

ANALISIS SENTIMEN PADA ULASAN APLIKASI GOOGLE MAPS TERHADAP PELAYANAN BADAN PENYELENGGARA JAMINAN SOSIAL (BPJS) KESEHATAN SAMARINDA MENGGUNAKAN METODE K-NEAREST NEIGHBOR DENGAN FITUR EKSTRAKSI TF-IDF

Ikhsan Nuttakwa Takbirata Ihram Nabawi ^{a,1}, Rudiman ^{b,2*}, Fendy Yulianto ^{c,3}

^{abc} Universitas Muhammadiyah Kalimantan Timur Jl. Ir. H. Juanda No.15, Sidodadi, Kec. Samarinda Ulu, Kota Samarinda, Kalimantan Timur 75124

¹ 2011102441072@umkt.ac.id; ² rudiman@umkt.ac.id*; ³ fyi415@umkt.ac.id

* corresponding author

ARTICLE INFO

Keywords

Sentiment Analysis, BPJS Kesehatan, K-Nearest Neighbor

ABSTRACT

This study aims to analyze public sentiment towards the services of BPJS Kesehatan Samarinda based on reviews on the Google Maps application. The method used in this research is K-Nearest Neighbor (KNN) with TF-IDF (Term Frequency-Inverse Document Frequency) feature extraction. The data used consists of 500 Indonesian-language reviews collected through web scraping techniques. After the data collection process, the data was labeled by an expert, and then a pre-processing stage was carried out, including case folding, cleaning, tokenizing, stop word removal, and stemming. The data was then weighted using the TF-IDF method to identify important words. The testing was conducted using a training and testing data ratio of 70:30 and a k value of 5. The results showed that the KNN method was able to classify positive and negative sentiments with an accuracy rate of 93.3%. This analysis provides an overview of the service quality of BPJS Kesehatan in Samarinda and can be used as a basis for service improvements. Additionally, this research contributes to the use of KNN and TF-IDF for sentiment analysis, opening opportunities for further research in this field.

1. Pendahuluan

Badan Penyelenggara Jaminan Sosial (BPJS) merupakan suatu lembaga yang didirikan untuk mengelola program jaminan sosial, dengan fokus utama pada aspek kesehatan dan ketenagakerjaan, Jaminan Kesehatan Nasional (JKN) telah diselenggarakan sejak tahun 2014, semua penduduk Indonesia wajib menjadi peserta BPJS termasuk orang asing yang telah bekerja di Indonesia [1]. Salah satu tujuan dan manfaat dari BPJS adalah untuk memberikan layanan yang baik bagi peserta dalam bidang kesehatan, dan juga mempermudah akses masyarakat dalam mendapatkan layanan dan kini manfaatnya semakin meluas dengan memfasilitasi masyarakat dalam mendapatkan pelayanan publik di berbagai sektor dan industri [2]

Berdasarkan data dari bpjs-kesehatan.go.id sampai dengan 31 Desember 2023 jumlah peserta BPJS Kesehatan sebanyak 267 juta penduduk Indonesia, sedangkan pada tahun 2022 total peserta BPJS Kesehatan mencapai 248 juta orang yang artinya peserta BPJS Kesehatan Mengalami Kenaikan Mencapai 19 juta orang [3]. Untuk di Kota Samarinda total penduduk sebanyak 838.935 jiwa, jumlah peserta JKN sebanyak 837.890 jiwa, hal ini menunjukkan bahwa sebagian besar orang Indonesia menggunakan BPJS

Kesehatan [4]. Seiring berjalannya waktu semakin banyak orang di Indonesia yang menggunakan dan memanfaatkan fasilitas yang disediakan yaitu layanan BPJS, dikarenakan hal tersebut maka banyak timbul opini serta keluhan yang diungkapkan dari peserta mengenai layanan BPJS [5]

Terdapat berbagai opini negatif dan positif mengenai layanan BPJS di seluruh Indonesia yang ditemukan melalui pengamatan berbagai media online, seperti masyarakat mengeluhkan antrian panjang hingga 5-6 jam [6] serta tanggapan positif seperti biaya pelayanan kesehatan tidak menjadi bebannya lagi berkat bantuan BPJS Kesehatan [7]. Pada pelayanan BPJS Kesehatan di kota Samarinda juga terdapat opini mengenai layanan BPJS seperti proses panjang yang menyulitkan pengguna kartu yang sedang sakit [8]. Dari berbagai keluhan dan opini tersebut peneliti tertarik untuk menganalisis mengenai bagaimana sentimen masyarakat terhadap pelayanan yang disediakan oleh BPJS Kesehatan di Samarinda.

