata dalam suatu kalimat atau paragraf. Pada tahap ini digunakan perintah split() dalam bahasa pemrograman Python untuk memisahkan setiap kata, yang hasilnya berupa deretan kata yang dipisahkan dengan tanda koma[15].

E. Stopword Removal

Stop words merupakan kata-kata umum yang kerap muncul dalam teks, namun tidak memiliki nilai informasi yang signifikan dalam proses analisis. Oleh karena itu, kata-kata tersebut biasanya dihapus agar tidak memengaruhi hasil analisis secara keseluruhan, seperti kata sambung, kata depan, atau kata umum lainnya[16].

F. Stemming

Stemming merupakan tahap yang bertujuan untuk menyederhanakan kata menjadi bentuk dasarnya. Proses ini dilakukan dengan menghapus afiks, seperti awalan, akhiran, maupun sisipan, sehingga berbagai variasi kata yang berasal dari satu kata dasar dapat dikelompokkan ke dalam satu bentuk yang sama[17].

2.3 Pelabelan Data

Setelah tahap *preprocessing* selesai, langkah selanjutnya adalah proses pelabelan. Tahapan ini bertujuan untuk memberikan label pada *tweet* pengguna Twitter berdasarkan nilai sentimennya. Setiap *tweet* akan diklasifikasikan ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Selain itu, visualisasi memanfaatkan *word cloud* untuk menampilkan hasil pelabelan secara visual dan informatif[18].

2.4 Feature Extraction

Pada tahap ini, teks diubah menjadi bentuk numerik dengan cara menetapkan bobot atau nilai tertentu pada setiap kata atau fitur, sehingga dapat diproses lebih lanjut oleh algoritma komputer. *Term Frequency* (TF) digunakan untuk mengevaluasi seberapa sering suatu kata muncul dalam dokumen, sementara *Inverse Document Frequency* (IDF) digunakan untuk menentukan seberapa sedikit kata tersebut muncul dalam keseluruhan teks. Kombinasi keduanya membantu menentukan pentingnya kata dalam konteks analisis teks. Kombinasi antara TF dan IDF memungkinkan pemberian bobot yang lebih proporsional pada setiap kata, berdasarkan frekuensi kemunculannya dalam dokumen serta distribusinya di seluruh kumpulan dokumen.[19]. Hasil perhitungan *TF-IDF* inilah yang selanjutnya dijadikan sebagai fitur utama dalam proses klasifikasi sentimen, karena nilai ini mencerminkan pentingnya setiap kata dalam konteks dokumen dan keseluruhan korpus.

2.5 Split Dataset

Pada tahap *Split Dataset*, Data tersebut dibagi menjadi dua bagian, yaitu informasi persiapan yang khusus dilakukan untuk menyiapkan demonstrasi, dan informasi pengujian yang dilakukan untuk menguji kinerja model setelah proses persiapan, Untuk memastikan bahwa model *machine learning* dapat dilatih dan dievaluasi dengan

cara yang paling efektif. Pembagian data dilakukan dengan alokasi 70% untuk data pelatihan dan 30% untuk data pengujian, guna memastikan model dapat dilatih dengan cukup data dan juga diuji untuk mengukur akurasi serta performanya.

2.6 Optimasi SMOTE

Optimasi SMOTE merupakan proses yang digunakan untuk mengatasi ketidakseimbangan pada data latih. Metode SMOTE adalah teknik yang digunakan untuk menghasilkan data sintetis baru dengan memperbanyak sampel dari kelas minoritas dalam dataset. Teknik ini dilakukan dengan melakukan *resampling* terhadap data yang tersedia sehingga distribusi data menjadi lebih seimbang. Tujuan dari penerapan SMOTE adalah untuk meningkatkan kinerja dan efektivitas model agar pengolahan data menjadi lebih optimal[19].

2.7 Model Classification

Pada langkah ini, sebuah klasifikasi dibangun berdasarkan informasi tweet yang telah melalui serangkaian bentuk persiapan sebelumnya, seperti *preprocessing*, ekstraksi data, penerapan SMOTE *(Synthetic Minority Oversampling Technique)*, dan pembagian informasi. Semua tahapan ini bertujuan untuk merencanakan informasi sehingga dapat digunakan secara ideal dalam pegangan klasifikasi. Selain itu, pembuat menerapkan beberapa model klasifikasi, salah satunya adalah *Naïve Bayes Classifier*, yang merupakan strategi klasifikasi yang menerapkan Hipotesis Bayes dengan dugaan bahwa setiap variabel atau kejadian dianggap independen satu sama lain. Dengan kata lain, jika hasil hasil tertentu sudah diketahui, kemungkinan persepsi gabungan dapat dihitung dengan meningkatkan kemungkinan setiap kejadian secara independen, dengan menerima bahwa kejadian tersebut independen satu sama lain.

2.8 Model Evaluasi

Evaluasi model dilakukan untuk dilakukan untuk mengetahui seberapa meyakinkan pelaksanaan klasifikasi yang telah dibangun, dengan mengukur seberapa akurat model dalam mengklasifikasikan data berdasarkan hasil prediksi yang dihasilkan, yaitu Support Vector Machine (SVM)**,** Naive Bayes, dan Random Forest, dalam mengklasifikasikan opini publik tentang Pertamina. Kinerja model ini diukur dengan menggunakan *confusion matrix* untuk menghitung berbagai metrik evaluasi, seperti akurasi, presisi*, recall*, dan *F1-score*, yang memberikan gambaran yang lebih komprehensif mengenai performa model dalam melakukan klasifikasi.

III. HASIL DAN PEMBAHASAN

A. Hasil

Pada segmen ini, kita akan menggambarkan hasil yang didapat setelah pengujian menggunakan tiga kalkulasi pembelajaran mesin yang terhubung ke data, yaitu Naïve Bayes, Random Forest, dan Support Vector Machine (SVM), serta analisis mengenai performa masing-masing algoritma**,** dalam analisis sentimen terhadap Percakapan Publik tentang Pertamina. Selain itu, akan dijelaskan pula bagaimana penerapan teknik SMOTE berhasil meningkatkan kinerja model, khususnya dalam mengatasi ketidakseimbangan data. Setiap tahapan, mulai dari pengumpulan data, *preprocessing*, pelabelan, penerapan SMOTE, hingga evaluasi model, akan dibahas secara rinci.

3.1 Pengumpulan Data

Pengorganisasian utama dalam penyelidikan ini adalah penanganan pengumpulan data, di mana data yang dianalisis berada dalam kerangka konten yang diperoleh melalui prosedur merayap memanfaatkan Tweepy API dari Twitter, dengan rentang waktu pengambilan data antara 1 Januari 2025 hingga 17 Maret 2025, menggunakan bahasa pemrograman Python. Dari Hasil tersebut Pengumpulan Data mendapatkan 7.224 tweet yang mengandung kata kunci "Pertamina", "Pertamax", dan "Oplosan". Meskipun demikian, Data yang terkumpul masih mengandung bagian yang tidak relevan, seperti duplikasi teks, tanda baca berlebihan, dan karakter khusus, yang dapat memengaruhi kualitas analisis sentimen. Oleh karena itu, diperlukan tahap *preprocessing* untuk menyaring dan membersihkan data sebelum dilakukan proses klasifikasi.

