

## Komparasi Naïve Bayes dan SVM Analisis Sentimen RUU Kesehatan di Twitter

Tetrian Widyanto<sup>1</sup>, Ina Ristiana<sup>2</sup>, Arief Wibowo<sup>3</sup>

<sup>123</sup>Magister Ilmu Komputer, Universitas Budi Luhur  
Jl. Ciledug Raya, Petukangan Utara, Kec. Pesanggrahan, Jakarta Selatan, DKI Jakarta, Indonesia

2211600602@student.budiluhur.ac.id<sup>1</sup>, 2211601428@student.budiluhur.ac.id<sup>2</sup>,  
arief.wibowo@budiluhur.ac.id<sup>3</sup>

Received : October, 2023

Accepted : December, 2023

Published : Desember, 2023

### Abstract

*This research focuses on sentiment analysis regarding the plan to ratify the Health Bill which has become a hot topic of conversation on social media, especially Twitter. This research aims to classify tweets that reflect various opinions regarding the Health Bill, including support, rejection and neutrality. In this research, the author uses two types of classification algorithms, namely the Multinomial Naïve Bayes Algorithm and the Support Vector Machine (SVM) Algorithm. Previously, tweets were labelled using the Lexicon InSet dictionary. The research was conducted in the Python programming language and using Google Collaboratory. Data validation was carried out using the K-fold cross-validation method. The research results indicate that both algorithms predominantly produce positive sentiments over negative ones. However, SVM with a linear kernel achieves a higher accuracy rate of 0.87, compared to Multinomial Naïve Bayes, which has an accuracy of 0.82. SVM also records a precision of 0.87, recall of 0.97, and an F1-score of 0.91, while Multinomial Naïve Bayes shows a precision of 0.81, recall of 0.98, and an F1-score of 0.89. Overall, this research confirms that SVM excels in text sentiment classification, while Multinomial Naïve Bayes also provides good results in recognising positive and negative sentiment. These results have important implications for understanding public sentiment regarding the Health Bill on the Twitter platform.*

**Keywords:** Support Vector Machine, Multinomial Naïve Bayes, Bill of health, Inset Lexicon

### Abstrak

*Penelitian ini fokus pada analisis sentimen terhadap rencana pengesahan RUU Kesehatan yang menjadi perbincangan hangat di platform media sosial, terkhusus Twitter. Penelitian ini bertujuan untuk mengklasifikasikan tweet yang mencerminkan berbagai pendapat terkait RUU Kesehatan, termasuk dukungan, penolakan, dan netralitas. Dalam penelitian ini, penulis menggunakan dua jenis algoritma klasifikasi, yaitu Algoritma Multinomial Naïve Bayes dan Algoritma Support Vector Machine (SVM). Sebelumnya, tweet telah dilabeli menggunakan kamus Lexicon InSet. Penelitian dilakukan dengan bahasa pemrograman Python dan menggunakan Google Collaboratory. Validasi data dilakukan dengan metode K-fold Cross Validation. Hasil penelitian menunjukkan bahwa kedua algoritma menghasilkan sentimen positif yang lebih dominan daripada sentimen negatif. Namun, SVM dengan kernel linier memiliki tingkat akurasi yang lebih tinggi, mencapai 0,87, dibandingkan dengan Multinomial Naïve Bayes yang memiliki akurasi sebesar 0,82. SVM juga mencatat presisi 0,87, recall 0,97, dan F1-score 0,91, sementara Multinomial Naïve Bayes mencatat presisi 0,81, recall 0,98, dan F1-score 0,89. Secara keseluruhan,*

penelitian ini menegaskan bahwa SVM unggul dalam klasifikasi sentimen teks, sementara Multinomial Naïve Bayes juga memberikan hasil yang baik dalam mengenali sentimen positif dan negatif. Hasil ini memiliki implikasi penting dalam pemahaman sentimen masyarakat terkait RUU Kesehatan di platform Twitter.

**Kata Kunci:** Support Vector Machine, Multinomial Naïve Bayes, RUU kesehatan, Inset Lexicon

## 1. PENDAHULUAN

RUU Kesehatan yang merupakan singkatan dari Rancangan Undang-Undang Kesehatan, adalah sebuah undang-undang yang dirancang untuk mengatur dan melindungi sistem kesehatan negara, meningkatkan kualitas Kesehatan dan kesejahteraan masyarakat. Undang-undang ini bertujuan untuk memperbaiki akses yang diperlukan masyarakat terhadap layanan kesehatan yang baik, menjaga dan mempromosikan kesehatan masyarakat, serta mengatur aspek-aspek terkait kebijakan kesehatan dan pengaturan sistem kesehatan secara keseluruhan. Melalui *RUU Kesehatan*, pemerintah berupaya untuk menciptakan lingkungan yang mendukung bagi kesejahteraan dan kehidupan yang sehat bagi seluruh warga negara.

Seperti diketahui media sosial berpengaruh besar terhadap berbagai dimensi kesehatan di Indonesia [1]. Beberapa bulan terakhir polemik terkait *RUU Kesehatan* mencuat di platform media sosial Twitter, memancing respon yang beraneka ragam. Dari pendapat pengguna media sosial tersebut, beberapa pengguna mengkritik isu-isu sensitif yang dianggap melanggar privasi individu dan potensial membatasi kebebasan dalam pengambilan keputusan terkait kesehatan. Sementara itu, ada juga pengguna yang mendukung RUU tersebut, menganggapnya sebagai langkah penting untuk meningkatkan kualitas pelayanan kesehatan dan mengatasi masalah yang ada.

Berbagai macam tanggapan masyarakat terhadap topik tersebut menjadi latar belakang penelitian ini terkait dengan analisis sentimen pengguna twitter terhadap rencana pengesahan RUU Kesehatan.

Analisis sentimen adalah proses yang melibatkan pemahaman, ekstraksi, dan pengolahan data teks secara otomatis untuk mendapatkan informasi tentang sentimen yang terkandung

dalam sebuah opini [2]. Hasil dari analisis sentimen dari Twitter bisa dikelompokkan menjadi tiga: positif, negatif, dan netral.

Kemudian M. Pan [3] melakukan publikasi penelitian yang berjudul "*Discussion of Online Reviews Impacts on Consumers Behaviors*". Menurut M. Pan, banyaknya ulasan pada media digital saat ini membuat proses pencarian informasi menjadi semakin sulit. Dengan adanya analisis ulasan dapat membantu penjual dalam memahami keinginan dan ketertarikan konsumen sebelum produsen mengeluarkan produk baru.

Sebuah metode dalam machine learning yang dapat diaplikasikan untuk proses pengelompokan teks adalah menggunakan algoritma naïve bayes serta Support Vector Machine (SVM) [4]. Pendekatan Naïve Bayes berfokus pada pencarian probabilitas tertinggi untuk setiap kategori atau kelas, sementara SVM beroperasi dengan mencari hyperplane optimal untuk memisahkan kategori atau kelas yang ada [5].

