

Perbandingan Algoritma NBC Dan SVM Untuk Melakukan Analisis Sentimen Terhadap PP NO.82 Tahun 2021

Arum Mustika Rani, Nirwana Hendrastuty*

Fakultas Teknik dan Ilmu Komputer, Sistem Informasi, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

Email: ¹arum_mustika_rani@teknokrat.ac.id, ^{2,*}nirwanahendrastuty@teknokrat.ac.id

Email Penulis Korespondensi: nirwanahendrastuty@teknokrat.ac.id

Submitted: 21/12/2024; Accepted: 26/02/2025; Published: 01/03/2025

Abstrak—Peraturan Pemerintah (PP) No. 82 Tahun 2021, yang mengatur pembayaran pensiun dan tunjangan bagi Hakim Konstitusi dan Hakim Agung, telah memicu perdebatan publik, terutama setelah muncul dugaan pemotongan anggaran Mahkamah Agung yang signifikan. Masalah ini menimbulkan kekhawatiran terkait transparansi kebijakan, sehingga penting untuk menganalisis sentimen masyarakat terhadap PP ini. Penelitian ini menggunakan dua metode analisis sentimen, yaitu *Naïve Bayes Classifier (NBC)* dan *Support Vector Machine (SVM)*, untuk mengevaluasi opini masyarakat berdasarkan data dari *Twitter*. Dataset terdiri dari 2.719 *tweet* yang telah melalui tahapan praproses, seperti *cleansing*, *stemming*, dan penggunaan teknik *SMOTE*, dengan pembagian data 70% untuk pelatihan dan 30% untuk pengujian model. Penelitian ini menguji performa *NBC* dan *SVM* melalui empat skenario: (1) tanpa *stemming* dan tanpa *SMOTE*, (2) tanpa *stemming* dengan *SMOTE*, (3) dengan *stemming* tanpa *SMOTE*, dan (4) dengan *stemming* dan *SMOTE*. Hasil menunjukkan bahwa *SVM* memiliki performa lebih stabil dibandingkan *NBC* pada semua skenario. Pada skenario tanpa *stemming* dan tanpa *SMOTE*, kedua model mencatat akurasi 100%, namun *NBC* gagal mendeteksi sentimen positif secara akurat. Ketika *SMOTE* diterapkan tanpa *stemming*, akurasi *NBC* menurun menjadi 97%, sedangkan *SVM* tetap mencapai akurasi sempurna 100%. Pada skenario dengan *stemming* tanpa *SMOTE*, *NBC* mencatat akurasi 97%, sementara *SVM* mencapai 99%. Dengan penerapan *SMOTE* dan *stemming*, akurasi *NBC* menurun menjadi 95%, sedangkan *SVM* kembali mencatat akurasi sempurna 100%. Penelitian ini menyimpulkan bahwa *SVM* adalah metode terbaik untuk analisis sentimen terhadap PP No.82 Tahun 2021, terutama pada skenario dengan *stemming* dan *SMOTE*, memberikan wawasan penting tentang opini masyarakat serta menegaskan keunggulan *SVM* dalam klasifikasi sentimen terkait kebijakan publik.

Kata Kunci: Analisis Sentimen; *Naïve Bayes*; *SVM*; Persepsi Publik; Peraturan Pemerintah No.82 Tahun 2021

Abstract—Government Regulation (PP) No. 82/2021, which regulates the payment of pensions and allowances for Constitutional and Supreme Court Justices, has sparked public debate, especially after allegations of significant cuts to the Supreme Court's budget. This issue raises concerns regarding policy transparency, making it important to analyze public sentiment towards this PP. This study uses two sentiment analysis methods, namely *Naïve Bayes Classifier (NBC)* and *Support Vector Machine (SVM)*, to evaluate public opinion based on data from *Twitter*. The dataset consists of 2,719 tweets that have gone through preprocessing stages, such as *cleansing*, *stemming*, and using *SMOTE* techniques, with 70% data division for training and 30% for model testing. This study tests the performance of *NBC* and *SVM* through four scenarios: (1) without *stemming* and without *SMOTE*, (2) without *stemming* with *SMOTE*, (3) with *stemming* without *SMOTE*, and (4) with *stemming* and *SMOTE*. The results show that *SVM* has a more stable performance than *NBC* in all scenarios. In the scenario without *stemming* and without *SMOTE*, both models recorded 100% accuracy, but *NBC* failed to detect positive sentiment accurately. When *SMOTE* was applied without *stemming*, *NBC*'s accuracy decreased to 97%, while *SVM* still achieved a perfect accuracy of 100%. In the scenario with *stemming* without *SMOTE*, *NBC* recorded 97% accuracy, while *SVM* reached 99%. With the application of *SMOTE* and *stemming*, *NBC* accuracy decreased to 95%, while *SVM* again recorded a perfect accuracy of 100%. This study concludes that *SVM* is the best method for sentiment analysis of PP No. 82 of 2021, especially in scenarios with *stemming* and *SMOTE*, providing important insights into public opinion and confirming the superiority of *SVM* in sentiment classification related to public policy.

Keywords: Sentiment Analysis; *Naïve Bayes*; *SVM*; Public Perception; Government Regulation No.82 of 2021

1. PENDAHULUAN

Peraturan Pemerintah (PP) No.82 Tahun 2021 mengatur perubahan penting terkait pemberian honorarium bagi sejumlah pihak di lembaga peradilan tertinggi di Indonesia, termasuk Hakim Agung di Mahkamah Agung, Hakim Konstitusi, gugus tugas, serta pegawai di lingkungan Kepaniteraan dan Sekretariat Jenderal Mahkamah Konstitusi. Kebijakan ini dirancang untuk memberikan dukungan finansial yang memadai guna memastikan pelaksanaan tugas pejabat peradilan berjalan optimal. Namun, pelaksanaan PP ini mendapat sorotan tajam dari masyarakat setelah muncul dugaan penarikan dana sebesar Rp 97 miliar dari Honorarium Penanganan Perkara (HPP). Dugaan tersebut menimbulkan kekhawatiran publik terkait transparansi dan potensi penyalahgunaan anggaran, khususnya dalam distribusi hak keuangan yang diatur dalam kebijakan ini. Kritik publik semakin menguat di tengah harapan yang tinggi terhadap tata kelola keuangan negara yang lebih akuntabel, terutama di sektor peradilan yang memiliki tanggung jawab strategis dalam menjaga integritas hukum. Isu ini menggarisbawahi pentingnya pengawasan yang lebih baik dan transparansi yang lebih tinggi dalam implementasi kebijakan untuk mencegah penyalahgunaan di masa mendatang [1].

Twitter menjadi salah satu platform media sosial yang kerap digunakan masyarakat untuk menyampaikan opini terkait kebijakan ini. Beragam pandangan, mulai dari dukungan hingga kritik, mencerminkan dinamika persepsi publik terhadap PP No.82 Tahun 2021. Dengan karakteristiknya yang memungkinkan penyebaran informasi secara cepat, Twitter menjadi sumber data yang relevan untuk menganalisis opini publik. Analisis sentimen terhadap komentar masyarakat di media sosial ini dapat memberikan wawasan yang lebih komprehensif mengenai bagaimana

publik menilai kebijakan tersebut, terutama dari sisi transparansi, keadilan, dan dampak implementasinya terhadap kinerja lembaga peradilan [2]. Untuk mendapatkan temuan yang dapat diandalkan dari analisis sentimen publik, maka perlu digunakan metodologi yang tepat. *SVM* dan *NBC* adalah dua metode yang sering digunakan dalam analisis sentimen. Penelitian ini membandingkan efisiensi masing-masing algoritma dengan menggunakan kedua metode tersebut [3].

Penelitian yang dilakukan oleh S. Styawati dan rekan-rekannya menunjukkan bahwa *Support Vector Machines* yang menggunakan kernel *RBF* mengungguli kernel *Linear* dan *Polynomial* dengan tingkat akurasi sebesar 88,8 persen. Model *Naïve Bayes*, di sisi lain, berhasil mencapai tingkat akurasi 82,51%. Kemampuan untuk memetakan sebuah data yang lebih presisi dan menemukan nilai yang ideal untuk setiap dataset merupakan manfaat utama dari pelatihan *support vector machine* dengan kernel *RBF* [4]. Menurut beberapa penelitian yang meneliti analisis sentimen dalam aplikasi Dana menggunakan algoritma *NBC* dan *SVM*, *SVM* mengungguli *NBC* dalam kategorisasi sentimen. Dari segi akurasi, *SVM* mencapai tingkat akurasi sempurna sebesar 1.00, yang berarti mampu mengklasifikasikan seluruh data uji dengan benar tanpa kesalahan. Sebaliknya, *NBC* mencatatkan akurasi sebesar 91.78%, yang tetap menunjukkan kinerja yang baik meskipun terdapat beberapa kesalahan dalam klasifikasinya [5].