3.2 Preprocessing Data

Data hasil *crawling* masih mengandung bagian-bagian yang tidak relevan, seperti duplikasi teks, penggunaan tanda baca yang berlebihan, serta karakter-karakter khusus yang berpotensi memengaruhi akurasi dalam analisis sentimen. Oleh karena itu, diperlukan tahap *preprocessing* guna menyaring dan membersihkan data sebelum dilakukan proses klasifikasi[20].

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.92-105

a. Cleansing

Pada tahap ini, teks dibersihkan dengan menghapus karakter-karakter khusus, seperti tanda baca yang tidak perlu, angka, dan simbol, untuk memastikan hanya elemen-elemen yang relevan yang tersisa untuk analisis lebih lanjut. Tujuan dari langkah ini adalah untuk menjamin bahwa data hanya berisi kata-kata yang relevan untuk analisis sentimen. Proses ini diterapkan pada data komentar setelah tahap pembersihan sebelumnya.

TABEL I
HASIL CLEANSING

Content	*Cleansing*
@msaid_didu @prabowo Serius nanya kalau bapak dutawari komisaris pertamina atau dirut pertaminan mau ga?	Serius nanya kalau bapak dutawari komisaris pertamina atau dirut pertaminan mau ga

b. Case Folding

Case Folding merupakan langkah pemrosesan teks yang bertujuan untuk menstandardisasi format teks dengan mengubah semua karakter menjadi huruf kecil. Hal ini memastikan tidak ada perbedaan antara huruf besar dan huruf kecil selama proses analisis, mengingat bahasa pemrograman Python bersifat *case sensitive*. Dengan demikian, kata seperti "Pertamina", "PERTAMINA", dan "pertamina" akan diperlakukan sama oleh sistem dan dapat dikelompokkan secara konsisten pada proses analisis selanjutnya.

TABEL II
HASIL CASE FOLDING

Cleansing	*Case Folding*
LO PIKIR PERTAMINA KEK GITU YG JADI DIRUTNYA SIAPEEEE	lo pikir pertamina kek gitu yg jadi dirutnya siapeeee

c. Normalisasi

Normalisasi merupakan proses mengubah kata-kata tidak baku atau tidak sesuai kaidah bahasa dalam teks menjadi bentuk kata yang sesuai dengan aturan bahasa Indonesia. Tahap ini dilakukan dengan mengacu pada kamus atau daftar kata baku yang digunakan sebagai acuan. Tujuan dari proses normalisasi adalah untuk menyamakan variasi penulisan kata, khususnya pada teks media sosial yang sering mengandung singkatan, kata tidak baku, atau bentuk slang, sehingga data menjadi lebih konsisten dan layak untuk dianalisis pada tahap selanjutnya.

TABEL III
HASIL NORMALISASI

Case Folding	Normalisasi
pertamina siapkan satgas ramadan dan idulfitri untuk pastikan kelancaran distribusi energi mantap nih jadi ngga perlu khawatir buat yang mau mudik nanti	pertamina siapkan satgas ramadan dan idulfitri untuk pastikan kelancaran distribusi energi mantap ini jadi tidak perlu khawatir buat yang mau mudik nanti httpstcojasqkjqi

d. Tokenizing

Tahapan ini penting dilakukan agar setiap kata dalam teks dapat dianalisis secara individual. Dalam praktiknya, proses tokenizing biasanya dilakukan dengan memanfaatkan spasi sebagai pemisah antar kata. Pada implementasi dengan bahasa pemrograman Python, proses ini dapat dilakukan dengan menggunakan fungsi split() yang akan memisahkan setiap kata berdasarkan spasi.

TABEL IV
HASIL TOKENIZING

Normalisasi	*Tokenizing*
agar mudik aman bbm lancar tidak pakai drama kehabisan di jalan pertamina siapkan satgas ramadan dan idulfitri untuk pastikan kelancaran distribusi energi bagus job pertamina dukung banget kalau begini	agar,mudik,aman,bbm,lancar,tidak,pakai,drama, kehabisan,di,jalan,pertamina,siapkan,satgas,ramadan, dan,idulfitri,untuk,pastikan,kelancaran,distribusi,energi,bagus,job, pertamina,dukung,banget,kalau,begini,httpstcowsyuzczy

e. Stopword Removal

Langkah ini melibatkan pemrosesan teks yang ditujukan untuk menghilangkan kata-kata umum yang tidak memiliki makna signifikan dalam analisis seperti "yang", "dan", "karena", bersama dengan kata hubung atau kata bantu lainnya. Penghapusan kata-kata ini membantu mengurangi kompleksitas komputasi serta meningkatkan relevansi kata-kata yang dianalisis dalam proses analisis sentimen. Tabel 5 berikut menyajikan contoh perbedaan data ulasan sebelum dan sesudah tahap penghapusan kata umum dilakukan.

TABEL V
HASIL STOPWORD REMOVAL

Tokenizing	*Stopword Removal*
ini,yang,legal,yang,tidak,legal,mah,banyak,ada,sebabnya, kok,pertamina,buat,sistem,barcode,buat,bbm,subsidi	legal,legal,mah,pertamina,sistem,barcode,bbm,subsidi

f. Stemming

Stemming dilakukan untuk mengubah kata menjadi bentuk dasarnya agar model dapat mengenali variasi kata sebagai satu entitas yang sama. Sebagai contoh, kata "kenaikan" akan dikonversi menjadi "naik". Tabel 7 dibawah ini adalah contoh hasil dan perbedaan data setelah dilakukan tahap *Stemming*.

TABEL VI
HASIL STEMMING

Stopword Removal	*Stemming*
rela,rugi,pertamina,biarin,asing,kaya,produk,adil,jujur,pemerintah	rela rugi pertamina biarin asing kaya produk adil jujur perintah

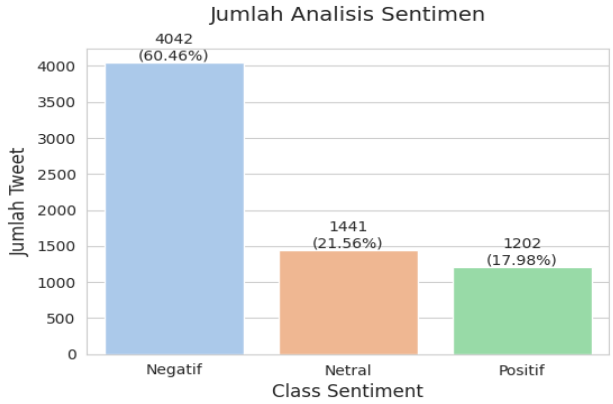
3.3 Pelabelan Data

Setelah tahap *preprocessing* data selesai, tahap berikutnya adalah *labeling* data. Tahap ini bertujuan untuk memberikan label pada setiap konten komentar yang dipublikasikan oleh pengguna Twitter, berdasarkan polaritas sentimennya. Label yang diberikan menunjukkan apakah komentar tersebut bersifat positif, negatif, atau netral. Hasil dari proses pelabelan ini disajikan dalam Tabel 6**.**

