

# ANALISIS SENTIMEN 100 HARI KERJA PRESIDEN PRABOWO SUBIANTO MENGGUNAKAN NAIVE BAYES DAN LOGISTIC REGRESSION

Aziz Mujahiddin Nugraha<sup>1\*</sup>, Hari Soetanto<sup>2</sup>

<sup>1,2</sup> Teknik Informatika, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia

Email: <sup>1\*</sup> azizmn03@gmail.com <sup>2</sup> hari.soetanto@budiluhur.ac.id  
(\* : corresponding author)

**Abstrak-** Media sosial dan portal berita *online* telah menjadi *platform* utama bagi masyarakat Indonesia untuk menyuarakan opini, terutama terkait isu politik seperti kinerja pemerintahan. Penelitian ini bertujuan untuk menganalisis sentimen publik terhadap 100 hari kerja pemerintahan Presiden Prabowo Subianto menggunakan data dari media sosial X dan situs media *online* Detik.com. Sebanyak 12.919 data, berupa tweet dan judul berita, yang berasal dari 20 Oktober 2024 hingga 2024. Penelitian ini menerapkan metode *Multinomial Naive Bayes* dan *Multinomial Logistic Regression* untuk mengklasifikasikan sentimen menjadi positif, netral, dan negatif. Proses pengolahan data mencakup *scraping*, *text preprocessing* (*case folding*, *cleaning*, *filtering*, *tokenizing*, *stemming*), pelabelan berbasis *lexicon*, dan TF-IDF. Pengujian dilakukan melalui 12 skenario dengan variasi *SMOTE*, metode pelatihan (*Split 80:20* dan *K-Fold*), serta evaluasi performa model berdasarkan akurasi, *recall*, presisi, dan *F1-score*. Hasil menunjukkan *Multinomial Logistic Regression* menghasilkan akurasi tertinggi yaitu 74% tanpa *SMOTE* dan 75% dengan *SMOTE*, sedangkan *Multinomial Naive Bayes* hanya mencapai akurasi tertinggi 68% tanpa *SMOTE* dan 71% dengan *SMOTE*. Penelitian ini menyimpulkan bahwa *Multinomial Logistic Regression* memiliki akurasi lebih baik dan ditambahkan optimalisasi dengan *SMOTE* meningkatkan *Recall* pada kelas sentimen yang *undersampling*. Hasil ini bisa memberikan wawasan bagi pemangku kebijakan dalam merespons dinamika opini publik di era digital.

**Kata Kunci:** *Multinomial Logistic Regression*, *Multinomial Naive Bayes*, Prabowo

## SENTIMENT ANALYSIS OF 100 DAYS OF PRESIDENT PRABOWO SUBIANTO'S USING NAIVE BAYES AND LOGISTIC REGRESSION

**Abstract-** Social media and online news portals have become the primary platforms for Indonesians to voice their opinions, particularly on political issues such as government performance. This study aims to analyze public sentiment towards the first 100 days of President Prabowo Subianto's administration using data from social media platform X and the online media site Detik.com. A total of 12,919 tweets and news headlines were collected from October 20, 2024, to 2024. This study applies the *Multinomial Naive Bayes* and *Multinomial Logistic Regression* methods to classify sentiment into positive, neutral, and negative. The data processing includes *scraping*, *text preprocessing* (*case folding*, *cleaning*, *filtering*, *tokenizing*, *stemming*), *lexicon-based labeling*, and TF-IDF. Testing was conducted through 12 scenarios with variations of *SMOTE*, training methods (*Split 80:20* and *K-Fold*), and model performance evaluation based on accuracy, recall, precision, and *F1-score*. The results show that *Multinomial Logistic Regression* produces the highest accuracy of 74% without *SMOTE* and 75% with *SMOTE*, while *Multinomial Naive Bayes* only achieves the highest accuracy of 68% without *SMOTE* and 71% with *SMOTE*. This study concludes that *Multinomial Logistic Regression* has better accuracy and that the addition of optimization with *SMOTE* improves *Recall* in *undersampled* sentiment classes. These results can provide insights for policymakers in responding to the dynamics of public opinion in the digital era.

**Keywords:** *Multinomial Logistic Regression*, *Multinomial Naive Bayes*, Prabowo

## 1. PENDAHULUAN

Media sosial telah menjadi salah satu *platform* utama bagi masyarakat untuk mengekspresikan pendapat, berbagi informasi, dan berpartisipasi dalam diskusi publik. Di Indonesia, fenomena ini semakin terlihat jelas, terutama dalam konteks politik, di mana pemilihan umum dan kebijakan pemerintah sering kali menjadi topik hangat yang dibahas di berbagai *platform*. Setelah melewati masa kampanye dan pemilihan yang penuh dinamika, Prabowo Subianto resmi dilantik sebagai Presiden Republik Indonesia pada Oktober 2024. Masa 100 hari pertama kepemimpinan presiden secara tradisional dianggap sebagai periode krusial untuk mengevaluasi kinerja serta indikator arah kebijakan pemerintah ke depan. Periode ini menjadi momentum awal bagi publik untuk mengevaluasi kinerja presiden dalam merealisasikan janji-janji kampanye.

