

Analisis Sentimen Media Sosial X Terhadap Kebijakan Presiden Republik Indonesia Prabowo Subianto

Ina Najiyah¹, Miftahul Rizal²

¹Program Studi Sistem Informasi, Fakultas Teknologi Informasi, Universitas Adhirajasa Reswara Sanjaya

²Program Teknik Informatika, Fakultas Teknologi Informasi, Universitas Adhirajasa Reswara Sanjaya

inajiyah@ars.ac.id, miftahulrizal04@gmail.com*

Abstract

This study aims to identify and measure the tendency of public sentiment towards the implementation of the policies of the President of the Republic of Indonesia, Prabowo Subianto. The methodology used is text mining-based sentiment analysis, utilizing a data corpus taken from the social media platform X. This study adopts the SEMMA (Sample, Explore, Modify, Model, Assess) workflow as a procedural framework. Data retrieval is carried out automatically using crawling techniques. Next, the data goes through a comprehensive text pre-processing stage, including cleaning, case folding, normalization, convert negation, tokenizing, stopword removal, stemming. Sentiment polarity is determined automatically through a lexicon-based approach, implemented with the VADER (Valence Aware Dictionary for Sentiment Reasoning) algorithm. The modeling phase uses two machine learning classification algorithms, namely Naïve Bayes and Support Vector Machine (SVM). Performance testing is carried out on three different training and testing data distribution schemes (90:10, 80:20, and 70:30). The evaluation findings show that the Naïve Bayes algorithm achieved the highest accuracy rate of 81.25% at a ratio of 80:20. Meanwhile, SVM consistently recorded superior accuracy, reaching a maximum value of 92.60% at a ratio of 90:10. Based on a comprehensive assessment of performance metrics (accuracy, precision, recall, and f1-score), the Support Vector Machine (SVM) algorithm was proven to provide significantly superior performance compared to Naïve Bayes in this sentiment classification task.

Keywords: sentiment analysis, text mining, SEMMA, naïve bayes, support vector machine (SVM)

Abstrak

Penelitian ini bertujuan mengidentifikasi dan mengukur tendensi sentimen masyarakat terhadap implementasi kebijakan Presiden Republik Indonesia, Prabowo Subianto. Metodologi yang digunakan adalah analisis sentimen berbasis penambangan teks (*text mining*), dengan memanfaatkan korpus data yang diambil dari *platform* media sosial X. Penelitian ini mengadopsi alur kerja SEMMA (*Sample, Explore, Modify, Model, Assess*) sebagai kerangka prosedural. Pengambilan data dilaksanakan secara otomatis menggunakan teknik *crawling*. Selanjutnya, data melalui tahap pra-pemrosesan teks yang komprehensif, meliputi *cleaning, case folding, normalization, convert negation, tokenizing, stopword removal, stemming*. Polaritas sentimen ditentukan secara otomatis melalui pendekatan berbasis leksikon, diimplementasikan dengan algoritma VADER (*Valence Aware Dictionary for Sentiment Reasoning*). Fase pemodelan, dua algoritma klasifikasi *machine learning*, yaitu *Naïve Bayes* dan *Support Vector Machine (SVM)*. Pengujian performa dilakukan pada tiga skema pembagian data *training* dan *testing* yang berbeda (90:10, 80:20, dan 70:30). Temuan evaluasi menunjukkan bahwa algoritma *Naïve Bayes* mencapai tingkat akurasi tertinggi sebesar 81,25% pada rasio 80:20. Sementara itu, SVM secara konsisten mencatatkan akurasi yang lebih superior, mencapai nilai maksimal 92,60% pada rasio 90:10. Berdasarkan penilaian komprehensif terhadap metrik kinerja (*accuracy, precision, recall, dan f1-score*), algoritma *Support Vector Machine (SVM)* terbukti menyajikan kinerja yang jauh lebih unggul (*significantly superior performance*) dibandingkan *Naïve Bayes* dalam tugas klasifikasi sentimen ini.

Kata kunci: analisis sentimen, *text mining*, SEMMA, *naïve bayes*, *support vector machine (SVM)*

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

1. Pendahuluan

Presiden menduduki posisi sebagai otoritas eksekutif tertinggi dalam sistem pemerintahan yang menganut prinsip presidensial. Berdasarkan sistem presidensial yang diterapkan di Republik Indonesia, Presiden memegang kekuasaan eksekutif tunggal, yang mencakup tanggung jawab seremonial Kepala Negara sekaligus tanggung jawab administratif Kepala Pemerintahan [1]. Kedua peran tersebut memberikan mandat dan kewenangan eksekutif untuk melaksanakan fungsi administrasi pemerintahan. Implementasi otoritas eksekutif tersebut dilaksanakan secara kolektif (kolegial) melalui kerja sama fungsional antara

Presiden, wakil presiden, dan seluruh anggota kabinet menteri. Masa jabatan presiden dan wakil presiden ditetapkan selama lima tahun. Perpanjangan masa jabatan dimungkinkan untuk satu periode melalui mekanisme pemilihan umum yang bersifat langsung dan demokratis [2].

Tanggal 20 Oktober 2024, Indonesia secara resmi memasuki era pemerintahan baru dengan dilantikannya Bapak Prabowo Subianto sebagai Presiden Republik Indonesia. Sosok Prabowo dikenal memiliki latar belakang militer dengan karakter kepemimpinan yang tegas, visioner, serta memiliki dedikasi tinggi terhadap kepentingan nasional. Dalam kepemimpinannya,

beliau berkomitmen memperkuat perekonomian nasional, meningkatkan kesejahteraan rakyat, dan mewujudkan tata kelola pemerintahan yang transparan, efektif, serta berorientasi pada pembangunan yang inklusif [3].

Dilantiknya bapak Prabowo Subianto menandai dimulainya era pemerintahan baru dengan berbagai kebijakan yang kini mulai diterapkan. Sejumlah kebijakan tersebut memunculkan beragam respons dan perdebatan di masyarakat. Mulai dari kebijakan Swasembada pangan, hilirisasi, program Makanan Bergizi Gratis (MBG), penghapusan utang Usaha Mikro, Kecil dan Menengah (UMKM), Kenaikan Tarif Pajak Pertambahan Nilai (PPN) 12%, efisiensi anggaran, pembentukan badan pengelola investasi Danantara, Pemberantasan korupsi, kenaikan Harga Pembelian Pemerintah (HPP) gabah dan jagung dan Pembentukan koperasi merah putih. Kebijakan yang diterapkan oleh bapak Prabowo Subianto menuai opini yang beragam, Setiap kebijakan membawa konsekuensi sosial, ekonomi, maupun politik yang dirasakan oleh berbagai lapisan masyarakat dan sektor usaha [4].

Secara sosial, program seperti MBG berpotensi meningkatkan gizi pelajar dan kelompok rentan, sedangkan pembentukan koperasi merah putih dapat memperkuat pemberdayaan komunitas. Dari aspek ekonomi, kebijakan hilirisasi dan swasembada pangan diharapkan mendorong kemandirian industri dan stabilitas produksi, sementara kenaikan PPN 12% dan efisiensi anggaran memunculkan kekhawatiran mengenai turunnya daya beli serta beban bagi sektor usaha kecil. Secara politik, langkah pemberantasan korupsi dan pembentukan badan pengelola investasi Danantara berpengaruh pada persepsi publik mengenai transparansi, akuntabilitas, dan arah investasi nasional.

Penelitian ini mencakup seluruh kebijakan utama yang diimplementasikan pada masa awal pemerintahan Prabowo Subianto, sehingga analisis dampak sosial, ekonomi, dan politik dapat dilakukan secara menyeluruh tanpa membatasi pada satu kebijakan tertentu.

Kemajuan teknologi informasi telah mendorong peningkatan penggunaan media sosial sebagai sarana komunikasi masyarakat. Platform seperti X, menjadi ruang digital yang banyak dimanfaatkan masyarakat untuk menyampaikan pandangan, tanggapan, dan evaluasi terhadap berbagai kebijakan pemerintahan Presiden Prabowo Subianto. Penelitian ini berfokus untuk menganalisis kecenderungan opini dan sentimen masyarakat yang muncul pada media sosial tersebut terhadap kebijakan yang dijalankan oleh pemerintah.

Sejumlah penelitian terdahulu telah mengintegrasikan teknik *text mining* dengan algoritma *machine learning*, khususnya *Naïve Bayes* dan *Support Vector Machine* (SVM), untuk menganalisis sentimen masyarakat terhadap berbagai isu sosial, ekonomi, serta kebijakan pemerintah. Di antara penelitian tersebut terdapat karya

analisis sentimen *twitter* terhadap tokoh masyarakat dengan algoritma *naïve bayes* dan *support vector machine* [5], analisis sentimen pada proyeksi pemilihan presiden 2024 menggunakan metode *support vector machine* [6], analisis sentimen pada media sosial x terhadap tokoh publik peserta pilpres 2019 [7], penelitian oleh nanda dwi husna sadikin dan sari susanti, berjudul analisis sentimen publik terhadap kampanye pengurangan sampah plastik menggunakan algoritma *naïve bayes* [8], analisis sentimen terhadap menteri indonesia dengan algoritma *support vector machine* dan *naïve bayes* [9], analisis sentimen tanggapan masyarakat tentang kenaikan BBM menggunakan metode *artificial neural network* [10], analisis sentimen terhadap layanan aplikasi grab indonesia menggunakan metode *naïve bayes* [11], penerapan *text mining* analisis sentimen mengenai vaksin covid-19 menggunakan metode *naïve bayes* [12], analisis sentimen *review* halodoc menggunakan *naïve bayes classifier* [13], sentimen analisis covid-19 dengan metode *probabilistic neural network* dan TF-IDF [14], penerapan algoritma *naïve bayes* dan SVM untuk analisis sentimen *boy band* bts pada media sosial twitter [15], sentimen analisis vaksin covid-19 menggunakan *naïve bayes* dan *support vector machine* [16], metode SVM dan *naïve bayes* untuk analisis sentimen chatgpt di twitter [17], analisis sentimen terhadap kebijakan pemerintah tentang larangan mudik hari raya idul fitri di indonesia tahun 2021 menggunakan *naïve bayes* [18], analisis sentimen publik terhadap kenaikan pajak PPN di indonesia tahun 2024 menggunakan algoritma *machine learning* [19].

