

Perbandingan Random Forest dan SVM dalam Analisis Sentimen Opini Masyarakat Terhadap Kenaikan Harga Pertamina

Comparison of Random Forest and SVM in Sentiment Analysis of Public Opinion Regarding the Pertamina Price Hike

Fahmy Wira Oktavier*, Auliya Rahman Isnain

Fakultas Teknik dan Ilmu Komputer, Program Studi Informatika, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

Email: ^{1,*}fahmy_wira_oktavier@teknokrat.ac.id, ²auliyarahman@teknokrat.ac.id

Email Penulis Korespondensi: fahmy_wira_oktavier@teknokrat.ac.id

Received: 03/08/2026, Revised: 19/08/2026, Accepted: 04/09/2026, Published: 08/09/2026

Abstrak—Kenaikan harga Pertamina memicu bermacam respon dari khalayak, banyak di antaranya terungkap melalui media sosial X. Karena banyaknya pendapat yang muncul, analisis sentimen terbukti menjadi cara yang tepat untuk otomatis mengenali tren opini masyarakat. Penelitian ini dilakukan dengan tujuan untuk mengetahui seberapa efektif algoritma "Random Forest" dan "Support Vector Machine" (SVM) dalam proses pengelompokan sentimen masyarakat terkait kenaikan harga Pertamina. Data penelitian didapat dengan mengumpulkan informasi dari platform X menggunakan kata kunci yang sesuai dengan topik Pertamina. Setelah melakukan penyaringan dan menghapus duplikat, diperoleh 5.006 catatan yang digunakan sebagai dataset dalam penelitian ini. Langkah-langkah penelitian ini mencakup pra-pemrosesan data, proses klasifikasi sentimen, ekstraksi fitur memakai teknik Term Frequency Inverse Document Frequency (TF-IDF), Menggunakan metode SMOTE untuk menyeimbangkan jumlah kelas dan membagi dataset ke dalam kategori, lalu melakukan klasifikasi dengan dua algoritma, yaitu Random Forest serta Support Vector Machine (SVM). Confusion matrix digunakan untuk menilai kinerja model dengan beragam metrik seperti akurasi, presisi, recall, dan skor F1. Penelitian ini memperlihatkan bahwasanya data didominasi oleh sentimen negatif, yaitu sebesar 51,64%, kemudian didominasi oleh sentimen positif sebesar 35,60%, dan sentimen netral mencapai 12,76%. Sebelum menggunakan SMOTE, Random Forest memiliki akurasi 73% sedangkan SVM mencapai 75%. Setelah menggunakan SMOTE, akurasi model Random Forest naik menjadi 85% dan akurasi SVM meningkat menjadi 89%. Penelitian ini memberikan kontribusi dalam meningkatkan kualitas analisis sentimen serta menjadi referensi dalam pengembangan penelitian selanjutnya serta memberi pemahaman kepada para pemangku kepentingan mengenai tren opini masyarakat terkait kenaikan harga Pertamina, sehingga dapat membantu mereka dalam mengambil keputusan

Kata Kunci: Analisis Sentimen; Random Forest; Support Vector Machine; SMOTE; TF-IDF

Abstract—The increase in Pertamina prices triggered various responses from the public, many of which were expressed through social media X. Due to the large number of opinions that emerged, sentiment analysis proved to be an appropriate way to automatically recognize public opinion trends. This study was conducted with the aim of determining how effective the "Random Forest" and "Support Vector Machine" (SVM) algorithms are in the process of grouping public sentiment regarding the increase in Pertamina prices. The research data was obtained by collecting information from platform X using keywords that match the topic of Pertamina. After filtering and removing duplicates, 5,006 records were obtained which were used as the dataset in this study. The steps of this study include data pre-processing, sentiment classification process, feature extraction using the Term Frequency Inverse Document Frequency (TF-IDF) technique, Using the SMOTE method to balance the number of classes and divide the dataset into categories, then classifying with two algorithms, namely Random Forest and Support Vector Machine (SVM). Confusion matrix is used to assess model performance with various metrics such as accuracy, precision, recall, and F1 score. This study shows that the data is dominated by negative sentiment, amounting to 51.64%, then dominated by positive sentiment at 35.60%, and neutral sentiment reached 12.76%. Before using SMOTE, Random Forest had an accuracy of 73% while SVM reached 75%. After using SMOTE, the accuracy of the Random Forest model increased to 85% and the accuracy of the SVM increased to 89%. This research contributes to improving the quality of sentiment analysis and serves as a reference for future studies; furthermore, it provides stakeholders with an understanding of public opinion trends regarding the price hike of Pertamina, thereby assisting them in decision-making.

Keywords: Sentiment Analysis; Random Forest; Support Vector Machine; SMOTE; TF-IDF

1. PENDAHULUAN

Bahan bakar seperti BBM adalah bahan yang sangat penting dan strategis, serta memiliki peran besar dalam mendukung berbagai kegiatan yang dilakukan oleh masyarakat Indonesia. Bahan bakar digunakan sebagai sumber energi utama untuk menggerakkan kendaraan bermotor serta mendukung berbagai mesin dan alat yang digunakan di sektor industri dan sektor produktif lainnya. Oleh karena itu, kelancaran dan keamanan pasokan bahan bakar sangat penting untuk memastikan mobilitas penduduk serta pertumbuhan ekonomi nasional yang berkelanjutan [1]. Baru baru ini, topik pembicaraan mengenai kenaikan harga bahan bakar, terutama Pertamina, semakin menarik perhatian banyak orang dan menjadi pembicaraan hangat di media sosial Twitter (X) [2]. Sebagai respons, pemerintah memutuskan pada bulan Juni tahun 2026 untuk menyesuaikan harga bahan bakar non-subsidi yang dihasilkan oleh Pertamina. Berdasarkan peraturan tersebut harga Pertamina (RON 92) meningkat dari 12.300 menjadi 16.250 rupiah per liter sedangkan harga Pertamina Green 95 naik dari 12.900 menjadi 17.000 rupiah per liter [3]. Perubahan harga ini memengaruhi kondisi ekonomi warga. Kenaikan harga bahan bakar memicu banyak reaksi, kritik, dan keluhan

dari masyarakat, karena hal ini bisa menyebabkan peningkatan biaya hidup dan biaya operasional di berbagai sektor. Situasi ini sangat mengejutkan karena sebagian masyarakat masih dalam proses pemulihan ekonomi yang dipengaruhi oleh berbagai faktor makroekonomi, seperti melemahnya nilai rupiah terhadap dolar Amerika Serikat. Akibatnya, kenaikan harga Pertamina dianggap sebagai faktor yang semakin memperburuk tekanan ekonomi masyarakat [2].

Perkembangan media sosial membuat masyarakat lebih mudah menyampaikan perasaan, pendapat, dan tanggapannya terhadap berbagai isu terkini. Beberapa platform digital saat ini digunakan sebagai tempat untuk berdiskusi dan menyampaikan pendapat, seperti Twitter (X), yang telah menjadi media yang populer untuk berbagi dan mendiskusikan pandangan secara terbuka [4]. Pada Oktober 2025, jumlah orang yang menggunakan media sosial secara aktif di Indonesia diperkirakan mencapai sekitar 230 juta, yang menunjukkan peningkatan dibandingkan masa sebelumnya. Di antara berbagai platform yang ada, Twitter (X) menjadi media sosial yang banyak jumlah penggunaannya dengan sekitar 22,9 juta pengguna di Indonesia pada tahun 2025 [5]. Banyak pengguna yang menggunakan platform X, sehingga membuatnya menjadi tempat publik digital yang sering dikunjungi orang-orang untuk mengobrol tentang berbagai hal, seperti kebijakan kenaikan harga bahan bakar. Beragam pendapat, tanggapan, dan kritik yang diberikan oleh pengguna menghasilkan banyak data teks yang bisa digunakan sebagai sumber untuk memahami pandangan masyarakat. Oleh karena itu, data yang didapatkan dari Platform X sangat relevan untuk digunakan pada analisis sentimen, karena memberikan visualisasi yang terstruktur dan berdasarkan data mengenai tren opini publik terkait kebijakan kenaikan harga Pertamina [6].