*Platform* Twitter merupakan tempat yang ideal untuk melakukan analisis sentimen karena sifatnya yang dinamis dan terbuka [1]. Selain media sosial, situs media *online* seperti Detik.com juga memegang peran penting dalam membentuk persepsi publik melalui pemberitaan dan kolom komentar pembaca yang menyertai artikel. Dengan demikian, *platform* X dan Detik.com dipilih sebagai objek penelitian karena mewakili dua dimensi pandangan publik yang saling melengkapi, di mana media sosial mencerminkan opini spontan dan tidak terstruktur, sedangkan situs media *online* memberikan konteks yang lebih terarah dan terverifikasi.


Analisis sentimen adalah proses analisis teks untuk mengekstraksi opini dari berbagai sumber, termasuk media sosial, dengan tujuan mengidentifikasi kecenderungan positif, negatif, atau netral dari suatu teks [2]. Dalam konteks politik, analisis sentimen menjadi instrumen penting untuk memahami persepsi masyarakat terhadap kepemimpinan dan kebijakan pemerintah. Masa 100 hari pertama menjadi waktu yang tepat untuk menangkap bagaimana masyarakat menanggapi arah awal kebijakan dan program pemerintah. Tingginya partisipasi masyarakat dalam menyampaikan opini secara terbuka di media sosial membuka peluang besar untuk mengekstraksi informasi terkait polaritas sentimen publik.

Beberapa penelitian sebelumnya telah membahas analisis sentimen terhadap kebijakan pemerintah dengan pendekatan dan metode yang beragam. Penelitian [3] menggunakan aplikasi *RapidMiner* untuk mengklasifikasikan data Twitter, dan hasilnya menunjukkan 81,7% sentimen negatif, 6,6% netral, serta 11,7% positif, dengan tingkat akurasi model sebesar 92,96%. Penelitian oleh [4] menganalisis sentimen publik terhadap wacana pemindahan ibu kota melalui media sosial Twitter. Penelitian ini berhasil mencapai tingkat akurasi sebesar 94,33% dengan klasifikasi dua kelas: positif dan negatif. Penelitian sebelumnya banyak berfokus pada analisis sentimen terkait kebijakan pemerintah menggunakan data media sosial Twitter semata, serta mengandalkan klasifikasi biner (positif dan negatif). Selain itu, metode yang digunakan lebih sederhana dengan dukungan aplikasi seperti *RapidMiner* tanpa melibatkan perbandingan model yang lebih kompleks. Penelitian ini menghadirkan pembaruan dari sisi data dengan menggabungkan dua sumber, yaitu media sosial X dan portal berita *online* Detik.com, serta klasifikasi tiga kelas sentimen (positif, netral, negatif) yang memberikan gambaran lebih komprehensif. Dari sisi metode, penelitian ini membandingkan dua algoritma yaitu *Multinomial Naive Bayes* dan *Multinomial Logistic Regression*, yang sebelumnya belum banyak dieksplorasi secara bersamaan pada kasus politik di Indonesia. Pada tahap pengujian, penelitian ini tidak hanya menggunakan split data tradisional, tetapi juga menerapkan *K-Fold cross validation* serta optimalisasi data melalui *SMOTE* untuk menangani *imbalance class*, sehingga menghasilkan evaluasi performa model yang lebih *robust* dibandingkan penelitian terdahulu.

Berdasarkan berbagai temuan tersebut, penelitian ini bertujuan untuk menganalisis sentimen publik terhadap 100 hari pertama pemerintahan Presiden Prabowo Subianto melalui data media sosial dan media online. Hasil penelitian diharapkan dapat memberikan wawasan yang lebih komprehensif mengenai opini publik di era digital sekaligus menjadi rujukan bagi pemangku kebijakan dan akademisi dalam memahami dinamika persepsi masyarakat.

## 2. METODE PENELITIAN

Metode penelitian merupakan tahapan penting dalam menjelaskan secara detail bagaimana metode yang telah dipilih akan diterapkan. Dalam penelitian ini untuk membangun sistem analisis sentimen terdapat beberapa tahapan. Pada Gambar 1 berisi tahapan metodologi penelitian tersebut.



Gambar 1. Metodologi Penelitian

### 2.1 Pengumpulan Data

Pengumpulan data atau *Scraping* data adalah sebuah teknik untuk mengumpulkan data dari internet dan menyimpannya untuk proses analisis atau penggunaan lebih lanjut. *Scraping* data bisa melalui *Application Programming Interface (API)* untuk mengambil data dari *server* yang dituju [3]. Dalam penelitian ini proses pengumpulan data dilakukan pada platform media sosial X dan situs media *online* Detik.com. Proses pengumpulan data pada media sosial X membutuhkan *Auth Token* dari media sosial X yang dapat di proses menggunakan library *Harvest* pada bahasa pemrograman python dengan memasukkan kata kunci yang digunakan yaitu “Prabowo” dan “Pemerintah” untuk mencari data yang relevan dengan rentang waktu 20 Oktober 2024 sampai 28 Januari 2025.

Untuk pengumpulan data pada situs media *online* Detik.com, data diambil melalui Protokol *Transfer Hiperteks (HTTP)*. Proses pengumpulan data pada portal berita dimulai dengan mengidentifikasi tag *HTML* yang pada informasi yang diinginkan lalu aplikasi *web scrapper* dikembangkan untuk otomatisasi proses pengambilan informasi dari situs web.