TABEL VII
HASIL PREPROCESSING

Stemming	*Score*	*Label*
serius dutawari komisaris pertamina dirut pertaminan	-1	Negatif
mudik aman bbm lancar pakai drama habis jalan pertamina siap satgas ramadan idulfitri pasti lancar distribusi energi bagus job pertamina dukung banget	4	Positif
pikir pertamina dirutnya siapeeee	0	Netral

Berdasarkan hasil tahap pelabelan, klasifikasi sentimen menghasilkan 1.202 komentar positif, 4.042 komentar negatif, dan 1.441 komentar netral. Klasifikasi ini ditentukan melalui perhitungan skor polaritas. Apabila skor ekstremitas lebih besar dari 0, maka konten tersebut dikategorikan sebagai asumsi positif. Apabila skor ekstremitas kurang dari 0, maka konten tersebut termasuk dalam asumsi negatif. Sementara itu, skor polaritas sebesar 0 menunjukkan bahwa teks diklasifikasikan sebagai sentimen netral. Visualisasi dari hasil pelabelan ini ditampilkan pada Gambar 3.



Gambar 3. Visualisasi Hasil Pelabelan

Hasil pelabelan menunjukkan bahwa mayoritas komentar mencerminkan sentimen negatif, yaitu sebesar 60,46% dari total komentar. Sementara itu, komentar dengan sentimen positif sebesar 17,98% dan komentar netral sebesar 21,56%. Temuan ini mengindikasikan bahwa sebagian besar percakapan publik mengenai

Pertamina di media sosial didominasi oleh sentimen negatif.

3.4 Visualisasi *Wordcloud*

Penggunaan *Word Cloud* bertujuan untuk memvisualisasikan dataset dalam bentuk grafis, Dengan demikian, Tahap ini membantu dalam mengenali teks yang memiliki frekuensi kemunculan tertinggi di dalam dokumen. Proses pembuatan *Word Cloud* ini dilakukan dengan memanfaatkan pustaka matplotlib dalam bahasa pemrograman Python[21]. Gambar 4 menampilkan hasil visualisasi dalam bentuk Word Cloud. Dalam visualisasi tersebut, ukuran teks yang lebih dominan besar merepresentasikan Intensitas kemunculan yang lebih tinggi dalam dokumen, seperti kata "pertamina" dan "korupsi".



Gambar 4. Visualisasi Hasil *Wordcloud*

3.5 Feature Extraction

Feature Extraction adalah proses yang digunakan untuk mengubah data berbasis teks menjadi format numerik, sehingga dapat diproses lebih lanjut oleh algoritma *machine learning*. Dalam studi ini, teknik yang digunakan untuk melakukan ekstraksi fitur adalah TF-*IDF (Term Frequency–Inverse Document Frequency)*. Strategi ini menghitung seberapa sering kata muncul dalam laporan, dengan mempertimbangkan tingkat kelangkaannya di seluruh kumpulan dokumen, kemudian mengalikannya dengan tingkat kelangkaan kata tersebut dalam seluruh kumpulan dokumen *(inverse document frequency)*[22]. Persiapan ini menghasilkan representasi numerik dari informasi konten yang kemudian digunakan sebagai sorotan paling dalam investigasi klasifikasi sentimen.

TABEL VII
HASIL TF-IDF

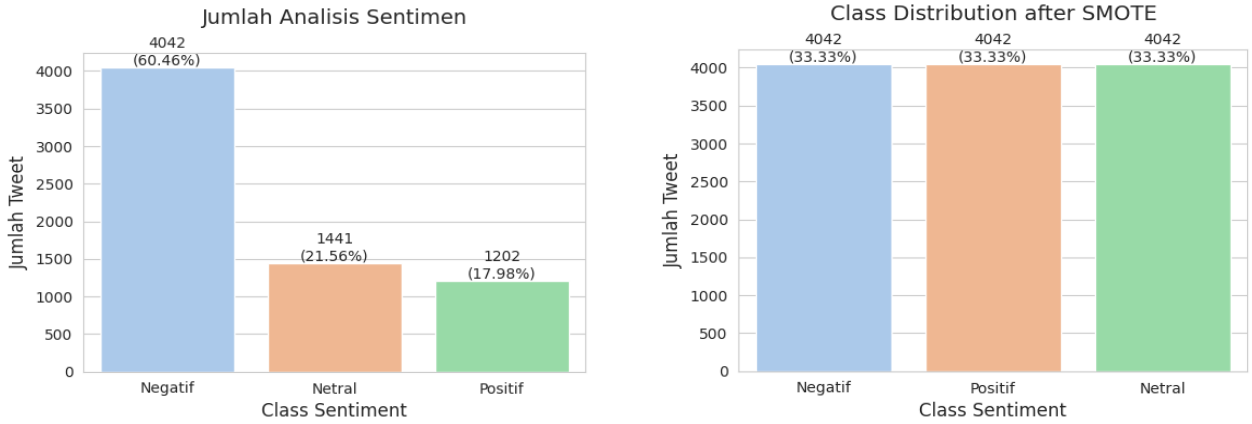
	Term	TFIDF_SUM
9287	pertamina	347.051649
6852	korupsi	251.533559
8838	oplos	223.723295
5857	isu	169.890250
9336	pertamina	167.283196
123	ahok	158.333806
826	bbm	153.543885

Tabel 7 menyajikan tujuh kata dengan nilai TF-IDF tertinggi yang ditemukan dalam komentar Twitter terkait kasus Pertamina. Nilai TF-IDF menggambarkan seberapa penting suatu kata dalam suatu catatan relatif terhadap kejadiannya dalam keseluruhan koleksi arsip. Kata-kata dengan nilai tinggi, seperti "pertamina", "korupsi", dan "oplos", mencerminkan topik utama yang dominan dalam percakapan publik. Kata-kata ini memiliki peran penting dalam membedakan sentimen pada proses analisis.

3.6 Optimasi SMOTE

Ketidakseimbangan distribusi data pada kategori sentimen diatasi melalui metode SMOTE, yang bekerja dengan menghasilkan data sintetis dari kelas minoritas menggunakan pendekatan interpolasi terhadap data yang memiliki karakteristik serupa. Dengan demikian, proporsi data antar kelas menjadi lebih seimbang. Teknik ini penting diterapkan karena ketidakseimbangan data dapat menyebabkan model pembelajaran mesin cenderung mengabaikan kelas yang jumlahnya lebih sedikit[23]. Dengan menerapkan SMOTE, diharapkan kinerja model dalam mengklasifikasikan setiap kelas sentimen menjadi lebih optimal dan akurat.

