

# Perbandingan Pelabelan *Rating-based* dan Inset *Lexicon-based* dalam Analisis Sentimen Menggunakan SVM (Studi Kasus: Ulasan Aplikasi GoBiz di *Google Play Store*)

## *Comparison of Rating-based and Inset Lexicon-based Labeling in Sentiment Analysis using SVM (Case Study: GoBiz Application Reviews on Google Play Store)*

<sup>1</sup>Hiliah Firda, <sup>2</sup>Pacu Putra\*, <sup>3</sup>Nabila Rizky Oktadini, <sup>4</sup>Putri Eka Sevtyuni, <sup>5</sup>Putri Eka Sevtyuni

<sup>1,2,3,4,5</sup>Program Studi Sistem Informasi, Fakultas Ilmu Komputer, Universitas Sriwijaya  
<sup>1,2,3,4,5</sup>Jl. Palembang-Prabumulih, KM 32 Indralaya, Kabupaten Ogan Ilir, Sumatera Selatan,  
Indonesia

\*e-mail: [pacuputra@unsri.ac.id](mailto:pacuputra@unsri.ac.id)

(received: 12 November 2024, revised: 27 February 2025, accepted: 1 Maret 2025)

### Abstrak

Transformasi digital telah mempengaruhi berbagai sektor, termasuk Usaha Mikro, Kecil, dan Menengah (UMKM). Aplikasi GoBiz, sebagai platform mitra usaha Gojek untuk layanan GoFood, berperan dalam mendukung digitalisasi UMKM, sehingga penting untuk memahami persepsi pengguna terhadap aplikasi ini. Penelitian ini melakukan analisis sentimen terhadap 5.000 ulasan pengguna GoBiz dari Google Play Store. Penelitian ini membandingkan dua metode pelabelan, yaitu *Rating-based* dan Inset *Lexicon*, kemudian dievaluasi dengan algoritma *Support Vector Machine* (SVM). Proses analisis mencakup data *selection*, *text preprocessing*, data *transformation* menggunakan TF-IDF, penerapan SVM dengan *10-fold cross-validation*, serta visualisasi hasil melalui *wordcloud*. Hasil pengujian menunjukkan bahwa pelabelan *Rating-based* mendapatkan akurasi 87%, presisi 86,7%, recall 87,1%, dan *f1-score* 86,8%. Sementara itu, pelabelan Inset *Lexicon* mencapai akurasi 89,7%, presisi 89%, recall 89,8%, dan *f1-score* 89,3%. Temuan ini menunjukkan bahwa kombinasi metode pelabelan Inset *Lexicon* dan algoritma SVM lebih efektif dalam mengklasifikasikan sentimen ulasan pengguna serta memberikan pemahaman yang lebih akurat mengenai persepsi pengguna terhadap aplikasi GoBiz. Hasil analisis sentimen menunjukkan bahwa pengguna mengapresiasi kemudahan operasional GoBiz, namun menghadapi kendala pada layanan *driver* dan fitur iklan, sehingga aspek tersebut perlu diperbaiki untuk meningkatkan kepuasan pengguna.

**Kata kunci:** analisis sentimen, inset *lexicon*, *rating-based*, aplikasi GoBiz, *support vector machine*

### Abstract

Digital transformation has impacted various sectors, including Micro, Small, and Medium Enterprises (MSMEs). GoBiz, a partner platform for Gojek's GoFood service, plays a crucial role in supporting MSME digitalization, making it essential to understand user perceptions of the application. This study conducts sentiment analysis on 5,000 GoBiz user reviews from the Google Play Store. It compares two labeling methods—*Rating-Based* and *Inset Lexicon*—and evaluates them using the *Support Vector Machine* (SVM) algorithm. The analysis process includes data selection, text preprocessing, data transformation using TF-IDF, SVM implementation with *10-fold cross-validation*, and result visualization through word clouds. The findings indicate that the *Rating-Based* labeling method achieved an accuracy of 87%, with a precision of 86.7%, recall of 87.1%, and an *F1-score* of 86.8%. Meanwhile, the *Inset Lexicon* labeling method outperformed it, achieving an accuracy of 89.7%, precision of 89%, recall of 89.8%, and an *F1-score* of 89.3%. These results suggest that the combination of the *Inset Lexicon* labeling method and the SVM algorithm is more effective in classifying user sentiment and providing a more accurate understanding of user perceptions regarding the GoBiz application. Sentiment analysis results indicate that users appreciate

*GoBiz's ease of operation but face challenges with driver services and advertisement features, highlighting areas for improvement to enhance user satisfaction.*

**Keywords:** *sentiment analysis, inset lexicon, rating-based, GoBiz application, support vector machine*

## 1 Pendahuluan

Transformasi digital telah membawa dampak signifikan di berbagai sektor kehidupan, termasuk sektor perekonomian. Transformasi digital turut mendorong terciptanya ekonomi digital, yaitu kumpulan aktivitas ekonomi yang memanfaatkan teknologi digital dan komunikasi elektronik [1]. Pertumbuhan ekonomi digital di Indonesia pada tahun 2025 di prediksi akan mengalami kenaikan sebesar 15 persen dibandingkan tahun sebelumnya, dengan proyeksi nilai mencapai USD 109 miliar [2]. Tingginya potensi pertumbuhan ekonomi digital di Indonesia memberikan peluang kepada para pelaku Usaha Mikro, Kecil, dan Menengah (UMKM) untuk beradaptasi dan memperluas pasar mereka melalui transformasi digital.

Salah satu platform digital yang membantu UMKM melakukan transformasi digital adalah aplikasi GoBiz. Sebagai aplikasi mitra usaha Gojek, GoBiz dirancang untuk mendukung digitalisasi operasional UMKM, terutama dalam sektor kuliner melalui fitur GoFood yang memfasilitasi transaksi jual beli makanan secara online. Pada tahun 2024, aplikasi GoBiz telah diunduh sebanyak 5 juta kali dan memperoleh rating 4.1 dengan total 192 ribu ulasan pengguna di Google Play Store. Aplikasi ini memungkinkan UMKM mencatat pesanan secara digital, menawarkan beragam metode pembayaran, dan mengoptimalkan bisnis guna menarik lebih banyak pelanggan baru [3]. Platform GoBiz mencakup seluruh proses bisnis UMKM, dari pemasaran, pemesanan, pembayaran, pengiriman, hingga administrasi, sehingga mempermudah akses pelanggan, mempercepat proses pemesanan, dan mengurangi risiko kesalahan manusia, yang pada akhirnya meningkatkan efisiensi operasional dan pertumbuhan UMKM [4].

Meskipun transformasi digital menawarkan berbagai manfaat, tingkat adopsinya di kalangan UMKM di Indonesia masih relatif rendah. Berdasarkan data dari Kementerian Koordinator Bidang Perekonomian pada tahun 2023, terdapat sekitar 65 juta UMKM di Indonesia, namun hanya sekitar 27 juta yang telah beralih ke platform digital. Rendahnya tingkat adopsi ini dipengaruhi oleh berbagai faktor, seperti kesiapan teknologi yang terbatas dan tantangan dalam mengubah proses bisnis tradisional menjadi sistem digital [5].

