

OPINI PUBLIK TERHADAP ULASAN VIDEO RUU TNI MENGUNAKAN TF-IDF, NAÏVE BAYES DAN SMOTE

Patrisius Satria Hendrawan^{1*}, Michael Gunawan², Hafiz Irsyad³, Abdul Rahman⁴

Universitas Multi Data Palembang, Palembang, Sumatera Selatan, Indonesia¹

Email*: patrisiussatriahendrawan_2226250062@mhs.mdp.ac.id

Universitas Multi Data Palembang, Palembang, Sumatera Selatan, Indonesia²

Email: michaelgunawan_2226250062@mhs.mdp.ac.id

Universitas Multi Data Palembang, Palembang, Sumatera Selatan, Indonesia³

Email: hafizirsyad@mdp.ac.id

Universitas Multi Data Palembang, Palembang, Sumatera Selatan, Indonesia⁴

Email: arahman@mdp.ac.id

(*) *Corresponding Author*

ABSTRAK

Perkembangan teknologi digital mendorong masyarakat untuk aktif menyuarakan opini terhadap isu-isu publik melalui media sosial, salah satunya YouTube. Kolom komentar pada video yang membahas Rancangan Undang-Undang Tentara Nasional Indonesia (RUU TNI) menjadi ruang interaktif bagi publik dalam mengekspresikan dukungan maupun penolakan. Penelitian ini bertujuan untuk menganalisis opini publik terhadap RUU TNI dengan mengklasifikasikan komentar YouTube ke dalam dua kategori sentimen, yaitu positif dan negatif. Metode yang digunakan mencakup pra-pemrosesan teks, ekstraksi fitur menggunakan TF-IDF, klasifikasi dengan algoritma *Naïve Bayes*, serta penyeimbangan data menggunakan teknik SMOTE untuk mengatasi dominasi kelas tertentu. Hasil pengujian menunjukkan bahwa akurasi model sebelum SMOTE sebesar 80,7%, namun nilai *recall* dan *f1-score* pada kelas positif sangat rendah akibat ketidakseimbangan data. Setelah diterapkan SMOTE, akurasi sedikit menurun menjadi 80,38%, tetapi terjadi peningkatan signifikan pada matrik evaluasi kelas positif, khususnya *recall* sebesar 86,21% dan *f1-score* sebesar 81,3%. Visualisasi melalui *WordCloud* juga memperlihatkan kata-kata dominan yang mewakili masing-masing sentimen. Berdasarkan hasil tersebut, penggunaan algoritma *Naïve Bayes* yang dikombinasikan dengan SMOTE terbukti lebih seimbang dalam mengklasifikasikan opini publik dan direkomendasikan untuk digunakan dalam analisis sentimen pada data tidak seimbang.

Kata kunci: *Naïve bayes*, opini publik, RUU TNI, SMOTE, TF-IDF

ABSTRACT

The rapid development of digital technology has encouraged the public to actively express their opinions on public issues through social media platforms, including YouTube. The comment section on videos discussing the Draft Law on the Indonesian National Armed Forces (RUU TNI) has become a space for the public to convey support or rejection. This study aims to analyze public opinion regarding the RUU TNI by classifying YouTube comments into two sentiment categories: positive and negative. The methods employed include text preprocessing, feature extraction using TF-IDF, sentiment classification with the *Naïve Bayes* algorithm, and data balancing using the SMOTE technique to address class imbalance. The evaluation results show that the model

achieved 80.7% accuracy before SMOTE; however, the recall and f1-score for the positive class were very low due to the imbalanced dataset. After applying SMOTE, the accuracy slightly decreased to 80.38%, but there was a significant improvement in the evaluation metrics for the positive class, with recall reaching 86.21% and f1-score 81.3%. WordCloud visualization also revealed dominant keywords that represent each sentiment. These findings indicate that the Naïve Bayes algorithm, when combined with SMOTE, is more effective in producing a balanced sentiment classification and is recommended for use in analyzing imbalanced textual data related to public opinion.

Keywords: Naïve bayes, public opinion, RUU TNI, SMOTE, TF-IDF

1. PENDAHULUAN

Perkembangan pesat teknologi informasi telah mendorong perubahan signifikan dalam pola komunikasi masyarakat, khususnya dalam mengekspresikan opini dan pandangan terhadap isu-isu sosial serta kebijakan publik di ruang digital. YouTube, sebagai salah satu platform penyiar video terbesar di dunia, kini menjadi ruang diskusi baru yang sangat dinamis, di mana setiap individu dapat memberikan komentar secara terbuka terhadap berbagai topik yang sedang hangat dibicarakan, salah satunya adalah Rancangan Undang-Undang Tentara Nasional Indonesia (RUU TNI). Melalui kolom komentar, masyarakat tidak hanya sekadar menanggapi konten, namun juga membentuk ekosistem opini publik yang beragam.