Analisis sentimen yaitu metode di bidang pemrosesan bahasa alami, ini dipergunakan untuk memahami teks yang tidak memiliki struktur khusus, dengan tujuan mengenali dan menilai pendapat, sikap, serta perasaan yang disampaikan di dalam teks tersebut. Teknik ini memungkinkan kita mengetahui cara seseorang memahami suatu topik dan membaginya menjadi kelas positif, negatif, atau netral [7]. Sentimen umumnya dianalisis memakai gabungan metode NLP dan algoritma pembelajaran mesin agar proses pengklasifikasian lebih mudah dan hasilnya lebih tepat. Banyak jenis algoritma yang digunakan dalam penelitian analisis sentimen, seperti *Maximum Entropy*, *Naive Bayes Classifier (NBC)*, *Random Forest*, dan *Support Vector Machine (SVM)*. Setiap algoritma mempunyai sifat, keunggulan, dan kelemahan yang berbeda ketika mengolah data teks. Maka itu, memilih algoritma yang tepat sangat penting agar model klasifikasi yang dibuat akurat dan dapat diandalkan [8].

Salah satu permasalahan dalam menganalisis sentimen di media sosial adalah "ketidakseimbangan kelas," yang berarti distribusi data tidak merata di berbagai jenis sentimen. Ini bisa membuat model lebih mudah mengenali kelas yang frekuensinya tinggi, sehingga performanya menurun pada kelas yang frekuensinya rendah. Untuk menyelesaikan permasalahan itu, penelitian ini memakai teknik SMOTE, yaitu metode yang membuat data palsu untuk kelas minoritas agar distribusi datanya lebih seimbang. Diinginkan hal ini dapat meningkatkan keahlian model dalam hal mengklasifikasikan, terutama dalam mengenali sentimen di kelas-kelas yang jumlahnya sedikit [7].

Beberapa penelitian sudah dilakukan untuk melihat perasaan masyarakat soal kenaikan harga bahan bakar Pertamina, tapi sebagian besar hasilnya sama saja. Kebanyakan penelitian sebelumnya hanya menggunakan satu jenis algoritma, jadi sulit membandingkan berbagai metode yang ada. Misalnya, Rahadi dan timnya pada tahun 2023 mencapai akurasi sebesar 82,69% memakai algoritma *Support Vector Machine (SVM)*, sensitivitas 100%, serta spesifisitas 79,07% [8]. Studi yang dilakukan oleh Sartika dan Ria di tahun 2022 memakai algoritma *Naive Bayes* dan berhasil mencapai akurasi senilai 99%. Studi ini menunjukkan bahwa 19 persen dari sentimen bersifat positif, 22 persen negatif, dan 59 persen netral [9]. Ikhlasul Amal dan Jayanta (2023) juga menggunakan algoritma SVM, namun mereka mendapatkan presisi sebesar 0,02, recall 0,01, spesifisitas 0,02, dan skor F1 sebesar 0,01 [10]. Jaysen dan timnya pada tahun 2026 menggunakan model *IndoBERT* dan menemukan bahwa mayoritas hasil klasifikasi memiliki sentimen negatif senilai 49,8%, kemudian sentimen netral mencapai 48,5%, sementara sentimen positif hanya senilai 1,7% [6]. Penelitian lain oleh Gusti et al. (2024) menggunakan metode InSet untuk menganalisis sentimen terkait kenaikan harga bahan bakar, dengan hasil akurasi sebesar 93,16%, presisi 89,47%, dan recall 96,23% [11].


Berdasarkan penelitian sebelumnya, kebanyakan mempelajari analisis sentimen hanya menggunakan satu jenis klasifikasi algoritma, sehingga tidak ada perbandingan hasil antara algoritma yang berbeda dalam konteks kenaikan harga Pertamina. Maka dari itu, algoritma *Random Forest* dan *Support Vector Machine (SVM)* digunakan dalam penelitian ini untuk dibandingkan, untuk dibandingkan kinerjanya serta untuk mengetahui mana yang lebih baik dengan menggunakan berbagai metode penilaian. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam meningkatkan kualitas analisis sentimen serta menjadi referensi dalam pengembangan penelitian selanjutnya serta memberi pemahaman kepada para pemangku kepentingan mengenai tren opini masyarakat terkait kenaikan harga Pertamina, sehingga dapat membantu mereka dalam mengambil keputusan [4].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Proses penelitian dilaksanakan melalui langkah-langkah yang terencana dan terstruktur untuk membuat model pengevaluasian opini masyarakat tentang kenaikan harga Pertamina yang dibagikan di media sosial Twitter (X). Langkah-langkah dalam penelitian ini saling terhubung dan mencakup berbagai tahap seperti pengumpulan data, pemrosesan data, analisis, hingga pengevaluasian hasil model klasifikasi yang telah dibuat. Penelitian ini dirancang

dengan urutan tertentu agar bisa menghasilkan model yang mampu mengklasifikasikan sentimen secara terbaik. Gambar 1 memberikan gambaran umum mengenai seluruh proses penelitian yang dilakukan.



Gambar 1. Tahapan Penelitian

Gambar 1 memperlihatkan alur cara menganalisis sentimen, yang dikerjakan secara perlahan dan bertahap. Awal penelitian dilakukan dengan mengumpulkan data menggunakan metode *crawling* pada platform X. Setelah data terkumpul, langkah selanjutnya yaitu *preprocessing* yang terdiri dari beberapa tahap. Tahapannya meliputi membersihkan data, mengubah semua kata ke bentuk dasar, merubah semua huruf menjadi huruf kecil, memisahkan kalimat menjadi kata individu, melakukan penghapusan kata-kata umum (stopwords) yang tidak memberikan kontribusi terhadap proses analisis, serta merubah kata - kata menjadi bentuk akarnya. Langkah - langkah ini untuk menghilangkan yang tidak digunakan, memastikan penulisan yang lebih seragam, serta membuat data lebih mudah diatur dan siap untuk dianalisis lebih lanjut. Setelah tahap *preprocessing* dilakukan, Proses pelabelan dilakukan pada seluruh data berdasarkan indikator sentimen untuk menentukan kategori masing-masing data, yang bertindak sebagai acuan dalam proses pengelompokan. Setelah label diberikan, Data kemudian dipisahkan menjadi data latih dan data uji berdasarkan proporsi yang telah ditetapkan sebelumnya. Selanjutnya, teks data diubah menjadi angka - angka menggunakan metode ekstraksi fitur yang disebut *Term Frekuensi – Inverse Document Frekuensi* (TF-IDF). Untuk menangani masalah ketidakseimbangan antar kelas dalam data pelatihan, metode SMOTE digunakan, sehingga distribusi data menjadi lebih seimbang. Selanjutnya klasifikasi model dibuat dengan menggunakan data latihan serta algoritma *Random Forest* serta *Support Vector Machine* (SVM). Data uji dimanfaatkan untuk mengukur kemampuan model dalam mengenali data yang tidak termasuk dalam data pelatihan. Akhirnya kedua algoritma tersebut dibandingkan dengan memakai beberapa kriteria pengukuran, yaitu akurasi, presisi, recall, dan skor F1, agar dapat mengidentifikasi metode yang memberikan hasil klasifikasi sentimen paling optimal.

2.2 Pengumpulan Data

Perolehan data penelitian dilakukan melalui proses akuisisi informasi secara otomatis dari internet dengan memanfaatkan teknik *crawling* menggunakan perangkat lunak bernama *web crawler* atau *web spider* [12]. Platform media sosial X digunakan sebagai sumber data, melalui penggunaan kata kunci yang sesuai dengan topik kenaikan harga Pertamina. Pengumpulan data dilakukan bulan Juli 2026 dan berhasil mendapatkan total 5.009 catatan. Semua data hasil pengumpulan disimpan dalam format *Comma Separated Values* (CSV) sebagai langkah awal sebelum proses pemrosesan data dan analisis sentimen dimulai. *Google Colab* digunakan sebagai tempat komputasi untuk melakukan proses analisis data, dengan menggunakan bahasa pemrograman *Python*. Selain itu, Pustaka *Pandas* digunakan untuk membantu mengumpulkan, mengelola, dan menyimpan data secara efisien [4]. Format CSV dipilih agar integrasi dataset berjalan lancar dalam fase analisis berikutnya, karena format ini dapat digunakan oleh berbagai program pemrosesan data.