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.92-105



Gambar 6. Visualisasi Before dan After SMOTE

Gambar 6 menunjukkan distribusi dataset sebelum dan setelah penerapan SMOTE. Sebelum penerapan SMOTE, dataset didominasi oleh sentimen negatif, sementara sentimen positif dan netral memiliki proporsi yang jauh lebih kecil. Ketidakseimbangan ini menyebabkan model cenderung mengklasifikasikan komentar ke dalam kategori negatif, sehingga mengurangi akurasi dalam mengenali sentimen positif dan netral. Setelah SMOTE diterapkan, kelas minoritas (positif dan netral) diperbanyak dengan data sintetis sehingga distribusi data menjadi lebih seimbang. Dengan demikian, model menjadi lebih sensitif terhadap sentimen positif dan netral, serta mampu meningkatkan akurasi klasifikasi secara keseluruhan.

3.7 Hasil Pengujian Model

Bagian ini menyajikan hasil penilaian tayangan yang menguraikan pelaksanaan setiap perhitungan dalam mengklasifikasikan opini positif, negatif, dan netral berdasarkan informasi Twitter yang telah melalui proses *preprocessing*. Sebanyak 70% data digunakan untuk pelatihan, sedangkan 30% sisanya digunakan untuk pengujian. Evaluasi model dilakukan berdasarkan metrik termasuk akurasi, presisi, *recall*, dan skor F1, dengan hasil ditampilkan dalam dua kondisi, sebelum dan setelah penggunaan SMOTE.

a. Hasil Sebelum Penerapan SMOTE

Sebelum penerapan teknik SMOTE, ketiga model menunjukkan perbedaan kinerja yang cukup signifikan. Tabel 8 di bawah ini menyajikan hasil evaluasi masing-masing model pada kondisi awal sebelum dilakukan penyeimbangan data.

TABEL VIII
HASIL SEBELUM PENERAPAN SMOTE

Model	Precision (Negatif %)	Precision (Positif %)	Recall (Negatif %)	Recall (Positif %)	F1-Score (Negatif %)	F1-Score (Positif %)	Accuracy
Naïve Bayes	59.00	100.00	100.00	3.00	74.00	5.00	60.00
Random Forest	73.00	75.00	92.00	38.00	82.00	50.00	70.00
SVM	79.00	79.00	94.00	56.00	86.00	65.00	75.00

Tabel di atas menunjukkan bahwa ketiga model mengalami kesulitan dalam mengklasifikasikan sentimen positif dan netral akibat ketidakseimbangan data, di mana sentimen negatif mendominasi dataset.

1. Naïve Bayes memiliki presisi yang sangat tinggi untuk sentimen positif (100%), namun recall-nya sangat rendah (3%), yang berarti model hanya mengenali sedikit komentar positif. Nilai F1-score untuk sentimen positif pun hanya sebesar 5%.
2. Random Forest memberikan hasil yang lebih seimbang dengan akurasi sebesar 70%, namun recall untuk sentimen positif masih rendah, yaitu 38%.
3. SVM menunjukkan performa terbaik dengan akurasi sebesar 75% dan recall untuk sentimen positif mencapai 56%, meskipun model ini masih cenderung bias terhadap sentimen negatif.

Secara keseluruhan, tanpa penerapan SMOTE, model lebih condong memprediksi kelas mayoritas. Oleh karena itu, SMOTE sangat diperlukan untuk menyeimbangkan distribusi data dan meningkatkan kemampuan klasifikasi terhadap semua kategori sentimen secara lebih adil.

b. Hasil Setelah Penerapan SMOTE

Implementasi teknik SMOTE dalam menangani ketidakseimbangan data terbukti mampu meningkatkan

performa seluruh model secara signifikan. Dengan menambahkan data sintetis pada kelas minoritas, jumlah data untuk sentimen positif dan netral menjadi lebih seimbang. Dampak dari penerapan SMOTE ini dapat dilihat pada hasil pengujian yang disajikan dalam Tabel 9.

TABEL IX
HASIL SETELAH PENERAPAN SMOTE

Model	Precision (Negatif %)	Precision (Positif %)	Recall (Negatif %)	Recall (Positif %)	F1-Score (Negatif %)	F1-Score (Positif %)	Accuracy
Naïve Bayes	79.00	74.00	78.00	94.00	78.00	82.00	78.00
Random Forest	89.00	96.00	81.00	93.00	85.00	94.00	88.00
SVM	94.00	97.00	85.00	95.00	90.00	96.00	91.00

Tabel tersebut menunjukkan adanya peningkatan kinerja dari ketiga model—Naïve Bayes, Random Forest, dan SVM dalam melakukan klasifikasi sentiment setelah masalah ketidakseimbangan data diatasi melalui penerapan teknik SMOTE.

1. Model Naïve Bayes mengalami peningkatan performa yang cukup baik dengan tingkat akurasi sebesar 78%, recall untuk sentimen positif mencapai 94%, dan skor F1 untuk sentimen positif sebesar 82%, yang menunjukkan bahwa model ini mulai lebih responsif terhadap kelas minoritas.
2. Model Random Forest menunjukkan performa yang lebih stabil dan akurat dengan akurasi sebesar 88%, serta *precision* dan *F1-score* untuk sentimen positif masing-masing mencapai 96% dan 94%, yang menunjukkan bahwa klasifikasi antar kelas menjadi lebih seimbang.
3. Sementara itu, SVM (Support Vector Machine) memberikan hasil terbaik di antara ketiganya dengan akurasi mencapai 91%, precision dan recall yang tinggi pada kelas sentimen negatif maupun positif (masing-masing di atas 94%), serta F1-score untuk sentimen positif sebesar 96%.

penerapan teknik SMOTE secara signifikan berhasil meningkatkan performa ketiga model, khususnya dalam mendeteksi sentimen positif dan netral yang sebelumnya kurang terdeteksi akibat distribusi data yang tidak seimbang. Model SVM menjadi yang paling unggul dalam mengklasifikasikan sentimen publik terhadap Pertamina.

3.8 Confuse Matrix - Evaluasi Model

Confuse Matrix digunakan untuk memberikan gambaran yang lebih rinci tentang eksekusi model dalam mengklasifikasikan setiap pelajaran asumsi (positif, negatif, dan tidak bias). Kerangka kerja ini menunjukkan jumlah perbaikan dan perkiraan yang tidak akurat dari pertunjukan untuk setiap pelajaran, sehingga membantu dalam mengevaluasi sejauh mana model mampu membedakan kelas sentimen dengan akurat.