Analisis opini menjadi salah satu metode yang banyak digunakan untuk menganalisis dan mengelompokkan opini masyarakat dalam bentuk sentimen positif maupun negatif pada data teks. Perkembangan teknologi *text mining* memungkinkan proses ini dilakukan secara otomatis dan efisien pada data dalam jumlah besar [1]. Dengan semakin luasnya penggunaan media sosial dan platform digital, analisis sentimen memberikan kontribusi penting untuk memahami persepsi publik secara objektif terhadap isu-isu aktual, seperti kebijakan pemerintah, tren politik, maupun produk tertentu [2].

Sementara itu, di platform media sosial lain seperti X (Twitter), analisis opini juga digunakan untuk memahami respons masyarakat terhadap isu-isu viral, termasuk fenomena maraknya platform ilegal atau diskusi tentang layanan digital lainnya [3]. Hal ini menunjukkan bahwa penerapan analisis sentimen telah meluas ke berbagai ranah digital dan menjadi alat penting dalam memetakan persepsi publik terhadap berbagai topik.

Untuk memperoleh hasil analisis yang akurat, diperlukan tahapan pra-pemrosesan data yang komprehensif, antara lain pembersihan data (*cleaning*), *case folding*, tokenisasi, penghapusan *stopword*, hingga *stemming*. Tahapan-tahapan ini penting untuk memastikan data teks yang dianalisis telah dalam bentuk yang optimal dan siap untuk diolah lebih lanjut [1]. Selanjutnya, metode *Term Frequency-Inverse Document Frequency* (TF-IDF) digunakan untuk merepresentasikan data teks ke dalam bentuk numerik, sehingga fitur-fitur penting dari komentar dapat diekstraksi secara efektif untuk proses klasifikasi [4].

Naive Bayes, yang dikenal sebagai salah satu metode paling efektif dalam pengolahan data teks karena kesederhanaan, kecepatan, dan akurasi yang tinggi, bahkan pada data dalam skala besar [5]. Namun, permasalahan umum yang kerap muncul adalah ketidakseimbangan jumlah data antar kelas sentimen, misalnya jumlah komentar negatif yang jauh lebih banyak dibandingkan komentar positif atau sebaliknya. Kondisi ini dapat mempengaruhi kinerja model klasifikasi. Oleh karena itu, digunakan teknik *Synthetic Minority Oversampling Technique* (SMOTE) untuk menyeimbangkan distribusi kelas

dengan menciptakan data sintetik pada kelas minoritas. Penerapan SMOTE terbukti efektif dalam meningkatkan akurasi dan kinerja model klasifikasi dalam berbagai studi analisis sentimen digital [4].

Selain itu, tren penelitian terbaru juga menunjukkan peningkatan minat dalam pemanfaatan platform YouTube untuk analisis sentimen terhadap isu-isu publik. Penelitian terdahulu membahas analisis sentimen masyarakat Indonesia terhadap aksi boikot produk Israel melalui komentar pada YouTube Shorts dengan metode *Naive Bayes* dan SMOTE. Penelitian ini menegaskan efektivitas metode tersebut dalam mengklasifikasikan sentimen komentar publik, sekaligus menyoroti pentingnya penyeimbangan data dengan SMOTE untuk mengatasi masalah distribusi kelas yang tidak seimbang. Hasilnya, akurasi model dapat mencapai 94% setelah proses penyeimbangan data dilakukan, menunjukkan bahwa kombinasi *Naive Bayes* dan SMOTE sangat optimal untuk analisis sentimen berbasis teks dalam skala besar [6].

Penelitian terdahulu menunjukkan efektivitas metode vektorisasi TF-IDF dalam analisis sentimen komentar media sosial, khususnya di platform Instagram, dengan tingkat akurasi mencapai 96,25% menggunakan algoritma Random Forest [7]. Metode ini terbukti mampu secara efektif menangkap kata kunci penting dalam teks sehingga meningkatkan kualitas klasifikasi sentimen secara signifikan. Oleh karena itu, penelitian ini mengadopsi pendekatan TF-IDF serupa untuk menganalisis opini publik terhadap RUU TNI melalui komentar YouTube, bertujuan menghasilkan klasifikasi sentimen yang akurat dan objektif. Penelitian yang juga membahas tentang RUU TNI dengan metode SVM berhasil menunjukkan bahwa metode *Support Vector Machine* (SVM) efektif dalam mengklasifikasikan sentimen publik terhadap RUU TNI berdasarkan data dari Twitter. Dengan akurasi 94,66%, model mampu mengenali sentimen netral secara sempurna 1,00, serta sentimen negatif dan positif dengan recall masing masing 0,98 dan 0,88. Meski hasilnya cukup baik distribusi data yang tidak seimbang menyebabkan model cenderung lebih akurat pada sentimen netral [8].