2.3 Preprocessing Data

Sebelum proses analisis dilakukan, data teks perlu melalui tahap *preprocessing* sebagai langkah persiapan yang penting. Proses ini bertujuan membersihkan data, membuat formatnya sama, serta mengolah data mentah menjadi format yang lebih terstruktur agar mudah diproses serta dimanfaatkan. Praproses membantu memperbaiki kualitas data, sehingga analisis sentimen yang dihasilkan lebih efektif dan lebih tepat [13]. Dalam penelitian ini, kami mengambil 5.009 tweet dari platform media sosial X. Karena data ini berupa teks yang belum teratur, diperlukan beberapa tahap pra- transmisi untuk menghilangkan gangguan, menyamakan penulisan, dan meningkatkan kualitas datanya. Langkah - langkah tersebut membantu memahami informasi analitis dalam teks selama proses pengambilan fitur dengan menggunakan teknik TF-IDF, sehingga memudahkan dalam proses analisis data [14].

Dalam penelitian ini, data disiapkan melalui beberapa tahap agar kualitas teks data menjadi lebih baik sebelum dilakukan. Langkah pertama adalah membersihkan data, yaitu menghapus berbagai hal yang tidak perlu untuk menganalisis perasaan dalam teks, seperti alamat website, nama orang, tagar, emoji, angka, simbol, tanda baca, serta karakter khusus lainnya. Fase ini berfungsi supaya data menjadi lebih mudah dipahami, lebih rapi, dan lebih siap

untuk dianalisis, sehingga dapat dilanjutkan ke tahap berikutnya. Setelah pembersihan selesai, dilakukan normalisasi huruf besar/kecil. Proses normalisasi ini mencakup perubahan semua huruf menjadi huruf kecil. Standarisasi menjamin tidak terjadi perbedaan penampilan kata karena penggunaan huruf besar, Sehingga Kata-kata yang memiliki arti serupa dapat diseragamkan menjadi satu bentuk untuk keperluan analisis [15].

Setelah proses *case folding*, langkah berikutnya adalah normalisasi, yaitu mengubah kata-kata, singkatan, atau sehari-hari yang tidak memiliki bentuk kalimat baku menjadi bentuk yang standar. Langkah ini juga memperbaiki pengucapan yang berbeda tetapi memiliki arti yang sama, sehingga memastikan data tetap konsisten dan meningkatkan kualitas analisis sentimen [16]. Normalisasi membantu mengurangi ketidakjelasan dalam teks data dan membuat representasi yang lebih beragam, sehingga mempermudah analisis sentimen yang lebih baik [4]. Selanjutnya dilakukan proses tokenisasi, yaitu memisahkan teks menjadi kata-kata atau token sebagai unit dasar analisis. Dalam proses ini, setiap kalimat dipisahkan menjadi beberapa token, di mana setiap token mewakili sebuah kata. Tokenisasi memudahkan sistem dalam mengenali dan memproses setiap bagian teks agar dapat dijelaskan lebih lanjut, sehingga meningkatkan proses ekstraksi fitur dan klasifikasi sentimen [17].

Langkah berikutnya adalah menghilangkan kata-kata umum, yaitu kata-kata yang digunakan secara rutin dan tidak memiliki pengaruh besar terhadap analisis sentimen, sehingga dihapus dari daftar stopword. Proses ini bertujuan agar kata-kata yang digunakan tetap informatif sehingga representasi data menjadi lebih tepat sasaran [4]. Langkah terakhir adalah stemming, yaitu merubah kata yang mengandung imbuhan dikembalikan ke bentuk dasar dengan menghilangkan bagian awal, akhir, dan imbuhan tambahan lainnya. Pada penelitian ini, proses stemming diterapkan dengan menggunakan perpustakaan Python bernama Sastrawi agar dapat menghasilkan bentuk kata yang lebih beragam dalam teks bahasa Indonesia [18].

Fase preprocessing, mengubah teks yang belum diproses menjadi dataset yang lebih baik dengan cara membersihkan, menyamakan bentuk, dan membuatnya sesuai standar. Dataset yang sudah diproses sebelumnya kemudian digunakan dalam tahap ekstraksi fitur dan penggunaan bobot, mempergunakan Term Frequency Inverse Document Frequency (TF-IDF). Hasil fitur kemudian dimanfaatkan sebagai input pada proses analisis sentimen, dengan menerapkan dua algoritma yaitu Random Forest serta Support Vector Machine (SVM).

2.4 Pelabelan Data

Langkah berikutnya adalah memberi tag/label data, yaitu menentukan peringkat sentimen pada 5.006 tweet yang sudah dibersihkan dari duplikat sebelumnya. Penandaan tag/label dilakukan secara otomatis dengan menggunakan kitab kata VADER, untuk setiap tweet dikelompokkan menjadi tiga kelompok yaitu positif, netral, atau negatif. Tweet yang menyampaikan pendapat positif masuk ke kategori positif, tweet yang berisi kritik atau ketidakpuasan masuk ke kategori negatif, sedangkan tweet yang hanya memberikan informasi tanpa menunjukkan kecenderungan sentimen tertentu masuk ke kategori netral.

2.5 Pembagian Data

Setelah semua data diberi tanda berdasarkan perasaan yang diungkapkan, Pembagian dataset dilakukan ke dalam dua kelompok, yaitu data latih untuk membangun model dan data uji untuk menilai performa model. Dalam penelitian ini menggunakan perbandingan 80:20, di mana 80% dari seluruh dataset dimasukkan ke dalam dataset pelatihan, sedangkan 20% lainnya digunakan untuk pengujian dataset. Pelatihan ini bertujuan untuk mengembangkan dan mengembangkan kemampuan model klasifikasi agar mampu mengenali pola dalam setiap jenis perasaan, yaitu positif, negatif, dan netral. Pengujian bertujuan untuk melihat bagaimana model mampu memilah data yang baru dan belum pernah dilihat sebelumnya, agar mengetahui sejauh mana model tersebut dapat digunakan dalam kondisi nyata [19].

2.6 TF-IDF

Pada fase ini, Sebelum proses klasifikasi dilakukan, Teks diubah menjadi angka dengan menggunakan metode TF-IDF agar bisa digunakan sebagai input untuk algoritma pembelajaran mesin. Metode TF-IDF terbagi menjadi dua bagian utama Frekuensi Istilah (TF), Menghitung tingkat kemunculan suatu kata pada setiap dokumen, serta Frekuensi Dokumen Terbalik (IDF), Yang menentukan tingkat keunikan dan kesesuaian suatu kata berdasarkan seberapa sering dan di mana saja kata tersebut muncul dalam koleksi dokumen yang ada. Hasil penggabungan kedua komponen tersebut menghasilkan bobot yang lebih tepat untuk setiap kata, Karena penilaiannya tidak hanya didasarkan pada jumlah kemunculan suatu kata dalam satu dokumen, Tetapi juga mengukur tingkat penyebaran kata tersebut di seluruh kumpulan dokumen berdasarkan frekuensi kemunculannya [7]. Nilai bobot yang diperoleh dari proses analisis TF-IDF selanjutnya digunakan sebagai fitur untuk merepresentasikan fase sentimen. Representasi numerik ini membantu klasifikasi model dalam mengenali pola dan fitur di setiap dokumen dengan lebih mudah, sehingga memudahkan proses identifikasi sentimen dan meningkatkan hasil klasifikasi secara optimal.

2.7 Optimasi SMOTE

Hasil analisis penyebaran data sentimen menunjukkan bahwa dataset dalam penelitian ini tidak seimbang, Hal ini terlihat jelas dari fakta bahwa jumlah tweet data sentimen negatif lebih tinggi daripada jumlah titik data sentimen positif atau netral. Ketidakseimbangan dalam distribusi data bisa memengaruhi hasil model klasifikasi, karena model lebih mudah belajar dari kelas yang memiliki data lebih banyak, sehingga kurang mampu mendeteksi kelas yang

memiliki data lebih sedikit. Untuk mengurangi masalah yang terjadi, penelitian ini menggunakan teknik SMOTE sebagai cara untuk mengimbangi jumlah data dalam setiap kategori sentimen.