Penelitian ini dilaksanakan dengan tujuan utama untuk menganalisis kecenderungan sentimen masyarakat terhadap berbagai kebijakan yang diimplementasikan oleh pemerintahan bapak Prabowo Subianto. Selain memberikan pemahaman empiris mengenai respons publik, penelitian ini juga memiliki nilai praktis, yakni menjadi dasar pertimbangan bagi pemerintah dalam menilai efektivitas suatu kebijakan dari perspektif masyarakat. Temuan penelitian ini diharapkan dapat memberikan gambaran mengenai aspek kebijakan yang diterima maupun ditolak masyarakat, sehingga dapat dimanfaatkan untuk perbaikan pelaksanaan program, penyesuaian strategi komunikasi pemerintah, serta penyusunan kebijakan lanjutan yang lebih responsif, inklusif, dan sesuai dengan kebutuhan masyarakat. Untuk mencapai tujuan tersebut, diterapkan pendekatan *text mining* sebagai metodologi pengolahan data yang memfasilitasi identifikasi serta klasifikasi opini masyarakat berdasarkan polaritas sentimen yang terdapat dalam teks. Kebijakan-kebijakan yang diimplementasikan oleh bapak Prabowo Subianto mencakup swasembada pangan, hilirisasi, program makanan bergizi gratis (MBG), pembebasan kewajiban utang bagi sektor usaha mikro, kecil, dan menengah (UMKM), kenaikan tarif pajak pertambahan nilai (PPN) 12%, efisiensi anggaran, pembentukan badan pengelola investasi danantara, pemberantasan korupsi, kenaikan harga pembelian pemerintah (HPP) gabah

dan jagung, serta bantuan koperasi merah putih. Dampak kebijakan pemerintahan terhadap berbagai sektor sosial, ekonomi, dan politik yang diterapkan pada pemerintahan bapak Prabowo Subianto juga menjadi fokus analisis.

Penelitian ini mengadopsi kerangka kerja SEMMA (*Sample, Explore, Modify, Model dan Assess*) sebagai panduan struktural untuk keseluruhan persiapan data dan proses analisis sentimen [20]. Pada tahap pemodelan (model), penelitian ini memanfaatkan dua algoritma pembelajaran mesin (*machine learning*), yaitu *Naïve Bayes* dan *Support Vector Machine (SVM)*, yang diaplikasikan untuk tugas klasifikasi polaritas opini. Volume opini masyarakat yang terekam terhadap inisiatif kebijakan spesifik dijadikan sebagai indikator kuantitatif utama dalam analisis. Korpus data bersumber dari *platform* media sosial X, yang diekstraksi menggunakan teknik *crawling*. Total data yang berhasil dikumpulkan adalah 10.735 *tweet*, yang mencakup spektrum sentimen, baik positif maupun negatif.

Data yang telah dikumpulkan selanjutnya menjalani proses pengolahan data (*preprocessing*) guna meningkatkan kualitas analisis. Tahapan tersebut meliputi *cleaning, case folding, normalization, convert negation, tokenizing, stopword removal, stemming*.

Penelitian ini bertujuan untuk memberikan kontribusi dalam memahami opini masyarakat terhadap kebijakan pemerintahan bapak Prabowo Subianto, serta berfungsi sebagai masukan bagi pemerintah dalam menyusun strategi peningkatan kualitas kebijakan. Dengan demikian, dapat diperoleh pemahaman mendalam atas opini masyarakat terhadap kebijakan pemerintahan Bapak Prabowo Subianto. Temuan dari penelitian ini diharapkan dapat berfungsi sebagai basis empiris yang substansial untuk merumuskan dan menyempurnakan kebijakan yang dicirikan oleh sifat responsif, inklusif, dan adaptif terhadap kebutuhan masyarakat Indonesia.

2. Metode Penelitian

Penelitian ini mengimplementasikan pendekatan kuantitatif yang berlandaskan pada analisis penambangan teks (*text mining*) dan pembelajaran mesin (*machine learning*) sebagai fondasi metodologis utama. Inti dari pendekatan ini adalah pemrosesan, ekstraksi, dan klasifikasi data tekstual berdasarkan polaritas sentimen, yang dikategorikan secara dikotomi menjadi positif dan negatif. Prosedur analisis melibatkan serangkaian tahapan sekuensial, mencakup akuisisi data, proses pembersihan data (*data cleaning*) yang mendalam, dan selanjutnya penerapan algoritma klasifikasi untuk menghasilkan interpretasi sentimen yang akurat. Secara teknis, penelitian ini mengkomparasikan kinerja dua algoritma klasifikasi utama, yaitu *Naïve Bayes* dan *Support Vector Machine (SVM)*. Kedua algoritma ini dipilih berdasarkan efektivitasnya yang telah teruji dalam konteks analisis sentimen terhadap korpus data yang bersumber dari

platform media sosial. *Naïve Bayes* memiliki kelebihan dalam menangani data teks yang bersifat bervolume besar, bersifat *noisy*, serta memiliki fitur yang tinggi. Algoritma ini mampu bekerja dengan cepat, efisien, dan menunjukkan performa yang baik pada data yang telah melalui tahap pembersihan (*preprocessing*). Sementara itu, *Support Vector Machine (SVM)* dikenal unggul dalam mengklasifikasikan data dengan batas pemisah yang kompleks, sehingga efektif dalam menangani variasi bahasa, ambiguitas, dan pola ekspresi pengguna media sosial yang cenderung tidak terstruktur. Dengan karakteristik tersebut, kedua algoritma ini dinilai sesuai untuk menghasilkan prediksi sentimen yang akurat pada data yang berasal dari *platform X*.

2.1. Pengumpulan Data

Pengumpulan data dilaksanakan secara terstruktur dan sistematis guna memastikan perolehan data yang relevan, valid, dan representatif terhadap topik yang diteliti. Proses ini mencakup dua langkah utama.

1. Studi Literatur

Tahap awal penelitian melibatkan kajian literatur yang komprehensif, melibatkan berbagai sumber akademik dan pustaka relevan, meliputi buku, artikel ilmiah, dan hasil penelitian terdahulu yang berkaitan dengan analisis sentimen. Kajian ini difokuskan pada kerangka teoritis Pemrosesan Bahasa Alami (*Natural Language Processing*), konsep *text mining*, serta metode algoritma klasifikasi *Naïve Bayes* dan *Support Vector Machine (SVM)*. Selain itu, dilakukan penelaahan mendalam mengenai penerapan bahasa pemrograman Python untuk mengimplementasikan proses analisis sentimen.

2. *Crawling* Data

Tahap penelitian berikutnya berfokus pada akuisisi data melalui proses penambangan data (*data crawling*). Kegiatan ini merupakan ekstraksi data tekstual secara sistematis dari *platform* media sosial X yang berkaitan dengan kebijakan Pemerintahan Presiden Republik Indonesia, bapak Prabowo Subianto. Proses *crawling* diimplementasikan menggunakan bahasa pemrograman *Python* dalam lingkungan *Google Colaboratory*, memanfaatkan berbagai pustaka (*libraries*) untuk mengekstraksi, memfilter, dan menyimpan data secara otomatis.

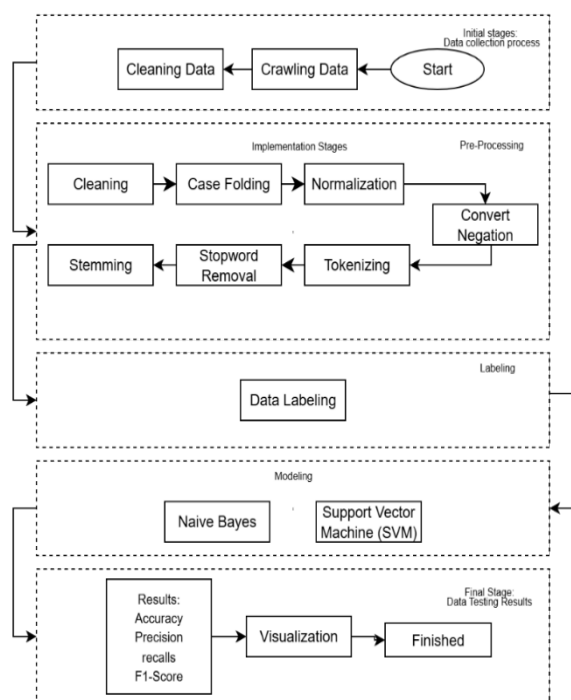
Teknik *crawling* dilakukan melalui pemanfaatan API atau *library* Python yang dirancang untuk mengakses data dari *platform X*, seperti *Tweepy, snsrape*. Pustaka tersebut memungkinkan peneliti untuk mengambil data secara efisien berdasarkan kata kunci tertentu, rentang waktu, maupun parameter relevan lainnya. Dengan pendekatan ini, data yang dihasilkan menjadi lebih terstruktur, akurat, dan sesuai dengan kebutuhan penelitian. *Dataset* yang diperoleh melalui teknik ini kemudian menjadi bahan baku utama untuk tahap analisis sentimen, sehingga kualitas dan relevansinya sangat menentukan ketepatan hasil penelitian.