Dengan merujuk pada penelitian terdahulu didapatkan bahwa kombinasi metode TF-IDF, algoritma *Naive Bayes*, dan teknik SMOTE terbukti efektif dalam meningkatkan akurasi dan relevansi hasil analisis sentimen pada data komentar di platform digital seperti YouTube. Hal ini menjadi landasan kuat bagi penelitian ini dalam mengadopsi pendekatan serupa untuk menganalisis opini publik terhadap RUU TNI secara komprehensif dan objektif. Penelitian ini bertujuan untuk menganalisis opini publik terhadap RUU TNI melalui komentar YouTube dengan pendekatan kombinasi metode TF-IDF, algoritma *Naive Bayes*, dan teknik SMOTE. Diharapkan, penelitian ini dapat menghasilkan sistem klasifikasi sentimen yang akurat dan mampu memberikan gambaran objektif mengenai persepsi masyarakat terhadap isu kebijakan negara.

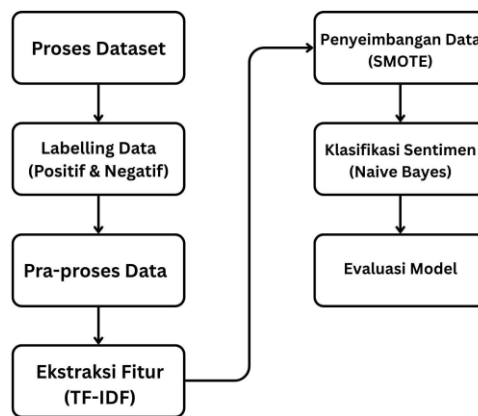
2. METODE

Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode klasifikasi teks untuk menganalisis opini masyarakat terhadap Rancangan Undang-Undang Tentara Nasional Indonesia (RUU TNI). Data diperoleh melalui teknik *text mining* berupa pengumpulan komentar dari platform YouTube. Komentar-komentar tersebut kemudian diberi *label* sentimen secara manual oleh penulis menjadi dua kelas, yaitu positif dan negatif. Setelah proses *labeling*, dilakukan proses pra-pemrosesan data yang dimana pada tahap pertama akan dilakukan normalisasi data, lalu dilakukan pembersihan data melakukan *case folding* yang dimana semua data akan menjadi huruf kecil, menghapus

kata-kata yang tidak penting, lalu proses *Stemming*. Hasil dari pra-pemrosesan ini adalah teks bersih yang siap diekstraksi menggunakan metode TF-IDF (*Term Frequency–Inverse Document Frequency*), yang mengubah teks menjadi representasi numerik. Untuk menangani ketidakseimbangan jumlah data antara kelas positif dan negatif, diterapkan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) pada data latih. Selanjutnya, proses klasifikasi dilakukan menggunakan algoritma *Naïve Bayes*, yang dinilai cocok untuk pengolahan data teks karena efisien dan akurat dalam mengidentifikasi pola kata dalam dokumen. Alur lengkap proses penelitian ini ditunjukkan pada Gambar 1.

+



Gambar 1. Tahapan penelitian yang digunakan

Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 1000 komentar YouTube yang dikumpulkan secara manual dari video terkait pembahasan RUU TNI. Komentar yang dikumpulkan memakai metode *text mining*. Setiap komentar diberi *label* secara manual sendiri oleh penulis yang berjumlah 2 orang berdasarkan konteks isi menjadi dua kelas sentimen yaitu positif dan negatif. Setelah melalui proses *labeling*, didapatkan data berupa 781 sentimen positif dan 219 sentimen negatif. Data-data yang telah dikumpulkan ini kemudian digunakan untuk menjadi dasar pelatihan dan pengujian untuk model opini publik.

Pra-pemrosesan Data

Tahapan pra-pemrosesan dilakukan untuk merapikan dan menyaring teks komentar sebelum masuk ke proses representasi fitur. Langkah ini bertujuan agar hanya informasi yang penting dan relevan yang diproses oleh algoritma klasifikasi. Proses pertama adalah *case folding*, yaitu mengubah seluruh huruf menjadi huruf kecil untuk menjaga keseragaman penulisan. Setelah itu, dilakukan pembersihan (*cleaning*) dengan cara menghapus angka, tanda baca, dan karakter-karakter khusus lain yang tidak mengandung nilai semantik. Selanjutnya, sistem menerapkan *stopword removal* menggunakan daftar kata umum dalam Bahasa Indonesia dari pustaka Sastrawi yang telah diperluas dengan beberapa kata tambahan seperti “yg”, “aja”, dan “deh”. Langkah ini berguna untuk menghilangkan kata-kata yang sering muncul namun tidak memiliki bobot makna dalam penentuan sentimen. Terakhir, dilakukan *stemming* untuk mengubah kata-

kata turunan menjadi bentuk dasarnya, misalnya kata "mendukung" menjadi "dukung". Output dari proses ini adalah teks bersih yang telah distandarisasi dan siap untuk diubah menjadi fitur numerik menggunakan TF-IDF.