Dalam beberapa penelitian sebelumnya telah dibahas terkait dengan analisis sentiment. Pada penelitian dengan judul "Analisis Sentimen Wacana Pemindahan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (SVM)". Pemberian label atau kelas dilakukan secara manual. Hasil yang diperoleh adalah akurasi sebanyak 96,68 %, presisi 95.82 %, recall 94.04 % dan AUC 0,979 [6].

Dalam riset yang dilakukan oleh Pravina pada tahun 2019 berjudul "Analisis Sentimen mengenai Pandangan Masyarakat terhadap Maskapai Penerbangan di Twitter," tujuannya adalah untuk mengklasifikasikan pendapat masyarakat menjadi dua kategori, yaitu positif dan negatif, menggunakan metode klasifikasi Support Vector Machine (SVM). Temuan dari

studi tersebut menunjukkan tingkat akurasi sekitar 40%, presisi 40%, recall 100%, dan f-measure sekitar 57,14% [7].

Sebuah riset terdahulu dengan judul "Analisis Sentimen Pendapat Masyarakat mengenai Keberhasilan Pembelajaran Daring di Masa Pandemi COVID-19 Melalui Pendekatan Naïve Bayes Classifier"[8], menemukan bahwa dari total 524 data yang dianalisis, terdapat 480 pendapat positif dan 44 pendapat negatif. Hasil evaluasi menunjukkan tingkat akurasi sebesar 88,5%. Untuk pendapat negatif, presisi mencapai 12%, recall 17%, dan nilai f1-score 14%. Sementara itu, pada pendapat positif, presisi mencapai 95%, recall 93%, dan nilai f1-score mencapai 94%.

Untuk memahami respons masyarakat terhadap RUU Kesehatan di Twitter, penting untuk melakukan analisis sentimen terhadap komentar-komentar yang membahas topik tersebut. Mengingat keterbatasan penelitian sebelumnya yang lebih banyak menggunakan SVM, ada kebutuhan untuk mengeksplorasi metode lain yang mungkin lebih relevan dalam konteks RUU Kesehatan di Twitter. Oleh karena itu, penelitian ini mengadopsi algoritma SVM dan Multinomial Naïve Bayes untuk membandingkan performa keduanya. Evaluasi performa kedua algoritma ini didasarkan pada akurasi, presisi, dan recall. Alasan pemilihan kedua algoritma ini adalah kemampuan algoritma tersebut dalam mengidentifikasi

nuansa sentimen yang khusus terkait dengan RUU Kesehatan. Eksperimen ini dilakukan menggunakan *Google Collaboratory* dan bahasa pemrograman Python sebagai alatnya.

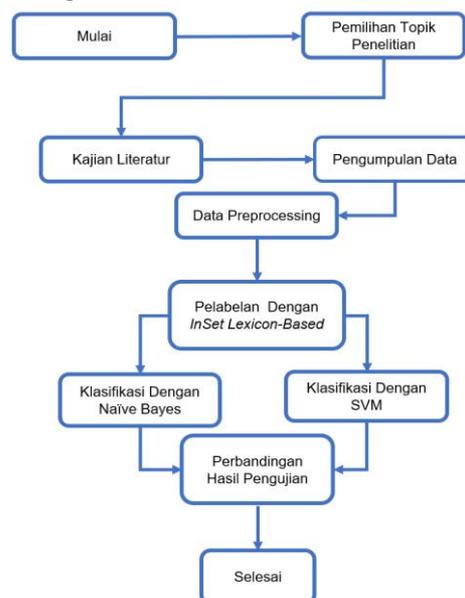
Hasil dari penelitian ini diharapkan bisa memberikan saran kepada pemerintah atau badan legislatif dalam sektor kesehatan untuk mengetahui respon atau sentimen masyarakat di terhadap adanya pengesahan RUU kesehatan menjadi UU Kesehatan.

## 2. METODE

Metode dalam penelitian harus dilakukan agar penelitian yang dilakukan lebih sistematis, sehingga hasil yang didapatkan sesuai dengan tujuan awal penelitian [9]. Penelitian ini mengadopsi pendekatan eksperimental, suatu metode penelitian yang menguji kebenaran suatu hipotesis dengan melibatkan analisis statistic pada beberapa variable yang terlibat. Pendekatan ini memerlukan serangkaian uji khusus yang digunakan untuk menjelaskan dan mengaitkan variable-variabel tersebut dengan masalah penelitian yang diteliti [10].

### 2.1. Kerangka Penelitian

Untuk menjalankan penelitian dengan lancar sesuai rencana awal, penting untuk memiliki pedoman dalam bentuk alur proses. Ilustrasi pada Gambar 1 memperlihatkan diagram alur proses penelitian yang diterapkan dalam studi ini.



Gambar 1. Diagram Alur Proses Penelitian

## 2.2. Pengumpulan Data

Pada penelitian ini, tahap penggalian data menjadi salah satu langkah yang sangat krusial. Penggalian data dilakukan dengan metode *crawling* atau ekstraksi data dari platform media sosial twitter, dan alat yang digunakan untuk melaksanakan tahapan ini adalah perpustakaan (library) *tweepy* yang terintegrasi dengan bahasa pemrograman Python.

Proses *crawling data* dilakukan dengan memasukkan kata kunci "ruu kesehatan" mulai dari bulan Mei 2023 hingga Juni 2023. Hasil *crawling* berupa data dalam format \*.xlsx sebanyak 974 data tweets.

## 2.3. Data Preprocessing

Data *preprocessing* atau pra pemrosesan data adalah serangkaian tindakan yang dilakukan untuk membersihkan, mengubah, dan mempersiapkan data mentah sebelum dilakukan tahapan selanjutnya. Tujuan utama dari proses data *preprocessing* adalah untuk menghilangkan gangguan, mengatasi duplikasi, mengatasi nilai yang hilang, serta menghapus karakter yang tidak relevan dan lain sebagainya. Dengan cara ini, data siap untuk diproses atau dianalisis lebih lanjut. Berikut ini adalah tahapan *data preprocessing* yang dilakukan:

- 1) *Data cleaning*: proses pembersihan pada data yang meliputi simbol-simbol, dan karakter – karakter lain yang tidak bermakna
- 2) *Case folding*: upaya atau proses untuk merubah kata-kata yang mengandung huruf kapital menjadi format seragam, yakni huruf kecil, sehingga memastikan konsistensi data ketika digunakan sebagai input dalam model klasifikasi [11].
- 3) *Cleaning*: proses pembersihan atau penghapusan emoji, hashtag, tanda baca, nomor, spasi ganda, pengulangan kata dan sebagainya
- 4) *Tokenization*: proses pemisahan kata pada teks di kolom *full\_review*

5) *Normalization*: Proses untuk penyamaan istilah, dimana kata berbeda namun memiliki makna yang sama

6) *Stopword removal* atau *filtering* merupakan tahap dalam pemilihan kata-kata yang dianggap kurang relevan atau tidak signifikan dalam proses pengolahan data.