## 2.2 Preprocessing Data

*Preprocessing* adalah bagian penting dari proses analisis sentimen. Menurut [2] *Text Preprocessing* adalah tahap awal dari proses *text mining*. Dalam proses ini mencakup persiapan data yang akan digunakan pada proses *text mining*. Dengan proses *text preprocessing* ini akan terbentuk *dataset* yang bersih dan akan memudahkan dalam proses selanjutnya karena data masukan berubah menjadi format yang sesuai dan siap untuk diproses. Tahapan *text preprocessing* meliputi:

- a *Casefolding*, seperti pengertian dari [5] Tahapan *casefolding* merupakan tahap untuk mengkonversi huruf kapital pada teks ulasan ke dalam huruf kecil. Tahapan ini bertujuan supaya dokumen teks ulasan memiliki bentuk standar.
- b *Cleaning*, proses ini didefinisikan oleh [3] sebagai salah satu tahapan dalam *preprocessing* data, dimana tahapan ini berfungsi untuk membersihkan data seperti menghapus data duplikat, menghapus data kosong, menghapus karakter maupun tanda baca, menghapus *Uniform Resource Locator (URL)*, menghapus *HyperText Markup Language (HTML)*, serta menghapus *emoticon* dan *mention* yang tidak relevan. Dalam proses ini juga dilakukan perubahan kata tidak baku menjadi kata baku (*slangword*).
- c *Filtering*, menurut [3] *Stopword* atau *filtering* merupakan proses untuk menghapus kata-kata tidak penting yang terdapat di dalam daftar *stopword*, sehingga kata-kata tersebut tidak akan ada di dalam analisis teks.
- d Tokenisasi, dalam tahap ini kata-kata yang telah melewati proses sebelumnya akan dijadikan bentuk potongan kata tunggal. Pengertian kata dalam dokumen yang dimaksud menurut [5] adalah kata yang dipisah oleh spasi.
- e *Stemming*, menurut [5] *stemming* adalah suatu proses yang dilakukan untuk mengubah kata yang terdapat dalam suatu dokumen ke dalam kata dasar dengan menggunakan aturan tertentu.

## 2.3 Labelling Data

*Labelling* atau pelabelan data adalah proses penamaan atau melabel data kedalam sebuah kelas yang telah [2]. Proses *labelling* bisa dilakukan secara otomatis dengan metode *lexicon* dengan *InSet* atau Indonesia *Sentiment Lexicon* yang diriset oleh [6], dimana pada metode ini menggunakan list kata yang telah diurutkan dengan skala dari negatif sampai positif. Metode ini akan menghitung jumlah kata pada suatu kalimat dan dihitung sesuai skala yang telah diatur pada *list* kata dimulai dari -5 untuk kata paling negatif sampai +5 sebagai skala kata paling positif. Kata negatif akan mengurangi nilai dan kata positif akan menambahkan nilai, total nilai itulah yang akan menentukan label tersebut positif, negatif, atau netral. Hasil *labelling* diberikan kepada pakar, dimana pada penelitian ini adalah dosen bahasa sekaligus dosen prodi Kriminologi Universitas Budi Luhur. Pakar melakukan verifikasi dengan melihat hasil *labelling* otomatis dan memberikan persetujuan bahwa data telah siap digunakan untuk proses klasifikasi.

## 2.4 Optimasi SMOTE

Menurut [7] Ketidak seimbangan kelas terjadi ketika jumlah sampel dalam satu kelas jauh lebih besar atau lebih kecil dibandingkan dengan kelas lainnya. Pada penelitian [3] melakukan perbandingan antara akurasi model yang menggunakan optimasi *SMOTE* dan tidak. *SMOTE* adalah salah satu teknik untuk mengambil sebuah sampel data dengan jumlah klasifikasi terendah sehingga dapat membuat keseimbangan dengan jumlah klasifikasi tertinggi dalam suatu data [3]. Optimasi ini bisa membantu pelatihan model jika kelas pada data memiliki ketidakseimbangan kelas.

## 2.5 Ekstraksi Fitur

Setelah data melalui proses *preprocessing* hingga pelabelan data, ada proses yang memiliki fungsi penting untuk mengukur pentingnya sebuah kata dalam sebuah dokumen. Pembobotan kata yang sering dijumpai untuk ekstraksi fitur dalam analisis sentimen adalah *TF-IDF*, *Count Vectorizer*, dan *Bag of N-Grams*. Hasil dari pembobotan kata ini akan digunakan untuk melatih model analisis sentimen yang memungkinkan klasifikasi data ke dalam kategori negatif, netral, dan positif berdasarkan kemunculan kata-kata yang relevan dalam teks [8]. Untuk metode *TF-IDF* menurut [2] adalah metode untuk menghitung setiap kata yang paling umum digunakan untuk

pemberian bobot kata pada setiap dokumen yang akan mencerminkan betapa pentingnya sebuah kata pada dokumen. *Term Frequency-Invers Document Frequency* (TF-IDF) merupakan sebuah teknik pembobotan yang paling sering digunakan. Berikut adalah persamaan TF-IDF [9]. Pada metode ini terdapat beberapa perhitungan TF, seperti pada penelitian [10] disebutkan TF memiliki beberapa jenis perhitungan yaitu *Natural TF*, *Normalization TF*, *Logaritma TF* atau *Subliner TF*, dan *Boolean TF*. Pada perbandingan perhitungan TF ini dapat diketahui bahwa perhitungan *Logaritma TF* adalah jenis perhitungan TF terbaik untuk kombinasi dengan IDF.