Hasil dari dua penelitian berbeda yang menggunakan *Naïve Bayes Classifier (NBC)* dan *Support Vector Machine (SVM)* untuk mengklasifikasikan sikap terkait Omnibus Law Cipta Kerja patut diperhatikan. Untuk data *Twitter*, metode *NBC* mendapatkan nilai *G-mean* sebesar 81,3% dan *AUC* sebesar 82,36%. Namun, untuk data media *Twitter*, model ini memiliki akurasi 97,8%. Sebagai alternatif, menggunakan *support vector machines (SVM)* pada data media *Twitter* menghasilkan akurasi 97,9% dan 99,3%, nilai *G-mean* 97,35%, dan area di bawah kurva (*AUC*) 97,38% [6]. Penelitian ini membandingkan algoritma klasifikasi *SVM* dan *Naive Bayes* serta menyelidiki pendapat pengguna *Twitter* tentang *ChatGPT*. Ketika *SVM* dikombinasikan dengan *Vader*, akurasi, presisi, dan *recall*-nya adalah 59%, namun ketika *RoBERTa* digunakan sendiri, mereka mencapai 55%. *Vader* menghasilkan akurasi 47% dibandingkan dengan 43% untuk *Naive Bayes* dengan *RoBERTa*. Manfaat *SVM* ditunjukkan oleh analisis sentimen dalam penelitian ini [7]. Hasil dari penelitian lain yang membandingkan keefektifan algoritma *Naïve Bayes* dan *Support Vector Machine (SVM)* dalam menganalisis sentimen terhadap Gojek Indonesia di *Twitter* adalah konsisten. Dengan akurasi 99%, *SVM* mengungguli algoritma *Naïve Bayes* yang hanya 91%, menurut data tersebut. Dalam hal akurasi, *SVM* bernasib lebih baik daripada *Naïve Bayes* dalam kategorisasi sentimen ketika penelitian ini menggunakan dataset *Twitter* [8].

Penelitian ini memiliki sejumlah perbedaan dibandingkan dengan penelitian sebelumnya. Meskipun kajian terdahulu telah memberikan kontribusi penting dalam bidang analisis sentimen, masih terdapat potensi pengembangan lebih lanjut. Sebagian besar penelitian sebelumnya berfokus pada penggunaan satu algoritma atau pendekatan *preprocessing* data tertentu tanpa mengadopsi teknik tambahan seperti *stemming* dan *SMOTE* yang dapat meningkatkan kinerja model. Selain itu, kajian yang secara spesifik mengeksplorasi sentimen masyarakat terhadap PP No. 82 Tahun 2021 masih sangat terbatas, sehingga penelitian ini diharapkan dapat melengkapi wawasan dalam konteks tersebut.

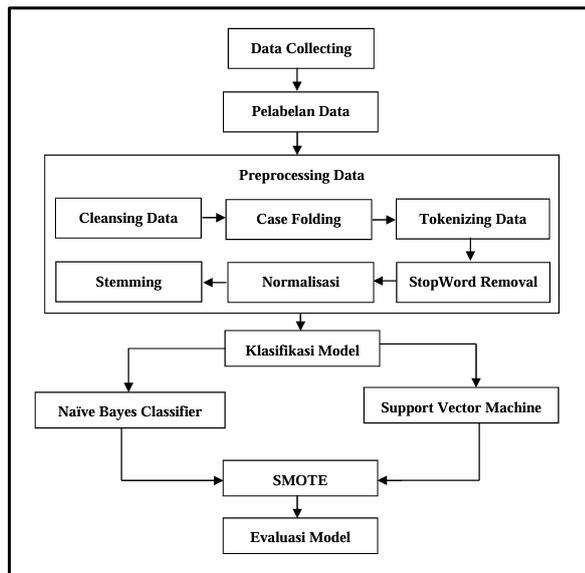
Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap PP No. 82 Tahun 2021 menggunakan data yang diambil dari *Twitter*. Penelitian ini akan membandingkan performa dua algoritma utama, yaitu *Naïve Bayes Classifier (NBC)* dan *Support Vector Machine (SVM)*, melalui empat skenario *preprocessing* data: (1) tanpa *stemming* dan tanpa *SMOTE*, (2) tanpa *stemming* dengan *SMOTE*, (3) dengan *stemming* tanpa *SMOTE*, dan (4) dengan *stemming* dan *SMOTE*. Melalui pendekatan ini, penelitian diharapkan dapat memberikan pemahaman yang lebih mendalam tentang opini masyarakat terhadap kebijakan tersebut serta menawarkan rekomendasi bagi pembuat kebijakan untuk meningkatkan transparansi dan akuntabilitas dalam pelaksanaannya.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui tahapan sistematis untuk menganalisis sentimen publik terhadap PP No. 82 Tahun 2021. Tahap pertama adalah pengumpulan data dari *Twitter* menggunakan kata kunci seperti "*pp 82 lahan korupsi*", "*hakim agung*", dan "*pemotongan honorarium*", yang menghasilkan 2.719 *tweet* relevan sebagai *dataset*. Data yang terkumpul kemudian diberi label sentimen, yaitu positif atau negatif, sesuai dengan isi *tweet*. Setelah proses pelabelan, dilakukan tahap *pre-processing* untuk meningkatkan kualitas data. Tahapan ini mencakup *cleansing* untuk menghapus karakter yang tidak diperlukan, *case folding* untuk mengubah teks menjadi huruf kecil, *tokenizing* untuk memecah teks menjadi unit lebih kecil, *stopword removal* untuk menghilangkan kata-kata umum yang tidak bermakna, *normalization* untuk menyeragamkan kata-kata, dan *stemming* untuk mengembalikan kata ke bentuk dasarnya. Setelah data diproses, dilakukan penerapan model klasifikasi sentimen menggunakan dua metode, yaitu *Support Vector Machine (SVM)* dan *Naïve Bayes Classifier (NBC)*. *SVM* dipilih karena kemampuannya dalam menangani data dengan dimensi tinggi, sementara *NBC* digunakan karena sifat probabilistiknya yang sederhana namun efektif dalam analisis teks. Untuk mengatasi ketidakseimbangan kelas dalam *dataset*, digunakan teknik *Synthetic Minority Over-sampling Technique (SMOTE)* yang menghasilkan data sintesis untuk memperkuat representasi kelas minoritas. Kinerja model dievaluasi menggunakan beberapa metrik seperti *F1-score*, *recall*, akurasi, dan presisi, yang memberikan gambaran komprehensif tentang efektivitas model dalam mengklasifikasikan sentimen publik. Semua tahapan ini dirancang

secara terpadu untuk menghasilkan analisis yang akurat dan relevan. Diagram alur lengkap penelitian dapat dilihat pada Gambar 1 untuk memperjelas proses penelitian.



Gambar 1. Tahap Penelitian

2.2 Data Collection

Pengumpulan data mengacu pada proses memperoleh informasi dari berbagai sumber yang relevan dengan subjek atau tujuan penelitian [9]. Penelitian ini melibatkan pengumpulan data dari *Twitter* menggunakan teknik *crawling* dengan memanfaatkan *Application Programming Interface (API)*. Data diambil berdasarkan kata kunci yang relevan melalui penggunaan *library Tweet Harvest* dalam bahasa pemrograman *Python*. Proses ini menghasilkan total 2.719 *tweet* yang kemudian digunakan untuk analisis lebih lanjut [10].

2.3 Pelabelan Data

Pelabelan data melibatkan pengklasifikasian data menurut kriteria yang telah ditetapkan dengan menandai atau menetapkan kategori padanya. Data ini kemudian digunakan untuk analisis atau pemodelan. Tahap ini bertujuan untuk mengidentifikasi apakah setiap *tweet* mengandung sentimen positif atau negatif [11].

2.4 Pre-processing

Teknik yang dikenal sebagai *pre-processing* dilakukan untuk memfasilitasi pemrosesan data. Data *cleaning* dan *cleansing* mencakup tugas-tugas seperti menghilangkan *noise*, memperbaiki struktur data yang miring, dan menangani data yang hilang [12]. *Cleansing*, *case folding*, *tokenizing*, *normalisasi*, *stemming*, dan *stopword removal* adalah langkah-langkah yang terlibat dalam *pre-processing* [13]. Saat memproses data, langkah-langkah berikut ini dilakukan:

2.4.1 Cleansing

Sebelum analisis, data perlu dibersihkan dari aspek-aspek yang tidak relevan, seperti emoji, hastag, URL, angka, dan tanda baca. Sehingga, hasil analisis lebih akurat dan dapat dipercaya [14].

2.4.2 Case Folding

Langkah yang dilakukan untuk mengonversi huruf "a-z" menjadi huruf kecil. Proses ini juga mencakup penghapusan elemen yang dianggap tidak valid, seperti angka dan karakter lainnya [15].

2.4.3 Tokenizing

Istilah "*tokenizing*" menggambarkan proses pengurangan teks dalam jumlah besar menjadi unit yang lebih kecil, misalnya kata, frasa, atau karakter. Karena prosedur ini memfasilitasi pemrosesan data yang lebih baik dan pemahaman bahasa oleh komputer, maka *tokenizing* menjadi sangat penting [16].

2.4.4 Stopword Removal

Karena tidak relevan dengan analisis sentimen, kata-kata seperti kata keterangan, kata penghubung, kata depan, dan lainnya yang sering muncul akan dihilangkan selama proses ini. Misalnya, ada istilah seperti "*dan*", "*atau*", "*yang*", "*untuk*", dan banyak lainnya [17].

2.4.5 Normalization

Kata-kata seperti "gk" yang berarti "tidak", "bgt" yang berarti "benar-benar", dan "kyk" yang berarti "seperti" adalah contoh dari kata tidak baku yang mengalami *normalization*. Proses ini sangat penting dalam analisis sentimen karena membantu menyederhanakan data teks, khususnya dari media sosial yang sering menggunakan bahasa informal. Normalisasi data membuat data menjadi lebih konsisten dan terstruktur, yang meningkatkan pemahaman pola teks dengan model analitik dan memberikan hasil yang lebih akurat [18].

2.4.6 Stemming

Tujuan *stemming* adalah untuk menyederhanakan pola kata agar dapat diidentifikasi oleh model dengan cara menguranginya menjadi bentuk yang paling dasar dengan menghapus imbuhan. Sebagai contoh, "pemerintah" diubah menjadi "perintah" [19].