Teknik Over sampling Minoritas Sintetis (SMOTE) adalah cara meningkatkan jumlah data dengan membuat data baru untuk kelas yang memiliki jumlah siswa yang tidak banyak. Metode ini menambahkan dataset dengan memperhatikan kedekatan sampel antar di dalam ruang fitur. Dalam penelitian ini, metode SMOTE digunakan setelah proses ekstraksi fitur dan pemberian bobot dengan TF-IDF, namun sebelum data tersebut dimasukkan ke dalam model klasifikasi. Kinerja kedua model kemudian dijelaskan dengan membandingkan hasil klasifikasi sebelum dan setelah penerapan SMOTE. Untuk mengetahui sejauh mana teknik resampling mempengaruhi peningkatan kemampuan klasifikasi dengan mempergunakan metrik yaitu akurasi, presisi, skor F1 makro, dan skor F1 sebagai alat penilaian [20].

2.8 Klasifikasi

Fase klasifikasi dimulai setelah proses ekstraksi fitur selesai, dan dataset telah terpecah dipisahkan menjadi dua kelompok yaitu data latih dan data uji. Dalam proses ini, data latih dipergunakan sebagai pembuat klasifikasi model dengan memakai algoritma Random Forest serta Support Vector Machine (SVM), sementara itu, data pengujian digunakan untuk mengevaluasi seberapa efektif setiap model dalam mengkategorikan informasi yang belum mereka pelajari sebelumnya. Untuk menilai metode yang paling efektif dalam mengklasifikasikan sentimen hasil uji coba dari kedua algoritma tersebut dibandingkan satu sama lain [21]. Klasifikasi adalah metode dalam pembelajaran mesin yang terawasi, di mana data dibagi ke dalam kelompok-kelompok tertentu berdasarkan pola yang ditemukan dari data yang telah diberi label. Dengan proses belajar ini, model bisa mengenali ciri-ciri dari setiap kelas dan memakai ciri-ciri tersebut untuk memprediksi kategori data baru yang belum diketahui. Dengan cara ini, model dapat melakukan proses klasifikasi secara otomatis berdasarkan pola yang telah dipelajari selama fase pelatihan [22].

2.8.1 Random Forest

Random Forest adalah metode klasifikasi yang memakai pendekatan ensemble, yaitu dengan menggabungkan banyak model keputusan berbentuk pohon untuk menghasilkan prediksi yang lebih tepat dan mengurangi risiko model terlalu cocok dengan data pelatihan. Setiap pohon keputusan dibuat dengan mengambil sampel bootstrap, dan pada setiap node, pemilihan fitur dilakukan secara acak. Strategi ini membuat banyak pohon keputusan dengan berbagai sifat, sehingga menambah beragam jenis model. Hasil akhir dari algoritma Random Forest ditentukan dengan cara voting mayoritas. Kelas yang mendapat suara paling banyak dari semua keputusan pohon dianggap sebagai hasil klasifikasi yang benar. Dengan menggabungkan beberapa pohon keputusan, algoritma ini bisa membuat model lebih stabil, mampu beradaptasi dengan data baru, dan memberikan hasil klasifikasi yang baik pada berbagai jenis fitur dataset [4]. Mekanisme pemilihan majority voting untuk menentukan kelas dalam algoritma Random Forest dapat dinyatakan dengan persamaan berikut.

$$f(x) = \text{Average}(f_1(x), f_2(x), \dots, f_n(x)) \quad (1)$$

Dalam rumus tersebut, $f(x)$ merupakan hasil prediksi yang diperoleh dari model klasifikasi. Sementara itu, $f_1(x), f_2(x), \dots, f_n(x)$ menunjukkan hasil prediksi yang dihasilkan oleh masing-masing pohon keputusan ke-1 hingga ke- n dalam algoritma Random Forest. Adapun x merupakan input data yang digunakan sebagai masukan ke dalam model untuk menghasilkan suatu prediksi.

2.8.1 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan metode dalam pembelajaran mesin yang diawasi, dimana tujuannya adalah menemukan garis pemisah terbaik antara berbagai kelas. Algoritma ini menggunakan pendekatan diskriminatif dengan cara mengoptimalkan jarak antara permukaan pemisah serta data tweet yang paling dekat dari setiap kelas, yang disebut vektor pendukung. Jarak yang lebih besar bertujuan meningkatkan kemampuan model dalam menggeneralisasi, sehingga meningkatkan tingkat akurasi klasifikasi terhadap data yang sebelumnya belum pernah dilatih. Dalam penelitian ini, kernel linier digunakan, sehingga memungkinkan permukaan optimal dijelaskan melalui persamaan berikut [20].

$$(w \cdot xi) + b = 0 \quad (2)$$

Data xi yang termasuk pada kelas -1 dapat direpresentasikan dengan persamaan (3).

$$(w \cdot xi + b) \leq yi = -1 \quad (3)$$

Untuk data xi yang termasuk pada kelas +1, rumusnya dapat dilihat pada persamaan (4).

$$(w \cdot xi + b) \geq yi = 1 \quad (4)$$

Pada rumus tersebut, xi merupakan data ke- i yang digunakan sebagai input dalam proses perhitungan. $w \cdot xi$ merupakan nilai bobot yang diberikan pada kelas dari data ke- i , sedangkan b merupakan nilai bias yang digunakan dalam perhitungan model. Selanjutnya, yi menunjukkan kelas atau label dari data ke- i yang menjadi hasil klasifikasi berdasarkan proses perhitungan yang dilakukan.

2.9 Evaluasi Model

Fase evaluasi bertujuan untuk mengecek seberapa baik model klasifikasi yang dibuat dalam penelitian ini bekerja. Evaluasi dilakukan dengan matriks kebingungan, yaitu metode penilaian yang membandingkan hasil prediksi model dengan klasifikasi sebenarnya untuk mengetahui berapa banyak prediksi yang benar dan salah. Metode ini memudahkan dalam mengetahui berapa banyak klasifikasi yang benar dan salah, sehingga memperbaikinya dalam menganalisis bagaimana baik buruknya model tersebut [23]. Dalam penelitian ini, confusion matrix digunakan untuk mengelompokkan hasil menjadi tiga kelompok sentimen yaitu positif, netral, dan negatif. Berdasarkan hasil matriks tersebut, berbagai metrik evaluasi seperti akurasi, presisi, recall, dan skor F1 dihitung untuk mengetahui seberapa efektif model dalam mengelompokkan setiap jenis sentimen [20]. Setiap nilai metrik tersebut digunakan sebagai acuan untuk membandingkan hasil dari kedua algoritma. Perbandingan ini membantu para peneliti memilih algoritma yang paling tepat untuk mengklasifikasikan pendapat masyarakat mengenai kenaikan harga Pertamina [24].

3. HASIL DAN PEMBAHASAN


3.1 Pengumpulan Data

Data yang diambil dalam penelitian ini berasal dari tweet di media sosial X. Dataset ini dibangun dengan menggunakan kata kunci "Pertamax" agar data yang diperoleh sesuai dengan maksud dari penelitian. Proses tersebut menghasilkan total 5.009 tweet sebagai dataset awalnya. Dataset yang dihasilkan kemudian melalui tahap pemilihan untuk menyaring data yang tidak relevan dengan topik penelitian, menghilangkan data yang sama, serta menghapus tweet yang tidak memenuhi syarat penelitian. Setelah proses seleksi, data kemudian melewati beberapa tahap pra pemrosesan, seperti membersihkan data, mengubah huruf menjadi besar atau kecil, melakukan normalisasi, memisahkan kalimat, menghapus kata-kata tertentu, serta menghapus kata umum dan mengubah kata menjadi bentuk dasar. Langkah ini berfungsi untuk meminimalkan suara bising, membuat format teks lebih rapi, serta meningkatkan mutu data agar data siap digunakan dalam analisis sentimen dengan lebih baik.

Data tersebut selanjutnya diolah untuk menyaring informasi yang tidak terkait dengan topik penelitian, menghapus data yang sama, serta membuang tweet yang tidak memenuhi syarat penelitian. Setelah proses seleksi data, memvalidasi hasil pelabelan, dan menghapus tweet yang berulang, terdapat 5.006 tweet yang tersisa, yang digunakan sebagai dataset akhir untuk proses pengklasifikasian sentimen. Setiap tweet selanjutnya diorganisir ke dalam tiga kategori positif, netral, serta negatif. Klasifikasi dari hasil pengumpulan data disajikan dalam Tabel 1 dan Gambar 2.