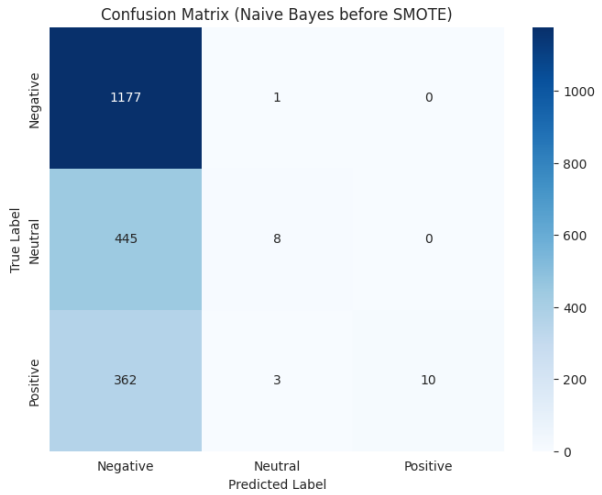
Setelah penerapan teknik SMOTE, confusion matrix dari ketiga model menunjukkan bahwa kesalahan klasifikasi pada kelas minoritas (positif dan netral) berhasil diminimalkan. Sebagai contoh, model SVM mampu mengklasifikasikan sebagian besar komentar ke dalam kategori yang tepat, yang terlihat dari jumlah prediksi benar yang tinggi pada garis diagonal utama matriks. Dalam Confuse Matrix, kinerja klasifikasi dinilai menggunakan empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *True Negative* (FN). *True Positive* (TP) merujuk pada contoh saat data yang diberi label positif diidentifikasi dengan benar oleh model. Sebaliknya, *True Negative* (TN) mewakili jumlah titik data berlabel negatif yang berhasil diprediksi model sebagai negatif. *False Positive* (FP) muncul saat model salah mengklasifikasikan data negatif sebagai positif, kesalahan yang dikenal sebagai kesalahan Tipe I. Di sisi lain, *False Negative* (FN) terjadi saat data yang seharusnya diidentifikasi sebagai positif secara keliru diprediksi sebagai negatif, yang umumnya disebut sebagai kesalahan Tipe II. Dengan memanfaatkan Confusion Matrix, kita dapat memperoleh gambaran yang jelas mengenai performa model, terutama dalam menghadapi ketidakseimbangan data. Tabel berikut menyajikan confusion matrix dari masing-masing algoritma sebelum dan sesudah penerapan teknik SMOTE.

3.9 Confusion Matrix Sebelum dan Setelah SMOTE

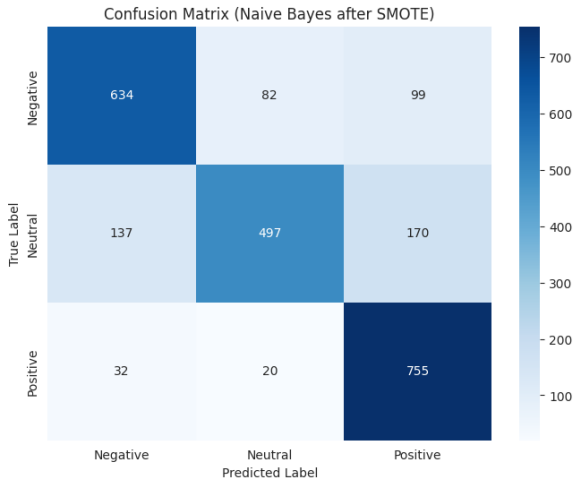
Pada bagian ini ditampilkan perbandingan confusion matrix dari ketiga algoritma Naïve Bayes, Random Forest, dan SVM guna menunjukkan pengaruh penerapan teknik SMOTE terhadap performa klasifikasi masing-masing model. Gambar dibawah menunjukkan bagaimana masing-masing model mengklasifikasikan sentimen positif, negatif, dan netral. Visualisasi hasil klasifikasi sebelum dan sesudah penerapan metode SMOTE dapat dilihat pada Gambar berikut.

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.92-105

a. Confusion Matrix Sebelum dan Setelah SMOTE (Naïve Bayes)



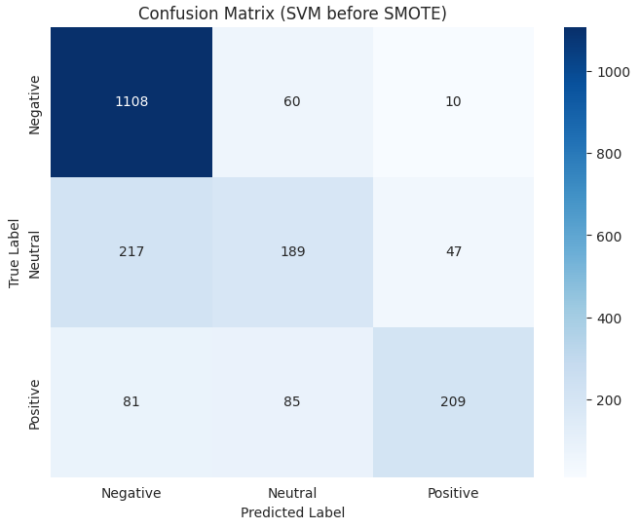
Gambar 7. Confusion Matrix Sebelum SMOTE (Naïve Bayes)



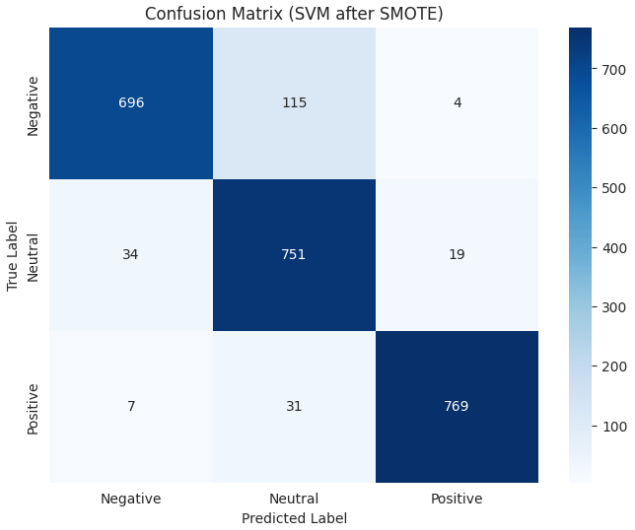
Gambar 8. Confusion Matrix Setelah SMOTE (Naïve Bayes)

Setelah penerapan SMOTE, model Naïve Bayes menunjukkan peningkatan kemampuan dalam mengenali sentimen positif dan netral. Prediksi benar pada kelas positif naik dari 10 menjadi 755, dan netral dari 8 menjadi 497. Meski demikian, terjadi peningkatan kesalahan klasifikasi pada kelas negatif, terutama yang salah dikenali sebagai netral dan positif. Ini menandakan bahwa SMOTE berhasil menyeimbangkan performa antar kelas, meski sedikit mengorbankan presisi pada kelas yang awalnya dominan.

b. Confusion Matrix Sebelum dan Setelah SMOTE (SVM)



Gambar 9. Confusion Matrix Sebelum SMOTE (SVM)