Faktor di atas seperti banyaknya jumlah ulasan pengguna aplikasi GoBiz dan rendahnya tingkat adopsi teknologi pelaku UMKM menjadi dasar bagi penelitian ini untuk melakukan analisis sentimen terhadap pelaku UMKM yang menggunakan aplikasi GoBiz. Analisis sentimen adalah metode untuk mengevaluasi opini, sikap, dan perasaan yang diekspresikan dalam teks, dengan tujuan mengidentifikasi aspek kelemahan produk atau layanan sehingga kualitasnya dapat ditingkatkan [6][7].

Analisis sentimen dapat dilakukan dengan berbagai metode klasifikasi, salah satunya adalah metode *Support Vector Machine*, yang populer digunakan dalam klasifikasi teks. Penelitian [8] menunjukkan hasil kinerja SVM yang lebih unggul dibanding algoritma lain. Selain metode analisis sentimen pada tahap pelabelan juga dapat menggunakan berbagai pendekatan seperti *Inset lexicon based*, *Rating based*, *VADER sentiment*, dan *TextBlob* [9][10]. Pada *dataset* berbahasa Indonesia, pendekatan *Inset Lexicon* terbukti memberikan hasil yang lebih tinggi dalam mengklasifikasikan sentimen [9]. Sementara itu, pendekatan *Rating-based* digunakan karena memanfaatkan beragamnya rating yang diberikan oleh pengguna pada halaman ulasan [11].

Penelitian ini bertujuan untuk membandingkan dua pendekatan pelabelan sentimen, yaitu *Lexicon-based* dan *Rating-based*, guna meningkatkan akurasi analisis sentimen pengguna aplikasi GoBiz dengan menggunakan algoritma *Support Vector Machine*. Fokus utama penelitian ini adalah mengevaluasi efektivitas masing-masing pendekatan dalam merepresentasikan sentimen pengguna dan mengidentifikasi mana yang menghasilkan akurasi lebih tinggi. Penelitian ini diharapkan dapat meningkatkan kualitas aplikasi GoBiz berdasarkan umpan balik pengguna, pemahaman tentang persepsi pelaku UMKM, serta identifikasi kendala adopsi teknologi yang dapat ditangani untuk meningkatkan penerimaan aplikasi. Selain itu, temuan penelitian ini diharapkan dapat menjadi referensi untuk penelitian selanjutnya dalam bidang analisis sentimen dan kontribusi terhadap pengembangan teknologi yang lebih relevan di sektor UMKM.

## 2 Tinjauan Literatur

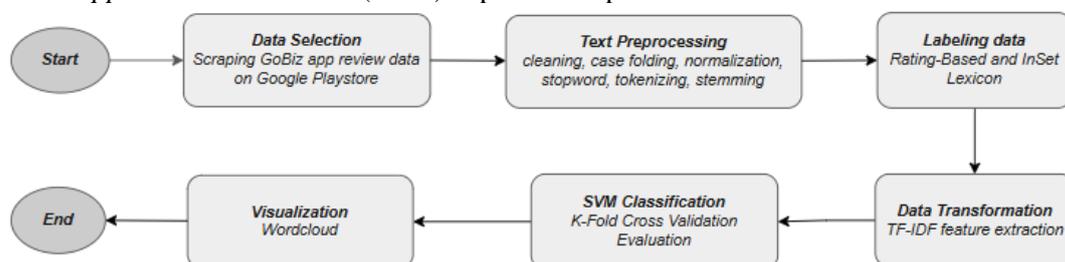
Penelitian mengenai analisis sentimen pada aplikasi digital telah banyak dilakukan untuk memahami persepsi pengguna dengan berbagai metode pelabelan dan algoritma. Misalnya, penelitian [12] yang menerapkan metode *Rating-based* dengan klasifikasi rating 1-3 sebagai sentimen negatif dan 4-5 sebagai sentimen positif pada ulasan aplikasi Shopee. Penelitian ini menunjukkan bahwa *Support Vector Machine* (SVM) bekerja sangat baik untuk analisis sentimen pengguna pada aplikasi Shopee, dengan akurasi sebesar 98%. Penelitian serupa [13] juga menggunakan fitur rating sebagai metode pelabelan sentimen pada aplikasi Maxim, Grab, dan Gojek. Hasilnya menunjukkan bahwa akurasi algoritma SVM berkisar antara 70% hingga 73%, dengan Maxim memiliki akurasi tertinggi di antara ketiga aplikasi tersebut. Sementara itu, penelitian [14] menggabungkan pelabelan manual dengan rating untuk analisis sentimen pada aplikasi Dana dan Ovo, yang menghasilkan akurasi sebesar 92% dan 90% menggunakan algoritma SVM.

Di sisi lain, beberapa penelitian fokus pada penggunaan *InSet Lexicon* dalam analisis sentimen. Penelitian [15] menggunakan *InSet Lexicon* untuk menganalisis sentimen aplikasi Gojek dan Grab dari data Twitter, dengan algoritma SVM, Random Forest, dan LSTM. Hasilnya menunjukkan bahwa SVM mencapai akurasi tertinggi, yakni 92% pada data Gojek, sementara LSTM dengan word embedding mencapai akurasi 91% pada data Grab. Studi lain pada aplikasi Google Translate menggunakan *InSet Lexicon* dan algoritma SVM menunjukkan akurasi sebesar 95% [16]. Penelitian [17] juga mengeksplorasi penggunaan *InSet Lexicon* pada opini pengguna platform X terhadap Ibu Kota Nusantara (IKN), dan menemukan bahwa SVM dengan penerapan SMOTE dan *5-fold cross-validation* menghasilkan akurasi tertinggi sebesar 87%.

Dari berbagai penelitian diatas, terlihat bahwa metode *Rating-based* dan *Inset Lexicon* telah digunakan secara luas dalam analisis sentimen aplikasi digital. Berbeda dari penelitian-penelitian terdahulu, penelitian ini akan membandingkan secara langsung performa metode pelabelan *Rating-based* dan *Inset Lexicon* dalam analisis sentimen aplikasi GoBiz menggunakan algoritma SVM. Validasi pengujian dalam penelitian ini akan dilakukan dengan *10-fold cross validation*. Diharapkan hasil penelitian ini dapat memberikan panduan yang lebih akurat tentang metode pelabelan yang optimal untuk analisis sentimen pada aplikasi dengan karakteristik pengguna yang beragam seperti GoBiz, serta membantu perusahaan dalam memahami persepsi pengguna secara lebih mendalam.

## 3 Metode Penelitian

Alur penelitian saat melakukan analisis sentimen pada ulasan aplikasi GoBiz di Google Play Store dengan membandingkan metode pelabelan *Rating-based* dan *Inset Lexicon* menggunakan algoritma *Support Vector Machine* (SVM) dapat dilihat pada Gambar 1.



Gambar 1. Alur penelitian

### 3.1 Data Selection

Pada tahapan ini dilakukan proses pengumpulan data dengan atribut yang telah di tentukan. Pengumpulan data dilakukan dengan metode web scraping pada laman aplikasi GoBiz di Google Playstore menggunakan library python google-play-scraper di Google Colaboratory. Teknik web scraping digunakan untuk mengambil data yang relevan dari sumber web [18].

Data yang dikumpulkan mencakup total 5.000 ulasan berbahasa Indonesia yang dipublikasikan dalam rentang waktu dari ulasan terbaru pada 28 September 2024 hingga ulasan paling lama pada 03 Desember 2023 dari pengguna aplikasi GoBiz. Sampel *dataset* dapat dilihat pada Tabel 1.