Ekstraksi Fitur

Teks yang telah melalui tahapan pra-pemrosesan kemudian dikonversi ke dalam bentuk representasi numerik menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF). TF-IDF merupakan metode pembobotan kata yang memperhitungkan dua komponen utama, yaitu *term frequency* (TF) dan *inverse document frequency* (IDF). TF menunjukkan seberapa sering sebuah kata muncul dalam satu dokumen, sementara IDF mengukur seberapa jarang kata tersebut muncul di seluruh dokumen dalam korpus. Kombinasi keduanya bertujuan untuk menekankan kata-kata yang dianggap penting dalam konteks satu dokumen, tetapi tidak terlalu umum di seluruh kumpulan data. Dengan kata lain, TF-IDF memberikan bobot tinggi pada kata-kata yang sering muncul dalam sebuah komentar, namun jarang ditemukan di komentar lainnya. Sebaliknya, kata-kata yang sering muncul di hampir semua komentar (misalnya "itu", "adalah", atau "dan") akan mendapatkan bobot yang lebih rendah karena dianggap kurang informatif. Representasi ini sangat bermanfaat dalam konteks opini publik karena membantu model klasifikasi dalam mengidentifikasi kata-kata kunci yang memiliki kontribusi penting terhadap *label* sentimen. penggunaan TF-IDF dalam analisis opini masyarakat terbukti mampu meningkatkan efektivitas model dalam memahami konteks semantik dari komentar teks, terutama saat dikombinasikan dengan algoritma klasifikasi seperti *Naïve Bayes* [9].

Penyeimbangan Data dengan SMOTE

Dalam penelitian ini, distribusi kelas sentimen pada data komentar menunjukkan ketidakseimbangan antara jumlah data positif dan negatif. Ketidakseimbangan ini dapat menimbulkan bias dalam proses klasifikasi, karena model cenderung lebih mengenali pola dari kelas mayoritas dan mengabaikan informasi dari kelas minoritas. Untuk mengatasi hal tersebut, digunakan pendekatan *Synthetic Minority Oversampling Technique* (SMOTE). SMOTE merupakan teknik *oversampling* yang menghasilkan data sintetik pada kelas minoritas berdasarkan interpolasi terhadap tetangga terdekat, sehingga menciptakan sampel baru yang lebih bervariasi namun tetap representatif terhadap distribusi asli. Dengan penerapan metode ini, diharapkan model dapat mengenali kedua kelas secara adil dan tidak berpihak pada dominasi satu kelas. Metode SMOTE telah banyak digunakan dalam penelitian klasifikasi berbasis teks, termasuk dalam pengolahan opini publik dan opini publik sosial. SMOTE membantu memperbaiki representasi kelas minoritas agar dapat diolah secara setara dalam algoritma pembelajaran mesin [10]. SMOTE merupakan salah satu teknik yang efektif dalam menyeimbangkan data input sebelum proses klasifikasi dilakukan [11].

Klasifikasi dengan Naïve Bayes

Proses klasifikasi pada penelitian ini menggunakan algoritma Naïve Bayes, yaitu metode berbasis probabilistik yang menghitung kemungkinan sebuah dokumen termasuk ke dalam suatu kelas berdasarkan distribusi kata dalam dokumen tersebut. Algoritma ini bekerja dengan menerapkan prinsip *Teorema Bayes* dan mengasumsikan independensi antar fitur, sehingga memungkinkan proses perhitungan menjadi lebih efisien dan ringan secara komputasi. Naïve Bayes dikenal luas dalam klasifikasi teks karena kemampuannya

dalam menangani data berdimensi tinggi secara cepat dan efektif. Sebelum tahap klasifikasi, teks komentar terlebih dahulu dikonversi menjadi fitur numerik menggunakan metode TF-IDF, kemudian dilakukan penyeimbangan kelas menggunakan teknik SMOTE. Setelah itu, *dataset* dibagi menjadi 70% data latih dan 30% data uji untuk proses pelatihan dan pengujian model. *Naïve Bayes* merupakan algoritma yang cocok untuk digunakan dalam klasifikasi sentimen di media sosial karena efisiensinya dalam memproses teks dalam jumlah besar [12].

Evaluasi Model

Model dievaluasi menggunakan matrik *accuracy*, *precision*, *recall*, dan *F1-score* yang dihitung berdasarkan confusion matrix untuk menilai kinerja klasifikasi sentimen. Metrik-metrik ini digunakan untuk mengukur sejauh mana model dapat melakukan prediksi dengan benar terhadap data uji. Confusion matrix menggambarkan distribusi prediksi model terhadap *label* aktual, yang terdiri dari nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Accuracy merupakan matrik utama yang mengukur proporsi total prediksi yang tepat dari seluruh jumlah data uji. Nilai akurasi diperoleh dari perbandingan antara jumlah prediksi benar (positif dan negatif) terhadap total jumlah data. Persamaan akurasi dituliskan ditunjukkan pada persamaan (1)[13].