$$tf_{i,j} = \frac{\text{Jumlah kemunculan kata } i \text{ dalam dokumen } j}{\text{Jumlah total kata dalam dokumen } j} \quad (1)$$

$$\text{Log } tf = 1 + \log (tf) \quad (2)$$

$$idf = \log \left( \frac{N}{df_i} \right) \quad (3)$$

$$TfIdf_{i,j} = tf_{i,j} \times idf \quad (4)$$

## 2.6 Klasifikasi

Analisis sentimen adalah suatu ilmu pengetahuan yang digunakan untuk mengetahui kecenderungan pendapat individu atau masyarakat, biasanya melalui tulisan atau komentar [3]. Menurut [7] Analisis sentimen, atau yang juga dikenal sebagai penambangan opini, merupakan bidang studi yang menyelidiki pandangan, sentimen, evaluasi, penilaian, sikap, dan emosi terhadap entitas seperti produk, layanan, organisasi, individu, masalah, peristiwa, topik, dan atribut yang terkait. Analisis sentimen dapat mengekstrak informasi penting dari data yang tidak terstruktur, informasi berupa pendapat dapat dikelompokkan ke dalam kelas sentimen positif, netral atau negatif. Pengelompokan kelas sentimen dapat dilakukan dengan melakukan klasifikasi teks.

a. Dalam konteks analisis sentimen, *Naive Bayes* bekerja dengan mengklasifikasikan teks ke dalam kategori sentimen berdasarkan probabilitas kemunculan kata-kata tertentu dalam dokumen dan statistik yang berasal dari *teorema bayes* [3]. Kemampuan *Naive Bayes* dalam mengelola data memiliki kecepatan komputasi yang tinggi, sehingga sangat ideal digunakan pada pengolahan data secara real-time atau aplikasi yang menuntut respons yang cepat. Selain itu, *Naive Bayes* juga cukup tangguh terhadap keberadaan variabel-variabel yang kurang relevan dalam proses klasifikasi. Saat menerapkan *Naive Bayes* dengan *Python* atau bahasa pemrograman lain, memahami asumsi serta keterbatasan algoritma ini sangat penting agar penggunaannya dapat dioptimalkan dan hasil yang diperoleh dapat diinterpretasikan secara tepat. *Naive Bayes* memiliki rumus *Teorema Bayes*, seperti ini:

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)} \quad (5)$$

b. *Multinomial Logistic Regression* juga dikenal sebagai *Softmax Regression* merupakan sebuah pendekatan pembelajaran mesin untuk mengklasifikasikan satu kelas vektor fitur dari beberapa kelas [9]. Berbeda dengan regresi logistik biner yang hanya menangani dua kategori (misalnya, positif atau negatif), regresi logistik multinomial cocok untuk analisis sentimen yang mengklasifikasikan teks ke dalam kategori seperti positif, netral, dan negatif. Pendekatan ini bekerja dengan menghitung probabilitas setiap kategori menggunakan fungsi softmax, yang menormalkan skor dari vektor fitur untuk menghasilkan distribusi probabilitas di seluruh kelas, menjadikannya alat yang sangat relevan untuk analisis sentimen.

$$\text{softmax} (z^{(i)}) = \frac{e^{z^{(i)}}}{\sum_{j=0}^k e^{z_j}} \quad (6)$$

## 2.7 Evaluasi

Salah satu evaluasi model yang digunakan dalam *machine learning* adalah *confusion matrix*. Setiap unsur matriks menunjukkan jumlah contoh data uji untuk kelas sebenarnya yang digambarkan dalam bentuk baris sedangkan kolom menggambarkan kelas yang di prediksi [2]. Tabel *confusion matrix* dapat dilihat pada Tabel 1.

**Tabel 1.** *Confusion Matrix*

Aktual	Prediksi		
	Negatif	Netral	Positif
Negatif	TNeg	FNegNet	FNegPos
Netral	FNetNeg	TNet	FNetPos
Positif	FPosNeg	FPosNet	TPos

Keterangan:

- TNeg (*True Negatif*) = Jumlah data yang sebenarnya berlabel Negatif dan diprediksi oleh model sebagai Negatif.
- TNet (*True Netral*) = Jumlah data yang sebenarnya berlabel Netral dan diprediksi oleh model sebagai Netral.
- TPos (*True Positif*) = Jumlah data yang sebenarnya berlabel Positif dan diprediksi oleh model sebagai Positif.
- FNegNet (*False Negatif-Netral*) = Jumlah data yang sebenarnya berlabel Negatif tetapi diprediksi oleh model sebagai Netral.
- FNegPos (*False Negatif-Positif*) = Jumlah data yang sebenarnya berlabel Negatif tetapi diprediksi oleh model sebagai Positif.
- FNetNeg (*False Netral-Negatif*) = Jumlah data yang sebenarnya berlabel Netral tetapi diprediksi oleh model sebagai Negatif.
- FNetPos (*False Netral-Positif*) = Jumlah data yang sebenarnya berlabel Netral tetapi diprediksi oleh model sebagai Positif.
- FPosNeg (*False Positif-Negatif*) = Jumlah data yang sebenarnya berlabel Positif tetapi diprediksi oleh model sebagai Negatif.
- FPosNet (*False Positif-Netral*) = Jumlah data yang sebenarnya berlabel Positif tetapi diprediksi oleh model sebagai Netral.