**Tabel 1. Data Selection**

No	Username	Content	Score
1		Sangat membantu umkm kecil sprti saya masih baru jualan di gofood alhamdulillah ada aja yg order ^â€¢^	5
...	...	...	...
5000	Aaron Putra	Biaya iklan nya itu Lo GK jelas. Bikin rugi pasang iklan aja engk	1

**3.2 Text Preprocessing**

*Text Preprocessing* adalah proses mempersiapkan data teks mentah menjadi data berkualitas untuk analisis berikutnya. Pada tahap ini data teks mentah akan diubah menjadi bentuk yang lebih baik sehingga menghasilkan informasi teks dengan kualitas yang baik dan siap digunakan pada proses selanjutnya [19].

Tahapan *Text Prepreprocessing* dilakukan agar lebih mudah dalam melakukan analisis lebih lanjut. Pada tahap ini, terdapat penggunaan library seperti Sastrawi, NLTK, dan library lainnya. *Text Preprocessing* dalam penelitian ini yaitu:

**3.2.1 Cleaning Data**

Tahapan untuk membersihkan data dari atribut yang tidak digunakan dalam penelitian [20]. Atribut seperti emoji dan tanda baca di hilangkan pada tahapan ini. Tabel 2 menunjukkan hasil tahap *cleansing data*.

**Tabel 2. Cleaning data**

Content	Cleaning data
Sangat membantu umkm kecil sprti saya masih baru jualan di gofood alhamdulillah ada aja yg order ^â€¢^	Sangat membantu umkm kecil sprti saya masih baru jualan di gofood alhamdulillah ada aja yg order
...	...
Biaya iklan nya itu Lo GK jelas. Bikin rugi pasang iklan aja engk	Biaya iklan nya itu Lo GK jelas Bikin rugi pasang iklan aja engk

**3.2.2 Case Folding**

Tahapan untuk mengubah huruf kapital dalam teks menjadi huruf kecil [21]. Tahap ini dilakukan untuk menghindari duplikasi kata dan menjaga konsistensi dalam analisis. Tabel 3 menunjukkan hasil tahap *case folding*.

**Tabel 3. Case folding**

Cleaning data	Case Folding
Sangat membantu umkm kecil sprti saya masih baru jualan di gofood alhamdulillah ada aja yg order	sangat membantu umkm kecil sprti saya masih baru jualan di gofood alhamdulillah ada aja yg order
...	...
Biaya iklan nya itu Lo GK jelas Bikin rugi pasang iklan aja engk	biaya iklan nya itu lo gk jelas bikin rugi pasang iklan aja engk

**3.2.3 Text Normalization**

Tahapan untuk mengubah kata tidak baku dalam teks menjadi kata yang sesuai dengan ejaan [22]. Tahap ini juga akan mempengaruhi hasil akhir data. Tabel 4 menunjukkan hasil tahap *text normalization*.

**Tabel 4. Text normalization**

Case Folding	Text Normalization
sangat membantu umkm kecil sprti saya masih baru jualan di gofood alhamdulillah ada aja yg order	sangat membantu umkm kecil seperti saya masih baru jualan di gofood alhamdulillah ada saja yang order
...	...
biaya iklan nya itu lo gk jelas bikin rugi pasang	biaya iklan nya itu lo tidak jelas bikin rugi

iklan aja engk	pasang iklan saja tidak
----------------	-------------------------

### 3.2.4 Remove StopWord

Tahapan untuk mengeliminasi kata-kata yang sering muncul namun tidak mengandung banyak informasi [23]. *Stopword* biasanya terdiri dari konjungsi dan preposisi. Tabel 5 menunjukkan hasil tahap *remove stopwords*.

**Tabel 5. Remove stopwords**

<i>Text Normalization</i>	<i>Remove Stopword</i>
sangat membantu umkm kecil seperti saya masih baru jualan di gofood alhamdulillah ada saja yang order	membantu umkm jualan gofood alhamdulillah ada order
...	...
biaya iklan nya itu lo tidak jelas bikin rugi pasang iklan saja tidak	biaya iklan nya lo bikin rugi pasang iklan

### 3.2.5 Tokenizing

Tahapan untuk mengubah rangkaian teks menjadi kata-kata atau token yang terpisah untuk mewakili teks tersebut [24]. Tokenisasi memudahkan untuk menganalisis konten dan mengidentifikasi pola yang tidak biasa. Tabel 6 menunjukkan hasil tahap *tokenizing*.

**Tabel 6. Tokenizing**

<i>Remove Stopword</i>	<i>Tokenizing</i>
membantu umkm jualan gofood alhamdulillah order	['membantu', 'umkm', 'jualan', 'gofood', 'alhamdulillah', 'order']
...	...
biaya iklan nya lo bikin rugi pasang iklan	['biaya', 'iklan', 'nya', 'lo', 'bikin', 'rugi', 'pasang', 'iklan']

### 3.2.6 Stemming

Tahapan untuk mengubah kata ke dalam bentuk dasarnya [24]. Stemming membantu untuk mengenali bahwa suatu kata menyampaikan makna dan sentimen yang sama meskipun memiliki bentuk yang berbeda. Tabel 7 menunjukkan hasil tahap *stemming*.

**Tabel 7. Stemming**

<i>Tokenizing</i>	<i>Stemming</i>
['membantu', 'umkm', 'jualan', 'gofood', 'alhamdulillah', 'order']	['bantu', 'umkm', 'jual', 'gofood', 'alhamdulillah', 'order']
...	...
['biaya', 'iklan', 'nya', 'lo', 'bikin', 'rugi', 'pasang', 'iklan']	['biaya', 'iklan', 'nya', 'lo', 'bikin', 'rugi', 'pasang', 'iklan']

## 3.3 Pelabelan Data

Pelabelan dalam analisis sentimen adalah proses untuk mengklasifikasikan data berdasarkan kategori sentimen seperti positif dan negatif. Proses ini membantu model *machine learning* memahami dan mengelompokkan data berdasarkan kategori yang telah ditentukan. Penelitian ini menggunakan dua pendekatan pelabelan yaitu:

### 3.3.1 Rating-based

*Rating-based* memanfaatkan penilaian berupa rating yang diberikan pengguna dalam ulasan aplikasi. Adanya rating sebagai indikator kepuasan pengguna memungkinkan interpretasi yang lebih mendalam [11]. Oleh karena itu, dalam penelitian ini digunakan pendekatan pelabelan *Rating-based*, di mana rating 1-3 dikategorikan sebagai negatif, dan rating 4-5 dikategorikan sebagai positif

### 3.3.2 Inset Lexicon

Inset *Lexicon* atau Kamus Inset merupakan kumpulan kata berbahasa Indonesia dengan nilai tertentu pada setiap kata, yang disusun oleh Fajri Koto dan Gemala Y. Rahmaningtyas. Dalam proses pelabelan, Inset *Lexicon* dibagi menjadi dua kategori nilai, yaitu *InSetPos* yang mencakup total skor

kata-kata positif dan *InSetNeg* yang mencakup total skor kata-kata negatif dalam kamus. Inset *Lexicon* memiliki 3.609 kata positif dan 6.609 kata negatif dengan rentang skor antara -5 hingga +5 [25].