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Precision menunjukkan seberapa banyak dari seluruh prediksi positif yang benar-benar relevan atau benar. *Precision* mengukur ketepatan model dalam memprediksi kelas positif. Persamaan untuk mendapatkan nilai *precision* dituliskan pada persamaan (2) [11].

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Recall adalah matrik yang mengukur seberapa banyak data positif yang benar dapat ditemukan oleh model dari seluruh data yang seharusnya berlabel positif. *Recall* penting dalam situasi ketika kesalahan dalam mengabaikan data relevan harus diminimalkan. Persamaan untuk mendapatkan nilai *recall* dituliskan pada persamaan (3) [11].

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

F1-score merupakan rata-rata harmonis dari *precision* dan *recall*. Metrik ini berguna ketika perlu dicapai keseimbangan antara presisi dan sensitivitas, khususnya pada data yang tidak seimbang. Persamaan untuk mendapatkan nilai *F1-score* dituliskan pada persamaan (4)[11].

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

3. HASIL DAN PEMBAHASAN

Deksripsi Dataset

Pengumpulan data yang didapat dari youtube digunakan untuk melatih dan mengukur tingkat akurasi dari hasil opini publik masyarakat mengenai RUU TNI yang

akan menjadi dasar pelatihan pada model yang dikembangkan. Pada *dataset* yang diambil melalui metode *Text Mining*, didapatkan 1000 komen yang ada di Youtube. Seluruh komentar yang didapat akan melalui proses pelabelan secara manual, dimana menghasilkan 781 komentar positif dan 219 komentar negatif. Pada pengujian nya ,akan diberlakukan pembagian data dimana 70% data untuk pelatihan dan 30% untuk pengujian. 300 Data yang didapat dibagi menjadi 237 negatif dan 63 positif.

Pra-processing data

Tahap pra-pemrosesan data dilakukan untuk mengubah komentar yang belum terstruktur dan tidak rapi menjadi komentar yang lebih terstruktur dan rapi. Berikut tahap pra-pemrosesan yang telah dilakukan pada *dataset* dapat dilihat di Tabel 1.