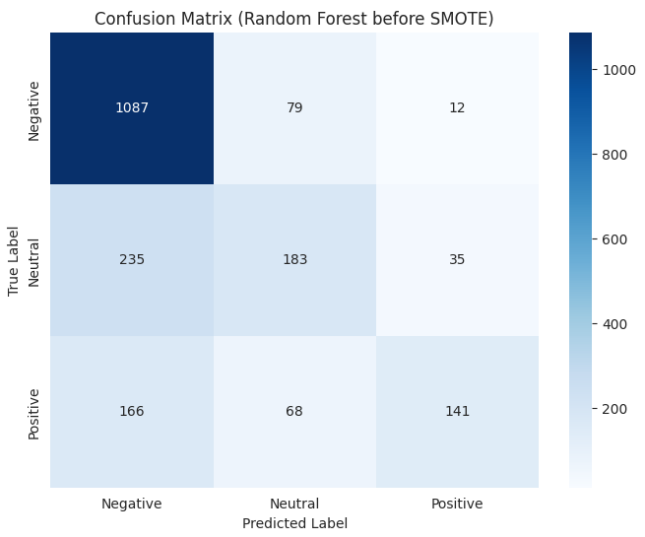


Gambar 10. Confusion Matrix Setelah SMOTE (SVM)

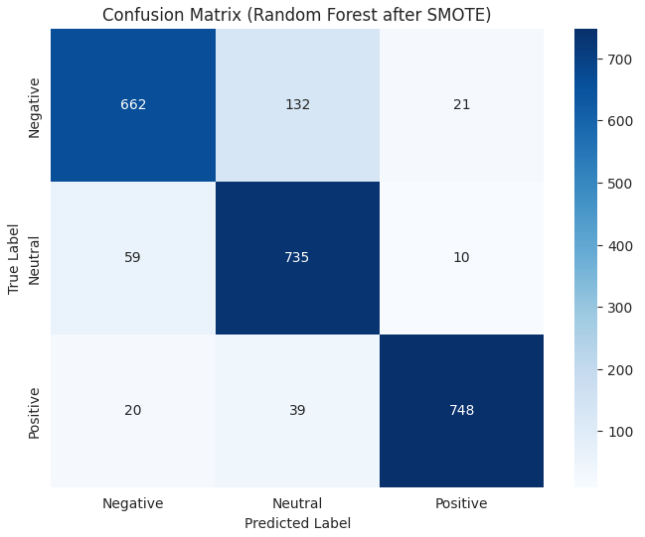
Setelah penerapan SMOTE, model SVM mengalami peningkatan yang signifikan dalam mengenali sentimen netral dan positif. Jumlah prediksi benar pada kelas positif meningkat dari 209 menjadi 769, sedangkan pada kelas netral naik dari 189 menjadi 751. Peningkatan ini menunjukkan bahwa model menjadi lebih peka terhadap kelas-kelas yang sebelumnya merupakan minoritas. Namun, terdapat sedikit penurunan akurasi pada kelas negatif, di mana jumlah prediksi benar menurun dari 1108 menjadi 696, serta terjadi peningkatan kesalahan klasifikasi pada kelas negatif yang salah dikenali sebagai netral, yaitu dari 60 menjadi 115. Hal ini menunjukkan bahwa SMOTE berhasil menyeimbangkan kinerja model dalam mengenali berbagai kelas, meskipun terdapat sedikit pengorbanan pada akurasi klasifikasi kelas yang sebelumnya dominan.

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 11, No. 1, March 2026, Pp.92-105

c. Confusion Matrix Sebelum dan Setelah SMOTE (Random Forest)



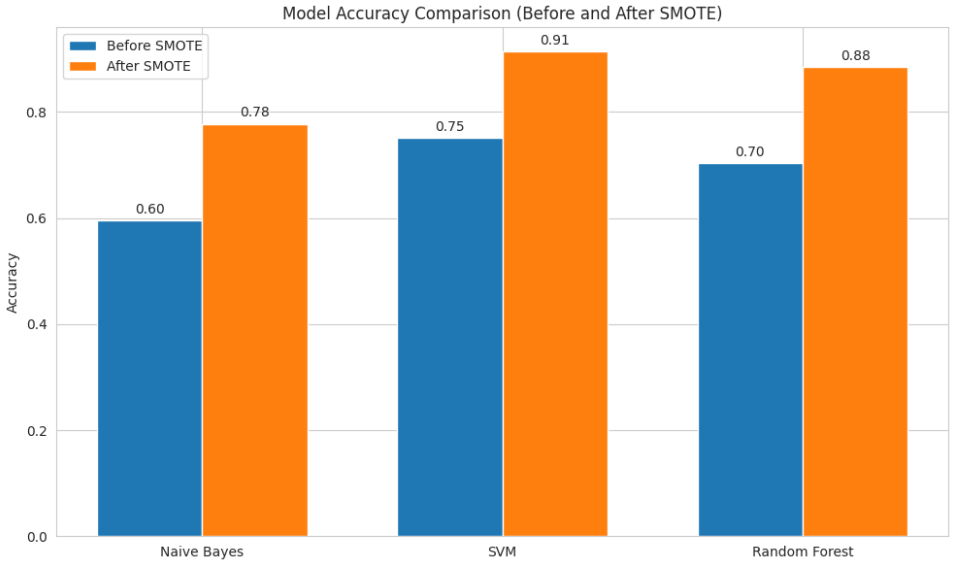
Gambar 11. Confusion Matrix Sebelum SMOTE (Random Forest)



Gambar 12. Confusion Matrix Setelah SMOTE (Random Forest)

Setelah penerapan SMOTE pada model Random Forest, terjadi peningkatan signifikan dalam kemampuan model mengenali sentimen netral dan positif. Prediksi benar pada kelas positif meningkat dari 141 menjadi 748, dan pada kelas netral meningkat dari 183 menjadi 735. Hal ini menunjukkan bahwa model menjadi lebih sensitif terhadap kelas-kelas yang sebelumnya minoritas. Namun, akurasi pada kelas negatif sedikit menurun, di mana prediksi benar turun dari 1087 menjadi 662, dan kesalahan klasifikasi negatif ke netral meningkat dari 79 menjadi 132. Meskipun demikian, distribusi prediksi menjadi lebih seimbang, mencerminkan bahwa SMOTE berhasil meningkatkan performa model dalam mendeteksi seluruh kelas secara lebih adil, meskipun dengan sedikit pengorbanan pada kelas yang awalnya dominan.

3.10 Visualisasi Perbandingan Algoritma



Gambar 13. Visualisasi Perbandingan Algoritma

Gambar 13 menyajikan perbandingan akurasi dari tiga model Naive Bayes, SVM, dan Random Forest—sebelum dan sesudah dilakukan penyeimbangan data menggunakan teknik SMOTE. Secara keseluruhan, terlihat bahwa akurasi ketiganya meningkat setelah masalah ketimpangan kelas diatasi.Model Naive Bayes yang awalnya memiliki akurasi cukup rendah, berhasil meningkat cukup signifikan setelah SMOTE diterapkan. SVM juga menunjukkan lonjakan performa, menjadi model dengan akurasi tertinggi setelah data diseimbangkan. Random Forest, meskipun sebelumnya paling rendah, juga mengalami peningkatan yang cukup stabil.Dari hasil ini, bisa

disimpulkan bahwa penerapan SMOTE mampu meningkatkan akurasi model secara merata, terutama dalam menangani kelas-kelas minoritas yang sebelumnya sering terabaikan.