### 3.4 Data Transformation

*Term Frequency-Inverse Document Frequency* (TF-IDF) adalah metode untuk menilai pentingnya suatu kata dalam sebuah dokumen dalam konteks seluruh koleksi dokumen. TF (*Term Frequency*) mengukur seberapa sering kata muncul dalam sebuah dokumen, sedangkan IDF (*Inverse Document Frequency*) mengukur seberapa unik atau jarang kata tersebut di seluruh koleksi dokumen [26]. Rumus TF-IDF ditunjukkan pada persamaan 1.

$$W_{(t,d)} = W_{tf(t,d)} \times idf_t \quad (1)$$

Keterangan:

$W_{(t,d)}$ : Bobot TF-IDF

$W_{tf(t,d)}$ : Bobot kata dalam setiap dokumen

$idf_t$ : Bobot Inverse Document Frequency dari nilai ( $\log(N/df)$ )

N: Jumlah seluruh dokumen

df: Jumlah dokumen yang mengandung term

### 3.5 SVM Classification

Pada tahapan ini dilakukan implementasi algoritma *Support Vector Machine* untuk mengelompokkan data ke dalam kelas yang telah ditentukan. Klasifikasi dilakukan dengan *Hyperplane* yang membedakan antara kelas positif dan negatif [27]. Klasifikasi dengan metode SVM memanfaatkan library *sklearn.svm*. Penelitian ini menerapkan kernel SVM linear untuk melakukan klasifikasi teks. Rumus sederhana SVM dapat dilihat pada persamaan 2.

$$f(x) = w \times x + b \quad (2)$$

Keterangan:

$f(x)$ : Fungsi keputusan yang menentukan apakah data termasuk dalam kelas tertentu.

$w$ : Vektor bobot (*weight vector*) yang menentukan kemiringan atau arah *hyperplane*.

$x$ : Vektor fitur input.

$b$ : Bias, konstanta yang menggeser garis atau *hyperplane* agar lebih sesuai dengan data.

Selain itu tahapan ini juga menggunakan library *sklearn.metrics* untuk mengukur kinerja model klasifikasi SVM. Pengukuran kinerja model diketahui berdasarkan *confusion matrix* yang nantinya akan menghasilkan akurasi, presisi, recall, dan f1-score [28]. Rumus pengukuran dapat dilihat pada persamaan 3 hingga 6.

Akurasi, merupakan ukuran seberapa besar kesesuaian nilai antara nilai aktual dan hasil prediksi klasifikasi, baik untuk kelas positif maupun negatif.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

Presisi, merupakan ketepatan model dalam memprediksi nilai positif yang benar.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

*Recall*, merupakan kemampuan model untuk memprediksi nilai positif dari semua nilai aktual yang benar-benar positif.

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

*F1-Score*, merupakan rata-rata antara presisi dan recall yang menunjukkan bahwa semakin mendekati nilai satu, semakin baik model dalam melakukan klasifikasi.

$$F1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

Keterangan :

- True Positive* (TP): Data diprediksi positif, dan prediksinya benar.  
*True Negative* (TN): Data diprediksi negatif, dan prediksinya benar.  
*False Positive* (FP): Data diprediksi positif, tetapi prediksinya salah.  
*False Negative* (FN): Data diprediksi negatif, tetapi prediksinya salah.

### 3.6 Visualization

Tahapan ini merupakan tahap terakhir dalam penelitian ini yang berisi visualisasi dari data ulasan yang ada. Wordcloud adalah representasi visual dari kata-kata yang sering muncul dalam sebuah teks, di mana ukuran kata menunjukkan frekuensi atau kepentingannya. Frekuensi kata mempengaruhi ukuran kata yang ditampilkan pada wordcloud [29]. Tahapan ini dapat membantu dalam representasi hasil analisis sentimen.

## 4 Hasil dan Pembahasan

*Dataset* yang telah melalui tahap *Text Preprocessing* akan dianalisis lebih lanjut. Tahapan selanjutnya mencakup pelabelan data menggunakan metode *Rating-based* dan Inset *Lexicon*, transformasi fitur melalui TF-IDF, serta klasifikasi model menggunakan SVM. Selain itu, hasil analisis sentimen juga akan di visualisasikan melalui pembuatan Wordcloud.

### 4.1 Pelabelan Data

Pelabelan data dilakukan dengan dua metode yang berbeda, yaitu *Rating-based* dan Inset *Lexicon*. Setiap metode pelabelan memiliki pendekatan yang berbeda dalam mengkategorikan sentimen teks sebagai positif atau negatif.

#### 4.1.1 *Rating-based*

Metode *Rating-based* memberikan label sentimen berdasarkan skor rating yang disediakan dalam data. Dalam pendekatan ini, teks dengan skor rating lebih tinggi seperti 4-5 dilabeli sebagai "Positif," sementara teks dengan skor rendah dilabeli seperti 1-3 dilabeli sebagai "Negatif." Proses pelabelan untuk metode *Rating-based* dapat dilihat pada Tabel 8.

**Tabel 8. Proses pelabelan *rating-based***

Content	Score	Label
['bantu', 'umkm', 'jual', 'gofood', 'alhamdulillah', 'order']	5	Positif
...	...	...
['biaya', 'iklan', 'nya', 'lo', 'bikin', 'rugi', 'pasang', 'iklan']	1	Negatif

Setelah proses pelabelan dilakukan, Tabel 8 menunjukkan distribusi label pada seluruh data, terdapat 2829 data sentimen positif dan 2169 data sentimen negatif.

#### 4.1.2 Inset *Lexicon*

Metode Inset *Lexicon* menggunakan pendekatan berbeda, di mana polaritas sentimen ditentukan berdasarkan skor leksikon kata-kata dalam teks. Jika skor keseluruhan teks >0 maka teks dilabeli sebagai "Positif", sedangkan jika skor keseluruhan <0 maka teks dilabeli sebagai "Negatif." Proses pelabelan menggunakan Inset *Lexicon* dapat dilihat pada Tabel 9.

**Tabel 9. Proses pelabelan inset *lexicon***

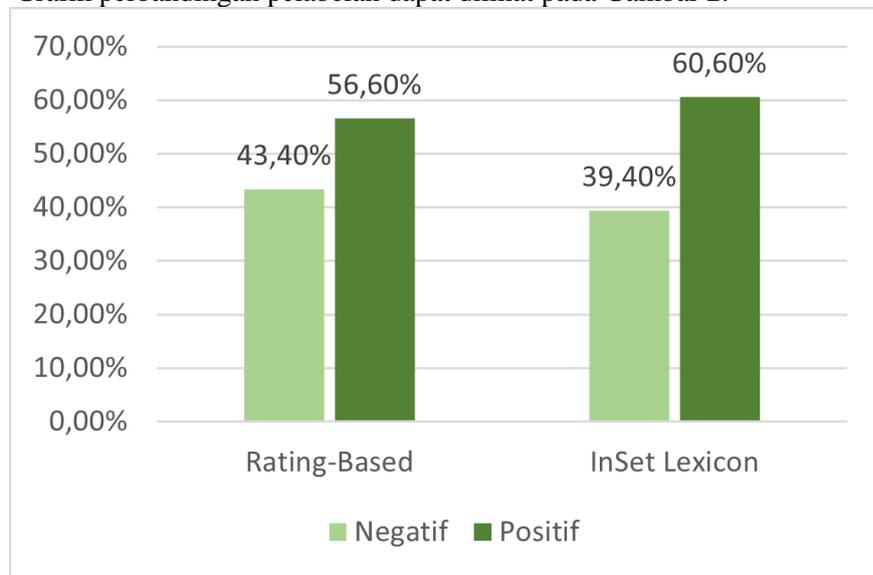
Content	Polaritas		Label
	InsetPos	InsetNeg	
['bantu', 'umkm', 'jual', 'gofood', 'alhamdulillah', 'order']	9	0	Positif
...	...	...	...
['biaya', 'iklan', 'nya', 'lo', 'bikin', 'rugi', 'pasang', 'iklan']	4	-5	Negatif

'iklan']

Hasil distribusi label pada Tabel 9, menunjukkan bahwa pada metode Inset *Lexicon*, terdapat 3029 data sentimen positif dan 1971 data sentimen negatif.