Tabel 1. Distribusi Sentimen Opini Twitter

No	Kategori Sentimen	Jumlah Data	Presentase
1	Negatif	2585	51,67%
2	Netral	1782	35,60%
3	Positif	639	12,76%
	Total	5006	100%



Gambar 2. Diagram Batang Hasil Label Sentimen

Visualisasi penyebaran opini yang ditampilkan pada Gambar 2 mengindikasikan bahwa kelompok data dengan sentiment negatif lebih banyak dibandingkan dengan kelompok yang memiliki sentiment positif dan netral. Hal tersebut menunjukkan perbedaan antar kelompok kelas, yang bisa membuat model lebih mudah belajar pola dari kelompok yang lebih besar, sehingga berisiko menurunkan kemampuan model dalam mengklasifikasikan kelompok yang jumlahnya lebih sedikit. Sentimen negatif yang mendominasi menunjukkan bahwa sebagian besar opini publik

berreaksi dengan cara kritis terhadap kenaikan harga Pertamina. Oleh sebab itu, untuk tahap selanjutnya dalam penelitian tersebut, teknik resampling akan digunakan untuk memperbaiki ketidakseimbangan kelas dan mengukur pengaruhnya terhadap peningkatan kinerja model dengan mengklasifikasikan semua jenis sentimen secara lebih seimbang.

3.2 Praproses Data

Fase praproses data berperan untuk memperbaiki kualitas data teks sebelum proses ekstraksi fitur dan analisis sentimen dimulai. Tujuan dari tahap ini adalah memperkecil gangguan suara, menyamakan bentuk teks, dan mendapatkan penyajian data yang lebih seragam. Teknik yang digunakan mencakup membersihkan data, mengubah huruf menjadi besar atau kecil, melakukan normalisasi, memecah kata menjadi bagian-bagian, menghilangkan kata kata umum, dan mereduksi kata menjadi bentuk dasarnya. Selama proses pembersihan, hal-hal yang kurang penting seperti URL, emoji, simbol, angka tertentu, serta tanda baca yang terlalu banyak dihilangkan. Selanjutnya, dalam tahap konversi huruf kecil atau besar, semua huruf diganti ke huruf kecil. Sementara itu, pada tahap normalisasi, kata-kata yang belum memiliki bentuk standar akan diubah menjadi bentuk yang baku. Teks lalu dipecah menjadi token, kata-kata tidak penting dihapus, dan kata-kata dengan imbuhan diubah menjadi bentuk dasarnya. Langkah-langkah pra-pemrosesan ini membantu membuat data lebih rapi dan teratur, sehingga pembobotan TF-IDF dapat menciptakan gambaran fitur yang lebih akurat, yang mendukung proses analisis sentimen dengan lebih baik.

3.3 Pelabelan Data Sentimen


Analisis terhadap 5.006 tweet menunjukkan bahwa sentimen negatif paling banyak dengan 2.585 komentar (51,64%), kemudian sentimen positif dengan 1.782 komentar (35,60%), dan sentimen netral berada di posisi ketiga dengan 639 komentar (12,76%). Sentimen negatif mendominasi, artinya sebagian besar komentar mengandung kritik, kekhawatiran, atau keraguan terhadap cara penerapan kenaikan harga Pertamina. Sebaliknya, sentimen positif menunjukkan dukungan dan apresiasi masyarakat terhadap tujuan kenaikan harga Pertamina, sedangkan sentimen netral biasanya terdiri dari tanggapan yang informatif atau pernyataan yang hanya menjelaskan sesuatu tanpa menyampaikan perasaan yang kuat. Distribusi ini menunjukkan perbedaan besar antar kelas, yang mana sentimen negatif jumlahnya lebih banyak jika disejajarkan dengan dua kelas yang lain. Hal ini bisa memengaruhi cara model klasifikasi dilatih, karena algoritma biasanya lebih fokus pada pola yang ada di kelas yang jumlahnya lebih banyak. Karena itu, hasil distribusi sentimen ini digunakan sebagai dasar dalam penerapan teknik untuk menyelesaikan ketidakseimbangan kelas pada tahap selanjutnya. Adapun sampel hasil dari pelabelan data dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pelabelan Data

Text	Skor Sentiment	Label Sentiment
eheheh abangggg pertamax pertalite ehtapi premium wkwkwk	5	Positif
supra gue pertamax	0	Netral
pertamax	0	Netral
istighfar kali beli pertamax nyetok tas jatuh orang antri atm ya selamat kost	6	Positif
ngisi ribu pertamax ngisi kagak bgst	-3	Negatif

3.4 Pembagian Data

Pada tahap pembagian data, sebesar 80% dataset dijadikan data latih dan sebesar 20% dataset dijadikan data uji untuk melatih serta menguji model. Pemisahan data dilakukan dengan menggunakan stratifikasi berdasarkan label sentimen agar proporsi setiap kelas tetap terjaga. Sebelum proses pembagian dilakukan, variabel target "Sentimen Indonesia" diubah menjadi bentuk angka dengan cara memberi kode label. Proses ini menggunakan angka acak 42, yang menghasilkan 4.004 data sebagai pelatihan dan 1.002 data sebagai pengujian. Gambaran dari hasil pembagian dataset terdapat di Gambar 3.



Gambar 3. Diagram Pembagian Data

3.5 Hasil Pembobotan TF-IDF

metode TF-IDF (Term Frekuensi Inverse Document Frekuensi) digunakan dalam penelitian ini. pada metode ini, setiap kata diberikan nilai yang ditentukan oleh frekuensi kemunculannya. Pembobotan TF-IDF menghasilkan kumpulan angka yang menunjukkan kata - kata penting pada setiap dokumen, dan kemudian digunakan sebagai bagian dari fitur dalam proses analisis sentimen. Adapun kata dengan nilai TF-IDF tertinggi dapat dilihat pada tabel 3.


Tabel 3. Kata dengan nilai TF-IDF Tertinggi

Ranking	Kata	Hasil TF-IDF
1	pertamax	0.082667
2	harga	0.045104
3	pertalite	0.043793
4	ya	0.027735
5	beli	0.027377

Tabel 4 menampilkan lima kata yang memiliki skor TF-IDF terbesar yang diperoleh dari kumpulan tweet mengenai Pertamina. Kata - kata seperti "Pertamax," "harga," serta "Pertalite" mempunyai skor paling tinggi, sehingga menjadi fitur utama yang berperan penting dalam mengklasifikasikan dan membedakan kategori sentimen.

3.6 Optimasi SMOTE

Penggunaan Teknik *Synthetic Minority Over Sampling Technique* (SMOTE) dalam penelitian ini untuk memperbaiki distribusi data pada setiap kelas sentimen. Teknik ini membuat dataset palsu pada kelas yang jumlahnya sedikit dengan memperhatikan konsistensi data dalam ruang fitur, sehingga distribusinya jadi lebih seimbang untuk setiap kelas. SMOTE digunakan untuk memperkecil pengaruh kelas-kelas yang jumlah data yang banyak saat model sedang dilakukan. Dengan demikian, model dapat mengenali kelas yang jumlahnya sedikit dan menghasilkan klasifikasi yang lebih tepat dan stabil. Adapun visualisasi before dan after SMOTE dapat dilihat pada gambar 4.



Gambar 4. Visualisasi Before dan After SMOTE

Gambar 4 menunjukkan perubahan cara data terdistribusi sebelum dan setelah menggunakan Teknik *Oversampling Minoritas Sintetis* (SMOTE). Sebelum melakukan resampling, dataset terutama berisi sentimen negatif, sedangkan jumlah data pada kelas positif dan netral tidak terlalu banyak, sehingga bisa membuat model cenderung lebih memperhatikan kelas yang jumlahnya lebih banyak. Setelah menggunakan metode SMOTE, jumlah data pada kelas yang jumlahnya sedikit bertambah karena dibuatnya data buatan, yang membuat pembagian data menjadi lebih proporsional dan seimbang. Ini membantu model belajar lebih baik tentang ciri-ciri dari setiap kelas, sehingga meningkatkan kemampuannya dalam mengklasifikasikan, terutama untuk sentimen positif dan netral.