2.5 TF-IDF

Term Frequency-Inverse Document Frequency (TF-IDF) adalah salah satu cara untuk menilai kata-kata dalam korpus teks. *Inverse Document Frequency (IDF)* menentukan kelangkaan sebuah kata di seluruh dokumen, sedangkan *Term Frequency (TF)* menentukan frekuensi kemunculan sebuah kata di dokumen tertentu [20]. Persamaan 1 menampilkan rumus *TF-IDF*.

$$TF-IDF(t, d) = \left(\frac{\text{Jumlah kemunculan kata } t \text{ dalam dokumen } d}{\text{Jumlah total kata dalam dokumen } d} \right) \times \log \left(\frac{\text{Jumlah total dokumen}}{\text{Jumlah dokumen yang mengandung kata } t} \right) \quad (1)$$

2.6 SMOTE

Tujuan dari pendekatan oversampling yang dikenal sebagai *SMOTE (Synthetic Minority Over-sampling approach)* adalah untuk menyeimbangkan distribusi kelas dataset dengan menggelembungkan data kelas minoritas secara artifisial hingga setara dengan data kelas mayoritas [21].

2.7 Klasifikasi Model

Data Model dapat "diklasifikasikan" secara matematis ke dalam kelompok-kelompok yang berbeda sesuai dengan karakteristik dan properti yang ada di dalam data tersebut [22]. Metode seperti *Naïve Bayes Classifier* dan *Support Vector Machine* digunakan di dalam penelitian ini. Di bawah ini adalah penjelasan lebih mendalam mengenai penerapan setiap metode:

2.7.1 Naïve Bayes Classifier

Sebuah pendekatan pembelajaran mesin yang menghitung probabilitas kelas menggunakan fitur. Algoritma ini mengandalkan *Teorema Bayes* untuk menentukan *probabilitas* setiap kelas dan memilih kelas dengan nilai *probabilitas* tertinggi. *Naïve Bayes* memiliki potensi yang sangat baik dalam klasifikasi karena kemampuannya untuk mencapai akurasi tinggi dan memproses data secara efisien, terutama ketika diterapkan pada dataset yang besar dan kompleks [23]. *Teorema Bayes* dapat dilihat pada persamaan 2.

$$P(H|X) = \frac{P(X|H) \times P(H)}{P(H)} \quad (2)$$

Probabilitas hipotesis H berdasarkan kondisi X , yang dikenal sebagai posteriori probabilitas, dilambangkan dengan $P(H|X)$ Probabilitas X berdasarkan kondisi hipotesis H direpresentasikan sebagai $P(X|H)$. Selain itu, $P(H)$ menggambarkan probabilitas awal dari hipotesis H , yang sering disebut *prior probabilitas*. Terakhir, $P(X)$ merupakan *probabilitas* dari X , yang menunjukkan kemungkinan terjadinya X tanpa memperhatikan kondisi hipotesis tertentu.

2.7.2 Support Vector Machine

Ini adalah pendekatan pembelajaran mesin yang menggunakan *hyperplane* untuk membagi data ke dalam beberapa kelas. *SVM* memberikan label pada data berdasarkan posisi data terhadap *hyperplane* tersebut. Algoritma ini sering digunakan dalam klasifikasi teks, terutama untuk dataset besar. *SVM* bekerja dengan membangun margin seimbang antara kelas-kelas, sehingga tidak condong ke salah satu kelas. *SVM* dapat menggunakan berbagai jenis kernel, termasuk *linier*, *radial*, dan *sigmoid* [24]. Dalam penelitian ini, digunakan *kernel linier* untuk data yang dapat dipisahkan secara *linier*.

$$y_i(w \cdot x_i + b) \geq 1 \quad (3)$$

$$y_i(w \cdot x_i + b) \leq -1 \quad (4)$$

Label kelas untuk data ke- i dilambangkan dengan y_i , di mana nilai 1 menunjukkan kelas positif dan -1 menunjukkan kelas negatif. Vektor bobot dilambangkan dengan w , sedangkan vektor fitur untuk data ke- i direpresentasikan sebagai x_i . Selain itu, b merupakan nilai bias yang digunakan dalam model.

2.6 Evaluasi Model

Akurasi prediksi atau klasifikasi model pembelajaran mesin dapat diukur melalui evaluasi model. Di sini, hasil prediksi diurutkan ke dalam empat kelompok: TP, TN, FP, dan FN. Untuk alasan ini, matriks kebingungan digunakan. Evaluasi ini juga menghitung *F1-score*, *recall*, dan presisi untuk membantu masalah ketidakseimbangan data. Hasilnya, evaluasi model membantu dalam memilih model terbaik dan memberikan pandangan yang lebih komprehensif [25]. Dalam persamaan ini, kita dapat mengamati elemen-elemen dari confusion matrix.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{5}$$

$$Recall = \frac{TP}{TP+FN} \tag{6}$$

$$F1 = 2 \times \frac{Precision+Recall}{Precision+Recal} \tag{7}$$

True Positive (TP) adalah jumlah prediksi yang tepat untuk kelas positif, di mana model berhasil mengidentifikasi data yang benar-benar termasuk kategori positif. *False Positive (FP)* mencerminkan jumlah kesalahan prediksi untuk kelas positif, yaitu ketika model menganggap data sebagai positif padahal sebenarnya negatif. *True Negative (TN)* menggambarkan jumlah prediksi yang benar untuk kelas negatif, ketika model secara akurat mengenali data yang seharusnya negatif. Sebaliknya, *False Negative (FN)* menunjukkan jumlah kesalahan prediksi untuk kelas negatif, yaitu saat model memprediksi data sebagai negatif meskipun sebenarnya positif.

3. HASIL DAN PEMBAHASAN

3.1 Data Collection

Tahap pertama dalam penelitian ini adalah melakukan *crawling* data dari *platform Twitter* menggunakan kata kunci "PP 82 lahan korupsi", "hakim agung", dan "pemotongan honorarium" untuk mempermudah pengumpulan data. Sebanyak 2.719 *tweet* berhasil diambil dari hasil pencarian tersebut. Proses *crawling* dilakukan dengan menggunakan Python, memanfaatkan *library Tweet Harvest* untuk pengambilan data, serta *library* pandas untuk pengelolaan dataset. Seluruh proses dilakukan melalui Google Colab. Tabel 1 menyajikan dataset yang digunakan sebagai sampel penelitian.

Tabel 1. Hasil Sampel *Data Collection Tweet*

| <i>Tweet</i> |
|--|
| “@magnoliacchild setuju! kpk harus gercep nanganin kasus ini nih soalnya dampaknya gede banget PP 82 Lahan Korupsi MA #PPno82thn2021LahanKorupsiMA PERUBAHAN KEDUA ATAS PERATURAN PEMERINTAH NOMOR 55 TAHUN 2014 TENTANG HAK KEUANGAN DAN FASILITAS HAKIM AGUNG... https://t.co/GVipYhSNxt ” |

3.2 Pelabelan Data

Pelabelan data adalah proses untuk memberikan label pada teks berdasarkan emosi atau opini yang terkandung, seperti sentimen positif atau negatif. Dalam penelitian ini, pelabelan dilakukan menggunakan program Python di *Google Colaboratory* dengan pustaka *VADER (Valence Aware Dictionary and sEntiment Reasoner)*. *VADER* menganalisis teks dengan menghitung skor sentimen berdasarkan leksikon kata yang telah ditentukan. Teks dengan skor polaritas lebih besar dari nol dianggap positif, sedangkan teks dengan skor kurang dari atau sama dengan nol dianggap negatif. Hasil pelabelan menunjukkan bahwa terdapat 92 teks dengan sentimen positif dan 2.627 teks dengan sentimen negatif. Hasil Pelabelan data dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pelabelan Data

| <i>Tweet</i> | Label |
|--|---------|
| “@magnoliacchild setuju! kpk harus gercep nanganin kasus ini nih soalnya dampaknya gede banget PP 82 Lahan Korupsi MA #PPno82thn2021LahanKorupsiMA PERUBAHAN KEDUA ATAS PERATURAN PEMERINTAH NOMOR 55 TAHUN 2014 TENTANG HAK KEUANGAN DAN FASILITAS HAKIM AGUNG... https://t.co/GVipYhSNxt ” | Negatif |
| “@magnoliacchild setuju! kpk harus gercep nanganin kasus ini nih soalnya dampaknya gede banget PP 82 Lahan Korupsi MA #PPno82thn2021LahanKorupsiMA PERUBAHAN KEDUA ATAS PERATURAN PEMERINTAH NOMOR 55 TAHUN 2014 TENTANG HAK KEUANGAN DAN FASILITAS HAKIM AGUNG... https://t.co/GVipYhSNxt ” | Positif |

3.3 Pre-processing

Proses menyiapkan data untuk dianalisis atau dikembangkan. Tujuannya adalah untuk membersihkan, mengatur, dan mengkonsolidasikan data, memperbaiki nilai yang hilang atau salah, dan mengurangi noise yang dapat memengaruhi akurasi model. Untuk pre-processing data, prosedurnya adalah sebagai berikut:



3.3.1 *Cleansing*

Cleansing data merupakan tahap persiapan data teks dengan cara menghilangkan elemen-elemen yang tidak relevan atau dapat mengganggu proses analisis, seperti URL (misalnya, <http://>), nama pengguna atau mention (@username), hashtag (#), emoji, angka, dan tanda baca. Tujuan dari langkah ini adalah untuk memastikan data terstruktur dan rapi sehingga analisis bisa lebih tepat. Hasil *Cleansing* dapat dilihat pada Tabel 3.