7) *Stemming* : proses ini melibatkan penyederhanaan sebuah kata ke bentuk dasarnya atau mereduksinya ke akar katanya [12].

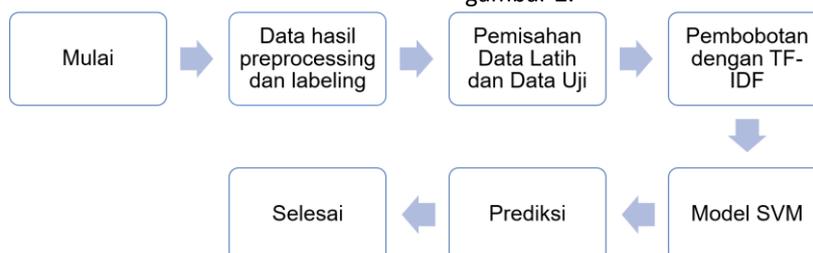
## 2.4. Labeling

Labeling adalah proses melakukan pemberian label sentimen pada teks ulasan [13]. Dalam penelitian ini pelabelan pada data teks hasil dari proses *data preprocessing* dilakukan dengan metode yang disebut *lexicon-based* dimana pelabelan dengan cara memberikan nilai bobot pada tulisan untuk mengetahui tulisan tersebut memiliki sentimen negatif, netral atau positif. *Lexicon-based* adalah metode pemberian atau pemilihan kata atau dokumen dengan menggunakan kamus [14].

Sedangkan Library python yang digunakan adalah *InSet Lexicon* atau kamus berbahasa Indonesia. *InSet* merupakan Lexicon sentimen bahas Indonesia yang digunakan untuk mengidentifikasi komentar atau pendapat dan mengkategorikan komentar tersebut ke dalam pendapat negatif atau positif [15].

## 2.5. Algoritma Klasifikasi Support Vector Machine (SVM)

Proses klasifikasi memiliki tujuan untuk menyajikan kelas sentimen terhadap dataset yang telah diproses sebelumnya. Support Vector Machine (SVM) yaitu suatu metode klasifikasi di dalam *machine learning* yang berprinsip pada *Structural Risk Minimization* (SRM). Tujuan utamanya adalah mencari hyperplane optimal yang mampu membagi jadi dua kelompok berbeda dalam ruang input [16]. Tahapan yang dilakukan pada klasifikasi ditunjukkan pada gambar 2.



Gambar 2. Tahapan Klasifikasi SVM

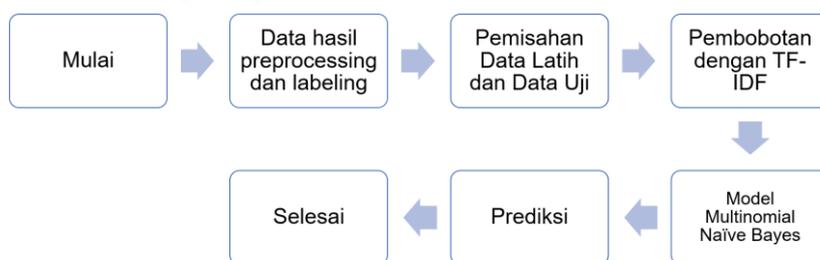
## 2.6. Algoritma Klasifikasi Multinomial Naïve Bayes

Pendekatan dalam pembelajaran mesin yang dikenal sebagai Metode Klasifikasi Naïve Bayes adalah suatu pendekatan statistik dan probabilitas yang menggunakan prinsip Naïve Bayes untuk mengategorikan data ke dalam kategori yang telah ditetapkan sebelumnya [17].

Penggunaan kata "naïve" disebabkan oleh fakta bahwa nilai dari suatu atribut tidak memiliki dampak yang besar atau tidak saling berhubungan secara signifikan dengan nilai atribut lainnya. Hal tersebut biasa diistilahkan dengan *conditional independence*. Persepsi pada metode *naïve bayes* yang menyebutkan bahwa setiap kata tidak memiliki dependensi dengan yang lain, bertolakbelakang dengan keadaan

yang sebenarnya. Hal tersebut terjadi karena dokumen atau teks perlu mengandung kata-kata yang berhubungan satu sama lain, sehingga dokumen tersebut memiliki makna atau signifikansi [18]. Metode naïve Bayes bisa juga membantu dalam mengklasifikasikan kelas yang hasilnya dapat digunakan paralel dalam meningkatkan skala kumpulan data, khususnya di studi kasus data skala besar [19].

*Multinomial Naïve Bayes* merupakan varian dari model Naïve Bayes yang umumnya digunakan dalam proses klasifikasi teks. Model ini menerapkan *supervised learning*, yang berarti bahwa data harus diberi label sebelum tahap pelatihan dimulai. Tahapan yang dilakukan pada klasifikasi ditunjukkan pada gambar 3.



Gambar 3. Tahapan Klasifikasi Multinomial Naïve Bayes

## 2.7. Data Splitting

Pembagian data atau data splitting mengacu pada proses memisahkan dataset menjadi dua bagian, yakni data pelatihan (*data training*) dan data pengujian (*data testing*).

- 1) Data pelatihan adalah dataset yang digunakan untuk melatih model *machine learning* dengan metode *supervised learning*. Data latih berisi dataset yang berisi contoh-contoh dengan variabel atau atribut yang relevan dan label atau kelas yang diketahui. Dalam SVM, setiap contoh dalam data latih diwakili oleh vektor fitur dan diberi label atau kelas yang sesuai. Misalnya, dalam klasifikasi biner, setiap contoh akan memiliki label 1 (kelas positif) atau -1 (kelas negatif).
- 2) Data Test (Data uji) adalah set data yang akan digunakan untuk pengujian kinerja *machine learning* menggunakan metode *supervised learning* setelah melalui proses pelatihan. Data ini biasanya tidak digunakan dalam proses pelatihan, sehingga memberikan evaluasi yang obyektif tentang

kemampuan prediksi model pada data belum pernah dilihat.

## 2.8. Pembobotan TF IDF

*Term Frequency Inverse Document Frequency (TF-IDF)* adalah teknik yang umum digunakan untuk menentukan bobot kata-kata dalam sebuah dokumen. Komponen TF (*Term Frequency*) mengindikasikan setinggi apakah frekuensinya suatu kata muncul dalam dokumen tersebut.

## 2.9. Prediction

Prediksi adalah proses menghasilkan nilai atau kelas yang diprediksi berdasarkan model yang telah dilatih pada data yang belum pernah dilihat sebelumnya. Dalam konteks pembelajaran mesin, prediksi dilakukan untuk memperoleh estimasi atau hasil yang diharapkan berdasarkan informasi yang ada dalam data. Proses prediksi melibatkan penggunaan model yang telah dilatih pada data latih untuk membuat prediksi terhadap data uji

atau data baru yang belum pernah dilihat sebelumnya. Model ini akan mengambil fitur-fitur dari data tersebut dan menggunakan aturan atau pola yang telah dipelajari selama pelatihan untuk menghasilkan prediksi.