2.2. Alur Penelitian

Alur penelitian ini diimplementasikan menggunakan kerangka kerja metodologis SEMMA (*Sample, Explore, Modify, Model, Assess*). Kerangka ini dipilih karena menawarkan pendekatan sistematis dan terstruktur yang sangat relevan dan efisien untuk digunakan dalam riset berbasis data (*data-driven research*). Khususnya dalam konteks analisis sentimen terhadap opini masyarakat di media sosial. Pendekatan ini dipilih karena dapat memberikan kejelasan dalam setiap proses penelitian, serta membantu dalam mengelola data dalam jumlah besar secara efisien dan terarah.

Melalui penggunaan pendekatan SEMMA ini, penelitian diharapkan mampu menghasilkan temuan yang tidak hanya akurat secara teknis, namun juga relevan secara kontekstual dengan dinamika sosial politik yang terjadi, sehingga penelitian ini dapat memberikan kontribusi ilmiah yang bermakna serta menjadi acuan dalam memahami dinamika opini masyarakat di era digital yang terus berkembang.

Berikut ini *flowchart* penelitian yang menjelaskan detail tahapan penelitian dalam gambar 1.



Gambar 1. *Flowchart* Penelitian

1. Proses Pengumpulan Data

Tahapan awal dalam penelitian ini diawali dengan pengumpulan data bersumber dari media sosial X. proses diawali dengan mengakses akun media sosial X dan menghubungkan dengan *Google Colaboratory*. Proses penelitian ini dilaksanakan pada rentang waktu 20 Oktober 2024 sampai 30 April 2025, karena pada 20 Oktober 2024 bapak Prabowo Subianto baru dilantik menjadi Presiden Republik Indonesia dan periode tersebut Bapak Prabowo Subianto menjadi salah satu

topik yang sedang *trending* di *platform* media sosial X. Selanjutnya dilakukan *crawling* data berdasarkan kata kunci seperti “presiden prabowo”, “prabowo”, “BPI danantara”, “danantara”, “makan bergizi gratis”, “MBG”, “Korupsi”, “PPN”, “PPN12%”, “hilirisasi”, “efisiensi”, “efisiensi anggaran”, “efisiensi pemerintah”, “swasembada”, “swasembada pangan”, “utang UMKM”, “UMKM”, “kenaikan harga gabah”, “gabah”, “kenaikan UMP”, “UMP”, “upah”, “koperasi merah putih”, Untuk memperoleh variasi data yang relevan. Hasil pengumpulan data menghasilkan total 10.735 *tweet*, terdapat 15 atribut.

Tahap selanjutnya adalah *cleaning* data, yaitu menghapus atribut atau kolom yang tidak relevan dari total 15 atribut yang diperoleh saat *crawling*. Pada tahap ini, fokusnya hanya pada penghapusan data yang tidak diperlukan tanpa melakukan penanganan data hilang atau duplikat. Karena *feature selection* dilakukan dengan pendekatan relevansi, bukan berdasarkan korelasi atau uji statistik. Dari 15 atribut yang tersedia, hanya *id* dan *tweet* yang dipilih karena keduanya merupakan atribut yang berkontribusi langsung terhadap proses analisis sentimen. Atribut lainnya seperti *username*, lokasi, jumlah *like*, jumlah *retweet*, tidak memengaruhi penentuan polaritas sentimen sehingga dianggap tidak relevan dan dihilangkan.

2. Tahap *Text Preprocessing*

Pra-pemrosesan teks (*text preprocessing*) merupakan fase fundamental yang krusial dalam transformasi *dataset* mentah. Tujuan utama dari tahapan ini adalah untuk menyiapkan dan menyempurnakan data tekstual, sehingga mencapai kondisi optimal untuk diumpungkan ke algoritma pemodelan (*modeling algorithms*). Proses pra-pemrosesan ini melibatkan serangkaian tahapan yang ketat dan sekuensial, tahapan *preprocessing* yang dilakukan meliputi *cleaning* yaitu proses menghapus elemen-elemen yang tidak relevan seperti URL, *mention*, angka, dan tanda baca, *case folding* yaitu mengubah seluruh teks menjadi huruf kecil untuk menjaga konsistensi, *normalization* yaitu menyeragamkan kata-kata tidak baku atau slang menjadi bentuk baku, *convert negation* yaitu mendeteksi kata negasi dan menggabungkannya dengan kata setelahnya agar makna kalimat tidak berubah, *tokenizing* yaitu memecah kalimat menjadi unit kata, *stopword removal*, yaitu menghilangkan kata-kata umum yang tidak memiliki makna signifikan dalam analisis (misalnya: di, ke, dan, yang), serta *stemming* yaitu mengubah kata ke bentuk dasar untuk meminimalisasi variasi kata dalam korpus..

3. Pelabelan Data

Data teks yang telah dibersihkan kemudian dilanjutkan ke proses pelabelan menggunakan pendekatan *lexicon-based VADER*. Pada tahap ini, setiap kata dalam teks dianalisis dan dibandingkan dengan kamus sentimen (*sentiment lexicon*) yang berisi daftar kata beserta nilai polaritas positif maupun negatif. *VADER (Valence*

Aware Dictionary for Sentiment Reasoning) bekerja dengan menilai intensitas sentimen berdasarkan konteks kata, penggunaan huruf kapital, tanda baca yang dapat memperkuat atau melemahkan makna suatu kata.

Selain menghitung skor polaritas setiap kata, VADER juga menghasilkan skor komposit (*compound score*) yang mencerminkan keseluruhan sentimen dalam sebuah kalimat. Berdasarkan skor ini, sistem kemudian secara otomatis menentukan label sentimen dari masing-masing *tweet* tanpa memerlukan data berlabel sebelumnya. Pendekatan ini memungkinkan proses klasifikasi awal dilakukan secara cepat, efisien, dan cukup akurat untuk data media sosial..

4. Pemodelan

Tahap krusial selanjutnya dalam penelitian ini adalah pemodelan data, di mana dataset yang telah melalui pelabelan dan pra-pemrosesan (*preprocessing*) diimplementasikan ke dalam dua algoritma klasifikasi adalah algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM). Secara spesifik, algoritma *Naïve Bayes* dipilih karena merupakan metode klasifikasi yang didasarkan pada prinsip probabilistik dan banyak diaplikasikan dalam konteks pemrosesan teks (*text processing*). Pemilihan ini didukung oleh karakteristik *Naïve Bayes* yang menawarkan efisiensi komputasi yang tinggi dan kecepatan eksekusi yang optimal. Di sisi lain, SVM beroperasi dengan menentukan hiperbidang (*hyperplane*) optimal yang memisahkan data ke dalam kelas-kelas tertentu berdasarkan karakteristik fiturnya. SVM dikenal efektif dalam mengelola data teks berdimensi tinggi (*high-dimensional text data*) sehingga sering digunakan dalam penelitian analisis sentimen untuk meningkatkan akurasi klasifikasi. *Naïve Bayes* umumnya lebih efektif digunakan ketika distribusi data relatif seimbang dan teks memiliki pola yang sederhana, sehingga proses perhitungan probabilitas dapat bekerja secara optimal. Sementara itu, SVM lebih unggul ketika data memiliki batas pemisah yang kompleks, distribusinya tidak linear, atau ketika terdapat banyak fitur, sehingga diperlukan model dengan kemampuan generalisasi yang lebih kuat untuk mencapai akurasi tinggi.

5. Hasil Pengujian Data

Tahap akhir atau penutup dari penelitian ini adalah evaluasi kinerja model dan penyajian hasil pengujian data. Proses evaluasi ini dirancang untuk mengukur kapabilitas prediktif dari model klasifikasi dengan mengaplikasikan rangkaian metrik pengukuran standar (*standard performance metrics*), meliputi *accuracy*, *precision*, *recall*, dan *f1-score*. Keempat metrik ini menyediakan gambaran komprehensif mengenai kemampuan model dalam mengklasifikasikan polaritas sentimen secara akurat. Secara spesifik, *accuracy* mengindikasikan tingkat ketepatan klasifikasi model secara agregat, sementara *precision* dan *recall* berfungsi untuk menilai keberhasilan model dalam mengidentifikasi setiap kelas sentimen secara benar,

meminimalkan *false positives* dan *false negatives*. *f1-score*, pada gilirannya, digunakan sebagai ukuran harmonis (*harmonic mean*) yang menyeimbangkan antara *precision* dan *recall*. Hasil evaluasi disajikan dalam format tabular dan grafis untuk memfasilitasi interpretasi kuantitatif dan terukur kinerja komparatif masing-masing algoritma dalam proses klasifikasi sentimen masyarakat. Dalam konteks analisis sentimen, *precision* menjadi penting untuk memastikan bahwa sentimen yang diprediksi positif atau negatif, sehingga menghindari kesalahan interpretasi terhadap opini masyarakat. *Recall* berperan penting ketika tujuan penelitian adalah menangkap sebanyak mungkin sentimen dari setiap kelas, terutama jika terdapat ketidakseimbangan data. *F1-score* kemudian menjadi indikator utama untuk menilai keseimbangan performa model, sedangkan *accuracy* memberikan gambaran umum namun tetap perlu dilihat bersama metrik lainnya agar penilaian tidak bias terhadap kelas yang dominan. Dengan pendekatan ini, evaluasi kinerja model menjadi lebih akurat dan relevan terhadap kebutuhan penelitian.