Tabel 3. Hasil *Cleansing*

| <i>Cleansing</i> |
|--|
| “setuju kpk harus gercep nanganin kasus ini nih soalnya dampaknya gede banget P Lahan Korupsi MA Pnothn Lahan Korupsi MA PERUBAHAN KEDUA ATAS PERATURAN NOMOR TAHUN TENTANG HAK KEUANGAN DAN FASILITAS HAKIM AGUNG” |

3.3.2 *Case Folding*

Proses pelipatan huruf melibatkan pengubahan semua huruf besar menjadi huruf kecil untuk menghilangkan perbedaan apa pun. Menyederhanakan analisis teks dan meningkatkan akurasi analisis sentimen adalah tujuan menyamakan kata-kata yang sama, terlepas dari apakah kata-kata tersebut ditulis dalam berbagai huruf kapital. Hasil *Case Folding* dapat dilihat pada Tabel 4.

Tabel 4. Hasil *Case Folding*

| <i>Case Folding</i> |
|--|
| setuju kpk harus gercep nanganin kasus ini nih soalnya dampaknya gede banget p lahan korupsi ma pnothn lahan korupsi ma perubahan kedua atas peraturan nomor tahun tentang hak keuangan dan fasilitas hakim agung d |

3.3.3 *Tokenizing*

Mengurangi teks menjadi komponen yang lebih kecil, seperti kata atau frasa, adalah inti dari *tokenizing*. Tujuannya adalah untuk mempermudah pemrosesan dan analisis. Pengorganisasian ini membuatnya lebih mudah dan lebih tepat untuk memahami konten dan konteks teks. Selain itu, tokenisasi menyiapkan teks untuk teknik pembelajaran mesin seperti analisis atau prediksi sentimen, yang selanjutnya meningkatkan kemampuan pemrosesan bahasa sistem dengan membantunya mengenali pola kata. Hasil *Tokenizing* dapat dilihat pada Tabel 5.

Tabel 5. Hasil *Tokenizing*

| <i>Tokenizing</i> |
|---|
| ['setuju', 'kpk', 'harus', 'gercep', 'nanganin', 'kasus', 'ini', 'nih', 'soalnya', 'dampaknya', 'gede', 'banget', 'p', 'lahan', 'korupsi', 'ma', 'pnothn', 'lahan', 'korupsi', 'ma'] ['perubahan', 'kedua', 'atas', 'peraturan', 'nomor', 'tahun', 'tentang', 'hak', 'keuangan', 'dan', 'fasilitas', 'hakim', 'agung'] |

3.3.4 *StopWord Removal*

Stopword removal adalah metode untuk membersihkan teks dari kata-kata yang tidak berguna bagi analisis. Pada titik ini, model ini dapat mencurahkan lebih banyak sumber daya untuk kata-kata yang paling bermakna dan relevan, yang mempercepat analisis. Proses ini juga memungkinkan sistem untuk bekerja lebih optimal dan menghasilkan analisis yang lebih tepat. Hasil *StopWord Removal* dapat dilihat pada Tabel 6.

Tabel 6. Hasil *StopWord Removal*

| <i>StopWord Removal</i> |
|--|
| “['setuju', 'kpk', 'gercep', 'nanganin', 'dampaknya', 'gede', 'banget', 'p', 'lahan', 'korupsi', 'ma', 'pnothn', 'lahan', 'korupsi', 'ma'] ['perubahan', 'peraturan', 'nomor', 'hak', 'keuangan', 'fasilitas', 'hakim', 'agung']” |

3.3.5 *Normalization*

Dalam analisis sentimen, *normalization* sangat penting untuk membuat materi informal lebih mudah dipahami. Prosedur ini meningkatkan struktur dan konsistensi data, sehingga memudahkan model untuk menemukan pola dan menghasilkan temuan yang lebih andal. Hal ini terutama berlaku ketika bekerja dengan sumber seperti media sosial, yang mengandung banyak keragaman bahasa. Hasil *Normalization* dapat dilihat pada Tabel 7.

Tabel 7. Hasil *Normalization*

| <i>Normalization</i> |
|----------------------|
|----------------------|

“[‘setuju’, ‘komisi pemberantasan korupsi’, ‘gerak cepat’, ‘menangani’, ‘dampaknya’, ‘besar’, ‘sangat’, ‘peraturan pemerintah’, ‘lahan’, ‘korupsi’, ‘mahkamah agung’, ‘peraturan pemerintah nomor tahun’, ‘lahan’, ‘korupsi’, ‘mahkamah agung’]
[‘transformasi’, ‘peraturan’, ‘nomor’, ‘hak’, ‘keuangan’, ‘fasilitas’, ‘hakim’, ‘agung’]”

3.3.6 Stemming

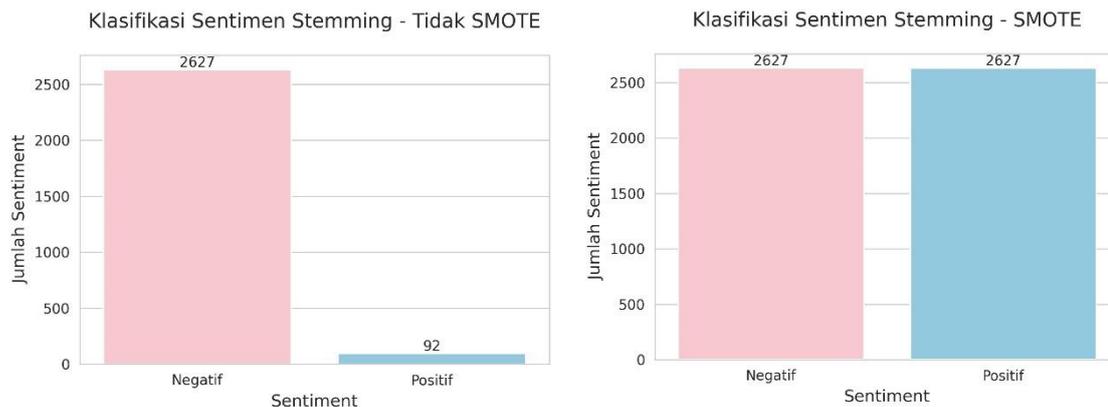
Kata-kata dengan makna yang sebanding disederhanakan menjadi bentuk yang paling dasar dengan melakukan stemming dalam analisis sentimen. Pengenalan pola yang lebih cepat, analisis yang lebih efisien, dan penilaian sentimen yang lebih akurat adalah manfaat dari prosedur algoritma ini. Hasil *Stemming* dapat dilihat pada Tabel 8.

Tabel 8. Hasil *Stemming*

| <i>Stemming</i> |
|--|
| setuju komisi berantas korupsi gerak cepat tangani dampak besar sangat atur perintah lahan korupsi mahkamah agung atur perintah nomor tahun lahan korupsi mahkamah agung |
| transformasi atur nomor hak uang fasilitas hakim agung |

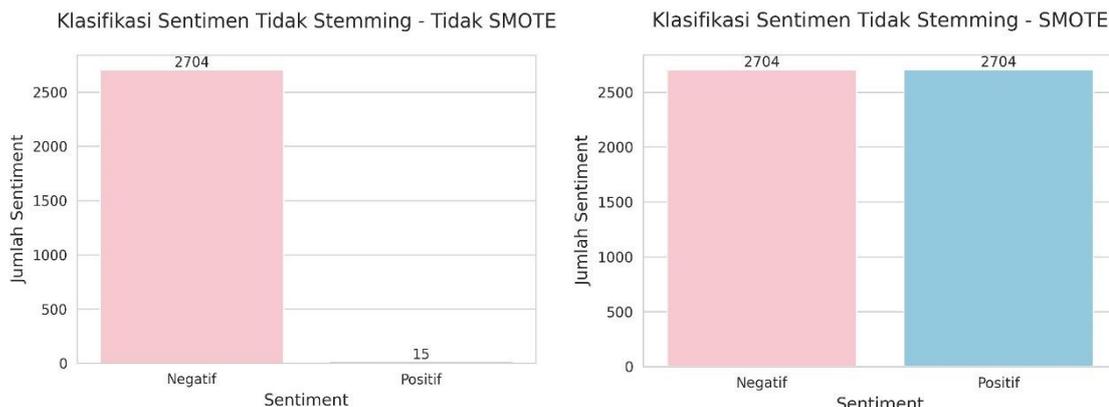
3.4 Evaluasi Model

Perbandingan klasifikasi sentimen dilakukan pada data yang telah melalui proses stemming dalam dua kondisi, yaitu tanpa *SMOTE* dan dengan penerapan *SMOTE*. Pada data tanpa *SMOTE*, terdapat total 2.719 *tweet* dengan distribusi sentimen yang sangat tidak merata. Sentimen negatif mendominasi dengan 2.627 *tweet*, sedangkan sentimen positif hanya terdiri dari 92 *tweet*. Ketidakseimbangan ini menyebabkan model lebih unggul dalam memprediksi kelas negatif tetapi kesulitan dalam mengklasifikasikan kelas positif. Sementara itu, setelah penerapan *SMOTE*, jumlah data pada kelas positif dan negatif menjadi sama, masing-masing memiliki 2.627 data. Dengan distribusi yang merata, model dapat dilatih secara lebih seimbang, sehingga kinerjanya dalam mengklasifikasikan kedua kelas meningkat, terutama untuk kelas positif. Kondisi ini membantu meningkatkan akurasi prediksi pada kelas positif sekaligus menghasilkan performa model yang lebih optimal secara keseluruhan. Hasil perbandingan ini menunjukkan bahwa *SMOTE* adalah metode penting untuk mengatasi ketidakseimbangan data dalam klasifikasi sentimen. Hasil Perbandingan klasifikasi sentimen dengan proses *stemming* tanpa *SMOTE* dan menggunakan *SMOTE* dapat dilihat pada Gambar 2.