### 2.10. Pengukuran Evaluasi

Untuk menguji efektivitas hasil klasifikasi machine learning, diperlukan adanya pengukuran terhadap evaluasi. Pengukuran tersebut biasanya menggunakan matrix yang

digunakan sebagai evaluasi pengukuran atau disebut dengan istilah *Confusion Matrix*.

*Confusion matrix* merupakan sebuah tabel (Tabel 1) yang umumnya berisi hasil diprediksi benar (true) atau false (salah) dari model klasifikasi. Matrix ini digunakan untuk mengevaluasi kinerja model klasifikasi [20].

Tabel 1: Tabel *Confusion Matrix*  
[Sumber : Zhang (2023) [20]]

		Kelas Prediksi	
		Positif	Negatives
Observasi	Positif	TP	FN
	Negatif	FP	TN

Keterangan:

- Tingkat kebenaran positif (*True Positif*) mencerminkan situasi dimana prediksi label positif adalah benar. Sebaliknya, tingkat kebenaran negatif (*True Negatif*) menunjukkan bahwa prediksi label negatif juga benar. Di sisi lain, tingkat kesalahan positif (*False Positif*) mewakili kasus dimana prediksi label positif ternyata salah, sementara tingkat kesalahan negatif (*False Negatif*) menggambarkan situasi dimana prediksi label negatif ternyata salah. Konsep ini membentuk dasar dari *Confusion Matrix*.
- Dari *confusion matrix* ini, kita dapat menghitung akurasi klasifikasi. Akurasi ini diperoleh dengan menjumlahkan jumlah True Positif dan True Negatif, lalu dibagi oleh total dari True Positif, True Negatif, False Positif, dan False Negatif, seperti dijelaskan pada rumus berikut ini:

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

Selain *confusion matrix*, juga dilakukan penghitungan akurasi, presisi, recall dan *F1-Score*. Dalam konteks matematika, akurasi diartikan sebagai perbandingan jumlah prediksi yang tepat terhadap keseluruhan prediksi yang dibuat. Sedangkan presisi mengukur perbandingan prediksi positif yang akurat dibandingkan dengan total prediksi positif. Recall, atau sensitivitas, mengukur seberapa akurat prediksi positif dalam kelas sebenarnya, dan *F1-Score* merupakan perhitungan rata-rata berbobot antara Presisi dan Recall [21].

$$Akurasi = \frac{TP+TN}{TP+FP+FN+TN} \quad (2)$$

$$Presisi = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1 - Score = \frac{2*(Recall*Presisi)}{Recall+Presisi} \quad (5)$$

### 2.11. K-Fold Cross Validation

Untuk membandingkan kinerja dua metode *machine learning* tersebut, diperlukan K-fold Cross validation. *K-fold Cross validation* adalah metode untuk validasi silang yang melakukan pembagian dataset menjadi k bagian dengan ukuran yang sama. Pada percobaan yang pertama, Subset S1 digunakan sebagai data pengujian, sementara subset yang lainnya berperan sebagai data pelatihan. Kemudian, pada percobaan kedua, Subset S2 menjadi data pengujian, dan subset lainnya digunakan sebagai data pelatihan. Tindakan ini diulang sebanyak k kali, di mana setiap kali Subset S<sub>k</sub> berperan sebagai data pengujian [22].

### 2.12. Visualisasi

Visualisasi merupakan representasi data secara visual untuk memberikan pengetahuan dari data yang dianalisis. Penelitian ini menggunakan library Matplotlib dan Wordcloud untuk visualisasi data. Wordcloud akan menampilkan frekuensi kata – kata yang muncul pada teks komentar di twitter. Selain itu juga ada

visualisasi dalam bentuk *pie chart*, terkait dengan sentimen.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Pengumpulan Data

Pada penelitian ini digunakan dataset yang berasal dari data twitter tentang topik RUU (Rancangan Undang Undang) Kesehatan. Proses *crawling data* dilakukan dengan memasukkan

kata kunci “ruu kesehatan” mulai dari bulan Mei 2023 hingga akhir Juni 2023. Hasil *crawling* berupa data dalam format \*.xlsx sebanyak 974 data tweets.

Tabel 2 menunjukkan informasi daftar atribut beserta deskripsi data.

Tabel 2: Daftar Atribut

Atribut	Deskripsi
Created-At	Tanggal tweet
From-User	Berisi nama pengguna yang berasal dari akun pembuat tweets yang diambil
To-User	Berisi nama pengguna yang disebut/dituju dalam tweet
Language	Bahasa yang digunakan
Text	Teks dari tweet
Geo-Location-Latitude	Titik koordinat latitude geo-lokasi tweet
Geo-Location-Longitude	Titik koordinat longitude geo-lokasi tweet
Id	Id dari tweet

#### 3.2. Data Preprocessing

Pada *preprocessing* ini hanya akan dilakukan pada atribut *text* yang berisi isi dari tweet karena atribut – atribut lainnya tidak diperlukan.

– karakter yang tidak relevan, termasuk tetapi tidak terbatas pada hashtag, tanda @, tanda titik, tanda koma, simbol, emoji serta menghilangkan karakter-karakter lain yang tidak sesuai. Hasil proses *data cleaning* sebagaimana ditunjukkan pada Tabel 3.

##### a. Data cleaning

*Data cleaning* merupakan langkah pertama dalam proses *data preprocessing*, yang melibatkan penghapusan kata-kata dan karakter

Tabel 3: Proses Cleaning

text	tweet_clean
! RILIS KAJIAN ! Selamat siang, Warga Kage! Dewan Perwakilan Rakyat (DPR) telah resmi mengajukan draf RUU kesehatan kepada pemerintah, setelah sebelumnya dibahas pada sidang paripurna. <a href="https://t.co/UkinPzaQZ7">https://t.co/UkinPzaQZ7</a>	RILIS KAJIAN Selamat siang Warga Kage Dewan Perwakilan Rakyat DPR telah resmi mengajukan draf RUU kesehatan kepada pemerintah setelah sebelumnya dibahas pada sidang paripurna

##### b. Case Folding

Pada tahapan ini, dilakukan perubahan huruf kapital yang terdapat dalam teks menjadi huruf

kecil (*lowercase*) seperti yang terdapat pada Tabel 4.

Tabel 4: Case Folding

tweet_clean	case_folding
RILIS KAJIAN Selamat siang Warga Kage Dewan Perwakilan Rakyat DPR telah resmi mengajukan draf RUU kesehatan kepada pemerintah setelah sebelumnya dibahas pada sidang paripurna	rilis kajian selamat siang warga kage dewan perwakilan rakyat dpr telah resmi mengajukan draf ruu kesehatan kepada pemerintah setelah sebelumnya dibahas pada sidang paripurna

##### c. Tokenization

Tokenization merupakan proses untuk memecah kata per kata pada teks ulasan. Tujuannya adalah agar mempermudah penghitungan frekuensi kemunculan kata. Pada penelitian ini, *tokenization* menggunakan tools library NLTK dari phyton. Hasil proses

*tokenization* sebagaimana ditunjukkan pada Tabel 5.