B. Pembahasasn

Temuan penelitian ini menunjukkan bahwa sentimen publik terkait isu pencampuran bahan bakar di Indonesia sebagian besar didominasi oleh opini negatif, terutama yang berpusat pada kekhawatiran atas kualitas bahan bakar, potensi dampak pada kinerja kendaraan, dan ketidakpercayaan umum terhadap perusahaan energi nasional. Hasil ini konsisten dengan penelitian sebelumnya yang juga mengidentifikasi prevalensi sentimen negatif terkait kenaikan harga bahan bakar dan kebijakan subsidi. Namun, dalam konteks pencampuran bahan bakar, sentimen negatif lebih kuat didorong oleh kekhawatiran teknis dan risiko yang dirasakan, daripada murni oleh faktor ekonomi[24].

Analisis pola kesalahan klasifikasi mengungkap bahwa sentimen netral sering kali salah diklasifikasikan sebagai negatif, terutama karena adanya istilah dominan seperti "oplosan" (pencampuran bahan bakar ilegal), "kerugian," dan "kualitas" dalam konteks yang menunjukkan ambiguitas semantik. Misalnya, pernyataan seperti "Pertamax yang dicampur dengan Pertalite masih dapat beroperasi, tetapi boros cenderung diklasifikasikan sebagai negatif meskipun sifatnya informatif. Lebih lanjut, analisis SHAP mengidentifikasi "oplosan," "Pertamina," dan "mesin" sebagai fitur yang paling berpengaruh dalam model SVM, masing-masing dengan nilai SHAP sekitar 10,45. Secara khusus, istilah "oplosan" sendiri mencakup 32% dari prediksi sentimen negatif, yang menyoroti kekhawatiran publik yang kuat seputar masalah pencampuran bahan bakar[25].

Meskipun model klasik (SVM) mencapai skor F1 sebesar 96%, kinerjanya masih kurang dibandingkan dengan arsitektur yang lebih maju seperti IndoBERT, yang telah menunjukkan akurasi hingga 98% dalam studi serupa. Kesenjangan ini khususnya terlihat jelas dalam menangkap ekspresi ironis, seperti "Pertamina juara oplosan," yang sering salah diklasifikasikan oleh model konvensional. Peningkatan metrik kinerja teknis dapat diubah menjadi dampak bisnis yang nyata, seperti pengurangan waktu respons pengaduan sebesar 30%, dengan mengotomatiskan prioritas tweet kritis. Khususnya, positif palsu yang terkait dengan sentimen korupsi bahan bakar lebih penting untuk segera ditangani, karena menimbulkan ancaman yang lebih besar terhadap reputasi perusahaan dibandingkan dengan negatif palsu yang melibatkan pengaduan teknis[26].

Hasil ini menekankan pentingnya mengintegrasikan model ensemble (seperti SVM yang dikombinasikan dengan BERT) bersama sumber daya leksikal khusus domain untuk meningkatkan akurasi klasifikasi dalam konteks sektor energi. Selain itu, hasil ini mendukung pengembangan kerangka prioritas respons berdasarkan dampak bisnis, yang dirancang khusus untuk industri perminyakan[26].

IV. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan pelaksanaan tiga perhitungan klasifikasi, yakni Naïve Bayes, Random Forest, Support Vector Machine (SVM), dalam menganalisis estimasi terbuka terhadap Pertamina berdasarkan informasi yang diperoleh dari Twitter. Data yang digunakan telah melalui berbagai tahap *preprocessing* dan dilakukan penyeimbangan menggunakan teknik SMOTE untuk mengatasi ketidakseimbangan kelas sentimen. Hasil penelitian menunjukkan bahwa sebelum penerapan SMOTE, seluruh model cenderung bias terhadap kelas mayoritas, yaitu sentimen negatif, sehingga pengenalan terhadap sentimen positif dan netral masih sangat rendah. Namun, setelah dilakukan SMOTE, kinerja semua model meningkat secara signifikan, khususnya dalam mendeteksi sentimen yang sebelumnya termasuk dalam kategori minoritas.Model Naïve Bayes mengalami peningkatan akurasi dari 60 menjadi 78, Random Forest dari 70 menjadi 88, dan SVM menunjukkan performa terbaik dengan akurasi yang meningkat dari 75 menjadi 91. Dengan demikian, dapat disimpulkan bahwa teknik SMOTE sangat efektif dalam menyeimbangkan data dan meningkatkan performa model dalam klasifikasi sentimen. Model SVM menjadi model yang paling direkomendasikan dalam penelitian ini karena mampu memberikan hasil klasifikasi paling stabil dan akurat setelah penerapan SMOTE.

DAFTAR PUSTAKA

[1] M. S. P. Putra, Sri Dharma Wati, and Imam Solikin, "Analisis Sentimen Serikat Pekerja Pertamina Tolak Ahok Pada Media Sosial Youtube Menggunakan Algoritma Naive Bayes," *J. Ilm. Betrik*, vol. 12, no. 2, pp. 99–105, 2021, doi: 10.36050/betrik.v12i2.219.

[2] M. R. Widyayulianto, M. Susanty, and A. Irawan, "Sentiment Analysis Terhadap Tulisan Mengenai Universitas Pertamina Di Media Sosial Twitter," *Petir*, vol. 15, no. 2, pp. 276–286, 2022, doi: 10.33322/petir.v15i2.1197.

[3] R. Maria, R. U. Umayah, S. Mahardinny, D. N. Kalana, and D. D. Saputra, "Analisis Sentimen Persepsi Masyarakat Terhadap Penggunaan Aplikasi My Pertamina Pada Media Sosial Twitter Menggunakan Metode Naïve Bayes Classifier," *J. Komput. Antart.*, vol. 1, no. 1, pp. 1–10, 2023.

[4] D. N. Agustia, R. R. Suryono, U. T. Indonesia, L. Ratu, and K. B. Lampung, "COMPARISON OF NAÏVE BAYES , RANDOM FOREST , AND LOGISTIC REGRESSION ALGORITHMS FOR SENTIMENT ANALYSIS ONLINE GAMBLING KOMPARASI ALGORITMA NAÏVE BAYES , RANDOM FOREST , DAN LOGISTIC REGRESION UNTUK ANALISIS," vol. 10, no. 1, pp. 284–295, 2025.