3. Hasil dan Pembahasan

3.1. Sample

Struktur penelitian ini dibagi menjadi dua bagian utama. Bagian pertama adalah tinjauan sistematis (*systematic review*) terhadap penelitian-penelitian sebelumnya untuk membangun dasar teoritis dan metodologis yang kuat, sehingga penelitian ini memiliki acuan yang jelas mengenai pendekatan analisis sentimen yang relevan. Bagian kedua berfokus pada proses akuisisi data empiris melalui teknik *crawling*, yaitu pengumpulan data dari *platform* media sosial X yang berkaitan dengan kebijakan pemerintahan. Kedua bagian ini saling melengkapi, tinjauan sistematis memberikan landasan teori dan arah analisis, sedangkan akuisisi data menyediakan informasi aktual dari masyarakat yang menjadi objek utama dalam penelitian ini.

1. Penelitian Sejenis

Tinjauan terhadap studi-studi sejenis (*related work*) digunakan sebagai dasar dalam merumuskan kerangka teoritis dan metodologi penelitian ini. Penelitian terdahulu mengenai analisis sentimen, terutama yang membahas penggunaan algoritma *Naïve Bayes* dan *Support Vector Machine* (SVM), memberikan gambaran mengenai efektivitas masing-masing metode dalam mengolah data berbasis teks. Selain itu, kajian terkait prosedur pelabelan data turut memengaruhi rancangan proses *labeling* yang diterapkan dalam penelitian ini. Secara keseluruhan, penelitian-penelitian sebelumnya berperan penting dalam menentukan pendekatan *preprocessing*, pemilihan algoritma, serta strategi evaluasi yang digunakan dalam penelitian ini.

2. Crawling Data

Pengambilan data dilakukan melalui menerapkan teknik *crawling* secara terprogram data dari *platform* media sosial X, menggunakan kata kunci sebagai berikut :

Tabel 1. Kata Kunci *Crawling*

Kategori	Kata Kunci
Presiden	“presiden prabowo”, “prabowo”
BPI Danantara	“BPI danantara”, “danantara”.
Makan Bergizi Gratis	“makan bergizi gratis”, “MBG”.
Korupsi	“Korupsi”.
Kenaikan PPN	“PPN”, “PPN12%”.
Hilirisasi Industri	“hilirisasi”.
Efisiensi Anggaran	“efisiensi”, “efisiensi anggaran”, “efisiensi pemerintah”.
Swasembada Pangan	“swasembada”, “swasembada pangan”.
Penghapusan Utang UMKM	“utang UMKM”, “UMKM”
Kenaikan Harga gabah	“kenaikan harga gabah”, “gabah”.
Kenaikan Upah	“kenaikan UMP”, “UMP”, “upah”.
Koperasi Merah Putih	“koperasi merah putih”.

Data yang dikumpulkan berupa teks *tweet* dari pengguna media sosial X pada rentang waktu 20 Oktober 2024 sampai 30 April 2025. Total jumlah *tweet* yang diperoleh sebanyak 10.735 *tweet*.

Proses pengambilan data, penelitian ini menggunakan *platform Google Colaboratory* untuk melakukan *crawling* data dari media sosial X, dimana hasil pengambilan data tersebut disimpan dalam format CSV. Proses ini dilakukan dengan memanfaatkan berbagai pustaka atau *library* yang mendukung koneksi ke API (*Application Programming Interface*) pada *platform* media sosial X, sehingga memungkinkan proses ekstraksi data dilakukan secara otomatis, efisien, dan terstruktur.

3.2. Explore

Data yang diperoleh melalui proses *crawling* terdiri dari 15 kolom yang masing-masing memuat informasi penting terkait *tweet* yang diambil, seperti nama pengguna, isi *tweet*, tanggal dan waktu unggahan, serta meta data lainnya.

Data hasil *crawling* yang diperoleh dalam penelitian ini terdiri atas 15 kolom, namun hanya 2 kolom yang dipilih untuk dianalisis lebih lanjut, yaitu kolom “ID” yang merepresentasikan identitas unik setiap *tweet* dan kolom “TEXT” yang berisi isi atau konten dari *tweet* tersebut. Kolom ini dianggap paling relevan dalam proses analisis sentimen.

3.3. Modify

Tahap Modifikasi (*Modify*) dalam kerangka SEMMA dilaksanakan melalui pra-pemrosesan teks (*text preprocessing*). Tujuan esensial dari proses ini adalah menyiapkan data tekstual agar dapat dikenali dan diproses secara optimal oleh sistem komputasi. Proses pra-pemrosesan teks (*text preprocessing*) memainkan peranan esensial dalam mengkonversi data tekstual mentah yang tidak terstruktur menjadi sebuah *dataset* yang terstruktur dan terorganisir dengan baik, sehingga

meningkatkan efektivitasnya pada tahapan analisis berikutnya. Secara spesifik, *text preprocessing* dalam penelitian ini mencakup tujuh langkah utama: *cleaning*, *case folding*, *normalization*, *convert negation*, *tokenizing*, *stopword removal*, dan *stemming*. Setiap langkah tersebut berkontribusi secara fungsional dalam peningkatan kualitas, konsistensi, dan keterbacaan data teks yang akan diolah lebih lanjut.

1. Cleaning dan Case Folding

Tahap Pada langkah awal ini, dua prosedur utama diimplementasikan, yaitu pembersihan data (*cleaning*) dan *case folding*. Proses *cleaning* (pembersihan data) bertujuan untuk mengeliminasi elemen-elemen yang tidak relevan dari korpus teks, termasuk karakter khusus, numerik, tanda baca, *mention*, *hashtag*, serta simbol-simbol lain yang tidak memiliki kontribusi semantik signifikan dalam konteks analisis sentimen. Melalui eliminasi ini, hanya *fragmen teks* yang informatif dan relevan secara kontekstual terhadap penelitian yang dipertahankan untuk analisis lebih lanjut. Sementara itu, penyeragaman kasus (*case folding*) dilakukan untuk menstandarisasi bentuk huruf pada seluruh *dataset* dengan mengonversi semua karakter menjadi huruf kecil. Prosedur ini berfungsi untuk mencegah sistem komputasi membedakan antara kapitalisasi dan non-kapitalisasi pada leksikon yang memiliki makna identik. Berikut adalah tampilan hasil *tweet* sebelum dan sesudah melalui tahap *cleaning*.

Tabel 2. Hasil Proses *Cleaning*

Sebelum (<i>Text</i>)	Sesudah (<i>Cleaning</i>)
Rakyat semua disuruh bayar pajak bagi yg tdk mampu tdk bayar pajak SPT tapi tetap bayar pajak saat beli barang & jasa. Disaat politik tdk profesional bekerja menandakan tdk amanah & koruptif dlm pelaksanaannya @prabowo @habiburokhman @setkabgoid @ariabima99 @AgusYudhoyono	Rakyat semua disuruh bayar pajak bagi yg tdk mampu tdk bayar pajak SPT tapi tetap bayar pajak saat beli barang amp jasa Disaat politik tdk profesional bekerja menandakan tdk amanah amp koruptif dlm pelaksanaannya

Berikut adalah tampilan hasil *tweet* sebelum dan sesudah melalui tahap *case folding*.

Tabel 3. Hasil Proses *Case Folding*

Sebelum (<i>Cleaning</i>)	Sesudah (<i>Case Folding</i>)
Rakyat semua disuruh bayar pajak bagi yg tdk mampu tdk bayar pajak SPT tapi tetap bayar pajak saat beli barang amp jasa Disaat politik tdk profesional bekerja menandakan tdk amanah amp koruptif dlm pelaksanaannya	rakyat semua disuruh bayar pajak bagi yg tdk mampu tdk bayar pajak spt tapi tetap bayar pajak saat beli barang amp jasa disaat politik tdk profesional bekerja menandakan tdk amanah amp koruptif dlm pelaksanaannya

2. Normalization

Tahap selanjutnya dalam rangkaian proses pra-pemrosesan data adalah normalisasi (*Normalization*). Prosedur ini melibatkan konversi leksikon yang tidak baku, seperti kata-kata serapan (*slang*) dan singkatan (*abbreviations*), menjadi bentuk kata dasar (*lema*) atau

bentuk yang sesuai dengan kaidah linguistik formal. Normalisasi bertujuan untuk menstandarisasi representasi leksikal dalam *dataset*, sehingga meningkatkan konsistensi dan akurasi pada tahap pemodelan komputasi berikutnya. Berikut adalah tampilan hasil *tweet* sebelum dan sesudah melalui tahap *normalization*.

Tabel 4. Hasil Proses *Normalization*

Sebelum (<i>Case Folding</i>)	Sesudah (<i>Normalization</i>)
rakyat semua disuruh bayar pajak bagi yg tdk mampu tdk bayar pajak spt tapi tetap bayar pajak saat beli barang amp jasa disaat politik tdk profesional bekerja menandakan tdk amanah amp koruptif dlm pelaksanaannya	rakyat semua disuruh bayar pajak bagi yang tidak mampu tidak bayar pajak seperti tapi tetap bayar pajak saat beli barang sampai jasa disaat politik tidak profesional bekerja menandakan tidak amanah sampai korupsi dalam pelaksanaannya

3. Pembersihan Data *Duplicate*

Tahap selanjutnya dalam proses pengolahan data adalah melakukan proses pembersihan data untuk menghapus data yang bersifat duplikat untuk memastikan keakuratan dan konsistensi *dataset*, sebelum dilakukan penghapusan, jumlah total *dataset* sebanyak 10.735, setelah proses penghapusan duplikat dijalankan, jumlah data berkurang menjadi 9.293, berarti sebanyak 1.442 data duplikat berhasil diidentifikasi dan dihapus. Proses pembersihan hanya dilakukan pada kolom tertentu yang mengandung duplikasi, sehingga tidak memberikan dampak terhadap *normalization* data.