Tabel 5: Hasil Tokenization

case_folding	tweet_tokens
rilis kajian selamat siang warga kage dewan perwakilan rakyat dpr telah resmi mengajukan draf ruu kesehatan kepada pemerintah setelah sebelumnya dibahas pada sidang paripurna	['rilis', 'kajian', 'selamat', 'siang', 'warga', 'kage', 'dewan', 'perwakilan', 'rakyat', 'dpr', 'telah', 'resmi', 'mengajukan', 'draf', 'ruu', 'kesehatan', 'kepada', 'pemerintah', 'setelah', 'sebelumnya', 'dibahas', 'pada', 'sidang', 'paripurna']

**d. Normalization**

*Normalization* atau normalisasi bertujuan untuk menyamakan istilah yang mempunyai arti yang sama tetapi ditulis dengan cara yang berbeda, yang bisa disebabkan oleh kesalahan dalam menulis, penggunaan singkatan, atau penggunaan bahasa sehari-hari (slang).

“yang”, “ke” dan yang lainnya yang bertujuan mengurangi noise dalam data, sehingga data yang digunakan lebih bersih.

**f. Stemming**

*Stemming* adalah salah satu metode untuk menghapus afiks dari kata atau mencari kata dasar dalam kata adalah proses *stemming*. Dalam penelitian ini, *stemming* dilakukan dengan memanfaatkan perpustakaan Python bernama Sastrawi. Hasil proses stemming sebagaimana ditunjukkan pada Tabel 6.

**e. Stopword Removal atau Filtering**

Tahap *stopword removal* adalah bagian dari proses pra-pemrosesan teks yang tujuannya adalah untuk eliminasi ungkapan yang tidak memiliki relevansi pada suatu kalimat berdasarkan daftar *stopword*, seperti “di”,

Tabel 6: Hasil Stemming

tweet_normalized	tweet_stemmed
['rilis', 'kajian', 'selamat', 'siang', 'warga', 'kage', 'dewan', 'perwakilan', 'rakyat', 'dpr', 'resmi', 'mengajukan', 'draf', 'ruu', 'kesehatan', 'pemerintah', 'dibahas', 'sidang', 'paripurna']	['rilis', 'kaji', 'selamat', 'siang', 'warga', 'kage', 'dewan', 'wakil', 'rakyat', 'dpr', 'resmi', 'aju', 'draf', 'ruu', 'sehat', 'perintah', 'bahas', 'sidang', 'paripurna']

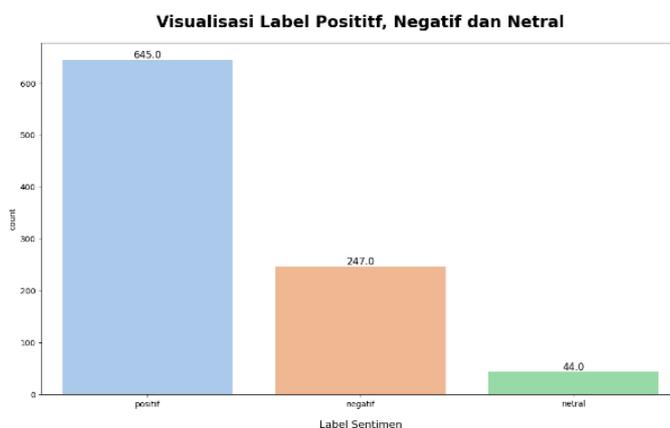
**g. Perhitungan Kelas Sentimen (Lexicon Based)**

Setelah dilakukan text processing text ulasan belum memiliki label sentimen sehingga belum diketahui apakah pengguna memberikan ulasan positif atau negatif. Pada penelitian ini pemberian label dilakukan dengan memberikan label sentimen dengan menerapkan metode lexicon atau biasa dikenal dengan *lexicon-based*. Sedangkan *library* yang digunakan adalah *InSet*

*lexicon*. Langkah pertama adalah dilakukan dengan membuat *polarity* sentimen dari hasil teks *processing*. *Polarity* dengan nilai > 0 berarti memiliki label sentimen positif, nilai *polarity* = 0 berlabel netral dan nilai *polarity* < 0 berarti memiliki label negatif. Hasil dari *labeling* dengan *InSet Lexicon* ditunjukkan pada Tabel 7. Dimana terdapat 645 data menghasilkan label positif, 247 data dengan label negatif, dan 44 data dengan label netral.

Tabel 7: Hasil Labeling Dengan InSet Lexicon

tweet_stemmed	polarity score	label
['rilis', 'kaji', 'selamat', 'siang', 'warga', 'kage', 'dewan', 'wakil', 'rakyat', 'dpr', 'resmi', 'aju', 'draf', 'ruu', 'sehat', 'perintah', 'bahas', 'sidang', 'paripurna']	12	positif
['proses', 'bahas', 'ruu', 'sehat', 'stop', 'solusi', 'penting', 'utama', 'organisasi', 'profesi', 'lindung', 'hukum', 'baik', 'dari', 'syahril', 'tenang', 'layan']	18	positif



Gambar 4. Hasil Labeling Dengan InSet Lexicon

Pada gambar 4 terlihat hasil visualisasi data label sentimen untuk dalam bentuk grafik bar. Untuk proses selanjutnya label dengan sentimen netral dihapus, karena untuk proses klasifikasi

hanya akan menggunakan label sentimen positif dan negatif. Gambar 5 dan 6 menunjukkan hasil visualisasi teks dengan wordcloud untuk sentimen positif dan negatif.



Gambar 5. Wordcloud Sentimen Positif



Gambar 6. Wordcloud Sentimen Negatif

### 3.3. Klasifikasi Sentimen Analisis

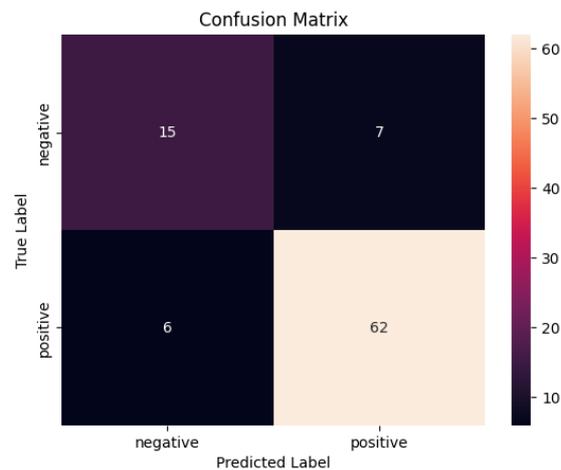
Analisis sentimen merupakan metode yang mencakup pemahaman, ekstraksi, dan pemrosesan otomatis data teks untuk memperoleh wawasan tentang sentimen yang ada dalam suatu opini [2]. Dalam analisis sentimen yang dilakukan pada Twitter, hasilnya biasanya dibagi menjadi tiga kelas: positif, negatif, dan netral. Akan tetapi penelitian ini hanya memfokuskan pada dua kelas sentimen, yaitu positif dan negatif.