Dari hasil *confusion matrix* dapat diketahui rumus untuk menghitung akurasi, *precision*, dan *recall*, hasil tersebut bisa menjadi alat ukur untuk bagaimana performa model yang telah dilatih.

- Accuracy* menunjukkan seberapa akurat model dalam mengklasifikasikan dengan benar dari tiap kelas.

$$\frac{TPos + TNeg + TNet}{Total\ Data} \times 100\% \quad (7)$$

- Precision (Pre)* menunjukkan hasil perhitungan tingkat ketepatan antara jawaban model dan informasi yang diminta.

$$Pre(Pos) = \frac{TPos}{TPos + FNegPos + FNetPos} \times 100\% \quad (8)$$

$$Pre(Neg) = \frac{TNeg}{TNeg + FNegPos + FNetNeg} \times 100\% \quad (9)$$

$$Pre(Net) = \frac{TNet}{TNet + FPosNet + FNegNet} \times 100\% \quad (10)$$

- Recall (Rec)* menunjukkan hasil perhitungan untuk tingkat ketepatan antara informasi yang diminta dengan jawaban yang diberikan oleh model.

$$Rec(Pos) = \frac{TPos}{TPos + FPosNeg + FPosNet} \times 100\% \quad (11)$$

$$Rec(Neg) = \frac{TNeg}{TNeg + FNegPos + FNegNet} \times 100\% \quad (12)$$

$$Rec(Net) = \frac{TNet}{TNet + FNetPos + FNetNeg} \times 100\% \quad (13)$$

### 3. HASIL DAN PEMBAHASAN

Hasil dan pembahasan berdasarkan implementasi metode yang telah dilakukan pada penelitian ini dalam beberapa tahapan utama yaitu tahapan Pengumpulan data, tahap *preprocessing*, tahap *labelling* data, tahap ekstraksi fitur TF-IDF, tahap pengujian atau klasifikasi, sampai dengan tahap evaluasi. Pada proses ini juga akan dilakukan optimasi *SMOTE* untuk proses klasifikasi.

#### 3.1 Tahap Pengumpulan Data

Pada penelitian ini data dikumpulkan dari *website* media detik.com dan sosial media X. Pada proses pengumpulan data ini dilakukan secara otomatis dan efisien menggunakan *Google Collab*, dengan bahasa pemrograman *Python* dan *library beautifulsoup* untuk mengambil data dari *website* detik.com dan *library tweet-harvest* untuk mengambil data dari sosial media X. Data pada penelitian ini adalah hasil dari *scraping* media sosial X dan judul media *online* detik.com dengan periode waktu 100 hari, mulai 20 Oktober 2024 sampai 28 Januari 2025 dengan menggunakan kata kunci “Prabowo” dan “pemerintah” berjumlah 12919 data.

**Tabel 2.** Sampel Data

No	<i>full_text</i>
1	Wamen PKP Bicara soal Program 3 Juta Rumah Prabowo
2	Prabowo Tegaskan Segaris dengan Malaysia Dukung Kemerdekaan Palestina
3	Prabowo dan Anwar Ibrahim Sepakat Tertibkan Masalah Tenaga Kerja
4	Video Djarot Optimistis Megawati-Prabowo Akan Bertemu: Saya Yakin Terwujud

#### 3.2 Tahap *Preprocessing* Data

Serangkaian langkah atau teknik yang diterapkan pada dataset yang diperoleh melalui *web scraping* akan menjalani tahapan *preprocessing* sebelum masuk ke tahap analisis atau pemrosesan lebih lanjut. Pada tahap *preprocessing* data ini akan dilakukan beberapa tahapan untuk membersihkan dan menormalisasi data yang telah diambil pada tahap pengumpulan data sebelumnya. Langkah-langkah pada tahap *preprocessing* data ini diantaranya adalah *casefolding*, *cleaning*, *filtering*, tokenisasi, dan *stemming*.

**Tabel 3.** Hasil *Preprocessing*

<i>id</i>	<i>full_text</i>	<i>Stemming</i>
1	Wamen PKP Bicara soal Program 3 Juta Rumah Prabowo	[wamen], [pkp], [bicara], [program], [juta], [rumah], [prabowo]
2	Prabowo Tegaskan Segaris dengan Malaysia Dukung Kemerdekaan Palestina	[prabowo], [tegas], [segar], [malaysia], [dukung], [merdeka], [palestina]
3	Prabowo dan Anwar Ibrahim Sepakat Tertibkan Masalah Tenaga Kerja	[Prabowo], [anwar], [ibrahim], [sepakat], [tertib], [tenaga], [kerja]
4	Video Djarot Optimistis Megawati-Prabowo Akan Bertemu: Saya Yakin Terwujud	[video], [djarot], [optimistis], [megawati], [Prabowo], [temu], [wujud]