4. *Convert Negation*

Tahap selanjutnya dalam proses pengolahan data, yaitu proses penggabungan kata negasi (*convert negation*), dengan kata yang mengikutinya untuk mempertahankan makna semantik dalam kalimat tetap terjaga. Proses ini penting dalam analisis sentimen karena kata negasi seperti 'bukan', 'tidak', 'tanpa', 'jangan', 'tanpa', 'enggak', 'nggak', 'gak', 'ga', 'tak', dapat membalikan arti dari kata setelahnya. Fungsi konversi negasi (*convert negation*) diimplementasikan untuk memeriksa setiap token dalam korpus teks, jika ditemukan kata negasi yang diikuti oleh kata lain, maka kedua kata tersebut akan digabung menggunakan tanda garis bawah () menjadi satu kesatuan, misalnya "tidak bagus" menjadi "tidak_bagus". Berikut adalah tampilan hasil *tweet* sebelum dan sesudah melalui tahap *convert negation*.

Tabel 5. Hasil Proses *Convert Negation*

Sebelum (<i>Normalization</i>)	Sesudah (<i>Convert Negation</i>)
rakyat semua disuruh bayar pajak bagi yang tidak mampu tidak bayar pajak seperti tapi tetap bayar pajak saat beli barang sampai jasa disaat politik tidak profesional bekerja menandakan tidak amanah sampai korupsi dalam pelaksanaannya	rakyat semua disuruh bayar pajak bagi yang tidak_mampu tidak_bayar pajak seperti tapi tetap bayar pajak saat beli barang sampai jasa disaat politik tidak_profesional bekerja menandakan tidak_amanah sampai korupsi dalam pelaksanaannya

5. *Tokenizing*

Tahap selanjutnya dalam proses pengolahan data adalah melakukan *tokenizing*, yaitu proses pemecahan kalimat menjadi potongan-potongan kata yang lebih kecil. Proses ini bertujuan mentransformasikan teks dalam bentuk yang lebih terstruktur dan mudah dianalisis. Penelitian ini, dilakukan ekstraksi fitur *unigram*, yang berarti kalimat akan dipotong menjadi satu kata (*unigram*) untuk memperkaya representasi data. Berikut adalah tampilan hasil *tweet* sebelum dan sesudah melalui tahap *tokenizing*.

Tabel 6. Hasil Proses *Tokenizing*

Sebelum (<i>Convert Negation</i>)	Sesudah (<i>Tokenizing</i>)
rakyat semua disuruh bayar pajak bagi yang tidak mampu tidak bayar pajak seperti tapi tetap bayar pajak saat beli barang sampai jasa disaat politik tidak profesional bekerja menandakan tidak amanah sampai korupsi dalam pelaksanaannya	['rakyat', 'semua', 'disuruh', 'bayar', 'pajak', 'bagi', 'yang', 'tidak_mampu', 'tidak_bayar', 'pajak', 'seperti', 'tapi', 'tetap', 'bayar', 'pajak', 'saat', 'beli', 'barang', 'sampai', 'jasa', 'disaat', 'politik', 'tidak_profesional', 'bekerja', 'menandakan', 'tidak_amanah', 'sampai', 'korupsi', 'dalam', 'pelaksanaannya']

6. *Stopword Removal*

Tahap selanjutnya dalam pra-pemrosesan data adalah penghapusan *stopword* (*stopword removal*). Prosedur ini melibatkan eliminasi leksikon umum yang memiliki frekuensi kemunculan tinggi namun kontribusi semantik yang minim terhadap analisis sentimen, contohnya "yang", "dan", dan "di". Tujuan fundamental dari tahapan ini adalah memurnikan korpus data guna mempertahankan secara eksklusif leksikon yang memiliki kontribusi semantik yang signifikan terhadap konteks atau fokus analisis penelitian, sehingga meningkatkan representasi dan efisiensi data tekstual untuk analisis lebih lanjut. Berikut adalah tampilan hasil *tweet* sebelum dan sesudah melalui tahap *stopword removal*.

Tabel 7. Hasil Proses *Stopword Removal*

Sebelum (<i>Tokenizing</i>)	Sesudah (<i>Stopword Removal</i>)
['rakyat', 'semua', 'disuruh', 'bayar', 'pajak', 'bagi', 'yang', 'tidak mampu', 'tidak bayar', 'pajak', 'seperti', 'tapi', 'tetap', 'bayar', 'pajak', 'saat', 'beli', 'barang', 'sampai', 'jasa', 'disaat', 'politik', 'tidak profesional', 'disaat', 'politik', 'menandakan', 'tidak amanah', 'tidak profesional', 'bekerja', 'menandakan', 'tidak amanah', 'sampai', 'korupsi', 'dalam', 'pelaksanaannya']	['rakyat', 'disuruh', 'bayar', 'pajak', 'tidak_mampu', 'tidak_bayar', 'pajak', 'bayar', 'pajak', 'beli', 'barang', 'jasa', 'disaat', 'politik', 'tidak_profesional', 'menandakan', 'tidak_amanah', 'korupsi', 'pelaksanaannya']

7. *Stemming*

Tahap selanjutnya dalam proses pengolahan data adalah melakukan *stemming*, yaitu proses reduksi kata berimbuhan menjadi bentuk kata dasarnya, dengan tujuan untuk menyamakan variasi morfologis dari suatu kata agar memiliki makna yang konsisten dalam analisis teks. Proses ini memiliki signifikansi krusial dalam rangka memastikan bahwa variasi morfologis (bentuk kata) tidak mempengaruhi atau menghambat validitas hasil analisis yang dilakukan. Berikut adalah

tampilan hasil *tweet* sebelum dan sesudah melalui tahap *stemming*.

Tabel 8. Hasil Proses *Stemming*

Sebelum (<i>Stopword Removal</i>)	Sesudah (<i>Stemming</i>)
['rakyat', 'disuruh', 'bayar', 'pajak', 'tidak_mampu', 'tidak_bayar', 'pajak', 'bayar', 'pajak', 'beli', 'barang', 'jasa', 'disaat', 'politik', 'tidak_profesional', 'menandakan', 'tidak_amanah', 'korupsi', 'pelaksanaannya']	rakyat suruh bayar pajak tidak mampu tidak bayar pajak bayar pajak beli barang jasa saat politik tidak profesional tanda tidak amanah korupsi laksana

3.4. Model

Penelitian ini menerapkan dua pendekatan utama, yaitu proses pelabelan data dan penerapan algoritma klasifikasi. Tahap pelabelan merupakan proses pemberian kategori sentimen pada setiap data teks yang telah melewati tahapan *text preprocessing*. Hasil dari prosedur pelabelan data (*data labeling*) berfungsi sebagai basis empiris (*ground truth*) pada tahapan pelatihan (*training*) model klasifikasi. Penelitian ini mengadopsi dan membandingkan kinerja dua metode klasifikasi pembelajaran mesin (*machine learning classification methods*) utama, yaitu *Naïve Bayes* dan *Support Vector Machine (SVM)*. Pemilihan *Naïve Bayes* didasarkan pada karakteristiknya yang sangat sesuai untuk analisis sentimen, terutama karena algoritma ini memiliki kecepatan eksekusi yang tinggi, mampu bekerja efektif pada data teks berdimensi besar, serta mudah diimplementasikan pada proses klasifikasi berbasis probabilistik. Sementara *SVM* dipilih sebagai pembanding utama karena kemampuannya menangani fitur teks yang kompleks dan menghasilkan batas keputusan (*decision boundary*) yang lebih optimal pada data berdimensi tinggi, sehingga relevan untuk meningkatkan akurasi dalam klasifikasi sentimen. Kedua algoritma tersebut dipilih secara strategis berdasarkan tingkat efektivitas dan akurasinya yang terbukti tinggi dalam analisis sentimen berbasis korpus teks.

1. Pelabelan

Setelah data melewati tahap *text preprocessing*, langkah selanjutnya adalah pelabelan sentimen. Proses ini dilakukan secara otomatis dengan menggunakan pendekatan *lexicon-based*, yang memanfaatkan metode *VADER (Valence Aware Dictionary and Sentiment Reasoner)*. Metode ini bekerja dengan mengukur polaritas sentimen dalam teks berdasarkan daftar kosakata atau kamus kata (*lexicon*) yang telah ditentukan sebelumnya. Setiap kata dalam kamus memiliki nilai positif dan negatif, yang digunakan untuk menentukan kecenderungan emosional dari suatu kalimat.

Dalam konteks analisis sentimen, *VADER* tidak hanya menghitung skor kata secara sederhana, tetapi juga mempertimbangkan elemen linguistik yang sering muncul dalam media sosial, seperti penggunaan huruf kapital, tanda seru, serta pengelolaan negasi yang dapat membalikkan makna sentimen. Selain itu, *VADER*

menghitung *compound score* yang merepresentasikan intensitas sentimen keseluruhan dalam rentang -1 sampai $+1$, sehingga memudahkan sistem dalam menentukan apakah suatu *tweet* bersentimen positif, atau negatif.

Pendekatan ini memungkinkan sistem untuk mengenali makna kontekstual dari teks secara lebih objektif dan konsisten tanpa memerlukan pelabelan manual oleh peneliti. Hasil dari tahap ini berupa data yang telah memiliki kategori sentimen, sehingga siap digunakan untuk pelatihan model klasifikasi dengan menerapkan algoritma klasifikasi *Naïve Bayes* dan *SVM* pada tahap selanjutnya. Berikut adalah tampilan hasil setelah melalui tahap pelabelan..