Gambar 2. Perbandingan Klasifikasi sentimen dengan proses *Stemming* tanpa *SMOTE* dan menggunakan *SMOTE*

Analisis klasifikasi sentimen dilakukan dengan membandingkan dua kondisi, yaitu tanpa menerapkan proses stemming maupun *SMOTE*, serta tanpa proses *stemming* namun dengan *SMOTE*. Pada kondisi tanpa stemming dan tanpa *SMOTE*, data menunjukkan ketidakseimbangan yang signifikan, dengan 2.074 data sentimen negatif dan hanya 15 data sentimen positif. Ketidakseimbangan ini membuat model lebih dominan dalam mengenali kelas negatif, tetapi lemah dalam mengklasifikasikan kelas positif. Di sisi lain, pada kondisi tanpa *stemming* tetapi dengan *SMOTE*, data menjadi lebih seimbang, dengan 2.074 data untuk masing-masing kelas positif dan negatif. Keseimbangan ini membantu model untuk belajar secara lebih adil, meningkatkan kemampuan prediksi pada kelas positif, dan menghasilkan kinerja yang lebih baik secara keseluruhan. Perbandingan ini menggarisbawahi pentingnya penerapan *SMOTE* dalam menangani ketidakseimbangan data, bahkan tanpa adanya proses stemming.



Gambar 3. Perbandingan Klasifikasi sentimen tanpa proses *Stemming* menggunakan *SMOTE* dan tanpa *SMOTE*

Pembagian data dalam proses pelatihan dan pengujian dilakukan dengan *rasio* 70% untuk pelatihan dan 30% untuk pengujian. Evaluasi model dilakukan menggunakan metrik seperti *recall*, akurasi, presisi, *F1-score*, dan *confusion matrix*. Pada model tanpa *SMOTE* dengan proses *stemming*, *Naïve Bayes* mencapai akurasi sebesar 97%. Namun, *recall* untuk kelas positif sangat rendah, yaitu hanya 4%. Hal ini menunjukkan bahwa model mengalami kesulitan mendeteksi sentimen positif dan lebih cenderung fokus pada sentimen negatif. Sebaliknya, *SVM* menunjukkan kinerja yang lebih baik dengan akurasi sebesar 99% dan *recall* untuk kelas negatif mencapai 100%. Namun, *recall* untuk kelas positif hanya mencapai 68%, yang berarti meskipun akurasi *SVM* tinggi, model masih menghadapi tantangan dalam mendeteksi sentimen positif. Hasil perbandingan model tanpa *SMOTE* dengan proses *stemming* ditampilkan pada Tabel 9.

Tabel 9. Model perbandingan tanpa *SMOTE* dengan proses *stemming*

| Model | Sentimen | Perbandingan tanpa <i>SMOTE</i> dengan proses <i>Stemming</i> | | | |
|-------------|----------|---|-----------|--------|----------|
| | | Accuracy | Precision | Recall | F1-Score |
| Naïve Bayes | Negatif | 97% | 97% | 100% | 99% |
| | Positif | | 100% | 4% | 8% |
| SVM | Negatif | 99% | 99% | 100% | 99% |
| | Positif | | 100% | 68% | 81% |

Ketika *SMOTE* diterapkan bersamaan dengan proses *stemming*, kinerja model menunjukkan peningkatan. Pada model *Naïve Bayes*, akurasi sedikit menurun menjadi 95%, tetapi *recall* untuk kelas positif meningkat signifikan hingga mencapai 97%. Hal ini menunjukkan bahwa *SMOTE* efektif dalam membantu *Naïve Bayes* mendeteksi lebih banyak sentimen positif, meskipun ada sedikit penurunan akurasi secara keseluruhan. Pada model *SVM*, penerapan *SMOTE* memberikan hasil yang lebih baik lagi, dengan akurasi yang meningkat secara signifikan dan *recall* untuk kedua kelas menjadi seimbang. Ini menunjukkan bahwa *SMOTE* mampu menyeimbangkan distribusi data dan meningkatkan kemampuan *SVM* dalam mengidentifikasi sentimen positif maupun negatif secara akurat. Hasil perbandingan model dengan *SMOTE* ditampilkan pada Tabel 10.

Tabel 10. Model perbandingan dengan proses *Stemming* dan optimasi *SMOTE*

| Model | Sentimen | Perbandingan Model dengan proses <i>Stemming</i> dan <i>SMOTE</i> | | | |
|-------------|----------|---|-----------|--------|----------|
| | | Accuracy | Precision | Recall | F1-Score |
| Naïve Bayes | Negatif | 95% | 97% | 93% | 95% |
| | Positif | | 93% | 97% | 95% |
| SVM | Negatif | 100% | 100% | 100% | 100% |
| | Positif | | 100% | 100% | 100% |

Pada model yang tidak menggunakan proses *stemming* dan tanpa penerapan *SMOTE*, *Naïve Bayes* (*NBC*) berhasil mencapai akurasi 100% untuk sentimen negatif, dengan *precision*, *recall*, dan *F1-score* masing-masing juga sebesar 100%. Namun, model ini gagal mendeteksi sentimen positif sama sekali, ditunjukkan dengan *precision*, *recall*, dan *F1-score* sebesar 0% untuk kelas tersebut. Di sisi lain, *SVM* mencatat akurasi sebesar 100%, dengan *performa* sempurna pada sentimen negatif, tetapi hanya mampu mencapai *precision* sebesar 50%, *recall* sebesar 33%, dan *F1-score* sebesar 40% untuk sentimen positif. Ini mengindikasikan bahwa *SVM* masih kesulitan dalam mengenali sentimen positif. Hasil perbandingan model tanpa *SMOTE* ditampilkan pada Tabel 11.

Tabel 11. Model perbandingan tanpa proses *stemming* dan tanpa *SMOTE*

| Model | Sentimen | Perbandingan Model tanpa <i>Stemming</i> maupun <i>SMOTE</i> | | | |
|-------|----------|--|-----------|--------|----------|
| | | Accuracy | Precision | Recall | F1-Score |

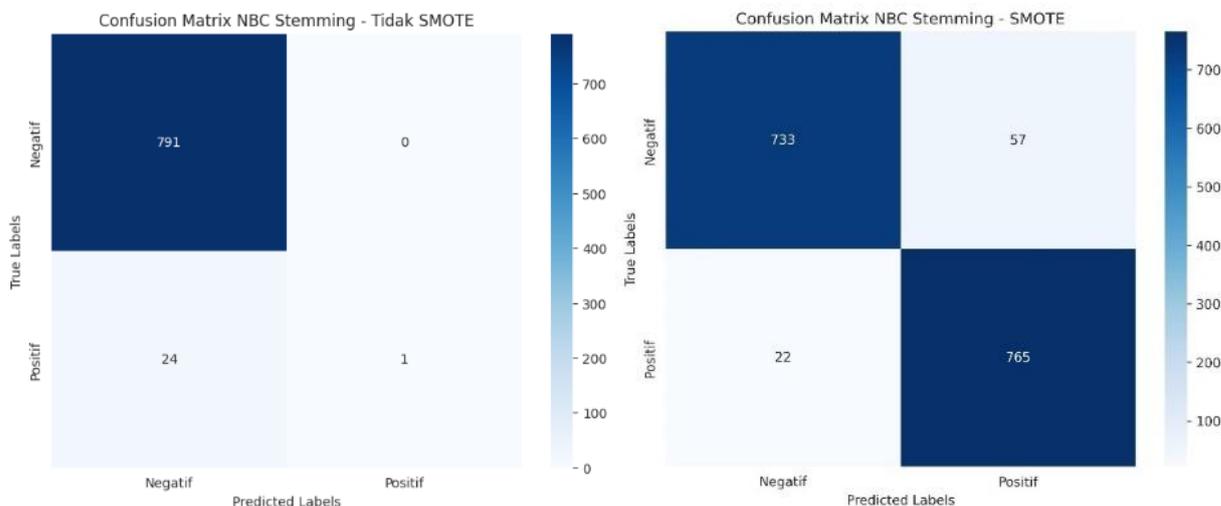
| | | | | | |
|-------------|---------|------|------|------|------|
| Naïve Bayes | Negatif | 100% | 100% | 100% | 100% |
| | Positif | | 0% | 0% | 0% |
| SVM | Negatif | 100% | 100% | 100% | 100% |
| | Positif | | 50% | 33% | 40% |

Ketika *SMOTE* diterapkan tanpa menggunakan proses *stemming*, *performa* model menunjukkan peningkatan yang signifikan. *Naïve Bayes* mengalami sedikit penurunan akurasi menjadi 97%, tetapi *recall* untuk sentimen positif meningkat menjadi 67%, meskipun *precision* dan *F1-score* untuk kelas tersebut tetap rendah, masing-masing hanya 8% dan 15%. Pada *SVM*, penerapan *SMOTE* menghasilkan *performa* yang jauh lebih baik, dengan akurasi 100% dan *precision*, *recall*, serta *F1-score* yang seimbang sebesar 100% untuk kedua kelas. Hal ini menunjukkan bahwa *SMOTE* efektif dalam menangani ketidakseimbangan data dan meningkatkan kemampuan model, khususnya dalam mendeteksi sentimen positif. Hasil dengan *SMOTE* dapat dilihat pada Tabel 12.