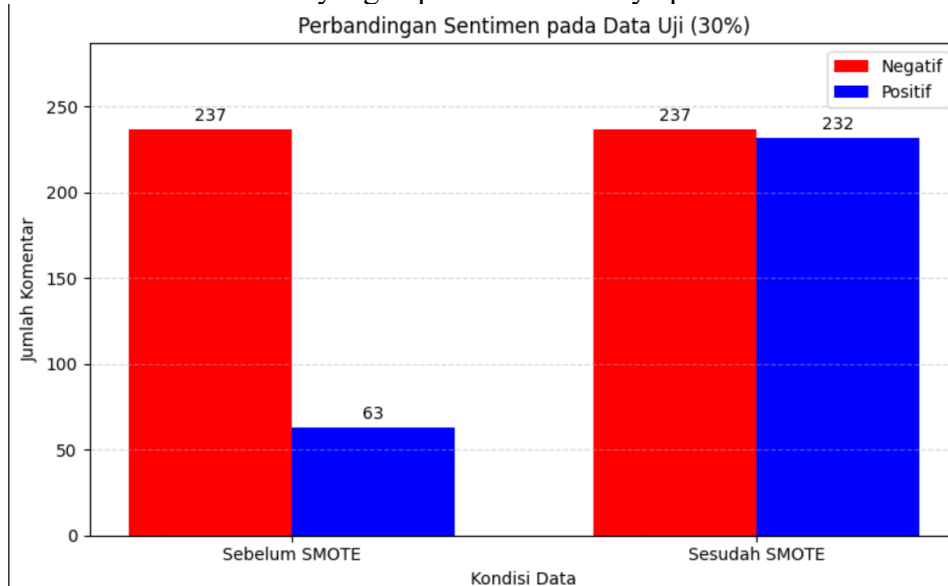
Tabel 1. Tabel pra-processing data

Ulasan	<i>Cleaning</i>	Tokenisasi	<i>StopWord</i>	<i>Stemming</i>	Hasil
Semua pura-pura ga baca kalau komenan seperti ini, apalagi mereka "orang terhormat" yang disono, disana kebanyakan yang "itu tu"	semua purapura ga baca kalau komenan seperti ini apalagi mereka orang yang disono disana kebanyakan yang itu	['semua', 'purapura', 'ga', 'baca', 'kalau', 'komenan', 'seperti', 'ini', 'apalagi', 'mereka', 'orang', 'terhormat', 'disono', 'mereka', 'orang', 'yang', 'disono', 'disana', 'kebanyaka n yang itu tu']	['baca', 'komenan', 'seperti', 'apalagi', 'mereka', 'orang', 'terhormat', 'disono', 'disana', 'kebanyakan']	['baca', 'komen', 'seperti', 'lagi', 'raka', 'orang', 'hormat', 'sono', 'sana', 'banyak']	baca komen seperti lagi raka orang hormat sono sana banyak
Sudah ketuk palu tidak di sahkan oleh sri mulyani ketua DPR, banyak rakyat Indonesia yang bodoh karna itu tidak terlalu banyak yng bergerak hanya adik2 mahasiswa saja yg terus bersuara,	sudah ketuk palu tidak di sahkan oleh sri mulyani ketua dpr banyak rakyat indonesia yang bodoh karna itu indonesia yang bodoh karna itu tidak terlalu banyak yng	['sudah', 'ketuk', 'palu', 'tidak', 'di', 'sahkan', 'oleh', 'sri', 'mulyani', 'ketua', 'dpr', 'banyak', 'rakyat', 'indonesia', 'yang', 'bodoh', 'karna', 'itu', 'indonesia', 'yang', 'bodoh', 'karna', 'itu', 'tidak', 'terlalu', 'banyak', 'yng']	['sudah', 'ketuk', 'palu', 'sahkan', 'sri', 'mulyani', 'ketua', 'dpr', 'rakyat', 'indonesia', 'bodoh', 'karna', 'adik', 'mahasiswa', 'terus', 'bersuara', 'warga', 'biasa', 'ada', 'juta', 'indonesia', 'menggu']	['sudah', 'ketuk', 'palu', 'sah', 'sri', 'mulyani', 'tuwa dpr', 'rakyat indonesia', 'bodoh', 'karna lalu gerak adik mahasisw a seru suara', 'warga biasa ada juta indonesia']	sudah ketuk palu sah sri mulyani tuwa dpr rakyat indonesia bodoh karna lalu gerak adik mahasisw a seru suara warga biasa ada juta indonesia

warga biasa mah ga ada, 280juta warga Indonesia hanya menggu nasib di tangan orang berkuasa	bergerak hanya adik mahasiswa saja yg terus bersuara warga biasa mah ga ada juta warga indonesia hanya menggu nasib di tangan orang berkuasa	'yng', 'bergerak', 'hanya', 'adik', 'mahasiswa', 'saja', 'yg', 'terus', 'bersuara', 'warga', 'biasa', 'mah', 'ga', 'ada', 'juta', 'warga', 'indonesia', 'hanya', 'menggu', 'nasib', 'di', 'tangan', 'orang', 'berkuasa']	'nasib', 'tangan', 'orang', 'berkuasa']	'biasa', 'ada', 'juta', 'indonesia', 'menggu', 'nasib', 'tangan', 'orang', 'kuasa']	menggu nasib tangan orang kuasa
---	--	---	--	--	---

Hasil Opini publik


Setelah menjalani tahap pra-pemrosesan data, dilakukan tahap TF-IDF yang dimana mengubah data tersebut menjadi bentuk numerik. Model yang dilatih dibagi menjadi 70% data latih dan 30% data uji, sehingga dari 1000 data hanya 300 data yang menjadi data uji. Pelatihan model yang diuji sendiri dibagi menjadi 2 yaitu sebelum SMOTE dan sesudah SMOTE yang dapat dilihat hasilnya pada Gambar 2.



Gambar 2. Perbandingan sebelum SMOTE & sesudah SMOTE

Pada data sebelum SMOTE terdapat ketidakseimbangan data yang menunjukkan perbandingan data sebesar 237 : 63 (300 data), yang lebih berat di *label* negatif. Setelah dilakukan SMOTE, terjadi perubahan data yang dimana data menjadi seimbang menjadi

237 : 232. Setelah penyeimbangan data, masuklah ke tahap klasifikasi data menggunakan *Multinomial Naïve Bayes*. Setelah dilakukan klasifikasi data, dilakukan evaluasi model menggunakan *confusion matrix*. *Confusion matrix* yang muncul dibagi menjadi 2 yaitu sebelum SMOTE dan sesudah SMOTE. Pada *confusion matrix* sebelum SMOTE yang dapat dilihat di Gambar 2 menunjukkan hasil $TP = 6$, $TN = 236$, $FN = 57$, $FP = 1$. *Confusion matrix* ini juga menghasilkan akurasi, *precision*, *recall* dan *F1-score* yang ditunjukkan pada Gambar 3.



Gambar 3. *Confusion matrix* sebelum SMOTE

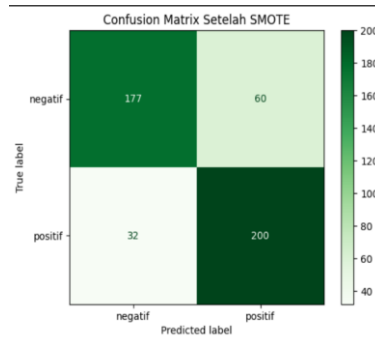
Berdasarkan *confusion matrix* pada gambar 3, didapatkan hasil pada gambar 4.

```

=== Classification Report – Sebelum SMOTE ===
              precision    recall  f1-score   support
negatif         80.55%    99.58%    89.06%     237
positif         85.71%     9.52%    17.14%      63
accuracy                -         -    80.67%     300
macro avg         83.13%    54.55%    53.1%     300
weighted avg         81.63%    80.67%    73.95%     300
    
```