Tabel 9. Hasil Proses Pelabelan

<i>Stemming</i>	Kata Positif	Kata Negatif	Sentimen
rakyat suruh bayar pajak tidak mampu tidak bayar pajak bayar pajak beli barang jasa saat politik tidak profesional tanda tidak amanah korupsi laksana	2	16	Negatif

Total korpus data yang dianalisis dalam penelitian ini berjumlah 8.110 *tweet*. Data tersebut memiliki distribusi sentimen yang terbagi atas 2.285 *tweet* berlabel positif dan 5.825 *tweet* berlabel negatif. Distribusi polaritas sentimen ini selanjutnya divisualisasikan secara kuantitatif pada gambar 2, yang menyajikan perbandingan proporsional yang eksplisit antara sentimen positif dan sentimen negatif dalam dataset tersebut.



Gambar 2. Perbandingan Sentimen

2. TF-IDF

Proses pada tahap ini melibatkan ekstraksi fitur teks melalui implementasi metode *TF-IDF (Term Frequency–Inverse Document Frequency)*. Pendekatan ini berfungsi sebagai alat pengukuran untuk menentukan tingkat signifikansi dan bobot relevansi setiap istilah (*term*) yang terdapat dalam suatu dokumen spesifik (*document*) relatif terhadap keseluruhan koleksi dokumen (*corpus*) yang menjadi subjek analisis. Secara prinsip, Konsep utama *TF-IDF* menghasilkan nilai bobot untuk setiap kata dengan mempertimbangkan pola kemunculannya. Istilah yang

muncul secara berulang di banyak dokumen akan memperoleh bobot lebih kecil karena dinilai kurang memberikan informasi khusus, sedangkan kata yang jarang muncul namun memiliki peran penting dalam konteks tertentu akan mendapatkan bobot lebih besar. Bobot tersebut digunakan sebagai representasi numerik teks yang menjadi input bagi model klasifikasi. Dalam penelitian ini, proses transformasi teks ke dalam bentuk vektor serta perhitungan bobot dilakukan melalui fungsi *TfidfVectorizer*, yang bekerja secara otomatis untuk menghasilkan representasi numerik dengan mempertimbangkan distribusi kata pada seluruh korpus data. *TfidfVectorizer* merupakan bagian dari pustaka *scikit-learn (sklearn)* dalam bahasa pemrograman *Python*, yang secara khusus dirancang untuk mengonversi teks mentah menjadi matriks berbobot berbasis *Term Frequency-Inverse Document Frequency (TF-IDF)*. Melalui mekanisme ini, kata-kata yang sering muncul pada sebuah dokumen tetapi jarang muncul di korpus keseluruhan akan diberikan bobot yang lebih tinggi, sehingga membantu model klasifikasi dalam mengenali kata-kata yang paling informatif. Pendekatan ini memungkinkan proses ekstraksi fitur dilakukan secara efisien dan konsisten sebelum data digunakan pada tahap pemodelan.

3. Naïve Bayes

Dataset yang digunakan dalam penelitian ini didistribusikan ke dalam set data pelatihan (*training data*) dan set data pengujian (*testing data*) dengan menerapkan tiga skema rasio pembagian yang berbeda, yaitu 90:10, 80:20, dan 70:30. Pembagian proporsional ini bertujuan untuk mengevaluasi kestabilan (*robustness*) dan akurasi prediktif model klasifikasi terhadap variasi proporsi data. Evaluasi *robustness* dilakukan dengan membandingkan konsistensi performa model pada setiap rasio pembagian. Jika nilai metrik seperti *accuracy*, *precision*, *recall*, dan *f1-score* tetap stabil atau tidak mengalami perubahan signifikan di berbagai skema, maka model dianggap *robust*. Melalui pendekatan ini, diperoleh gambaran yang lebih akurat mengenai ketangguhan model dalam menghadapi keragaman data dan kemampuan generalisasi yang baik pada data baru.

4. Support Vector Machine (SVM)

Dataset yang digunakan dalam penelitian ini didistribusikan ke dalam set data pelatihan (*training data*) dan set data pengujian (*testing data*) dengan menerapkan tiga skema rasio pembagian yang berbeda, yaitu 90:10, 80:20, dan 70:30. Pembagian proporsional ini bertujuan untuk mengevaluasi kestabilan (*robustness*) dan akurasi prediktif model klasifikasi terhadap variasi proporsi data. Evaluasi *robustness* dilakukan dengan membandingkan konsistensi performa model pada setiap rasio pembagian. Jika nilai metrik seperti *accuracy*, *precision*, *recall*, dan *f1-score* tetap stabil atau tidak mengalami perubahan signifikan di berbagai skema, maka model dianggap *robust*. Melalui pendekatan ini, diperoleh gambaran yang lebih

akurat mengenai ketangguhan model dalam menghadapi keragaman data dan kemampuan generalisasi yang baik pada data baru.

Dalam konteks ini, algoritma SVM bekerja dengan menentukan sebuah *hyperplane* garis pemisah pada ruang berdimensi tinggi yang memisahkan data ke dalam dua kelas sentimen, yaitu positif dan negatif. *Hyperplane* dipilih sedemikian rupa agar memiliki margin atau jarak pemisah paling lebar antara dua kelas, sehingga meminimalkan kemungkinan kesalahan klasifikasi. Pada analisis sentimen, di mana setiap *tweet* direpresentasikan dalam bentuk vektor *TF-IDF* berdimensi tinggi, kemampuan SVM untuk menemukan *hyperplane* optimal menjadi sangat relevan karena dapat menangani data teks yang kompleks, tidak teratur, dan memiliki fitur yang sangat banyak

3.5. Assess

Tahap asesmen (*assess*) merepresentasikan proses evaluasi kinerja komparatif terhadap kedua metode klasifikasi yang diterapkan dalam penelitian ini. Evaluasi model dilaksanakan dengan mengukur performa prediktif berdasarkan hasil pengujian pada data. *Confusion matrix* diutilisasi sebagai instrumen fundamental untuk mengevaluasi kinerja model klasifikasi, khususnya dalam mengukur frekuensi prediksi yang benar (*true positives/negatives*) dan prediksi yang salah (*false positives/negatives*). Matriks ini menjadi basis komputasi bagi serangkaian metrik evaluasi performa, termasuk *accuracy*, *precision*, *recall*, dan *f1-score*. Secara sederhana, *confusion matrix* dihitung dengan membandingkan hasil prediksi model terhadap label sebenarnya pada data uji. Misalnya, ketika model memprediksi sebuah *tweet* sebagai sentimen positif dan label aslinya juga positif, maka hal itu dicatat sebagai *true positive (TP)*. Jika model memprediksi positif tetapi label sebenarnya negatif, maka dihitung sebagai *false positive (FP)*. Proses serupa berlaku untuk *true negative (TN)* dan *false negative (FN)*. Dengan menghitung jumlah TP, TN, FP, dan FN, peneliti dapat melihat secara jelas pola kesalahan model dan kualitas prediksi secara keseluruhan. Penerapan metrik-metrik tersebut memungkinkan penilaian kinerja model secara multidimensional dan komprehensif, sehingga menghasilkan gambaran menyeluruh mengenai efektivitas dan kapabilitas hasil klasifikasi yang diperoleh.

3.6. Performance Report

Tahap laporan kinerja (*performance report*) melibatkan penyajian hasil evaluasi terhadap performa model yang diperoleh melalui analisis berbasis *confusion matrix*. Evaluasi ini mencakup empat metrik utama, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*. Metrik-metrik tersebut digunakan untuk menyediakan penilaian komprehensif terhadap kapabilitas model dalam melaksanakan klasifikasi sentimen secara akurat. Keempat metrik ini berperan penting dalam

mengukur tingkat efektivitas dan konsistensi setiap algoritma dalam memproses data dan mengidentifikasi pola polaritas sentimen secara andal, baik itu positif maupun negatif.

Selain itu, hasil dari keempat metrik ini digunakan sebagai dasar dalam menentukan model terbaik di antara algoritma yang diuji. Model yang memiliki nilai *accuracy* lebih tinggi, *precision* dan *recall* yang seimbang, serta skor *f1-score* yang lebih unggul dianggap lebih mampu mengelola ketidakseimbangan data dan menghasilkan prediksi yang stabil. Dengan membandingkan performa masing-masing algoritma pada seluruh metrik tersebut, penelitian ini dapat mengidentifikasi model yang paling optimal dalam menangani analisis sentimen pada *dataset* yang digunakan.

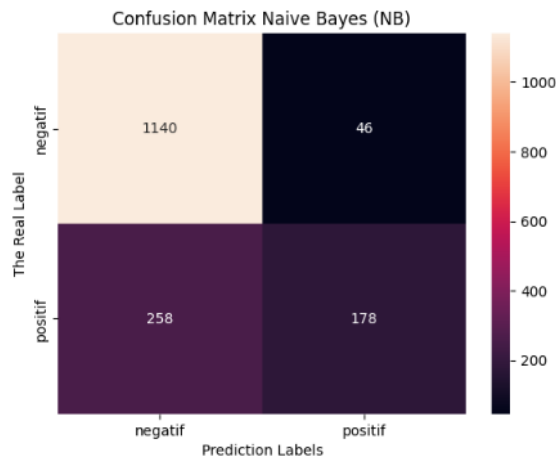
1. Naïve Bayes

Hasil pengujian model yang menggunakan algoritma *Naïve Bayes* menunjukkan bahwa nilai *accuracy* model tersebut bervariasi (*fluktuatif*) sebagai fungsi dari proporsi pembagian dataset (rasio data pelatihan (*training data*) dan data pengujian (*testing data*)) yang digunakan dalam prosedur evaluasi kinerja. Perbandingan performa tersebut disajikan pada Tabel 9, yang menggambarkan tingkat akurasi model terhadap masing-masing proporsi data *Training* dan *Testing*.