Tabel 12. Model perbandingan tanpa *stemming* dengan optimasi *SMOTE*

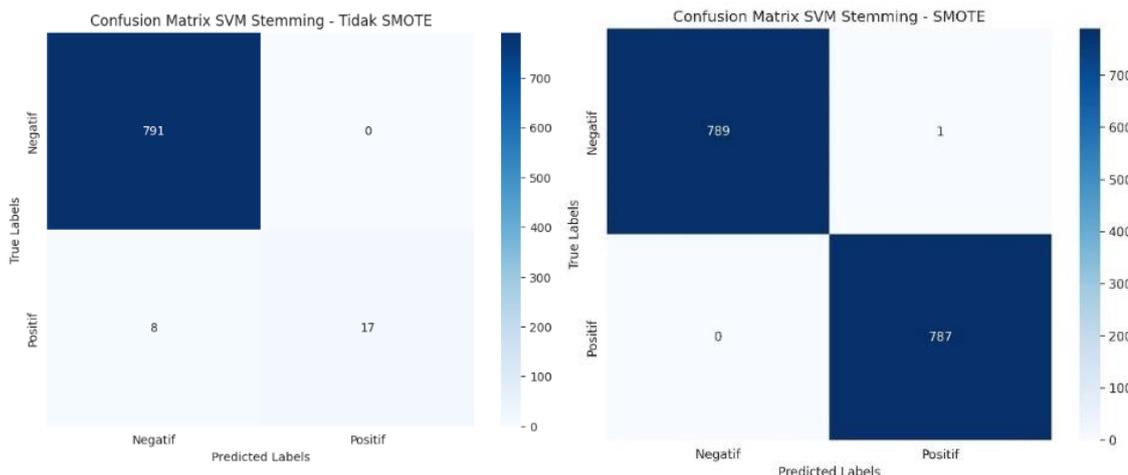
| Model | Sentimen | Perbandingan Model tanpa <i>Stemming</i> menggunakan <i>SMOTE</i> | | | |
|-------------|----------|---|-----------|--------|----------|
| | | Accuracy | Precision | Recall | F1-Score |
| Naïve Bayes | Negatif | 97% | 100% | 97% | 99% |
| | Positif | | 8% | 67% | 15% |
| SVM | Negatif | 100% | 100% | 100% | 100% |
| | Positif | | 100% | 100% | 100% |

Dengan membandingkan nilai yang diantisipasi dan nilai aktual dari data uji, *confusion matrix* digunakan untuk menilai kinerja model klasifikasi. Tabel ini memberikan ringkasan akurasi model dan menunjukkan seberapa baik model dapat mengidentifikasi data. Gambar 4 menunjukkan perbandingan hasil *confusion matrix* dengan proses *stemming* tanpa dan menggunakan *SMOTE*.



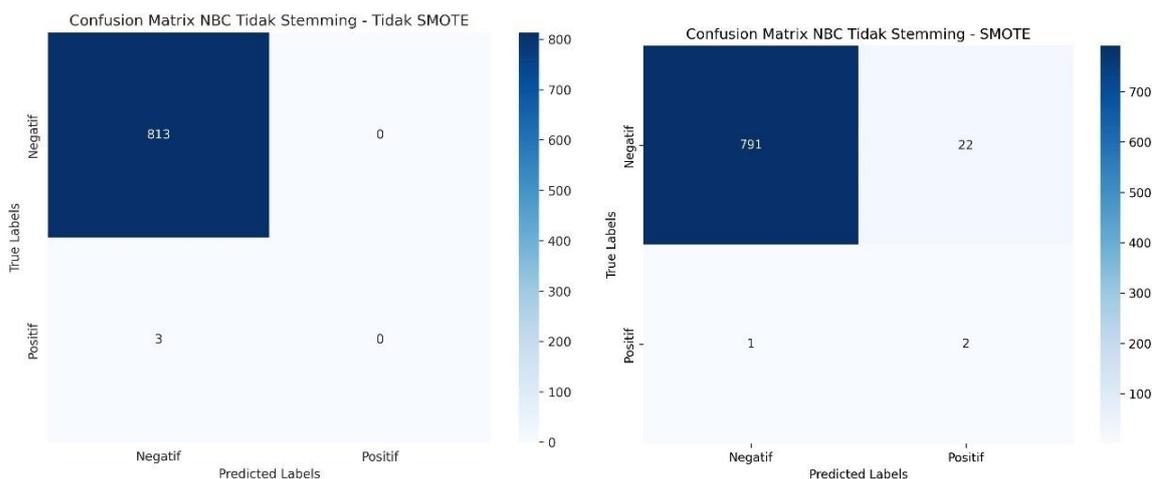
Gambar 4. Perbandingan *Confusion Matrix Naïve Bayes* dengan proses *Stemming* tanpa dan menggunakan *SMOTE*

Berdasarkan Gambar 4, perbandingan *confusion matrix Naïve Bayes* dengan dan tanpa penerapan *SMOTE* menggunakan proses *stemming* menunjukkan perubahan signifikan dalam *performa* model. Tanpa *SMOTE*, model menghasilkan 791 *True Negative* dan hanya 1 *True Positive*, dengan 22 *False Negative* dan tanpa *False Positive*. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi data negatif tetapi kesulitan dalam mendeteksi data positif. Setelah *SMOTE* diterapkan, jumlah *True Positive* meningkat drastis menjadi 765, sementara *True Negative* sedikit menurun menjadi 733. Kesalahan klasifikasi juga mengalami peningkatan, dengan 57 *False Positive* dan tetap 22 *False Negative*. Secara keseluruhan, penerapan *SMOTE* dengan proses *stemming* berhasil meningkatkan kemampuan model dalam mendeteksi data positif, meskipun ada sedikit kompromi dalam kesalahan klasifikasi.



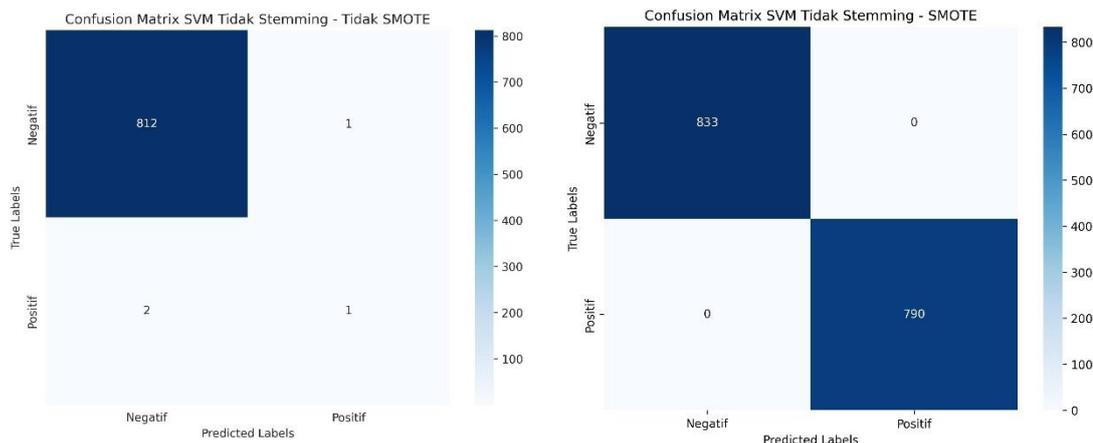
Gambar 5. Perbandingan *Confusion Matrix SVM* dengan proses *Stemming* tanpa dan menggunakan *SMOTE*

Berdasarkan Gambar 5, perbandingan *confusion matrix SVM* dengan proses *stemming* sebelum dan setelah penerapan *SMOTE* menunjukkan perbaikan yang signifikan dalam kinerja model. Tanpa *SMOTE*, model menghasilkan 791 *True Negative* dan 17 *True Positive*, dengan 8 *False Negative* dan tanpa *False Positive*. Hal ini menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam mengidentifikasi data negatif, tetapi masih mengalami kesulitan dalam mendeteksi data positif meskipun akurasinya tinggi. Setelah penerapan *SMOTE*, jumlah *True Positive* meningkat secara drastis menjadi 787, sementara *True Negative* sedikit menurun menjadi 789. Penerapan *SMOTE* juga menyebabkan sedikit peningkatan jumlah *False Positive* menjadi 1, sementara *False Negative* berhasil dikurangi sepenuhnya menjadi 0. Secara keseluruhan, *SMOTE* dengan proses *stemming* terbukti efektif dalam meningkatkan kemampuan model untuk mendeteksi data positif, dengan sedikit kompromi berupa peningkatan kesalahan klasifikasi data negatif sebagai positif.



Gambar 6. Perbandingan *Confusion Matrix Naïve Bayes* tanpa proses *Stemming* tanpa *SMOTE* dan dengan *SMOTE*

Berdasarkan Gambar 6, perbandingan *confusion matrix Naïve Bayes* tanpa proses *stemming* dan tanpa penerapan *SMOTE* menunjukkan bahwa model sangat baik dalam mengenali data negatif, tetapi sepenuhnya gagal mendeteksi data positif. Pada kondisi tanpa *SMOTE*, model menghasilkan 813 *True Negative* dan 0 *True Positive*, tanpa adanya *False Positive*, namun terdapat 3 *False Negative*. Hal ini mengindikasikan bahwa model hanya mampu memfokuskan klasifikasinya pada data negatif tanpa berhasil mengenali data positif sekali. Ketika *SMOTE* diterapkan tanpa proses *stemming*, performa model mulai membaik dalam mendeteksi data positif. Jumlah *True Positive* meningkat menjadi 2, sementara *True Negative* sedikit menurun menjadi 791. Meski demikian, kesalahan dalam bentuk *False Positive* meningkat menjadi 22, dan *False Negative* berkurang menjadi 1. Dengan demikian, penerapan *SMOTE* tanpa proses *stemming* berhasil meningkatkan kemampuan model dalam mendeteksi data positif, walaupun ada konsekuensi berupa sedikit peningkatan kesalahan klasifikasi data negatif sebagai positif.