#### 4.1.3 Perbandingan Distribusi Label antara Metode *Rating-based* dan InSet *Lexicon*

Terdapat perbedaan distribusi label antara metode *Rating-based* dan InSet *Lexicon*. Pada metode *Rating-based*, proporsi label positif sedikit lebih rendah yaitu 56,6% dibandingkan dengan InSet *Lexicon* yang menunjukkan 60,6% label positif. Sebaliknya, proporsi label negatif lebih tinggi pada metode *Rating-based* sebesar 43,4% sementara pada InSet *Lexicon* label negatif berkurang menjadi 39,4%. Grafik perbandingan pelabelan dapat dilihat pada Gambar 2.



Gambar 2. Grafik Perbandingan Pelabelan *Rating-based* dan Inset *Lexicon*

Perbedaan ini menunjukkan bahwa kedua metode memiliki karakteristik masing-masing dalam menentukan polaritas. Metode *Rating-based* lebih mengandalkan skor dari pengguna, sedangkan Inset *Lexicon* melihat polaritas dari kandungan leksikal dalam teks ulasan. Perbedaan ini dapat memberikan perspektif tambahan tentang bagaimana tiap metode menangkap sentimen pengguna.

Berdasarkan Gambar 2, grafik perbandingan pelabelan menunjukkan ketidakseimbangan distribusi label yang dapat berpengaruh terhadap performa model *Support Vector Machine* (SVM), terutama dalam memprediksi kelas minoritas. Model yang dilatih pada data yang tidak seimbang cenderung lebih sering mengklasifikasikan data ke dalam kelas mayoritas, yang dapat menyebabkan bias klasifikasi (*misclassification bias*). Namun, penelitian ini tetap mempertahankan kondisi ini karena penggunaan teknik penyeimbangan data juga dapat meningkatkan kompleksitas model seperti *overlapping* tanpa peningkatan yang signifikan dalam performa model [30].

#### 4.2 Data Transformation

Tahap ini bertujuan untuk mengubah data teks menjadi bentuk numerik agar dapat di proses oleh model klasifikasi. Penerapan metode TF-IDF (*Term Frequency-Inverse Document Frequency*) dalam pembobotan kata pada teks bertujuan menilai pentingnya suatu kata dalam sebuah dokumen dalam konteks seluruh dokumen. Hasil Matriks TF-IDF ditunjukkan pada Gambar 3.

(0, 3313)	0.4955300482952277
(0, 5059)	0.6225623012935635
(0, 2738)	0.6056947682162951
(1, 306)	0.44528111224938427
(1, 3238)	0.32495511123969095
(1, 5357)	0.19735883905516152
(1, 430)	0.20976410997710512
(1, 1817)	0.31273516273843605
(1, 2108)	0.395102536665487
(1, 279)	0.1648421192348525
(1, 2618)	0.48323973933202663

**Gambar 3. Matriks TF-IDF**

Berdasarkan Gambar 3, terdapat nilai TF-IDF untuk berbagai kata di beberapa dokumen. Kolom pertama menunjukkan indeks dokumen dan kata. Kolom kedua menunjukkan skor TF-IDF untuk pasangan dokumen-kata tersebut. Misalnya, 0 mengacu pada dokumen pertama dalam *dataset*, 3313 adalah nomor indeks kata yang berasal dari pemrosesan teks sebelumnya, dan 0.4955 merupakan hasil skor TF-IDF. Skor yang lebih tinggi menunjukkan kata yang lebih penting dalam dokumen tersebut.

### 4.3 SVM Classification

Setelah pembobotan kata menggunakan TF-IDF, evaluasi dilakukan terhadap algoritma *Support Vector Machine* (SVM) dengan menggunakan dua metode pelabelan, yaitu *Rating-based* dan *Inset Lexicon*. Pengujian ini menggunakan *10-fold cross validation* untuk memastikan performa yang optimal. Pengujian pertama dilakukan dengan implementasi SVM dan metode pelabelan *Rating-based*. Tabel 10 merupakan hasil evaluasi dari metode pelabelan *Rating-based* dengan SVM menggunakan *10-fold cross validation*.

**Tabel 10. Hasil evaluasi SVM dan *rating-based***

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Fold-1</i>	87,4%	87,1%	87,2%	87,2%
<i>Fold-2</i>	87%	86,6%	87,1%	86,8%
<i>Fold-3</i>	87,2%	86,9%	87,2%	87%
<i>Fold-4</i>	87,6%	87,2%	87,2%	87,2%
<b><i>Fold-5</i></b>	<b>88,4%</b>	<b>88,1%</b>	<b>88,3%</b>	<b>88,2%</b>
<i>Fold-6</i>	87,4%	87,2%	87,6%	87,3%
<i>Fold-7</i>	87%	86,8%	87,1%	86,9%
<i>Fold-8</i>	85%	84,7%	85,8%	84,8%
<i>Fold-9</i>	86,1%	85,8%	86%	85,9%
<i>Fold-10</i>	87,1%	86,9%	87,3%	87%
<b><i>Mean</i></b>	<b>87%</b>	<b>86,7%</b>	<b>87,1%</b>	<b>86,8%</b>

Berdasarkan pengujian pada Tabel 10, akurasi tertinggi diperoleh pada *Fold-5* dengan nilai 88,4%. Adapun performa rata-rata dari seluruh *fold* menghasilkan akurasi sebesar 87% dengan *precision*, *recall*, dan *F1-score* yang konsisten. Tabel 11 menunjukkan *confusion matrix* rata-rata untuk model SVM dengan metode *Rating-based*.

**Tabel 11. *Confusion matrix* rata-rata SVM dan *rating-based***

<i>Actual</i>	<i>Prediction Class</i>	
	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	244	38
<i>Negative</i>	26	190

Berdasarkan Tabel 11, penggunaan SVM dan *Rating-based* menunjukkan kemampuan yang baik dalam mengklasifikasikan data, meskipun masih terdapat beberapa kesalahan prediksi. Sebanyak 26 ulasan negatif keliru diklasifikasikan sebagai positif (*false positive*), yang berpotensi menyebabkan ulasan dianggap baik, padahal sebenarnya masih ada keluhan dari pengguna. Selain itu, terdapat 38

ulasan positif yang salah dikenali sebagai negatif (*false negative*), yang dapat menyebabkan aspek-aspek yang sebenarnya mendapat *respons* baik justru dinilai kurang memuaskan.