3.7 Hasil Pengujian Model

hasil penilaian pada tahap ini menampilkan model analisis sentimen yang dipergunakan untuk mengelompokkan pendapat ke dalam kategori positif, negatif, serta netral yang diambil dari data Twitter (X). Dataset dibagi sebagai data latih sebesar 80% dan data uji sebesar 20%. Metrik akurasi, presisi, recall, dan skor F1 dipergunakan untuk mengukur kinerja model. Evaluasi dilakukan dengan membandingkan hasil sebelum dan sesudah menerapkan teknik peningkatan minoritas sintetis (SMOTE).

3.7.1 Hasil Sebelum Penerapan SMOTE

Sebelum data diseimbangkan menggunakan teknik *Synthetic Minority Over-sampling Technique* (SMOTE), setiap model klasifikasi masih menghasilkan kinerja yang berbeda secara cukup signifikan. Tabel 4 menunjukkan Hasil pengecekan dari setiap model sebelum menggunakan teknik SMOTE.

Tabel 4. Hasil Sebelum Penerapan SMOTE

Model	Precision (Negatif%)	Precision (Positif%)	Recall (Negatif%)	Recall (Positif%)	F1-Score (Negatif%)	F1-Score (Positif%)	Accuracy
Random Forest	71.00	79.00	88.00	59.00	79.00	67.00	73.00
SVM	71.00	86.00	95.00	66.00	81.00	75.00	75.00

Berdasarkan hasil pada Tabel 4, kedua model masih kesulitan membedakan sentimen positif dan netral karena data tidak seimbang, dengan sentimen negatif yang paling banyak.

- Model Random Forest memiliki akurasi 73%, namun kemampuannya dalam mengenali sentimen positif masih kurang, dengan nilai recall sebesar 59%.
- Model SVM bekerja lebih baik dengan tingkat akurasi 75% serta recall 66% sebagai kategori sentimen positif. Namun, model ini lebih sering mengklasifikasikan sentimen negatif sebagai kategori utama.

Secara keseluruhan, hasil ini menunjukkan bahwa kedua model, tanpa menggunakan SMOTE, lebih mampu mengenali kelas yang jumlahnya banyak dibandingkan kelas yang jumlahnya sedikit. Karena itu, diperlukan penyeimbangan data agar kemampuan model dalam mengklasifikasikan berbagai kategori sentimen bisa lebih seimbang.

3.7.2 Hasil Sesudah Penerapan SMOTE

Setelah data diseimbangkan menggunakan teknik Synthetic Minority Over-sampling Technique (SMOTE) terbukti teknik ini dapat memperbaiki kualitas hasil dari model klasifikasi. Dengan menggunakan data sintesis untuk kelas minoritas, menyeimbangkan distribusi sentimen positif dan netral, model dapat lebih memahami karakteristik dari setiap kelas. Dampak penggunaan SMOTE terhadap kinerja model terlihat jelas dari hasil pengujian yang tercantum pada Tabel 5.

Tabel 5. Hasil Setelah Penerapan SMOTE

Model	Precision (Negatif%)	Precision (Positif%)	Recall (Negatif%)	Recall (Positif%)	F1-Score (Negatif%)	F1-Score (Positif%)	Accuracy
Random Forest	79.00	86.00	83.00	79.00	81.00	82.00	85.00
SVM	79.00	93.00	93.00	82.00	85.00	87.00	89.00

Berdasarkan hasil pada Tabel 5, penggunaan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) membuat tingkat akurasi meningkat baik algoritma *Random Forest* ataupun *Support Vector Machine* (SVM). Penyeimbangan distribusi data dengan membuat sampel buatan pada kelas minoritas mengurangi dampak ketidakseimbangan kelas, sehingga meningkatkan kemampuan model untuk mengenali sentimen dari setiap kategori.

- Setelah menggunakan teknik SMOTE, algoritma *Random Forest* berhasil memperoleh performa akurasi sebesar 85%. Dalam kelas sentimen negatif, model menghasilkan presisi sebesar 79%, recall 83%, dan skor F1 sebesar 81%. Di kelas sentimen positif, model memiliki presisi sebesar 86%, recall 79%, dan skor F1 mencapai 82%. Hasil ini menunjukkan bahwa metode Random Forest mampu membedakan kedua kelas dengan baik, meskipun kemampuannya dalam mendeteksi sentimen positif masih sedikit kurang dibandingkan dengan sentimen negatif.
- SVM menunjukkan hasil yang lebih baik dengan tingkat akurasi sebesar 89%. Dalam kelas negatif, model memiliki tingkat presisi 79%, recall 93%, dan skor F1 sebesar 85%, sedangkan untuk kelas positif, model mencapai presisi 93%, recall 82%, dan skor F1 87%. Berdasarkan nilai-nilai tersebut SVM terbukti lebih efektif dan lebih konsisten dalam melakukan klasifikasi pada setiap kategori sentimen.

Secara umum, SVM merupakan algoritma yang memiliki performa terbaik setelah menerapkan SMOTE. Dengan akurasi 89% dan skor F1 yang lebih baik daripada Random Forest baik untuk kelas positif maupun negatif, SVM terbukti lebih efektif dalam menganalisis sentimen masyarakat terkait kenaikan harga Pertamina di Platform X.


3.8 Confusion Matrix Sebelum dan Sesudah SMOTE

Tahap ini membandingkan confusion matriks antara algoritma *Random Forest* serta *Support Vector Machine* (SVM) dan melihat dampak penerapan teknik SMOTE (*Synthetic Minority Over-Sampling*) pada hasil klasifikasi. Hasil perbandingan kinerja model sebelum dan sesudah penerapan metode SMOTE disajikan pada gambar berikut untuk memberikan gambaran mengenai perubahan hasil klasifikasi yang diperoleh. Gambar tersebut memperlihatkan bagaimana masing-masing model mengelompokkan data ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Melalui visualisasi ini, dapat diamati perubahan kemampuan model dalam mengenali setiap kelas sentimen setelah dilakukan penyeimbangan data menggunakan metode SMOTE. Dengan demikian, visualisasi hasil klasifikasi sebelum dan sesudah penerapan metode SMOTE dapat dilihat pada Gambar 5.

- Confusion Matrix Sebelum dan Sesudah SMOTE (SVM)


Setelah penggunaan teknik SMOTE, model SVM dapat mengenali serta membedakan kelas sentimen yang tidak sering muncul secara lebih baik. Prediksi yang benar dalam kelas netral naik dari 24 menjadi 456, sedangkan dalam kelas positif naik dari 234 menjadi 432. Sebaliknya, jumlah prediksi yang benar di kelas negatif hanya turun

sedikit, dari 495 menjadi 487. Hasil ini menunjukkan bahwa metode SMOTE membantu mengurangi masalah ke pengisian antar kelas, sehingga membuat SVM lebih efektif dalam mengenali setiap jenis sentimen.



Gambar 5. Confusion Matrix Sebelum dan Setelah SMOTE (SVM)


b. Confusion Matrix Sebelum dan Sesudah SMOTE (Random Forest)



Gambar 6. Confusion Matrix Sebelum dan Setelah SMOTE (Random Forest)

Setelah menggunakan teknik SMOTE untuk meningkatkan data minoritas, model random forest menunjukkan peningkatan pada keterampilan mengklasifikasikan sentimen positif serta netral. perkiraan yang benar dalam kategori positif bertambah dari 209 menjadi 417, sedangkan dalam kategori netral meningkat dari 64 menjadi 472. Sebaliknya, jumlah prediksi yang benar dalam kategori negatif sedikit berkurang dari 458 menjadi 433, yang sesuai dengan peningkatan jumlah kesalahan klasifikasi dari kategori negatif ke kategori positif. Meskipun begitu, SMOTE berhasil membuat kinerja klasifikasi lebih seimbang, sehingga kemampuan model random forest dalam mendeteksi semua kategori sentimen meningkat, meskipun terjadi sedikit penurunan pada kategori yang jumlah datanya paling banyak.

3.9 Visualisasi Perbandingan Algoritma



Gambar 7. Visualisasi Perbandingan Algoritma

Gambar 7 membandingkan tingkat keakuratan dua algoritma yang digunakan sebelum serta sesudah mempergunakan teknik *Synthetic Minority Over-Sampling* (SMOTE). Pengujian memperlihatkan hasil dari kedua model memiliki akurasi yang lebih baik setelah data diimbangkan, menunjukkan bahwa metode SMOTE berhasil mengurangi pengaruh ketidakseimbangan kelas terhadap hasil klasifikasi.