#### a. Klasifikasi dengan metode Algoritma Support Vector Machine (SVM).

Sebelum menerapkan pengklasifikasian menggunakan SVM, langkah awal melibatkan perhitungan bobot kata menggunakan

pendekatan *Term Frequency Inverse Document Frequency* (TF-IDF). dengan bantuan perpustakaan (*library*) *sklearn* dalam bahasa pemrograman Python. Setelah tahap tersebut, dataset dibagi ke dalam dua jenis, yaitu Data pelatihan dan Data pengujian. Pembagian tersebut dilakukan dengan perbandingan 90:10 dan menggunakan seed atau random *state* 0 untuk memastikan hasil pembagian data yang konsisten.

Kemudian dilakukan proses pengujian klasifikasi algoritma SVM kernel linier yang dibantu dengan *library sklearn.svm* pada Python dengan kernel linier. Hasil pengujian ditunjukkan dengan *confusion matrix* dalam bentuk visualisasi agar mudah dipahami seperti pada gambar 7.



Gambar 7. Confusion Matrix Hasil Prediksi SVM

Confusion matrix di atas dapat dijelaskan sebagai berikut: Dari total 90 data pengujian, sebanyak 62 data berhasil diklasifikasikan dengan benar sebagai *True Positif* (TP), 15 data yang juga terklasifikasikan dengan benar sebagai *True Negatif* (TN), 6 data *False Negatif* (FN), dan 7 data terklasifikasikan *False Positif* (FP).

Setelah dilakukan pengujian algoritma yang dituangkan dalam confusion matrix, selanjutnya dilakukan proses pengujian evaluasi. Hasil evaluasi pada algoritma SVM menghasilkan akurasi sebesar 0,86, artinya algoritma SVM berhasil memprediksi secara benar 86% dari keseluruhan data yang diuji. Ini adalah ukuran umum untuk mengevaluasi performa keseluruhan algoritma dalam mengklasifikasikan data, baik itu sebagai sentimen negatif maupun positif. Pada sentimen negatif nilai presisi

sebanyak 0,71 yang artinya dari seluruh kasus yang diprediksi sebagai sentimen negatif, 71% di antaranya adalah prediksi yang benar. Nilai ini menunjukkan seberapa akurat algoritma dalam mengidentifikasi sentimen negatif. Sedangkan nilai *recall* sebanyak 0,68 dan *f-1 score* sebanyak 0,70.

Sementara itu pada sentimen positif nilai presisi sebanyak 0,90 yang artinya algoritma SVM memiliki presisi yang tinggi untuk sentimen positif, dengan 90% dari prediksi positifnya benar. Ini menunjukkan keakuratan yang sangat baik dalam mengidentifikasi sentimen positif. Nilai *recall* sebanyak 0,91 yang artinya SVM efektif dalam mengidentifikasi sebagian besar kasus yang sebenarnya positif. Sedangkan *recall* sebesar 91% dan *f-1 score* sebanyak 0,91 seperti ditunjukkan pada gambar 8.

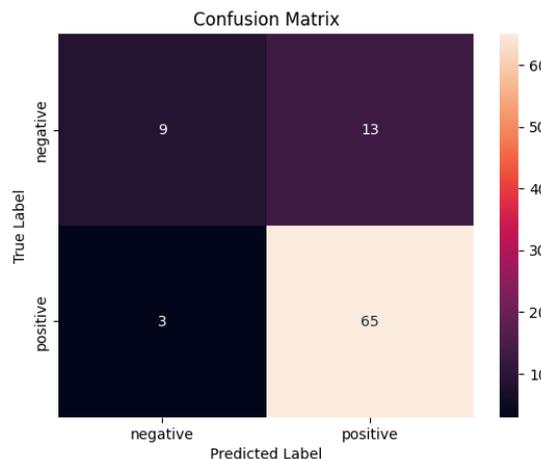
	precision	recall	f1-score	support
-1	0.71	0.68	0.70	22
1	0.90	0.91	0.91	68
accuracy			0.86	90
macro avg	0.81	0.80	0.80	90
weighted avg	0.85	0.86	0.85	90

Gambar 8. Hasil Evaluasi Model SVM Kernel Linier

### b. Klasifikasi dengan metode Multinomial Naïve Bayes

Sebagaimana prosedur yang dijalankan pada klasifikasi SVM, pada klasifikasi Multinomial Naïve Bayes terlebih dahulu dilakukan pembobotan kata menggunakan metode TF-IDF. Selanjutnya data dibagi dengan perbandingan yang sama, Persentase yang digunakan adalah 90% sebagai data pelatihan (data training) dan 10% sebagai data pengujian (data testing).

Setelah melakukan pembagian menjadi data pelatihan (data training) dan data pengujian (data testing), langkah selanjutnya adalah Menerapkan klasifikasi dengan memanfaatkan Algoritma Multinomial Naïve Bayes dengan bantuan perpustakaan (library) Sklearn\_naive\_bayes dalam Bahasa pemrograman Python. Hasil dari pengujian ditunjukkan dengan visualisasi data melalui *confusion matrix* yang ditunjukkan pada gambar 9.



Gambar 9. Confusion Matrix Hasil Prediksi Multinomial Naïve Bayes

Hasil dari *confusion matrix* diatas artinya dari 90 data uji ditemukan data sebanyak 65 data *True Positif* (TP), sebanyak 9 data *True Negatif* (TN), dan sebesar 3 data *False Negatif*, serta 13 data *False Positif* (FP).

Hasil evaluasi pengujian pada algoritma Multinomial Naïve Bayes menunjukkan bahwa metode ini memiliki tingkat akurasi sebesar 0,82 seperti dapat dilihat pada gambar 10.

Selanjutnya, pengujian juga dilakukan pada sentimen negatif dan positif. Untuk sentimen negatif, metodenya memiliki nilai Presisi sebesar 0,75, yang berarti sekitar 75% dari hasil yang dianggap negatif benar-benar negatif. Nilai Recall sebesar 0,41, mengindikasikan bahwa

metode ini berhasil mengidentifikasi sekitar 41% dari semua data negatif yang sebenarnya ada. F-1 score sebesar 0,53 mencerminkan keseimbangan antara Presisi dan Recall.