Hal ini disebabkan oleh keterbatasan metode pelabelan *Rating-based* yang hanya bergantung pada skor keseluruhan dan tidak selalu menggambarkan sentimen yang akurat dalam setiap kalimat. Selanjutnya, pengujian kedua dilakukan dengan mengimplementasikan SVM dan metode pelabelan Inset *Lexicon*. Tabel 12 menyajikan hasil evaluasi dari metode pelabelan Inset *Lexicon* menggunakan 10-fold cross validation.

**Tabel 12. Hasil evaluasi SVM dan inset lexicon**

<i>Fold</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Fold-1</i>	89%	87,9%	89,7%	88,5%
<i>Fold-2</i>	88,4%	87,9%	88,4%	88,1%
<i>Fold-3</i>	90,2%	89,3%	90,3%	89,7%
<i>Fold-4</i>	89,8%	89,2%	90%	89,5%
<i>Fold-5</i>	90,4%	89,6%	90%	90%
<i>Fold-6</i>	90,2%	89,2%	90%	89,7%
<i>Fold-7</i>	89,6%	89,2%	89,6%	89,4%
<i>Fold-8</i>	88,8%	88,2%	88,9%	88,5%
<i>Fold-9</i>	90%	89,2%	89,7%	89,4%
<b><i>Fold-10</i></b>	<b>91,2%</b>	<b>90,7%</b>	<b>90,6%</b>	<b>90,6%</b>
<b><i>Mean</i></b>	<b>89,7%</b>	<b>89%</b>	<b>89,8%</b>	<b>89,3%</b>

Berdasarkan pengujian pada Tabel 12, akurasi tertinggi diperoleh pada *Fold-10* dengan nilai 91,2%. Adapun performa rata-rata dari seluruh *fold* menghasilkan akurasi sebesar 89,7% dengan *precision*, *recall*, dan *F1-score* yang konsisten. Tabel 13 menunjukkan *confusion matrix* rata-rata untuk model SVM dengan metode Inset *Lexicon*.

**Tabel 13. Confusion matrix rata-rata SVM dan inset lexicon**

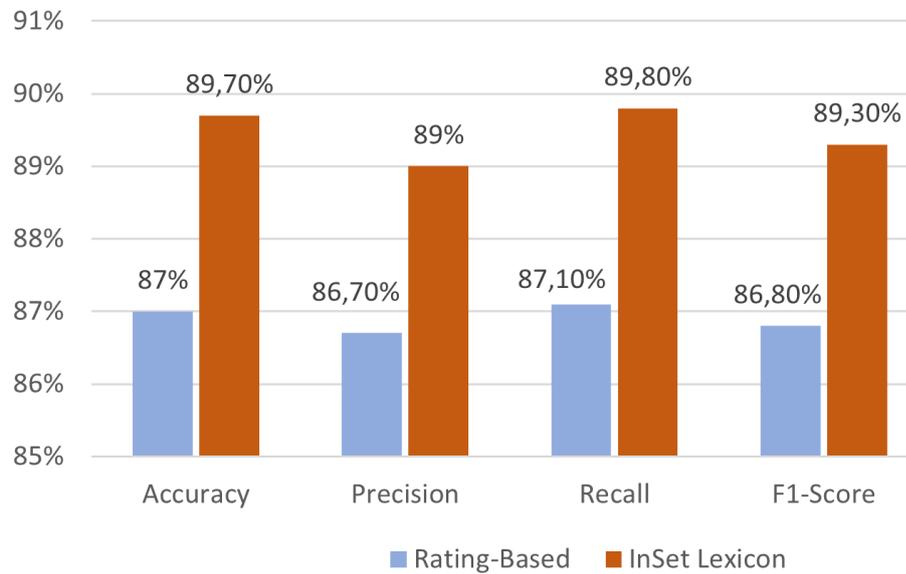
<i>Actual</i>	<i>Prediction Class</i>	
	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	271	31
<i>Negative</i>	19	177

Berdasarkan Tabel 13, model SVM dengan pelabelan Inset *Lexicon* menunjukkan kinerja yang lebih baik. Namun, masih terdapat beberapa kesalahan prediksi yang perlu diperhatikan. Sebanyak 19 ulasan negatif keliru diklasifikasikan sebagai positif (*false positive*), jumlah yang lebih rendah dibandingkan metode *Rating-based*, menunjukkan bahwa Inset *Lexicon* lebih baik dalam mengidentifikasi ulasan negatif dengan benar. Selain itu, terdapat 31 ulasan positif yang salah dikenali sebagai negatif (*false negative*), yang juga lebih sedikit dibandingkan metode *Rating-based*, yang menunjukkan bahwa model memiliki peningkatan dalam mengenali ulasan positif secara lebih tepat. Kesalahan prediksi dapat disebabkan oleh adanya kalimat dengan karakteristik yang kompleks atau ambigu, yang sulit untuk diprediksi dengan akurat oleh Inset *Lexicon*.

#### 4.3.1 Perbandingan Klasifikasi SVM

Secara keseluruhan, metode Inset *Lexicon* memberikan hasil yang lebih baik dibandingkan metode *Rating-based*, baik dalam hal akurasi, presisi, recall, maupun F1-skor. Rata-rata akurasi meningkat sekitar 2,7% dengan metode Inset *Lexicon*, yang menunjukkan peningkatan yang cukup berarti dalam performa klasifikasi.

Keunggulan ini disebabkan oleh kemampuan metode Inset *Lexicon* dalam menangkap nuansa sentimen yang lebih kompleks, relevansi fitur leksikalnya terhadap bahasa Indonesia, serta evaluasi polaritas kata secara spesifik. Berbeda dengan *Rating-based*, yang hanya mengandalkan skor pengguna yang subjektif, Inset *Lexicon* lebih efektif dalam merefleksikan makna sebenarnya dari ulasan. Grafik perbandingan hasil klasifikasi SVM dapat dilihat pada Gambar 4.

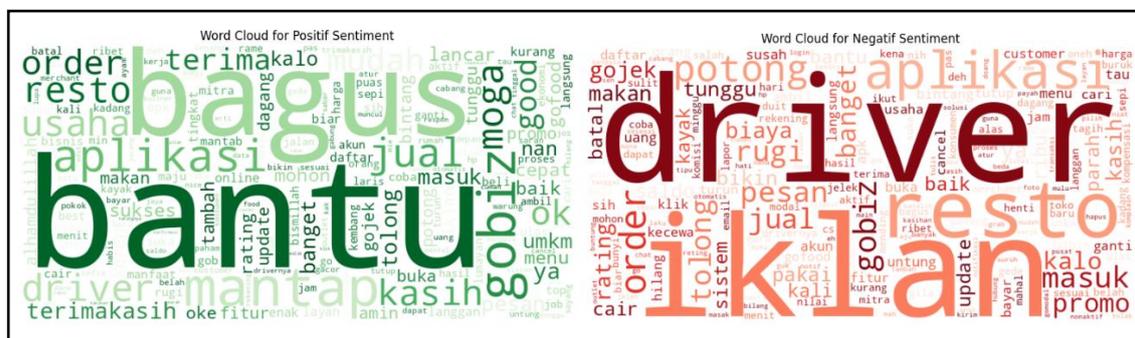


**Gambar 4. Grafik Perbandingan Hasil Klasifikasi SVM**

Berdasarkan Gambar 4, hasil ini menunjukkan bahwa untuk aplikasi yang memerlukan analisis sentimen yang lebih mendalam, seperti analisis ulasan atau media sosial, metode *InSet Lexicon* lebih disarankan dibandingkan metode *Rating-based*. Temuan ini sejalan dengan penelitian [31] yang menunjukkan bahwa pendekatan berbasis leksikon dapat memberikan hasil yang lebih optimal dibandingkan metode berbasis rating dalam berbagai konteks analisis sentimen. Dengan demikian, kombinasi metode *InSet Lexicon* dan SVM dapat menjadi alternatif yang lebih efektif dalam meningkatkan akurasi analisis sentimen serta mengurangi kesalahan klasifikasi, terutama dalam studi yang melibatkan bahasa Indonesia.