Tabel 10. Hasil *Accuracy* Pelabelan Data *Naïve Bayes*

Rasio	Data Training	Data Testing	Accuracy
90 : 10	7.299	811	79,53%
80 : 20	6.480	1.622	81,25%
70 : 30	5.677	2.433	80,68%

Berdasarkan hasil tabel 10 Menampilkan nilai performa dari algoritma *Naïve Bayes* berdasarkan tiga rasio Dengan Pembagian *dataset* menjadi data pelatihan (*training*) dan data pengujian (*testing*) dilakukan dengan menerapkan tiga skema rasio proporsional, yaitu 90:10, 80:20, dan 70:30, dapat disimpulkan bahwa algoritma *Naïve Bayes* menunjukkan bahwa rasio 80:20 menghasilkan *accuracy* tertinggi sebesar 81,25%, diikuti oleh rasio 70:30 dengan *accuracy* sebesar 80,68%, dan rasio 90:10 dengan *accuracy* terendah yaitu 79,53%, meskipun rasio 90:10 memiliki jumlah data *training* terbanyak, *accuracy* nya justru rendah, yang mengindikasikan bahwa penggunaan data *testing* yang terlalu sedikit dapat mengurangi representasi evaluasi terhadap performa model. Sementara rasio 70:30 memiliki jumlah *testing* terbanyak namun sedikit lebih rendah *accuracy* nya dibandingkan 80:20, kemungkinan karena jumlah data *training* yang lebih sedikit. Kesimpulannya bahwa rasio 80:20 sebagai data yang paling seimbang dan optimal karena memberikan *accuracy* terbaik serta evaluasi model yang lebih representatif.



Gambar 3. Evaluasi Model *Confusion Matrix* Pada Metode *Naïve Bayes* Rasio 80:20

Berdasarkan gambar 3 hasil evaluasi model, sebanyak 178 data berhasil diprediksi dengan tepat sebagai sentimen positif, sementara 258 data yang sebenarnya positif keliru diklasifikasikan sebagai negatif. Selain itu, terdapat 1140 data yang tepat diklasifikasikan sebagai sentimen negatif sementara 46 data negatif yang sebenarnya negatif keliru diklasifikasikan sebagai positif.

Accuracy digunakan untuk mengukur sejauh mana klasifikasi *Naïve Bayes* memprediksi data secara keseluruhan dengan benar. *accuracy* diperoleh dari rasio antara jumlah seluruh prediksi yang benar (positif maupun negatif) terhadap total data. Hasil evaluasi menunjukkan nilai *accuracy*.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{178 + 1.140}{178 + 1.140 + 46 + 258} = \frac{1.318}{1.622} = 0,8125 \text{ atau } 81,25\%$$

Precision digunakan untuk mengukur tingkat ketepatan model dalam memprediksi sentimen. Nilai ini diperoleh dari rasio antara jumlah prediksi yang benar terhadap total prediksi yang dilakukan. *Precision* untuk kelas positif dan negatif masing-masing bernilai.

$$Precision \text{ (positif)} = \frac{TP}{TP + FP} = \frac{178}{178 + 46} = \frac{178}{224} = 0,7946 \text{ atau } 79,46\%$$

$$Precision \text{ (negatif)} = \frac{TN}{TN + FN} = \frac{1.140}{1.140 + 258} = \frac{1.140}{1.398} = 0,8154 \text{ atau } 81,54\%$$

Recall atau sensitivitas digunakan untuk menilai kemampuan model dalam mengenali seluruh *instance* dari masing-masing kelas. *Recall* untuk kelas positif dan negatif masing-masing bernilai.

$$Recall \text{ (positif)} = \frac{TP}{TP+FN} = \frac{178}{178+258} = \frac{178}{436} = 0,4082 \text{ atau } 40,82\%$$

$$Recall \text{ (negatif)} = \frac{TN}{TN+FP} = \frac{1.140}{1.140+46} = \frac{1.140}{1.186} = 0,9612 \text{ atau } 96,12\%$$

F1-Score digunakan untuk memberikan penilaian yang seimbang terhadap performa model dalam melakukan prediksi dan mengenali data sentimen. Nilai ini dihitung berdasarkan kombinasi antara *precision* dan *recall*. *F1-Score* untuk masing-masing kelas bernilai.

$$F1\text{-Score} \text{ (positif)} = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2 \times 0,7946 \times 0,4082}{0,7946 + 0,4082} = \frac{2 \times 0,3243}{1,2028} = 0,5392 \text{ atau } 53,92\%$$

$$F1\text{-Score} \text{ (negatif)} = \frac{2 \times Precision \times Recall}{Precision + Recall} = \frac{2 \times 0,8154 \times 0,9612}{0,8154 + 0,9612} = \frac{2 \times 0,7837}{1,7766} = 0,8822 \text{ atau } 88,22\%$$

Rata-rata *F1-Score* adalah

$$= \frac{0,5392 + 0,8822}{2} = 0,6111 \text{ atau } 61,11\%$$

2. Support Vector Machine (SVM)

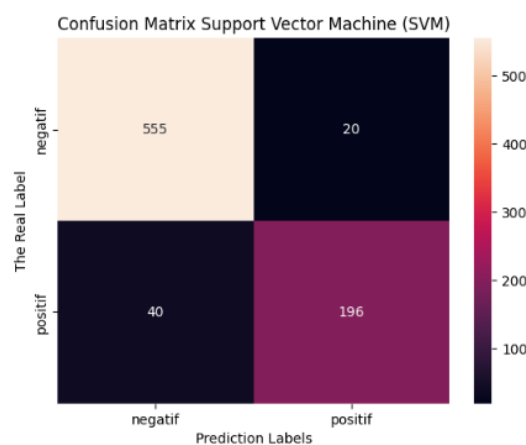
Hasil pengujian model yang menggunakan algoritma *Support Vector Machine* (SVM) menunjukkan bahwa nilai akurasi (*accuracy*) model tersebut berfluktuasi sebagai fungsi dari proporsi pembagian *dataset* (rasio data pelatihan dan data pengujian) yang diterapkan selama prosedur evaluasi. Perbandingan performa ini didokumentasikan secara rinci dalam Tabel 10, yang menggambarkan tingkat akurasi model terhadap masing-masing proporsi data *Training* dan *Testing*.

Tabel 11. Hasil *Accuracy* Pelabelan Data *Support Vector Machine*

Rasio	Data Training	Data Testing	Accuracy
90 : 10	7.299	811	92,60%
80 : 20	6.480	1.622	91,49%
70 : 30	5.677	2.433	91,24%

Berdasarkan hasil tabel 11, menunjukkan nilai performa prediktif algoritma *Support Vector Machine* (SVM). Hasil ini diperoleh melalui serangkaian pengujian yang melibatkan tiga skema proporsional untuk membagi *dataset* menjadi himpunan data pelatihan (*training*) dan data pengujian (*testing*), yakni dengan rasio 90:10, 80:20, dan 70:30, menunjukkan hasil yang sangat baik dan konsisten. Hasil tersebut

mengindikasikan bahwa algoritma SVM memiliki kemampuan klasifikasi yang unggul dengan tingkat *accuracy* tertinggi sebesar 92,60% pada rasio 90:10, diikuti oleh rasio 80:20 dengan *accuracy* sebesar 91,49%, serta rasio 70:30 yang tetap menunjukkan performa stabil dengan *accuracy* sebesar 91,24%. Perbedaan *accuracy* antara ketiga rasio relatif kecil, hanya berkisar sekitar 1%, yang menunjukkan bahwa model memiliki performa yang cukup stabil meskipun terjadi perubahan proporsi data *training* dan *testing*, namun rasio 90:10 memberikan *accuracy* terbaik karena memanfaatkan data *training* dalam jumlah besar, sehingga model dapat belajar lebih optimal. Kesimpulan bahwa rasio 90:10 merupakan pilihan yang paling efektif dalam skenario ini untuk menghasilkan model dengan tingkat *accuracy* yang paling tinggi.



Gambar 4. Evaluasi Model *Confusion Matrix* Pada Metode *Support Vector Machine* (SVM) Rasio 90:10.

Berdasarkan gambar 4 hasil evaluasi model, sebanyak 196 data berhasil diprediksi dengan tepat sebagai sentimen positif, sementara 40 data yang sebenarnya positif keliru diklasifikasikan sebagai negatif. Selain itu, terdapat 555 data yang tepat diklasifikasikan sebagai sentimen negatif sementara 20 data negatif yang sebenarnya negatif keliru diklasifikasikan sebagai positif.