Algoritma SVM mengalami peningkatan akurasi dari 75% menjadi 89%, sehingga meningkat sebesar 14%. Peningkatan ini menunjukkan bahwa data sintesis yang dibuat oleh SMOTE membantu SVM dalam menciptakan hypersurface yang lebih baik, sehingga model bisa membedakan antara kelas sentimen dengan lebih akurat.

Peningkatan serupa diamati untuk algoritma Random Forest. Setelah menggunakan teknik SMOTE, performa model meningkat dari 73% menjadi 85%, dengan peningkatan sebesar 12%. Hasil ini menunjukkan bahwa dengan menambahkan sampel ke kelas minoritas, Random Forest bisa membuat pohon keputusan yang lebih mewakili, sehingga proses klasifikasi menjadi lebih baik.

Dari hasil tersebut, terlihat bahwa penggunaan SMOTE memberikan dampak baik terhadap hasil kedua algoritma. Meskipun kedua metode tersebut mengalami peningkatan, SVM tetap memberikan hasil terbaik dengan tingkat akurasi 89%, yang lebih tinggi tidak seperti Random Forest yang hanya mencapai 85%. Temuan tersebut memperlihatkan bahwa SVM lebih optimal dalam membedakan opini publik yang seimbang terkait kenaikan harga Pertamina dibandingkan metode lainnya.

3.10 Pembahasan

Penelitian ini menemukan bahwa perasaan masyarakat terhadap kenaikan harga Pertamina di Platform X lebih banyak bersifat negatif, yaitu sebesar 51,64%, kemudian diikuti oleh perasaan positif sebesar 35,60%, dan perasaan netral sebesar 12,76%. Sentimen negatif yang mendominasi menunjukkan bahwa tindakan ini terus saja memicu kritik, kekhawatiran, dan ketidakpuasan dari masyarakat. Selain itu, distribusi data yang tidak merata menyebabkan ketidakseimbangan antara kelas-kelas, sehingga model klasifikasi lebih mudah mengenali kelas yang jumlahnya banyak dibandingkan kelas yang jumlahnya sedikit. Fase pra-pemrosesan, seperti pembersihan data, penyamaan kasus, normalisasi, tokenisasi, penghapusan kata tidak relevan, dan pemangkasan kata, berhasil meningkatkan kualitas data dengan mengurangi gangguan dan menyatukan cara penulisan kata. Pembobotan TF-IDF berikutnya memberikan representasi fitur yang lebih baik, di mana kata-kata seperti "Pertamax," "price," "Pertalite," "yes," dan "buy" menjadi fitur utama dalam proses klasifikasi.

Sebelum menggunakan SMOTE, model mengalami hambatan dalam kinerjanya karena data tidak seimbang. *Random Forest* mencapai akurasi 73%, sedangkan *Support Vector Machine* (SVM) mencapai 75%; meskipun demikian, kedua metode tersebut belum cukup baik untuk mengetahui sentimen positif serta netral. Setelah data diimbangkan menggunakan SMOTE, akurasi model Random Forest naik menjadi 85%, sedangkan akurasi SVM mencapai 89%. Selain peningkatan akurasi, presisi, recall, dan skor F1 juga meningkat, terutama pada kelas sentimen yang jumlahnya lebih sedikit.

Analisis *confusion matrix* menunjukkan bahwa metode SMOTE berhasil meningkatkan jumlah perkiraan yang benar bagi kelas positif serta netral, meskipun terjadi penurunan kecil dalam akurasi untuk kelas negatif. Teknik oversampling berhasil mengurangi bias model terhadap kelas sentimen yang jumlahnya lebih banyak, sehingga hasil klasifikasinya lebih seimbang.

Saat membandingkan kedua algoritma tersebut, SVM menunjukkan performa terbaik dengan akurasi mencapai 89%. Algoritma ini juga memiliki presisi terbesar pada kelas positif, recall terbaik pada kelas negatif, serta skor F1 yang unggul daripada *Random Forest*. Hasil tersebut menunjukkan bahwa menggabungkan beberapa tahap pra-pemrosesan, metode pembobotan TF-IDF, serta teknik SMOTE mampu meningkatkan kualitas hasil klasifikasi sentimen secara signifikan. Dari berbagai metode yang dicoba, SVM terbukti menjadi pendekatan paling efektif dalam menganalisis opini publik terkait kenaikan harga Pertamina di Platform X.

Temuan ini menunjukkan bahwa model SVM mampu melakukan generalisasi dengan lebih baik dalam mengklasifikasikan pola sentimen pada data Twitter terkait kenaikan harga Pertamina. Kemampuan tersebut terlihat dari kinerja SVM yang lebih optimal dalam membedakan setiap kategori sentimen pada data yang digunakan. Hasil ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa Support Vector Machine memiliki performa yang baik dalam analisis sentimen berbasis teks, terutama pada data dengan jumlah fitur yang banyak dan bersifat sparse seperti hasil pembobotan TF-IDF. Kondisi tersebut membuat SVM sesuai digunakan untuk mengolah data teks karena mampu menemukan batas pemisah yang optimal antar kelas sentimen. Berdasarkan hasil penelitian ini, Linear SVM dapat dipandang sebagai salah satu metode yang efektif untuk melakukan klasifikasi sentimen pada media sosial berbahasa Indonesia, khususnya dalam menganalisis opini masyarakat di Platform X mengenai kenaikan harga Pertamina..

4. KESIMPULAN

Tujuan penelitian dilakukan adalah mengkomparasikan bagaimana kedua algoritma tersebut bekerja dalam proses analisis perasaan atau pendapat publik tentang kenaikan harga Pertamina di Platform X. Proses pengklasifikasian menggunakan teknik bobot TF-IDF, sedangkan ketidakseimbangan data diselesaikan menggunakan metode SMOTE. Penelitian menunjukkan bahwa mayoritas data memiliki sentimen negatif, sehingga sebelum menggunakan SMOTE,

kedua model lebih baik dalam mengklasifikasikan data yang banyak daripada data yang sedikit. Dalam situasi ini, Random Forest mendapatkan tingkat akurasi 73%, sedangkan SVM mencapai 75%. Setelah data disetimbangkan dengan metode SMOTE, performa kedua algoritma meningkat secara nyata. Akurasi Random Forest naik menjadi 85%, sedangkan SVM mencapai 89%. Selain akurasi yang lebih baik, nilai presisi, recall, dan skor F1 juga meningkat, khususnya pada kelas sentiment "positif" dan "netral", yang sebelumnya sulit dibedakan karena ketidakseimbangan antar kelas. Analisis dengan matriks kebingungan menunjukkan bahwa SMOTE membantu meningkatkan jumlah prediksi yang benar pada kelas minoritas, sehingga membuat hasil klasifikasi lebih seimbang. Hasil ini menunjukkan bahwa dengan menggunakan SMOTE, performa model analisis sentimen menjadi lebih baik terutama pada dataset yang tidak seimbang. Dari dua algoritma yang diuji, Support Vector Machine (SVM) membuktikan hasil terbaik, memiliki tingkat akurasi tertinggi serta kemampuan klasifikasi yang lebih unggul dibandingkan Random Forest dalam menganalisis pandangan publik terkait kenaikan harga Pertamina di Platform X. Penelitian ini memberikan kontribusi dalam meningkatkan kualitas analisis sentimen serta menjadi referensi dalam pengembangan penelitian selanjutnya serta memberi pemahaman kepada para pemangku kepentingan mengenai tren opini masyarakat terkait kenaikan harga Pertamina, sehingga dapat membantu mereka dalam mengambil keputusan.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: F.W.O., dan A.R.I.;

Metodologi: F.W.O., dan A.R.I.;

Perangkat Lunak: F.W.O., dan A.R.I.;

Validasi: F.W.O., dan A.R.I.;

Analisis Formal: F.W.O., dan A.R.I.;

Investigasi: F.W.O., dan A.R.I.;

Sumber Daya: F.W.O., dan A.R.I.;

Kurasi Data: F.W.O., dan A.R.I.;

Penulisan Draf Awal: F.W.O., dan A.R.I.;

Penulisan, Peninjauan, dan Penyuntingan: F.W.O., dan A.R.I.;

Visualisasi: F.W.O., dan A.R.I.;

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data yang disajikan dalam penelitian ini tersedia berdasarkan permintaan kepada penulis korespondensi.