#### 4.4 Visualization

Tahapan terakhir yaitu visualisasi hasil analisis sentimen dengan *wordcloud*. *Wordcloud* menampilkan kata-kata bermakna yang paling sering muncul dalam teks berdasarkan frekuensi kemunculan kata setelah melalui tahap *preprocessing*, seperti *remove stopword*, *tokenizing*, dan *stemming*. Pemilihan kata dalam *wordcloud* didasarkan pada kemunculan tertinggi setelah proses tersebut, sehingga kata-kata yang ditampilkan merepresentasikan pola sentimen dominan dalam ulasan pengguna. Hasil visualisasi *wordcloud* pada aplikasi GoBiz dapat dilihat pada Gambar 5.



**Gambar 5. Visualisasi Wordcloud Positif dan Negatif**

Berdasarkan Gambar 5, *wordcloud* pada sentimen positif didominasi kata "bantu" dan "bagus", yang menunjukkan bahwa mayoritas ulasan pengguna mengapresiasi manfaat aplikasi GoBiz, terutama dalam hal kemudahan operasional bisnis dan peningkatan efisiensi layanan. Temuan ini menunjukkan bahwa GoBiz memiliki fitur yang memberikan bantuan nyata kepada pengguna, seperti dukungan operasional bisnis dan peningkatan kualitas layanan.

Sementara itu, pada *wordcloud* sentimen negatif, kata "driver" dan "iklan" lebih mendominasi, yang mengindikasikan bahwa pengguna mengalami kendala dalam memperoleh layanan *driver* serta merasa terganggu dengan fitur iklan dalam aplikasi. Temuan ini menunjukkan bahwa aspek

ketersediaan *driver* dan pengalaman pengguna terhadap fitur iklan, menjadi aspek penting yang perlu diperbaiki untuk meningkatkan kepuasan pelanggan.

## 5 Kesimpulan

Berdasarkan hasil pengujian, penelitian ini memanfaatkan ulasan aplikasi GoBiz di Google Play Store untuk menganalisis opini pengguna, dengan membandingkan metode pelabelan *Rating-based* dan Inset *Lexicon* menggunakan algoritma *Support Vector Machine* (SVM). Hasil yang diperoleh menunjukkan bahwa metode pelabelan *Rating-based* mencapai akurasi 87%, presisi 86,7%, recall 87,1%, dan *f1-score* 86,8%, sementara pelabelan Inset *Lexicon* mampu meningkatkan akurasi klasifikasi menjadi 89,7%. Selain akurasi, metode Inset *Lexicon* juga memiliki presisi, recall, dan *f1-score* yang lebih tinggi dibandingkan *Rating-based*, masing-masing mencapai 89%, 89,8%, dan 89,3%. Metode Inset *Lexicon* berhasil mengidentifikasi 3029 sentimen dan 1971 sentimen negatif. Hasil ini menunjukkan bahwa metode Inset *Lexicon* lebih efektif dalam mengklasifikasikan sentimen ulasan, terutama dalam mendeteksi sentimen yang mungkin tidak sesuai dengan rating pengguna, seperti ulasan berisi kritik namun memiliki rating tinggi. Penggunaan Inset *Lexicon* yang dirancang dalam bahasa Indonesia terbukti lebih relevan dalam menangkap karakteristik sentimen lokal, sehingga memberikan ketepatan yang lebih tinggi dalam analisis sentimen.

Hasil penelitian ini juga memberikan rekomendasi bagi pengembangan aplikasi GoBiz, khususnya dalam meningkatkan efektivitas layanan, seperti ketersediaan *driver* dan pengalaman pengguna terhadap fitur iklan, yang menjadi perhatian utama dalam ulasan negatif. Sebagai saran untuk penelitian selanjutnya, disarankan untuk mengeksplorasi penggunaan algoritma lain, seperti *Random Forest* atau *deep learning* seperti LSTM (*Long Short-Term Memory*), serta memanfaatkan dataset yang lebih besar untuk meningkatkan performa model. Selain itu, metode *balancing* seperti SMOTE juga dapat diterapkan untuk mengatasi ketidakseimbangan data dan mendukung optimalisasi model.

## Referensi

- [1] L. Xia, S. Baghaie, and S. M. Sajadi, "The Digital Economy: Challenges and Opportunities in the New Era of Technology and Electronic Communications," *Ain Shams Engineering Journal*, vol. 15, no. 2, p. 102411, Feb. 2024, doi: 10.1016/J.ASEJ.2023.102411.
- [2] Google, Temasek, and Bain & Company, "E-Conomy SEA 2023," 2023. [Online]. Available: <https://www.bain.com/insights/e-conomy-sea-2023/>
- [3] GoBiz, "Solusi Terbaik untuk Kelola Bisnis Anda." [Online]. Available: <https://gobiz.co.id/>
- [4] D. E. B. Jabat, L. L. Tarigan, M. Purba, and M. Purba, "Pemanfaatan Platform E-Commerce melalui Marketplace sebagai Upaya Peningkatan Penjualan," *Skylandsea Profesional Jurnal Ekonomi, Bisnis Dan Teknologi*, vol. 2, no. 2, pp. 16–21, 2022.
- [5] A. Awaluddin, "Pengenalan Integritas Aplikasi Digital dalam Meningkatkan Kinerja Bisnis sebagai Upaya Mengefektifkan Manajemen," *Jurnal Syntax Admiration*, vol. 5, no. 1, pp. 65–72, 2024.
- [6] M. Wankhade, C. Kulkarni, and A. C. S. Rao, "A Survey on Aspect base Sentiment Analysis Methods and Challenges," *Appl Soft Comput*, vol. 167, p. 112249, Dec. 2024, doi: 10.1016/J.ASOC.2024.112249.
- [7] C. Dervenis, G. Kanakis, and P. Fitsilis, "Sentiment Analysis of Student Feedback: A Comparative Study Employing Lexicon and Machine Learning Techniques," *Studies in Educational Evaluation*, vol. 83, p. 101406, Dec. 2024, doi: 10.1016/J.STUEDUC.2024.101406.
- [8] J. Iskandar and Y. Nataliani, "Perbandingan Naive Bayes, SVM, dan K-NN untuk Analisis Sentimen Gadget berbasis Aspek," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, pp. 1120–1126, Dec. 2021, doi: 10.29207/resti.v5i6.3588.
- [9] M. F. N. Fathoni, E. Y. Puspaningrum, and A. N. Sihananto, "Perbandingan Performa Labeling Lexicon InSet dan VADER pada Analisa Sentimen Rohingya di Aplikasi X dengan SVM," *Modem: Jurnal Informatika dan Sains Teknologi.*, vol. 2, no. 3, pp. 62–76, 2024.