#### 3.3 Tahap *Labelling* Data

Setelah proses *preprocessing*, dataset harus diberikan label sentimen untuk proses klasifikasi selanjutnya. Proses *labelling* akan dilakukan secara otomatis dengan menggunakan kamus *InSet Lexicon* dengan nilai -5 sampai -1 adalah kata negatif dan 1 sampai 5 adalah kata positif. Untuk proses *labelling* telah diberikan kepada pakar, dimana pada penelitian ini adalah dosen bahasa sekaligus dosen prodi Kriminologi Universitas Budi Luhur. Pakar melakukan verifikasi dengan melihat hasil *labelling* otomatis dan memberikan input dan persetujuan bahwa data telah siap digunakan untuk proses klasifikasi. Untuk hasil *labelling* menghasilkan seperti berikut

**Tabel 4.** Hasil *Labelling*

<i>id</i>	<i>Stemming</i>	<i>sentiment</i>
1	[wamen], [pkp], [bicara], [program], [juta], [rumah], [prabowo]	positif
2	[prabowo], [tegas], [segar], [malaysia], [dukung], [merdeka], [palestina]	positif

<i>id</i>	<i>Stemming</i>	<i>sentiment</i>
3	[Prabowo], [anwar], [ibrahim], [sepakat], [tertib], [tenaga], [kerja]	positif
4	[video], [djarot], [optimistis], [megawati], [Prabowo], [temu], [wujud]	positif

Hasil *labelling* menghasilkan 3 kelas yaitu positif, negatif, dan positif dengan distribusi kelas sentimen sebagai berikut

**Tabel 5. Distribusi Kelas**

Sentimen	Jumlah
negatif	7910
positif	2731
netral	1513
Total	12154

Dari hasil *labelling* bisa terlihat adanya ketidakseimbangan kelas sentimen. Kelas sentimen negatif memiliki jumlah lebih banyak melebihi 2 kali lipat dibanding kelas sentimen positif, dan kelas sentimen netral.

### 3.4 Tahap Optimasi *SMOTE*

Dari hasil *labelling* bisa terlihat adanya ketidakseimbangan kelas sentimen dimana kelas negatif memiliki jumlah sentimen hampir 7 kali lipat dari kelas sentimen terendah. Karena hal tersebut optimasi *SMOTE* dibutuhkan, untuk menangani ketidakseimbangan data tersebut supaya model dapat melakukan pelatihan dengan optimal dengan adanya distribusi kelas yang merata. *SMOTE* bekerja dengan cara menghasilkan data sintesis baru pada kelas minoritas, bukan sekadar menduplikasi data yang sudah ada. *SMOTE* membentuk titik data baru yang berada di antara sampel minoritas dengan tetangga terdekatnya, sehingga variasi data pada kelas minoritas menjadi lebih kaya. Dengan demikian, penerapan *SMOTE* pada penelitian ini bertujuan untuk menyeimbangkan distribusi kelas, mengurangi bias model terhadap kelas mayoritas, serta meningkatkan performa klasifikasi, khususnya dalam mengenali kelas dengan jumlah data yang lebih sedikit.

### 3.5 Tahap Ekstraksi Fitur

Pada proses perhitungan TF-IDF ini akan melakukan perhitungan tiap kata melalui perhitungan TF, IDF, dan TF-IDF. Proses TF-IDF ini digunakan karena data harus diubah dari data teks mentah menjadi fitur dengan cara menghitung bobot perkata dari seluruh dokumen data yang nantinya fitur tersebut dapat digunakan oleh model pembelajaran mesin. Proses ini akan menghitung TF dengan rumus  $\text{Log TF}$ ,  $\text{DF}$ ,  $\text{IDF}$  dengan *smoothing*, dan menghitung ranking TF-IDF ke seluruh dokumen untuk penentuan fitur.

Hasil TF-IDF(Top Terms)

	term	TF-IDF	TF_avg	DF	IDF
0	prabowo	8612.6643	1.0475	3804	2.1614
1	perintah	7628.9329	1.0578	3011	2.3951
2	presiden	4612.5572	1.1076	1282	3.2485
3	rakyat	4220.9377	1.1347	1091	3.4097
4	indonesia	3725.5643	1.0731	990	3.5068
5	ya	3519.9287	1.0738	914	3.5866
6	kerja	3060.1043	1.1346	700	3.853
7	orang	3053.5071	1.1358	697	3.8573
8	negara	2941.2113	1.1034	689	3.8688
9	jokowi	2433.8545	1.1117	530	4.1307

Gambar 2. Hasil TF-IDF

### 3.6 Pengujian dan Evaluasi

Dalam penelitian ini, skenario pengujian dibedakan berdasarkan tiga aspek, yaitu penggunaan *SMOTE*, model klasifikasi, dan strategi pelatihan data. Skenario 1–3 menggunakan *Naive Bayes* tanpa *SMOTE* dengan pembagian *data split* 80:20, *k-fold* 5, dan *k-fold* 15, sementara skenario 4–6 menggunakan *Multinomial Logistic Regression* tanpa *SMOTE* dengan pola pembagian data yang sama. Pada skenario 7–9, *SMOTE* diterapkan untuk

menyeimbangkan kelas sebelum pelatihan dengan *Naive Bayes*, sedangkan skenario 10–12 menerapkan *SMOTE* pada *Multinomial Logistic Regression*, juga dengan variasi *split* 80:20, *k-fold* 5, dan *k-fold* 15. Perbedaan utama antar skenario terletak pada ada tidaknya *SMOTE*, jenis model yang digunakan, serta strategi pembagian data, sehingga memungkinkan analisis perbandingan performa secara menyeluruh. Hasil pengujian akan menghasilkan *confusion matrix* untuk mendapatkan nilai akurasi, *precision*, *F1-score* dan *recall*.