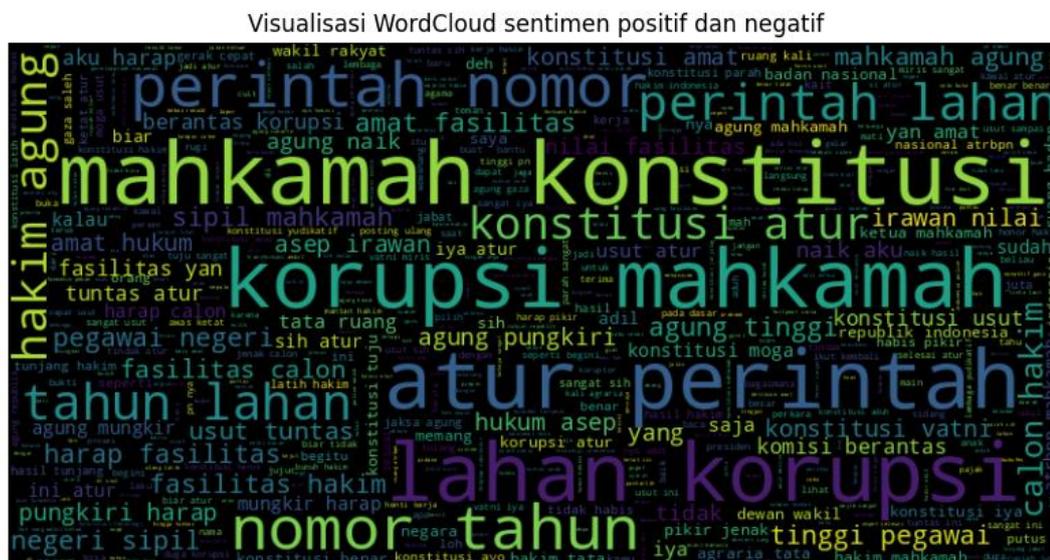


Gambar 7. Perbandingan Confusion Matrix SVM tanpa proses Stemming tanpa SMOTE dan dengan SMOTE

Berdasarkan Gambar 7, perbandingan *confusion matrix SVM* tanpa proses *stemming* sebelum dan setelah penerapan *SMOTE* menunjukkan perubahan yang signifikan dalam kinerja model. Tanpa *SMOTE*, model menghasilkan 812 *True Negative* dan hanya 1 *True Positive*, dengan 2 *False Negative* dan 1 *False Positive*. Hal ini menunjukkan bahwa model memiliki kemampuan yang baik dalam mengklasifikasikan data negatif, tetapi masih kesulitan mendeteksi data positif. Setelah penerapan *SMOTE* tanpa proses *stemming*, *performa* model meningkat secara signifikan. Jumlah *True Positive* melonjak menjadi 790, sementara *True Negative* meningkat menjadi 833. Selain itu, jumlah *False Positive* turun menjadi 0, dan *False Negative* berkurang sepenuhnya menjadi 0. Secara keseluruhan, penerapan *SMOTE* terbukti sangat efektif dalam meningkatkan kemampuan model untuk mendeteksi data positif dan negatif secara akurat, tanpa menambah kesalahan klasifikasi.

3.5 Visualisasi

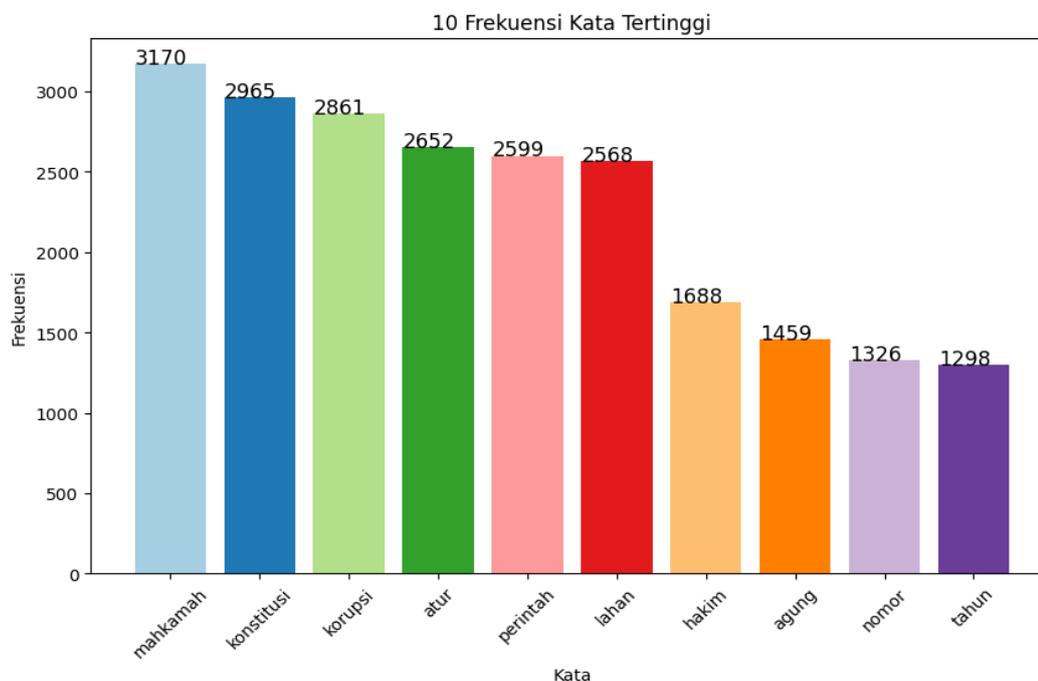
WordCloud menggunakan berbagai ukuran huruf untuk menampilkan istilah yang sering muncul dalam teks atau kumpulan data. Ketika kata-kata lebih sering muncul, ukuran font-nya ditingkatkan, dan ketika kata-kata tersebut lebih jarang muncul, ukuran font-nya diperkecil. Visualisasi ini memudahkan identifikasi tema atau kata kunci utama, serta memberikan gambaran jelas tentang elemen penting dalam data yang dianalisis. Hasil *wordcloud* dapat dilihat dibawah ini:



Gambar 8. WordCloud sentimen positif dan negatif

Berdasarkan Gambar 8, hasil visualisasi *wordcloud* analisis sentimen terhadap Peraturan Pemerintah Nomor 82 Tahun 2021 menunjukkan kata-kata seperti "mahkamah konstitusi", "korupsi mahkamah", "lahan korupsi", "atur perintah," "perintah nomor", "nomor tahun", dan "hakim agung". Kata-kata ini mencerminkan kekhawatiran masyarakat mengenai isu transparansi dan integritas di lembaga peradilan. Istilah "mahkamah konstitusi" dan "hakim agung" menunjukkan perhatian terhadap lembaga peradilan yang diharapkan bertindak dengan jujur dan adil. Sementara itu, kata "korupsi mahkamah" dan "lahan korupsi" mencerminkan kekhawatiran tentang adanya potensi penyalahgunaan kekuasaan dalam lembaga-lembaga hukum. Dalam studi ini, Peraturan Pemerintah No. 82 Tahun 2021 adalah topik

utama, dan istilah “atur perintah” “perintah nomor,” dan “nomor tahun” semuanya berhubungan dengan hal tersebut. Kata-kata ini menunjukkan perhatian terhadap aspek administratif dan legal dari peraturan tersebut, dengan harapan agar peraturan itu dapat diterapkan secara konsisten dan jelas untuk meningkatkan sistem hukum dan pemerintahan.



Gambar 9. Frekuensi Kata Tertinggi

Sepuluh kata yang paling sering muncul adalah sebagai berikut: "mahkamah", "konstitusi", "korupsi", "atur", "perintah", "lahan", "hakim", "agung", "nomor", dan "tahun" seperti yang ditunjukkan pada Gambar 9. Analisis sentimen menggunakan frekuensi kata untuk mengukur sentimen suatu dokumen dengan menghitung seberapa sering kata-kata tertentu muncul di dalamnya. Dengan menganalisis kata-kata yang sering muncul, kita dapat mengetahui apakah teks tersebut mengandung sentimen positif, negatif, atau netral. Selain itu, frekuensi kata juga membantu mengidentifikasi pola-pola tertentu dalam opini atau perasaan yang tercermin dalam teks, sehingga dapat memperjelas sentimen yang dominan dalam suatu kumpulan data atau percakapan. Frekuensi kata-kata ini menunjukkan bahwa pembahasan terkait PP No. 82 Tahun 2021 banyak berfokus pada aspek hukum, konstitusi, serta dugaan korupsi yang melibatkan hakim agung. Kata "mahkamah" dan "konstitusi" mengindikasikan bahwa perdebatan lebih banyak berpusat pada aspek hukum dan peraturan yang berlaku, sementara kata "korupsi" dan "lahan" menunjukkan adanya perhatian terhadap potensi penyalahgunaan wewenang terkait kebijakan tersebut.