Accuracy digunakan untuk mengukur sejauh mana klasifikasi *Support Vector Machine* (SVM) memprediksi data secara keseluruhan dengan benar. *Accuracy* diperoleh dari rasio antara jumlah seluruh prediksi yang benar (positif maupun negatif) terhadap total data. Hasil evaluasi menunjukkan nilai *accuracy*.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{196 + 555}{196 + 555 + 20 + 40} = \frac{751}{811} = 0,9260 \text{ atau } 92,60\%$$

Precision digunakan untuk mengukur tingkat ketepatan model dalam memprediksi sentimen. Nilai ini diperoleh dari rasio antara jumlah prediksi yang benar terhadap total prediksi yang dilakukan. *Precision* untuk kelas positif dan negatif masing-masing bernilai.

$$\begin{aligned} \text{Precision (positif)} &= \frac{TP}{TP+FP} = \frac{196}{196+20} = \frac{196}{216} \\ &= 0,9074 \text{ atau } 90,74\% \end{aligned}$$

$$\begin{aligned} \text{Precision (negatif)} &= \frac{TN}{TN+FN} = \frac{555}{555+40} = \frac{555}{595} \\ &= 0,9327 \text{ atau } 93,27\% \end{aligned}$$

Recall atau sensitivitas digunakan untuk menilai kemampuan model dalam mengenali seluruh *instance* dari masing-masing kelas. *Recall* untuk kelas positif dan negatif masing-masing bernilai.

$$\begin{aligned} \text{Recall (positif)} &= \frac{TP}{TP+FN} = \frac{196}{196+40} = \frac{196}{236} \\ &= 0,8305 \text{ atau } 83,05\% \end{aligned}$$

$$\begin{aligned} \text{Recall (negatif)} &= \frac{TN}{TN+FP} = \frac{555}{555+20} = \frac{555}{575} \\ &= 0,9652 \text{ atau } 96,52\% \end{aligned}$$

F1-Score digunakan untuk memberikan penilaian yang seimbang terhadap performa model dalam melakukan prediksi dan mengenali data sentimen. Nilai ini dihitung berdasarkan kombinasi antara *precision* dan *recall*. *F1-Score* untuk masing-masing kelas bernilai.

$$\begin{aligned} \text{F1-Score (positif)} &= \\ &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \times \frac{0,9074 \times 0,8305}{0,9074 + 0,8305} \\ &= 2 \times \frac{0,7535}{1,7397} = 0,8671 \text{ atau } 86,71\% \end{aligned}$$

$$\begin{aligned} \text{F1-Score (negatif)} &= \\ &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \times \frac{0,9327 \times 0,9652}{0,9327 + 0,9652} \\ &= 2 \times \frac{0,9002}{1,8979} = 0,9486 \text{ atau } 94,86\% \end{aligned}$$

$$\begin{aligned} \text{Rata-rata F1-Score} &\text{ adalah} \\ &= \frac{0,8671 + 0,9486}{2} = 0,9140 \text{ atau } 91,40\% \end{aligned}$$

3. Word Cloud

Visualisasi *word cloud* yang disajikan pada gambar 5 menampilkan kumpulan leksikon dengan frekuensi kemunculan tertinggi yang teridentifikasi dari hasil analisis sentimen terhadap kebijakan Pemerintahan Bapak Prabowo Subianto. Ukuran visual dari setiap istilah (*term*) dalam *word cloud* berkorelasi secara langsung dengan frekuensi kemunculannya dalam korpus data; dengan kata lain, kata yang ditampilkan dengan ukuran lebih besar mengindikasikan tingkat kemunculan yang lebih dominan. Visualisasi ini memberikan gambaran ringkas (*overview*) mengenai

topik-topik dan isu-isu diskursif yang paling banyak mendapat perhatian dan dibahas oleh publik dalam konteks penelitian yang relevan.



Gambar 5. Kata Yang Sering Muncul

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilaksanakan, diperoleh tiga temuan dan simpulan utama sebagai berikut.

1. Penelitian ini berhasil mengimplementasikan analisis sentimen terhadap berbagai inisiatif kebijakan yang diinisiasi oleh Pemerintahan Presiden Republik Indonesia, Prabowo Subianto. Hasil analisis kuantitatif secara definitif menunjukkan bahwa polaritas sentimen negatif jauh lebih dominan dibandingkan sentimen positif. Secara agregat, dataset terdiri atas 2.285 data bersentimen positif dan 5.825 data bersentimen negatif, yang secara eksplisit merefleksikan kecenderungan opini publik di platform media sosial terhadap kebijakan pemerintah yang sedang berjalan.
2. Seluruh tahapan analisis sentimen dalam studi ini berhasil diimplementasikan, meliputi pra-pemrosesan teks (*text preprocessing*) dan klasifikasi data. Evaluasi kinerja dilakukan secara komprehensif menggunakan *confusion matrix* serta empat metrik evaluasi utama, yaitu *accuracy*, *precision*, *recall*, dan *f1-score*, guna menilai performa algoritma secara menyeluruh.
3. Hasil pengujian kinerja model secara empiris mengindikasikan bahwa algoritma *Support Vector Machine* (SVM) memberikan performa yang paling optimal, mencatatkan tingkat akurasi puncak sebesar 92,60%. Sementara itu, algoritma *Naïve Bayes* menghasilkan tingkat akurasi maksimum sebesar 81,25%. Temuan ini mendukung kesimpulan bahwa SVM memiliki kapabilitas klasifikasi yang secara signifikan lebih efektif dan akurat dalam identifikasi sentimen teks dibandingkan dengan *Naïve Bayes* dalam konteks dataset penelitian ini.

Daftar Rujukan

- [1] Fikri. S and Ukhwaluddin. A. F, "perbandingan sistem pemerintahan presidensial dalam sistem ketatanegaraan di indonesia dan iran," *yustisia merdeka: jurnal ilmiah hukum*, vol. 8, no. 1, pp. 56–65, 2022.
- [2] Pratiwi. J. I, Salama. N, and Ulfah. S, "pembatasan masa jabatan presiden di indonesia," *jurnal rechten: riset hukum dan hak asasi manusia*, vol. 3, no. 1, pp. 18–26, 2021.

- [3] Albet. P, “biografi presiden ke-8 indonesia, prabowo subianto,” diambil dari: <https://www.rri.co.id/nasional/1064968/biografi-presiden-ke-8-indonesia-prabowo-subianto> (19 maret 2025).
- [4] Bolivia, “100 hari pemerintahan prabowo-gibran, pakar ugm nilai masih minim kejelasan perencanaan dan eksekusi,” diambil dari: <https://ugm.ac.id/id/berita/100-hari-pemerintahan-prabowo-gibran-pakar-ugm-nilai-masih-minim-kejelasan-perencanaan-dan-eksekusi/> (17 maret 2025).
- [5] Widawati. T. W and Sadikin. M, “analisis sentimen twitter terhadap tokoh publik dengan algoritma naive bayes dan support vector machine,” *simetris: jurnal teknik mesin, elektro dan ilmu komputer*, vol. 11, no. 2, pp. 626–636, 2020.
- [6] Firdaus, A. A, Yudhana. A, and Riadi. I, “analisis sentimen pada proyeksi pemilihan presiden 2024 menggunakan metode support vector machine,” *decode: jurnal pendidikan teknologi informasi*, vol. 3, no. 2, pp. 236–245, 2023.
- [7] Cahyani. R, Rozas. I. R, and Yalina. N, “analisis sentimen pada media sosial twitter terhadap tokoh publik peserta pilpres 2019,” *matics: jurnal ilmu komputer dan teknologi informasi (journal of computer science and information technology)*, vol. 12, no. 1, pp. 79–86, 2020.
- [8] Sadikin. N. D. H, and Susanti. S, “analisis sentimen publik terhadap kampanye pengurangan sampah plastik menggunakan algoritma naive bayes,” *agustus*, vol. 15, no. 2, pp. 202–212.
- [9] Nugraha. S. N, Pebrianto. R, Latif. A, and Firdaus. M. R, “analisis sentimen twitter terhadap menteri indonesia dengan algoritma support vector machine dan naive bayes,” *e-link: jurnal teknik elektro dan informatika*, vol. 17, no. 1, pp. 1–12, 2022.
- [10] Najiyah. I, “analisis sentimen tanggapan masyarakat indonesia tentang kenaikan bbm menggunakan metode artificial neural network,” *jurnal responsif: riset sains dan informatika*, vol. 5, no. 1, pp. 92–100, 2023.
- [11] Ahmad. R, Ardhani. R, Pratama. D, and Fatihanursari. F, “analisis sentimen terhadap layanan aplikasi grab indonesia menggunakan metode naive bayes,” *jati (jurnal mahasiswa teknik informatika)*, vol. 8, no. 1, pp. 303–309, 2024.
- [12] Fathonah. F and Herliana. A, “penerapan text mining analisis sentimen mengenai vaksin covid-19 menggunakan metode naive bayes,” *jurnal sains dan informatika*, vol. 7, no. 2, pp. 155–164, 2021.
- [13] Hendra. A and Fitriyani.F, “analisis sentimen review halodoc menggunakan naive bayes classifier,” *jiska (jurnal informatika sunan kalijaga)*, vol. 6, no. 2, pp. 78–89, 2021.
- [14] Inajiyah. I, and Hariyanti. I, “sentimen analisis covid-19 dengan metode probabilistic neural network dan tf-idf,” *jurnal responsif: riset sains dan informatika*, vol. 3, no. 1, pp. 100–111, 2021.
- [15] Noviana. R and Rasal. I, “penerapan algoritma naive bayes dan svm untuk analisis sentimen boy band bts pada media sosial twitter,” *jurnal teknik dan science*, vol. 2, no. 2, pp. 51–60, 2023.
- [16] Alita. D and Shodiqin. R. B. A, “sentimen analisis vaksin covid-19 menggunakan naive bayes dan support vector machine,” *journal of artificial intelligence and technology information*, vol. 1, no. 1, pp. 1–12, 2023.
- [17] Atmajaya. D, Febrianti. A, and Darwis. H, “metode svm dan naive bayes untuk analisis sentimen chatgpt di twitter,” *the indonesian journal of computer science*, vol. 12, no. 4, 2023.
- [18] Aziz. A, Fauziah. F, and Fitri. I, “analisis sentimen terhadap kebijakan pemerintah tentang larangan mudik hari raya idulfitri di indonesia tahun 2021 menggunakan metode naive bayes,” *j-sakti (jurnal sains komputer dan informatika)*, vol. 5, no. 2, pp. 842–851, 2021.
- [19] Hasan. M. A and Bimby. N. P, “analisis sentimen publik terhadap kenaikan pajak ppn di indonesia tahun 2024 menggunakan algoritma machine learning”.
- [20] Irfansyah. K and Fatah. Z, “implementasi algoritma clustering k-means pada pengguna wartel di pondok pesantren salafiyah syafi'iyah sukorejo,” *jurnal ilmiah multidisiplin ilmu*, vol. 1, no. 5, pp. 81–86, 2024.