5.3 Pendanaan

Penelitian ini dilaksanakan dan didanai secara mandiri oleh penulis. Seluruh biaya yang berkaitan dengan pelaksanaan penelitian, mulai dari proses pengumpulan data, pengolahan dan analisis data, penyusunan manuskrip, hingga proses penulisan dan penerbitan artikel, ditanggung sepenuhnya oleh penulis. Penelitian ini tidak memperoleh pendanaan, hibah, sponsor, maupun dukungan finansial dari pemerintah, perguruan tinggi, perusahaan, organisasi, atau lembaga pendanaan lainnya.

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (Not applicable).

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (Not applicable).

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.

5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif untuk meningkatkan kejelasan penulisan dalam artikel ini. Para penulis telah meninjau dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas versi akhir publikasi.

REFERENCES

- [1] W. M. S. N. Hutagalung, Tony, and N. J. Perdana, "Analisis Sentimen Pada Opini Kenaikan Harga Bahan Bakar Minyak Pada Media Sosial Twitter," *J. Sist. Inf. DAN Tek. Komput.*, vol. 8, no. 2, pp. 280–284, 2023.
- [2] T. Danirmala and Y. S. Nugroho, "Analisis Sentimen Terhadap Topik Kenaikan Harga Bahan Bakar Minyak (BBM) pada Media Sosial Twitter," *Indones. J. Comput. Sci.*, vol. 12, no. 3, pp. 1258–1268, 2023.

- [3] wilda Asmarini, “Sah! Pertamina Naikkan Sah! Pertamina Naikkan Harga BBM Pertamax Rabu 10 Juni 2026,” CNBC Indonesia. Accessed: Jun. 09, 2026. [Online]. Available: <https://www.cnbcindonesia.com/news/20260609233802-4-741528/sah-pertamina-naikkan-harga-bbm-pertamax-rabu-10-juni-2026>
- [4] I. Septiana and D. Alita, “Perbandingan Random Forest dan SVM dalam Analisis Sentimen Quick Count Pemilu 2024,” vol. 9, no. 3, pp. 224–233, 2024, doi: 10.30591/jpit.v9i3.6640.
- [5] S. Kemp, “Digital 2026: Indonesia,” Datareportal. Accessed: Nov. 05, 2025. [Online]. Available: <https://datareportal.com/reports/digital-2026-indonesia>
- [6] J. Stephanus, J. Tanujaya, and M. R. Pribadi, “Applied Information Technology and Computer Science Analisis Sentimen Masyarakat terhadap Kenaikan Harga BBM Non-Subsidi Akibat Penutupan Selat Hormuz Menggunakan IndoBERT,” vol. 5, no. 1, pp. 164–173, 2026.
- [7] H. Vazli and R. R. Suryono, “Komparasi model svm, naïve bayes, dan random forest dalam analisis sentimen terhadap percakapan publik tentang Pertamina,” *J. Ilm. Penelit. dan Pembelajaran Inform.*, vol. 11, no. 1, pp. 92–105, 2026.
- [8] R. Ramlan, N. Satyahadewi, and W. Andani, “Analisis Sentimen Pengguna Twitter Menggunakan Support Vector Machine Pada Kasus Kenaikan Harga BBM,” *JAMBURA J. Math.*, vol. 5, no. 2, pp. 431–445, 2023.
- [9] S. Lina, M. Sitio, and R. Nadiyah, “Analisis Sentimen Kenaikan Harga BBM Pertamax Pada Media Sosial Menggunakan Metode Naïve Bayes Classifier,” vol. 4, no. 3, pp. 1224–1231, 2022, doi: 10.47065/bits.v4i3.2331.
- [10] I. Amal and Jayanta, “Perbandingan Pelabelan Otomatis Dan Manual Untuk Analisis Sentimen Terhadap Kenaikan Harga BBM Pertamina Pada Twitter Menggunakan Algoritma Support Vector Machine,” *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, pp. 473–487, 2023.
- [11] G. E. Yuliasuti, S. R. Wardhana, and A. Maulana, “Penerapan Insert-Lexicon untuk Analisis Sentimen Kenaikan Harga BBM pada Media Sosial Twitter,” *J. Teknol. Inf. dan Komun.*, vol. 19, no. 2, pp. 93–100, 2024.
- [12] D. E. Saputra and A. R. Isnain, “Implementasi algoritma convolutional neural network untuk analisis sentimen bacapres 2024 pada kolom komentar youtube mata najwa,” *J. Ilm. Penelit. dan Pembelajaran Inform.*, vol. 9, no. 3, pp. 1431–1441, 2024.
- [13] W. Romadhona and A. R. Isnain, “Analisis sentimen pengguna media sosial terhadap kebijakan kenaikan pajak hiburan menggunakan metode svm (support vector machine),” vol. 9, no. 4, pp. 2185–2195, 2024.
- [14] A. R. Isnain, N. S. Marga, and D. Alita, “Sentiment Analysis Of Government Policy On Corona Case Using Naive Bayes Algorithm,” vol. 15, no. 1, pp. 55–64, 2021.
- [15] A. F. Wibowo and A. Susanto, “Analisis Sentimen Twitter Terhadap Isu Royalti Lagu di Industri Musik Indonesia Menggunakan Naive Bayes dan Support Vector Machine Berbasis TF-IDF,” vol. 8, no. 1, pp. 330–341, 2026, doi: 10.47065/bits.v8i1.9842.
- [16] A. Farhan, I. Ridat, and A. R. Isnain, “Pemodelan topik dengan lda untuk memahami persepsi publik terhadap apple vision pro melalui analisis berita twitter,” vol. 10, no. 4, pp. 3233–3246, 2025.
- [17] N. Wayan, A. Sekar, and A. R. Isnain, “Analisis Sentimen Terhadap Media Sosial Twitter dengan Kasus Kampanye Anti-Korupsi di Indonesia Menggunakan Naive Bayes,” vol. 8, no. April, pp. 695–703, 2024, doi: 10.30865/mib.v8i2.7582.
- [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,” vol. 5, no. 4, pp. 1025–1034, 2024.
- [19] P. Elisa and A. Rahman Isnain, “Comparison Of Random Forest, Support Vector Machine And Naive Bayes Algorithms To Analyze Sentiment Towards Mental Health Stigma,” *J. Tek. Inform.*, vol. 5, no. 1, pp. 321–329, 2024, doi: 10.52436/1.jutif.2024.5.1.1817.
- [20] L. Najib, A. A. Mahfudh, and S. Bakhri, “Analisis Sentimen Persepsi Publik Terhadap Program MBG Pada Komentar YouTube Menggunakan Naïve Bayes dan Resampling,” vol. 7, no. 4, pp. 2467–2478, 2026, doi: 10.47065/bits.v7i4.9400.
- [21] M. Samantri and Afyati, “Perbandingan Algoritma Support Vector Machine dan Random Forest untuk Analisis Sentimen Terhadap Kebijakan Pemerintah Indonesia Terkait Kenaikan Harga BBM Tahun 2022,” *J. Teknol. Inf. dan Komun.*, vol. 8, no. 1, pp. 1–9, 2024.
- [22] A. R. Isnain, J. Supriyanto, and M. P. Kharisma, “Implementation of K-Nearest Neighbor (K-NN) Algorithm For Public Sentiment Analysis of Online Learning,” *Indones. J. Comput. Cybern. Syst.*, vol. 15, no. 2, pp. 121–130, 2021, doi: 10.22146/ijccs.65176.
- [23] N. Hendrastuty, A. Rahman Isnain, and A. Yanti Rahmadhani, “Analisis Sentimen Masyarakat Terhadap Program Kartu Prakerja Pada Twitter Dengan Metode Support Vector Machine,” *J. Inform. J. Pengemb. IT*, vol. 6, no. 3, pp. 150–155, 2021, [Online]. Available: <http://situs.com>
- [24] S. B. Setiawan and A. R. Isnain, “Sentimen Analisis Masyarakat Terhadap Pembangunan IKN Menggunakan Algoritma Lexicon Based Approach dan Naïve Bayes,” vol. 8, no. April 2019, pp. 1019–1030, 2024, doi: 10.30865/mib.v8i2.7605.