Gambar 4. Hasil perhitungan sebelum SMOTE

Pada gambar 4, hasil perhitungan menunjukkan hasil akurasi yang tinggi yaitu sebesar 80,7%, untuk bagian *label* negatif memiliki data yang tergolong cukup tinggi dimana data *precision* sebesar 80,55%, *recall* 99,58% dan *f1-score* sebesar 89,06%. Tabel positif hanya memiliki *precision* yang cukup tinggi sebesar 85,71%, tetapi memiliki angka *recall* dan *f1-score* yang rendah, hanya sebesar 9,52% dan 17,14%. Pada *confusion matrix* pada gambar 3, didapatkan perubahan dimana $TP = 200$, $TN = 177$, $FP = 60$, dan $FN = 32$.



Gambar 5. *Confusion matrix* setelah SMOTE

Berdasarkan confusion matrix yang didapat pada Gambar 5, maka diperoleh hasil pada Gambar 6.

```

=== Classification Report – Setelah SMOTE ===
              precision    recall  f1-score   support

negatif         84.69%    74.68%    79.37%     237
positif         76.92%    86.21%    81.3%     232
accuracy                -         -    80.38%     469
macro avg         80.81%    80.45%    80.34%     469
weighted avg         80.85%    80.38%    80.33%     469
    
```

Gambar 6. Hasil perhitungan setelah SMOTE

Pada Gambar 6, hasil perhitungan menunjukkan akurasi yang tinggi namun turun dari akurasi sebelum SMOTE yang hanya sebesar 80,38%. Pada *label* negatif sendiri, hasil menunjukkan *precision* sebesar 84,69%, *recall* 74,68%, dan *f1 score* sebesar 79,37%. Sedangkan pada *label* positif menunjukkan *precision* sebesar 76,92%, *recall* 86,21% dan *f1-score* sebesar 81,3%. Hal ini menunjukkan bahwa sebelum SMOTE memiliki akurasi yang lebih besar dibandingkan memakai SMOTE. Hal ini disebabkan oleh data yang tidak seimbang terlalu besar yang mencapai 237 : 63.

Hasil Opini publik

Visualisasi didapatkan dengan menggunakan fitur *WordCloud*, yang menampilkan kumpulan kata-kata dominan dari komentar berdasarkan masing-masing *label* sentimen, yaitu positif dan negatif. *WordCloud* berguna untuk menggambarkan frekuensi kemunculan kata dalam bentuk visual yang intuitif: semakin besar ukuran kata, semakin sering kata tersebut muncul dalam kumpulan komentar. *WordCloud* dapat memberikan informasi mengenai pandangan masyarakat terhadap berita mengenai RUU TNI. *WordCloud* dapat dilihat pada Gambar 7.



Gambar 7. WordCloud label positif dan negatif

4. KESIMPULAN DAN SARAN

Kesimpulan

Hasil penelitian menunjukkan bahwa sebelum SMOTE akurasi yang didapatkan lebih besar dibandingkan setelah SMOTE. Hal ini disebabkan oleh ketidakseimbangan data yang ada sehingga menyebabkan akurasi yang dihasilkan sedikit lebih tinggi tetapi ketimpangan pada *recall* dan *f1-score* antar *label* terlampau jauh. Namun setelah terjadi penyeimbangan data oleh SMOTE, hasil akurasi yang dihasilkan hanya turun sedikit namun terjadi kenaikan yang drastis pada *recall* dan *f1-score* yang dihasilkan oleh *label* positif sehingga ketimpangan antar *label* hanya sedikit berbeda. Maka dari itu, penggunaan metode *Naïve Bayes* yang digabungkan dengan SMOTE lebih direkomendasikan karena meskipun akurasi turun sedikit, model lebih seimbang dan lebih adil terhadap *label* yang ‘minoritas’. Visualisasi menggunakan *WordCloud* sendiri sudah bisa menunjukkan kata-kata yang dominan untuk setiap *label*, sehingga bisa menggambarkan sebagian besar opini masyarakat.

Saran

Berdasarkan hasil yang diperoleh, terdapat beberapa saran yang dapat dijadikan pertimbangan untuk penelitian selanjutnya. Klasifikasi sentimen dapat dikembangkan dengan menambahkan kategori netral agar hasil analisis mencerminkan spektrum opini publik yang lebih lengkap. Penggunaan algoritma lain seperti *Random Forest*, atau *Logistic Regression* juga dapat dibandingkan dengan *Naïve Bayes* untuk memperoleh model klasifikasi yang lebih optimal. Selanjutnya, mengingat keterbatasan metode berbasis TF-IDF dalam memahami konteks dan sarkasme, maka pendekatan berbasis *word embedding* atau *deep learning* seperti BERT dapat dipertimbangkan pada penelitian berikutnya.