Sementara itu, pada sentimen positif, algoritma Multinomial Naive Bayes memiliki Presisi sebesar 0,83, menunjukkan bahwa sekitar 83% dari hasil yang dianggap positif adalah benar-benar positif. Nilai Recall yang tinggi sebesar 1,96 menandakan bahwa metode ini sangat baik dalam mengidentifikasi data positif yang sebenarnya. F-1 score sebesar 0,89 juga menunjukkan performa yang baik dalam hal keseimbangan antara Presisi dan Recall pada sentimen positif.

Sehingga secara umum metode Algoritma Multinomial Naïve Bayes ini memiliki tingkat akurasi yang baik dalam mengklasifikasikan sentimen, dengan kinerja yang lebih baik pada sentimen positif daripada sentimen negatif.

	precision	recall	f1-score	support
-1	0.75	0.41	0.53	22
1	0.83	0.96	0.89	68
accuracy			0.82	90
macro avg	0.79	0.68	0.71	90
weighted avg	0.81	0.82	0.80	90

Gambar 10: Hasil Evaluasi Model Multinomial Naïve Bayes

### c. K-Fold Cross Validation

Sama seperti dalam proses klasifikasi SVM, pada klasifikasi Multinomial Naïve Bayes, langkah awalnya adalah melakukan pembobotan kata dilakukan dengan memanfaatkan metode *Term Frequency-Inverse Document Frequency* (TF-IDF). menggunakan TF-IDF. Selama tahap ini, data juga dibagi dengan perbandingan yang sama.

Metode K-Fold Cross Validation adalah salah satu teknik yang digunakan untuk melakukan validasi pada model yang biasa digunakan dalam proses analisis data maupun dalam Pembangunan model prediksi. Tujuan utama penggunaan metode ini untuk melakukan pengukuran seberapa baik kinerja model secara keseluruhan. Adapun manfaat dari *K-fold Cross validation* adalah agar dapat menghindari overfitting, efisien dalam pemanfaatan data, dan mengurangi variabilitas. Langkah-langkah dalam proses K-Fold Cross Validation:

- 1) Data dipecah menjadi K bagian: Dataset awal dibagi menjadi K bagian yang mendekati atau fold yang ukurannya sama. Biasanya nilai K adalah bilangan bulat yang lebih besar daripada 1.
- 2) Model dilatih dan diuji: pada proses latihan dan uji model dilakukan sebanyak K kali. Pada setiap pengulangan salah satu iterasi atau fold sebagai data testing (uji), dan sisanya untuk data training (latih).
- 3) Pengukuran performa: pada setiap kali iterasi, performa model diukur dengan metrik evaluasi, seperti halnya akurasi, presisi, atau recall, tergantung pada jenis masalah yang dihadapi (klasifikasi atau regresi).

- 4) Penggabungan hasil: setelah k iterasi selesai, hasil evaluasi performa model dari setiap iterasi diambil rata-ratanya atau digabungkan untuk memberikan gambaran keseluruhan performa model.

Dalam pengujian data menggunakan metode K-Fold Cross Validation dengan Algoritma Multinomial Naive Bayes dan Algoritma Support Vector Machine (SVM), kami melakukan evaluasi kinerja model pada data teks. Dengan K-Fold Cross Validation, data dipecah ke dalam beberapa lipatan (folds), langkah pelatihan dan pengujian diulang berkali-kali dengan variasi kombinasi yang berbeda dari data latihan dan uji. Hal ini membantu dalam mendapatkan estimasi yang lebih kuat tentang kinerja model pada data yang beragam.

Sebagaimana ditunjukkan pada gambar 11, untuk algoritma Naïve Bayes hasil evaluasi menunjukkan hasil akurasi sebesar 0,82 yang berarti model naïve bayes dapat mengklasifikasi teks dengan benar sekitar 82% dari keseluruhan data uji. Selain itu nilai Presisi sebanyak 0,81, Recall sebanyak 0,98 dan F1 sebanyak 0,89 menggabungkan presisi dan recall, memberikan gambaran keseluruhan tentang model Multinomial Naïve Bayes.

Sementara itu, algoritma SVM menghasilkan hasil akurasi sebesar 0,87 yang berarti model SVM dapat mengklasifikasi teks dengan benar sekitar 87% dari keseluruhan data uji. Selain itu nilai Presisi sebanyak 0,87, Recall sebanyak 0,97, dan F1 sebanyak 0,91 menggabungkan seluruh performa model SVM.

```

Naive Bayes
accuracy - 0.8279938271604937
precision - 0.8161990060210579
recall - 0.9826376285541439
f1 - 0.8916009230276245

SVM
accuracy - 0.8766975308641974
precision - 0.8736496900291846
recall - 0.9705384150030248
f1 - 0.9192415213136428

```

Gambar 11: Hasil K-Fold Cross Validation

#### 4. KESIMPULAN

Penelitian ini membahas analisis sentimen terhadap Rancangan Undang-Undang (RUU) Kesehatan dengan membandingkan performa algoritma Multinomial Naïve Bayes dan Support Vector Machine (SVM), serta menggunakan InSet Lexicon untuk labelisasi (penghitungan kelas sentimen). Hasil labelisasi menunjukkan 645 data positif, 247 negatif, dan 44 netral.

Dengan metode K-Fold Cross Validation dan pembagian data 90:10 untuk data latih dan uji, ditemukan bahwa SVM dengan kernel linier memiliki akurasi lebih tinggi (0,87) dibandingkan Multinomial Naïve Bayes (0,82). SVM juga mencatat presisi 0,87, recall 0,97, dan F1-score 0,91, sementara Multinomial Naïve Bayes mencatat presisi 0,81, recall 0,98, dan F1-score 0,89.

Kedua algoritma cenderung memprediksi data uji sebagai sentimen positif, menunjukkan respon masyarakat yang umumnya positif terhadap RUU Kesehatan. Meskipun SVM lebih unggul dalam klasifikasi sentimen, Naïve Bayes juga menunjukkan kinerja yang baik. Hasil ini memberikan wawasan penting untuk analisis sentimen dan pengambilan keputusan berdasarkan data teks dalam berbagai aplikasi, termasuk media sosial, survei pelanggan, dan ulasan produk.

#### 5. SARAN

Hasil Klasifikasi data dengan metode Algoritma *Multinomial Naïve Bayes* dan Algoritma *Support Vector Machine (SVM)* dalam analisis data teks menunjukkan performa yang cukup baik. Ini menandakan bahwa kedua algoritma tersebut efektif dalam mengklasifikasikan data. Saran agar melakukan uji coba dengan algoritma lain dan menguji data yang berbeda adalah langkah yang sangat baik.

Dengan demikian, dapat melakukan identifikasi algoritma yang paling cocok untuk kasus tertentu dan memperoleh pemahaman yang lebih baik tentang seberapa umum atau robust model yang digunakan terhadap berbagai jenis data. Dengan melakukan eksperimen lebih lanjut, hasil penelitian dapat dioptimalkan dan dapat memberikan kontribusi yang lebih signifikan dalam analisis sentiment pada teks.