- [10] F. Y. Dharta, A. J. Mahardhani, S. R. Yahya, A. Dirsa, and E. M. Usulu, "Application of Naïve Bayes Classifier Method to Analyze Social Media User Sentiment Towards the Presidential Election Phase," *Jurnal Informasi dan Teknologi*, pp. 176–181, 2024.
- [11] S. A. H. Bahtiar, C. K. Dewa, and A. Luthfi, "Comparison of Naive Bayes and Logistic Regression in Sentiment Analysis on Marketplace Reviews using Rating-Based Labeling," *Journal of Information Systems and Informatics*, vol. 5, no. 3, pp. 915–927, 2023.
- [12] I. S. K. Idris, Y. A. Mustofa, and I. A. Salihi, "Analisis Sentimen terhadap Penggunaan Aplikasi Shopee menggunakan Algoritma Support Vector Machine (SVM)," *Jambura Journal of Electrical and Electronics Engineering*, vol. 5, no. 1, pp. 32–35, 2023.
- [13] D. Nugraha and D. Gustian, "Analisis Sentimen Penggunaan Aplikasi Transportasi Online pada Ulasan Google Play Store dengan Metode Naive Bayes Classifier," *Kesatria: Jurnal Penerapan Sistem Informasi (Komputer dan Manajemen)*, vol. 5, no. 1, pp. 326–335, 2024.
- [14] R. A. L. A. Renal and S. Alam, "Komparasi Payment Digital untuk Analisis Sentimen berdasarkan Ulasan di Google Playstore menggunakan Metode Support Vector Machine," *STORAGE: Jurnal Ilmiah Teknik dan Ilmu Komputer*, vol. 2, no. 3, pp. 118–128, 2023.
- [15] S. S. Maulidah, "Analisis Sentimen terhadap Brand Reputation Super Apps Gojek dan Grab di Indonesia menggunakan Algoritma Machine Learning," UIN Syarif Hidayatullah, Jakarta, 2024. [Online]. Available: <https://repository.uinjkt.ac.id/dspace/handle/123456789/76407>
- [16] S. A. Ashari, M. W. A. Saputra, E. Larosa, and B. S. Rijal, "Analisis Sentimen pada Aplikasi Translate Google menggunakan Metode SVM (Studi Kasus: Komentar pada Play Store)," *Jurnal Teknik*, vol. 21, no. 2, pp. 168–182, 2023.
- [17] P. Cahyani and L. Abdillah, "Perbandingan Performa Algoritma Naive Bayes, SVM, dan Random Forest: Studi Kasus Analisis Sentimen Pengguna Sosial Media X," *KALBIScientia Jurnal Sains dan Teknologi*, vol. 11, no. 02, pp. 12–21, 2024.
- [18] V. Pichiyan, S. Muthulingam, G. Sathar, S. Nalajala, A. Ch, and M. N. Das, "Web Scraping using Natural Language Processing: Exploiting Unstructured Text for Data Extraction and Analysis," *Procedia Comput Sci*, vol. 230, pp. 193–202, Jan. 2023, doi: 10.1016/J.PROCS.2023.12.074.
- [19] S. Khairunnisa, A. Adiwijaya, and S. Al Faraby, "Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19)," *Jurnal Media Informatika Budidarma*, vol. 5, no. 2, pp. 406–414, 2021.
- [20] M. R. Hanafi and R. K. R, "Analisis Sentimen pada Ulasan Aplikasi Sirekap di Google Play menggunakan Algoritma Naive Bayes," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1578–1586, 2024.
- [21] N. Saad, A. Abidi, Z. Yaacod, M. Ali, and K. Zhu, "Twitter Sentiment Analysis on Meta: a Lexicon-based Analysis using RapidMiner," *International Journal on Recent and Innovation Trends in Computing and Communication*, vol. 11, pp. 259–270, Jul. 2023, doi: 10.17762/ijritcc.v11i6.7561.
- [22] S. Fransiska, R. Rianto, and A. I. Gufroni, "Sentiment Analysis Provider by U on Google Play Store Reviews with TF-IDF and Support Vector Machine (SVM) Method," *Scientific Journal of Informatics*, vol. 7, no. 2, pp. 203–212, 2020.
- [23] A. V. D. Sano, A. A. Stefanus, E. D. Madyatmadja, H. Nindito, A. Purnomo, and C. P. M. Sianipar, "Proposing a Visualized Comparative Review Analysis Model on Tourism Domain using Naive Bayes Classifier," *Procedia Comput Sci*, vol. 227, pp. 482–489, Jan. 2023, doi: 10.1016/J.PROCS.2023.10.549.
- [24] M. Tajrian, A. Rahman, M. A. Kabir, and M. R. Islam, "Analysis of Child Development Facts and Myths using Text Mining Techniques and Classification Models," *Heliyon*, vol. 10, no. 17, p. e36652, Sep. 2024, doi: 10.1016/J.HELIYON.2024.E36652.
- [25] F. Koto and G. Y. Rahmaningtyas, "Inset Lexicon: Evaluation of a Word List for Indonesian Sentiment Analysis in Microblogs," in *2017 International Conference on Asian Language Processing (IALP)*, 2017, pp. 391–394. doi: 10.1109/IALP.2017.8300625.
- [26] P. A. Henríquez and F. Alessandri, "Analyzing Digital Societal Interactions and Sentiment Classification in Twitter (X) during Critical Events in Chile," *Heliyon*, vol. 10, no. 12, p. e32572, 2024, doi: <https://doi.org/10.1016/j.heliyon.2024.e32572>.

- [27] S. N. Rismanah, R. Astuti, and F. M. Basysyar, “Penerapan *Algoritma Support Vector Machine* dalam menganalisis Sentimen Ulasan Pelanggan ShopeeFood berdasarkan Twitter,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 406–412, 2024.
- [28] M. Rahardi, A. Aminuddin, F. F. Abdulloh, and R. A. Nugroho, “*Sentiment Analysis of COVID-19 Vaccination using Support Vector Machine in Indonesia*,” *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 6, 2022.
- [29] A. M. Ndapamuri, D. Manongga, and A. Iriani, “Analisis Sentimen Ulasan Aplikasi Tripadvisor dengan Metode *Support Vector Machine*, *K-Nearest Neighbor*, dan *Naive Bayes*,” *Jurnal Inovtek Polbeng Seri Informatika*, vol. 8, no. 1, pp. 127–140, 2023.
- [30] N. I. Wijayanti, I. P. E. N. Kencana, and I. W. Sumarjaya, “SMOTE: Potensi dan Kekurangannya pada Survei,” *E-Jurnal Matematika*, vol. 10, p. 235, Nov. 2021, doi: 10.24843/MTK.2021.v10.i04.p348.
- [31] K. Setyo Nugroho, A. Sukmadewa, H. DW, F. Bachtiar, and N. Yudistira, “*BERT Fine-Tuning for Sentiment Analysis on Indonesian Mobile Apps Reviews*.” 2021. doi: 10.48550/arXiv.2107.06802.