5. DAFTAR PUSTAKA

- [1] N. Annisa Murnastiti dan T. Noor Fatyanosa, “Analisis Sentimen Terhadap Makanan Manis di Platform X Menggunakan TF-IDF dan Naive Bayes,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 1, hlm. 2548–964, 2025, [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>

- [2] A. Prayoga Siswono *dkk.*, “Analisis Sentimen Pelantikan Presiden Indonesia 2024 Menggunakan Model Klasifikasi dan Algoritma Naive Bayes,” *CENTIVE*, vol. 4, no. 1, hlm. 1024–1035, 2024.
- [3] R. N. Rahmawaty, A. Pambudi, U. M. Sukabumi, K. Sukabumi, dan J. Barat, “Penerapan Metode Naive Bayes dan Cosine Similarity Dalam Analisis Sentimen Terhadap Platform Film Ilegal di Media Sosial X (Twiter),” *JAMASTIKA*, vol. 3, 2024, doi:10.35473/jamastika.v3i1.3059
- [4] T. Prana, W. Sukma, dan M. R. Pribadi, “Analisis Sentimen Review Pengguna Viu pada Play Store dengan Algoritma Random Forest,” *Journal Of Software Engineering And Computational Intelligence*, vol. 2, no. 1, 2024. doi: 10.36982/jseci.v2i01.4016
- [5] R. Y. Hidayat, “Analisis Dan Klasifikasi Sentimen Terhadap Brand Infinix Tecno dan ITEL Menggunakan Kombinasi Metode Naive Bayes Dan Cosine Similarity,” *JAMASTIKA*, vol. 4, 2025. doi: 10.35473/jamastika.v4i1.368
- [6] P. Ganda Dewata, A. Rizky, dan H. Irsyad, “JURNAL REIN (REKAYASA INFORMATIKA) Analisis Sentimen Terhadap Boikot Produk Israel Menggunakan Algoritma Naive Bayes Dan SMOTE,” *Jurnal Rekayasa Informatika*, vol. 1, no. 1, hlm. 7–15, 2024.
- [7] I. P. Ramayasa, I. G. A. D. Saryanti, I. K. Dharmendra, dan Edwar, “Perbandingan Metode Vektorisasi Pada Analisa Sentiment, Studi Kasus: Cyberbullying Pada Komentar Instagram,” *Jurnal Teknologi Informasi dan Komputer*, vol. 9, no. 5, Okt 2023, doi: 10.36002/JUTIK.V9I5.2645.
- [8] F. Fathoni, A. Ibrahim, F. R. Mumtaz, M. A. Zaky, M. J. Pratama, dan I. A. Kurniawan, “Analisis Sentimen Public Twitter Terhadap Kebijakan Pemerintah Menggunakan Metode SVM (Studi Kasus: RUU TNI)” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 4, hlm. 6322–6329, Mei 2025, doi: 10.36040/JATI.V9I4.14036.
- [9] J. E. Br Sinulingga dan H. C. K. Sitorus, “Analisis Sentimen Opini Masyarakat terhadap Film Horor Indonesia Menggunakan Metode SVM dan TF-IDF,” *Jurnal Manajemen Informatika (JAMIKA)*, vol. 14, no. 1, hlm. 42–53, Feb 2024, doi: 10.34010/jamika.v14i1.11946.
- [10] F. Destiyanti, A. Id Hadiana, F. Rakhmat Umbara, dan U. Jenderal Achmad Yani Jl Terusan Jenderal Jenderal Sudirman, “Penerapan Metode Support Vector Machine dan SMOTE untuk Klasifikasi Sentimen Publik Terhadap Polisi Republik Indonesia,” *Jurnal Masyarakat Informatika Unjani*, vol. 8, no. 1, hlm. 1–15, 2024. doi: 10.25077/teknosi.v9i2.2023.163-172.
- [11] A. F. Anjani, D. Anggraeni, dan I. M. Tirta, “Implementasi Random Forest Menggunakan SMOTE untuk Analisis Sentimen Ulasan Aplikasi Sister for Students UNEJ,” *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 9, no. 2, hlm. 163–172, Sep 2023, doi: 10.25077/teknosi.v9i2.2023.163-172.
- [12] V. Amalia Herlinda, C. Sri Kusuma Aditya, dan D. Rizki Chandranegara, “Analisis Sentimen Masyarakat Terhadap Generasi Z Dalam Dunia Kerja Pada Media Sosial Twitter Menggunakan Metode Naive Bayes,” *REPOSITOR*, vol. 6, no. 4, hlm. 405–414, 2024.
- [13] T. Ramadha Triputra dan A. Rubhasy, “Analisis Sentimen Ulasan Pengguna Aplikasi Facebook Di Google Play Store Menggunakan Algoritma Naive Bayes Dan K-Nearest Neighbor,” *Jurnal Mahasiswa Teknik Informatika*, vol. 9, no. 3, 2025.