#### Daftar Pustaka

- [1] F. Natasha, L. Christin, and Ferdinandus Winandy Soesilo, "The Effect of Entrepreneurial Orientation on Social Media Adoption and Business Performance Moderated by Innovation Capability in Healthy Food SMEs in DKI Jakarta," *J. Account. Financ. Manag.*, vol. 4, no. 1, pp. 104–117, 2023, doi: 10.38035/jafm.v4i1.197.
- [2] F. Sidik, I. Suhada, A. H. Anwar, and F. N. Hasan, "Analisis Sentimen Terhadap Pembelajaran Daring Dengan Algoritma Naive Bayes Classifier," *J. Linguist. Komputasional*, vol. 5, no. 1, p. 34, 2022, doi: 10.26418/jlk.v5i1.79.
- [3] M. Pan, "Discussion of Online Reviews Impacts on Consumers Behaviors," *J. Educ. Humanit. Soc. Sci. MAMEE*, vol. 13, pp. 219–225, 2023.
- [4] K. Fithriasari, W. Rakhmah, W. Mayasari, and W. Setya, "Surabaya Government Performance Evaluation using Tweet Analysis," 2020. [Online]. Available: [www.matematika.utm.my](http://www.matematika.utm.my)
- [5] F. S. Pamungkas and I. Kharisudin, "Analisis Sentimen dengan SVM, NAIVE BAYES dan KNN untuk Studi Tanggapan Masyarakat Indonesia Terhadap Pandemi Covid-19 pada Media Sosial Twitter," in *PRISMA, Prosiding Seminar Nasional Matematika*, 2021, vol. 4, pp. 628–634. [Online]. Available:

- <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [6] P. Arsi and R. Waluyo, "Analisis Sentimen Wacana Pemindahan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (SVM)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 8, no. 1, pp. 147–156, 2021, doi: 10.25126/jtiik.202183944.
- [7] A. M. Pravina, I. Cholissodin, and P. P. Adikara, "Analisis Sentimen Tentang Opini Maskapai Penerbangan pada Dokumen Twitter Menggunakan Algoritme Support Vector Machine (SVM)," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 3, pp. 2789–2797, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [8] A. Wibowo, F. Noor Hasan, L. Akbar Ramadhan, R. Nurhayati, and dan Arief Wibowo, "Jurnal Asimetrik: Jurnal Ilmiah Rekayasa Dan Inovasi Analisis Sentimen Opini Masyarakat Terhadap Keefektifan Pembelajaran Daring Selama Pandemi COVID-19 Menggunakan Naïve Bayes Classifier," vol. 4, pp. 239–248, 2022.
- [9] R. Azhar, A. Surahman, and C. Juliane, "Analisis Sentimen Terhadap Cryptocurrency Berbasis Python TextBlob Menggunakan Algoritma Naïve Bayes," *J. Sains Komput. Inform.*, vol. 6, no. 1, pp. 267–281, 2022.
- [10] A. Noviriandini and N. Nurajijah, "Analisis Kinerja Algoritma C4.5 Dan Naïve Bayes Untuk Memprediksi Prestasi Siswa Sekolah Menengah Kejuruan," *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 5, no. 1, pp. 23–28, 2019, doi: 10.33480/jitk.v5i1.607.
- [11] I. P. Dedy, W. Darmawan, G. Aditra Pradnyana, I. Bagus, and N. Pascima, "Optimasi Parameter Support Vector Machine Dengan Algoritma Genetika Untuk Analisis Sentimen Pada Media Sosial Instagram," *Sci. Inf. Technol. SINTECH J.*, vol. 6, no. 1, pp. 58–67, 2023, [Online]. Available: <https://doi.org/10.31598>
- [12] N. Seddari, A. Derhab, M. Belaoued, W. Halboob, J. Al-Muhtadi, and A. Bouras, "A Hybrid Linguistic and Knowledge-Based Analysis Approach for Fake News Detection on Social Media," *IEEE Access*, vol. 10, pp. 62097–62109, 2022, doi: 10.1109/ACCESS.2022.3181184.
- [13] E. Hauthal, D. Burghardt, C. Fish, and A. L. Griffin, "Sentiment Analysis," *Int. Encycl. Hum. Geogr. Second Ed.*, pp. 169–177, 2019, doi: 10.1016/B978-0-08-102295-5.10593-1.
- [14] A. Kurniawan and S. Adinugroho, "Analisis Sentimen Opini Film Menggunakan Metode Naive Bayes dan Lexicon Based Features," vol. 3, no. 9, pp. 8335–8342, 2019, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [15] 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*, Feb. 2018, vol. 2018-January, pp. 391–394. doi: 10.1109/IALP.2017.8300625.
- [16] . Analisis Dan Penerapan, A. Handayanto, K. Latifa, N. D. Saputro, and R. R. Waliyansyah, "Analisis dan Penerapan Algoritma Support Vector Machine (SVM) dalam Data Mining untuk Menunjang Strategi Promosi (Analysis and Application of Algorithm Support Vector Machine (SVM) in Data Mining to Support Promotional Strategies)," vol. 7, no. 2, pp. 71–79, 2019.
- [17] J. Han, M. Kamber, and J. Pe, *Data Mining: Concepts and Techniques*. 2011. doi: 10.1016/C2009-0-61819-5.
- [18] A. Sabrani, I. W. Gede Putu Wirarama Wedashwara, and F. Bimantoro, "Metode Multinomial Naïve Bayes Untuk Klasifikasi Artikel Online Tentang Gempa Di Indonesia," *JTIKA*, vol. 2, no. 1, pp. 89–100, 2020, [Online]. Available: [http://jtika.if.unram.ac.id/index.php/JTIKA A/](http://jtika.if.unram.ac.id/index.php/JTIKA/A/)
- [19] M. Wongkar and A. Angdresey, "Sentiment Analysis Using Naive Bayes Algorithm Of The Data Crawler: Twitter," *Proc. 2019 4th Int. Conf. Informatics Comput. ICIC 2019*, pp. 1–5, 2019, doi: 10.1109/ICIC47613.2019.8985884.
- [20] N. Zhang and J. Liu, "Fake Financial News Detection with Deep Learning: Evidence from China," *Procedia Comput. Sci.*, vol. 221, pp. 154–160, 2023, doi: 10.1016/j.procs.2023.07.022.
- [21] M. Qorib, T. Oladunni, M. Denis, E. Ososanya, and P. Cotae, "Covid-19 vaccine hesitancy: Text mining, sentiment analysis and machine learning on COVID-19 vaccination Twitter dataset," *Expert*

*Syst. Appl.*, vol. 212, no. August 2022, p. 118715, 2023, doi: 10.1016/j.eswa.2022.118715.

- [22] F. Tempola, M. Muhammad, and A. Khairan, "Perbandingan Klasifikasi Antara Knn Dan Naive Bayes Pada Penentuan Status Gunung Berapi Dengan K-Fold Cross Validation," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 5, pp. 577–584, 2018, doi: 10.25126/jtiik20185983.