**Tabel 6.** Skenario Pengujian

No.	TF-IDF	Model	Pelatihan
1	Tanpa SMOTE	<i>Naive Bayes</i>	Split 80:20
2	Tanpa SMOTE	<i>Naive Bayes</i>	K-Fold 5
3	Tanpa SMOTE	<i>Naive Bayes</i>	K-Fold 15
4	Tanpa SMOTE	<i>Multinomial Logistic Regression</i>	Split 80:20
5	Tanpa SMOTE	<i>Multinomial Logistic Regression</i>	K-Fold 5
6	Tanpa SMOTE	<i>Multinomial Logistic Regression</i>	K-Fold 15
7	Dengan SMOTE	<i>Naive Bayes</i>	Split 80:20
8	Dengan SMOTE	<i>Naive Bayes</i>	K-Fold 5
9	Dengan SMOTE	<i>Naive Bayes</i>	K-Fold 15
10	Dengan SMOTE	<i>Multinomial Logistic Regression</i>	Split 80:20
11	Dengan SMOTE	<i>Multinomial Logistic Regression</i>	K-Fold 5
12	Dengan SMOTE	<i>Multinomial Logistic Regression</i>	K-Fold 15

a. Skenario 1

**Tabel 7.** Hasil Skenario 1

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		59%	58%	58%
Netral	68%	30%	26%	28%
Negatif		78%	81%	79%

Performa terbaik pada kelas Negatif, tetapi kelas Netral memiliki *recall* dan *precision* rendah, menunjukkan kesulitan dalam mengklasifikasikan data netral.

b. Skenario 2

**Tabel 8.** Hasil Skenario 2

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		58%	57%	57%
Netral	68%	32%	27%	29%
Negatif		78%	82%	79%

Akurasi masih sama dengan skenario 1, kelas Netral tetap bermasalah dengan *recall* dan *precision* rendah, dan performa kelas Negatif konsisten kuat, sedangkan kelas Positif sedikit menurun.

c. Skenario 3

**Tabel 9.** Hasil Skenario 3

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		59%	57%	58%
Netral	68%	33%	27%	30%
Negatif		78%	82%	80%

Performa serupa dengan skenario 1, dengan sedikit peningkatan pada *recall* kelas Netral.

d. Skenario 4

**Tabel 10.** Hasil Skenario 4

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		48%	79%	60%
Netral	74%	2%	35%	4%
Negatif		96%	73%	83%

Akurasi lebih tinggi dibandingkan *Naive Bayes*, tetapi performa sangat buruk pada kelas Netral yang ditunjukkan dengan *recall* hanya mencapai 2% dan *F1-Score* hanya mencapai 4%, menunjukkan ketidakseimbangan dalam klasifikasi.

e. Skenario 5

**Tabel 11.** Hasil Skenario 5

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		69%	72%	70%
Netral	71%	67%	69%	68%
Negatif		76%	71%	73%

Performa lebih seimbang di semua kelas dibandingkan tanpa *SMOTE*, dengan peningkatan signifikan pada kelas Netral. Akurasi terlihat meningkat dibanding akurasi pada skenario 7.

f. Skenario 6

**Tabel 12.** Hasil Skenario 6

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		69%	71%	70%
Netral	70%	63%	69%	66%
Negatif		76%	70%	72%

Performa hampir serupa dengan skenario sebelumnya, dengan kelas Netral menunjukkan peningkatan dibandingkan tanpa *SMOTE*.

g. Skenario 7

**Tabel 13.** Hasil Skenario 7

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		72%	76%	74%
Netral	75%	80%	69%	74%
Negatif		71%	81%	76%

*SMOTE* meningkatkan performa kelas Netral secara signifikan dibandingkan tanpa *SMOTE*, dengan akurasi keseluruhan yang kompetitif dibanding dengan skenario lain.

h. Skenario 8

**Tabel 14.** Hasil Skenario 8

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		72%	76%	74%
Netral	75%	81%	69%	74%
Negatif		72%	82%	77%

Performa seimbang di semua kelas, dengan *recall* kelas Netral yang sangat baik berkat *SMOTE*.

i. Skenario 9

**Tabel 15.** Hasil Skenario 9

Sentimen	Akurasi	<i>Recall</i>	<i>Precision</i>	<i>F1-Score</i>
Positif		72%	76%	74%
Netral	75%	81%	69%	74%
Negatif		71%	82%	76%

Performa konsisten dengan skenario sebelumnya, dengan *SMOTE* membantu menyeimbangkan klasifikasi kelas Netral.