4. KESIMPULAN

Hasil penelitian ini menunjukkan bahwa algoritma *Support Vector Machine (SVM)* memiliki keunggulan dibandingkan *Naïve Bayes Classifier (NBC)* dalam analisis sentimen publik terhadap PP No. 82 Tahun 2021, khususnya pada skenario yang mengombinasikan teknik pra-proses *stemming* dan *SMOTE*. Pada skenario tersebut, *SVM* berhasil mencapai akurasi sempurna sebesar 100%, sedangkan *NBC* mencatatkan akurasi 95%. Temuan ini menegaskan bahwa *SVM* lebih andal dalam mengenali pola sentimen pada dataset yang telah diproses. Kombinasi *stemming* dan *SMOTE* juga terbukti efektif dalam mengatasi ketidakseimbangan kelas, sekaligus meningkatkan kemampuan algoritma dalam mengklasifikasikan sentimen positif dan negatif. Namun, penelitian ini terbatas pada dataset kecil dari Twitter, sehingga hasilnya mungkin tidak sepenuhnya merepresentasikan opini masyarakat. Penelitian selanjutnya disarankan untuk memperluas sumber data, meningkatkan ukuran dataset, dan menguji algoritma lain, seperti *Random Forest* atau *Deep Learning*, untuk memberikan hasil yang lebih kaya dan komprehensif.

REFERENCES

- [1] J. Widodo, “PERATURAN PEMERINTAH REPUBLIK INDONESIA NOMOR 82 TAHUN 2021.” [Online]. Available: <https://peraturan.bpk.go.id/Details/175150/pp-no-82-tahun-2021>
- [2] R. R. C. Putra, E. B. Perkasa, T. Sugihartono, A. P. Alkayess, I. D. Sandro, and R. Indallah, “Komparasi Naive Bayess dengan Support Vector Machine dalam Analisis Sentimen Aplikasi MyPertamina,” *SATIN-Sains dan Teknologi Informasi*, vol. 9, no. 2, pp. 90–99, 2023, doi: <https://doi.org/10.33372/stn.v9i2.1042>.
- [3] H. Faisal, A. Febriandirza, and F. N. Hasan, “Analisis Sentimen Terkait Ulasan Pada Aplikasi PLN Mobile Menggunakan



- Metode Support Vector Machine,” *Kesatria: Jurnal Penerapan Sistem Informasi (Komputer dan Manajemen)*, vol. 5, no. 1, pp. 303–312, 2024, doi: <https://doi.org/10.30645/kesatria.v5i1.339>.
- [4] S. Styawati, A. R. Isnain, N. Hendrastuty, and L. Andraini, “Comparison of Support Vector Machine and Naïve Bayes on Twitter Data Sentiment Analysis,” *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 6, no. 1, pp. 56–60, 2021, doi: <https://doi.org/10.30591/jpit.v6i1.3245>.
- [5] G. G. Warow and H. Pandia, “Analisis Sentimen Aplikasi Dana Menggunakan Naïve Bayes Classifier dan Support Vector Machine,” *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 13, no. 1, pp. 609–621, 2024, doi: 10.35889/jutisi.v13i1.1893.
- [6] A. Ndruru, “Analisis Sentimen UU Cipta Kerja Melalui Omnibus Law Menggunakan Naive Bayes Classifier (NBC) Dan Support Vector Machine (SVM),” *Pelita Informatika: Informasi dan Informatika*, vol. 10, no. 3, pp. 85–90, 2022, doi: <https://ejournal.stmik-budidarma.ac.id/index.php/pelita/article/view/3768/2495>.
- [7] D. Atmajaya, A. Febrianti, and H. Darwis, “Metode SVM dan Naive Bayes untuk Analisis Sentimen ChatGPT di Twitter,” *The Indonesian Journal of Computer Science*, vol. 12, no. 4, 2023, doi: <https://doi.org/10.33022/ijcs.v12i4.3341>.
- [8] Y. Khoiruddin, A. Fauzi, and A. M. Siregar, “Analisis Sentimen Gojek Indonesia Pada Twitter Menggunakan Algoritma Naïve Bayes Dan Support Vector Machine,” *Progresif: Jurnal Ilmiah Komputer*, vol. 19, no. 1, pp. 391–400, 2023, doi: 10.35889/progresif.v19i1.1173.
- [9] K. S. Putri, I. R. Setiawan, and A. Pambudi, “Analisis Sentimen Terhadap Brand Skincare Lokal Menggunakan Naïve Bayes Classifier,” *Technologia: Jurnal Ilmiah*, vol. 14, no. 3, pp. 227–232, 2023, doi: <http://eprints.ummi.ac.id/id/eprint/3348>.
- [10] T. D. Dikiyanti, A. M. Rukmi, and M. I. Irawan, “Sentiment analysis and topic modeling of BPJS Kesehatan based on twitter crawling data using Indonesian Sentiment Lexicon and Latent Dirichlet Allocation algorithm,” in *Journal of Physics: Conference Series*. IOP Publishing, 2021, p. 12054. doi: 10.1088/1742-6596/1821/1/012054.
- [11] I. G. S. M. Diyasa, N. M. I. M. Mandenni, M. I. Fachrurrozi, S. I. Pradika, K. R. N. Manab, and N. R. Sasmita, “Twitter sentiment analysis as an evaluation and service base on python textblob,” in *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, 2021, p. 12034. doi: 10.1088/1757-899X/1125/1/012034.
- [12] Y. Ikhsani, I. Permana, F. N. Salisah, and N. E. Rozanda, “Perbandingan Algoritma Support Vector Machine dan Naïve Bayes dalam Menganalisis Sentimen Pinjaman Online di Twitter,” *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 0–13, 2024, doi: 10.47065/bits.v6i3.6106.
- [13] R. Nurhidayat and N. Hendrastuty, “Analisis Sentimen Komentar Media Sosial Twitter Terhadap Tes CPNS dengan Algoritma Naive Bayes,” *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, pp. 1477–1489, 2024, doi: 10.47065/bits.v6i3.6148.
- [14] I. H. Kusuma and N. Cahyono, “Analisis Sentimen Masyarakat Terhadap Penggunaan E-Commerce Menggunakan Algoritma K-Nearest Neighbor,” *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 8, no. 3, pp. 302–307, 2023, doi: <https://doi.org/10.30591/jpit.v8i3.5734>.
- [15] R. A. Raharjo, I. M. G. Sunarya, and D. G. H. Divayana, “Perbandingan Metode Naïve Bayes Classifier Dan Support Vector Machine Pada Kasus Analisis Sentimen Terhadap Data Vaksin Covid-19 Di Twitter,” *Elkom: Jurnal Elektronika dan Komputer*, vol. 15, no. 2, pp. 456–464, 2022, doi: <https://doi.org/10.51903/elkom.v15i2.918>.
- [16] S. N. Nugraha, R. Pebrianto, A. Latif, and M. R. Firdaus, “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, doi: <http://dx.doi.org/10.30587/e-link.v17i1.3965>.
- [17] M. Manipi, R. Soekarta, M. Yusuf, and F. Tella, “Analisis Sentimen Tentang Undang-Undang Perlindungan Data Pribadi Menggunakan Algoritma Naive Bayes Classifier,” *Framework: Jurnal Ilmu Komputer dan Informatika*, vol. 2, no. 01, pp. 93–100, 2023, doi: <https://doi.org/10.33506/jiki.v2i01.3099>.
- [18] H. Sulastomo, R. Ramadiansyah, K. Gibran, E. Maryansyah, and A. Tegar, “Analisis Sentimen Pada Twitter@ Ovo_Id dengan Metode Support Vectore Machine (SVM),” *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, vol. 6, no. 2, pp. 1050–1056, 2022, doi: <http://dx.doi.org/10.30645/j-sakti.v6i2.514>.
- [19] M. N. Rahman, “Analisis performa penggunaan stopwords dan stemming dalam sentimen analisis dengan pendekatan klasifikasi naive bayes.” Fakultas Sains dan Teknologi UIN Syarif Hidayatullah Jakarta, 2022. doi: <https://repository.uinjkt.ac.id/dspace/handle/123456789/65210>.
- [20] L. Rofiqi and M. Akbar, “Analisis Sentimen Terkait RUU Perampasan Aset dengan Support Vector Machine,” *JEKIN-Jurnal Teknik Informatika*, vol. 4, no. 3, pp. 529–538, 2024, doi: <https://doi.org/10.58794/jekin.v4i3.824>.
- [21] G. Gumelar, Q. Ain, R. Marsuciati, S. A. Bambang, A. Sunyoto, and M. S. Mustafa, “Kombinasi Algoritma Sampling dengan Algoritma Klasifikasi untuk Meningkatkan Performa Klasifikasi Dataset Imbalance,” *Prosiding SISFOTEK*, vol. 5, no. 1, pp. 250–255, 2021, doi: <https://www.seminar.iaii.or.id/index.php/SISFOTEK/article/view/295/262>.
- [22] A. N. Indraini, I. Ernawati, and A. Zaidah, “Analisis Sentimen Terhadap Pembelajaran Daring Di Indonesia Menggunakan Support Vector Machine (SVM),” *Jurnal Ilmiah FIFO*, vol. 68, 2022, doi: <http://dx.doi.org/10.22441/fifo.2022.v14i1.007>.
- [23] D. N. Novianti, D. F. Shiddieq, F. F. Roji, and W. Susilawati, “Komparasi Algoritma Support Vector Machine dan Naïve Bayes untuk Analisis Sentimen pada Metaverse: Comparison of Support Vector Machine and Naïve Bayes Algorithms for Sentiment Analysis of the Metaverse,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 231–239, 2024, doi: <https://doi.org/10.57152/malcom.v4i1.1061>.
- [24] H. Hariyadi, D. Firdo, and M. H. Al Rafi, “Implementasi Algoritma Naïve Bayes dan Support Vector Machine pada Analisis Sentimen Ulasan Aplikasi Canva,” *Jurnal Minfo Polgan*, vol. 13, no. 1, pp. 261–269, 2024, doi: 10.33395/jmp.v13i1.13568.
- [25] R. Noviana and I. Rasal, “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, doi: <https://doi.org/10.56127/jts.v2i2.791>.