[5] S. Prayudani, D. Rouli, B. Situmorang, R. Hidayah, and H. S. Ginting, "Sentiment Analysis of Social Media X in the 2024 Indonesian Presidential

Election Using the Naive Bayes Algorithm : Candidates ' Backgrounds and Political Promises," vol. 8, no. 2, pp. 291–295, 2024.
[6] C. Mario, R. R. Suryono, U. T. Indonesia, and B. Lampung, "PUBLIC SENTIMENT ANALYSIS ON DIRTY VOTE MOVIE ON YOUTUBE USING RANDOM FOREST AND NAÏVE BAYES ANALISIS SENTIMEN PUBLIK PADA FILM DIRTY VOTE DI BAYES," vol. 10, no. 1, pp. 111–122, 2025.
[7] M. Zidan, *Analisis Sentimen Kenaikan Harga Bahan Bakar Minyak (BBM) Berdasarkan Respon Pengguna Media Sosial Twitter Di Indonesia Menggunakan Metode Naive Bayes*. 2022.
[8] P. S. Zalukhu, T. Handhayani, and M. Sitorus, "Analisis Sentimen Terhadap Kenaikan Bbm Di Indonesia Pada Media Sosial Twitter Menggunakan Metode Naïve Bayes," *Simtek J. Sist. Inf. dan Tek. Komput.*, vol. 8, no. 1, pp. 65–69, 2023, doi: 10.51876/simtek.v8i1.177.
[9] F. A. Firman, "Pengaruh kebijakan pemerintah terhadap inisiasi dan implementasi proyek : Penelitian empirik pada industri pembangkitan listrik berbasis energi terbarukan di Indonesia = The effect on perceived government policies on project initiation and implementation : An empirical research on renewable energy based power industry in Indonesia .," no. 4, 2016.
[10] D. Ananda and R. R. Suryono, "Analisis Sentimen Publik Terhadap Pengungsi Rohingya di Indonesia dengan Metode Support Vector Machine dan Naïve Bayes," vol. 8, no. April, pp. 748–757, 2024, doi: 10.30865/mib.v8i2.7517.
[11] L. Legito *et al.*, "Penerapan Algoritma K-Nearest Neighbor untuk Analisis Sentimen Terhadap Isu Khilafah dan Radikalisme di Indonesia," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 2, pp. 324–330, 2023, doi: 10.57152/malcom.v3i2.893.
[12] s wuni, a m Siregar, and ..., "K-Means Clustering Untuk Mengelompokan Tingkat Putus Sekolah Jenjang Smp Di Indonesia," *Sci. Student J. Information, Technol. Sci.*, vol. 1, pp. 47–54, 2020.
[13] A. Carla and H. Soetanto, "Implementasi Text Mining untuk Analisis Sentimen pada Pengguna PLN Mobile Menggunakan Metode Naïve Bayes," *Bit (Fakultas Teknol. Inf. Univ. Budi Luhur)*, vol. 21, no. 1, p. 72, 2024, doi: 10.36080/bit.v21i1.2974.
[14] U. Brawijaya, K. R. Hilal, N. Y. Setiawan, and D. E. Ratnawati, "Fakultas Ilmu Komputer ANALISIS SENTIMEN BERBASIS ASPEK UNTUK PENGGUNA PLN MOBILE PADA GOOGLE PLAYSTORE MENGGUNAKAN METODE SUPPORT VECTOR MACHINE (SVM)," vol. 1, no. 1, pp. 2548–964, 2017.
[15] F. A. Artanto, F. Teknik, U. Muhammadiyah, and P. Pekalongan, "Implementasi Algoritma Random Forest dan Model Bag of Words Dalam Analisis Sentimen Mengenai E-Materai," vol. 4, no. 2, pp. 139–145, 2024, doi: 10.54259/satesi.v4i2.3240.
[16] S. Khomsah and A. S. Aribowo, "Model Text-Preprocessing Komentar Youtube Dalam Bahasa Indonesia," *J. Resti*, vol. 1, no. 3, pp. 648–654, 2017.
[17] E. Ramadani, M. L. Hamzah, S. Syaifullah, and E. Saputra, "Analisis Kualitas Layanan Aplikasi Linkaja Terhadap Kepuasan Pengguna Menggunakan Metode E-Servqual Dan Kano," *INOVTEK Polbeng - Seri Inform.*, vol. 9, no. 1, pp. 30–41, 2024, doi: 10.35314/isi.v9i1.3814.
[18] D. F. Sebastian, H. Sulistiani, and A. R. Isnain, "Sentiment Analysis of Public Opinion on the Right of Inquiry in Indonesia in 2024 Using the Support Vector Machine (Svm) Method Analisis Sentimen Opini Masyarakat Mengenai Hak Angket Di Indonesia Tahun 2024 Menggunakan Metode Support Vector Machine (Sv," vol. 5, no. 4, pp. 1025–1034, 2024.
[19] Y. A. Prasetyo, E. Utami, and A. Yaqin, "Pengaruh Komposisi Split Data Terhadap Performa Akurasi Analisis Sentimen Algoritma Naïve Bayes dan SVM," vol. 6, no. 2, pp. 382–390, 2024, doi: 10.33650/jeecom.v4i2.
[20] A. Kaharudin, A. A. Supriyadi, and ..., "Analisis Sentimen pada Media Sosial dengan Teknik Kecerdasan Buatan Naïve Bayes: Kajian Literatur Review," *OKTAL J. Ilmu …*, vol. 2, no. 6, pp. 1642–1649, 2023.
[21] B. F. S. Supriyanto and S. Rosalin, "Analisis Sentimen Program Merdeka Belajar dengan Text Analysis Wordcloud & Word Frequency," *J. Minfo Polgan*, vol. 12, no. 1, pp. 25–32, 2023, doi: 10.33395/jmp.v12i1.12312.
[22] H. Tuhuteru and A. Iriani, "Analisis Sentimen Perusahaan Listrik Negara Cabang Ambon Menggunakan Metode Support Vector Machine dan Naive Bayes Classifier," *J. Inform. J. Pengemb. IT*, vol. 3, no. 3, pp. 394–401, 2018, doi: 10.30591/jpit.v3i3.977.
[23] S. Maula Chamzah, M. Lestandy, N. Kasan, and A. Nugraha, "Penerapan Synthetic Minority Oversampling Technique (SMOTE) untuk Imbalance Class pada Data Text Menggunakan kNN," *Syntax J. Inform.*, vol. 11, no. 02, pp. 56–67, 2022, doi: 10.35706/syji.v11i02.6940.
[24] "4958-14209-1-PB.pdf."
[25] A. A. A. Ahmed, S. Agarwal, Im. G. A. Kurniawan, S. P. D. Anantadjaya, and C. Krishnan, "Business boosting through sentiment analysis using Artificial Intelligence approach," *Int. J. Syst. Assur. Eng. Manag.*, vol. 13, pp. 699–709, 2022, doi: 10.1007/s13198-021-01594-x.
[26] Y. A. Singgalen, "Performance Analysis of IndoBERT for Sentiment Classification in Indonesian Hotel Review Data," vol. 6, no. 2, pp. 976–986, 2025, doi: 10.47065/josh.v6i2.6505.