#### 4. KESIMPULAN

Berdasarkan hasil analisis sentimen terhadap 100 hari kerja pemerintahan Presiden Prabowo Subianto menggunakan data dari sosial media X dan situs media *online* Detik.com menggunakan metode *Naive Bayes* dan *Multinomial Logistic Regression*, penelitian ini menyimpulkan bahwa sistem yang dikembangkan berhasil mengintegrasikan proses pengumpulan data, *preprocessing*, *labelling* data, pembobotan atau ekstraksi fitur TF-IDF, dan klasifikasi menggunakan *Multinomial Naive Bayes* serta *Multinomial Logistic Regression*. Pada hasil pelatihan model dapat disimpulkan bahwa metode klasifikasi *Naive Bayes* dan *Multinomial Logistic Regression* dapat digunakan untuk mengidentifikasi sentimen publik. Dengan hasil akurasi *Multinomial Logistic Regression* lebih baik dibandingkan *Naive Bayes*, dengan catatan hasil *recall* kelas netral dari *Multinomial Logistic Regression* memiliki hasil lebih rendah dibandingkan *Naive Bayes* karena ketidakseimbangan data pada kelas netral. Penerapan *SMOTE* secara signifikan meningkatkan performa kelas Netral terutama pada *Multinomial Logistic Regression* dengan *recall* mencapai 80 sampai 81%. Secara keseluruhan *Multinomial Logistic Regression* menghasilkan akurasi lebih tinggi, yaitu 74 sampai 75%, dibandingkan *Naive Bayes* dengan akurasi 67 sampai 71% saat dikombinasikan dengan *SMOTE* dan metode pelatihan *K-Fold*. *Naive Bayes* tanpa *SMOTE* memiliki *recall* kelas Netral lebih baik dibandingkan *Multinomial Logistic Regression*. Hasil ini menegaskan bahwa pendekatan yang seimbang dalam distribusi data dengan *SMOTE* dan pemilihan model *Multinomial Logistic Regression* dapat meningkatkan akurasi dan keandalan analisis sentimen.

#### DAFTAR PUSTAKA

- [1] A. Kaharudin, A. Agus Supriyadi, H. Baitika, And M. Derryanur, "Oktal : Jurnal Ilmu Komputer Dan Science Analisis Sentimen Pada Media Sosial Dengan Teknik Kecerdasan Buatan Naive Bayes: Kajian Literatur Review," Vol. 2, No. 6, 2023, [Online]. Available: <https://Harzing.Com/Resources/Publish-Or-Perish>
- [2] R. Prabowo, H. Sujaini, And T. Rismawan, "Analisis Sentimen Pengguna Twitter Terhadap Kasus Covid-19 Di Indonesia Menggunakan Metode Regresi Logistik Multinomial," *Jurnal Sistem Dan Teknologi Informasi (Justin)*, Vol. 11, No. 1, P. 85, Jan. 2023, Doi: 10.26418/Justin.V11i1.57450.
- [3] B. Ramadhani And R. R. Suryono, "Komparasi Algoritma Naive Bayes Dan Logistic Regression Untuk Analisis Sentimen Metaverse," *Jurnal Media Informatika Budidarma*, Vol. 8, No. 2, P. 714, Apr. 2024, Doi: 10.30865/Mib.V8i2.7458.
- [4] P. Arsi, B. A. Kusuma, And A. Nurhakim, "Analisis Sentimen Pindah Ibu Kota Berbasis Naive Bayes Classifier," *Jurnal Informatika Upgris*, Vol. 7, Jun. 2021.
- [5] Z. Firmansyah And N. F. Puspitasari, "Analisis Sentimen Masyarakat Terhadap Vaksinasi Covid-19 Berdasarkan Opini Pada Twitter Menggunakan Algoritma Naive Bayes," *Jurnal Teknik Informatika*, Vol. 14, No. 2, 2021, Doi: 10.15408/Jti.V14i2.24024.
- [6] F. Koto And G. Y. Rahmaningtyas, "Inset Lexicon: Evaluation Of A Word List For Indonesian Sentiment Analysis In Microblogs," In *Proceedings Of The 2017 International Conference On Asian Language Processing, Ialp 2017*, Institute Of Electrical And Electronics Engineers Inc., Jul. 2017, Pp. 391–394. Doi: 10.1109/Ialp.2017.8300625.
- [7] A. Karimah And G. Dwilestari, "Analisis Sentimen Komentar Video Mobil Listrik Di Platform Youtube Dengan Metode Naive Bayes," *Jurnal Mahasiswa Teknik Informatika*, Vol. 8, No. 1, Pp. 767–773, Feb. 2024.
- [8] R. Saputra And F. N. Hasan, "Analisis Sentimen Terhadap Program Makan Siang & Susu Gratis Menggunakan Algoritma Naive Bayes," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, Vol. 6, No. 3, Pp. 411–419, Jul. 2024, Doi: 10.47233/Jteksis.V6i3.1378.
- [9] M. Naufal Rizaldi And S. Al Faraby, "Jurnal Media Informatika Budidarma Klasifikasi Argument Pada Teks Dengan Menggunakan Metode Multinomial Logistic Regression Terhadap Kasus Pemandangan Ibu Kota Indonesia Di Twitter," Vol. 4, Oct. 2020, Doi: 10.30865/Mib.V4i4.2348.
- [10] I. P. Suputra, K. D. Prebiana, And F. O. Gorianto, "Perbandingan Jenis Tf Terhadap Hasil Evaluasi Information Retrieval," Vol. 8, Nov. 2019.