Dalam penelitian ini metode analisis sentimen digunakan untuk menganalisis pendapat atau opini berdasarkan ulasan pengguna Google Maps. Analisis sentimen adalah suatu metode untuk menganalisis, memproses, dan mengubah data berupa teks yang terkait dengan suatu objek seperti layanan, produk, figur publik, peristiwa, atau topik tertentu. Analisis sentimen dapat dianggap sebagai penggalian opini yang berfokus pada penelitian tentang opini positif dan negatif [9]. Analisis sentimen juga merupakan proses pengelompokan dari teks yang terdapat dalam kalimat atau dokumen dengan tujuan untuk menentukan apakah pendapat yang terungkap dalam kalimat atau dokumen tersebut bersifat positif atau negatif [10].

Terdapat beberapa penelitian sebelumnya yang pertama dilakukan oleh Rani Puspita dan Agus Widodo yang berjudul "Perbandingan Metode KNN, Decision Tree, dan Naïve Bayes Terhadap Analisis Sentimen Pengguna Layanan BPJS". Dengan metode KNN peneliti berhasil mendapatkan akurasi 95.58%, Decision Tree 96.13%, dan Naïve Bayes 89,14% [5]. Penelitian kedua oleh Al Khadafi yang berjudul "Penerapan metode Naïve Bayes Classifier dan Lexicon Based untuk analisis sentimen cyberbullying pada BPJS", peneliti menggunakan fitur TF-IDF untuk pembobotan kata berhasil menganalisis sentimen dengan tingkat akurasi untuk Naïve Bayes 80% sedangkan Lexicon Based 22% [11].

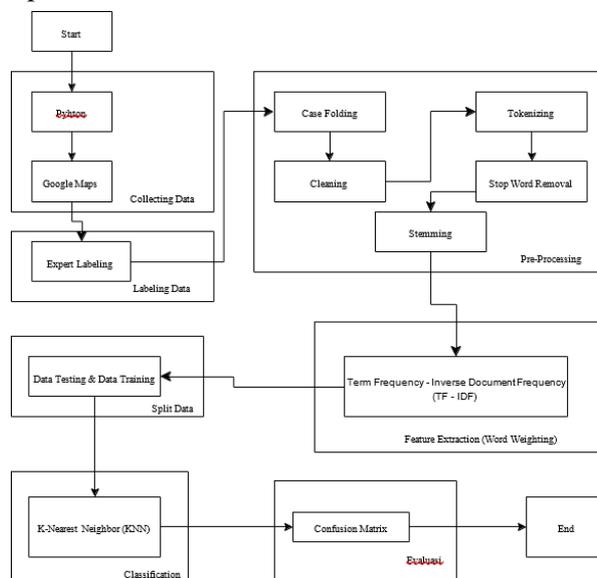
Peneliti menggunakan metode *K - Nearest Neighbor* untuk melihat berapa akurasi yang dihasilkan dari metode tersebut. Metode *K-Nearest Neighbor* (KNN) digunakan untuk proses klasifikasi dalam sebuah penelitian karena memiliki kesederhanaan yang berbasis pada pendekatan pembobotan yang sederhana. Selain itu, KNN juga dikenal karena kemudahannya dalam implementasi, adaptasi, dan proses pembelajaran. Keunggulan KNN yaitu mudah diimplementasikan karena cukup mendefinisikan fungsi untuk menghitung jarak antar kelas [12]

Berdasarkan uraian di atas, penelitian ini bertujuan untuk melakukan analisis sentimen terhadap opini publik mengenai pelayanan BPJS Kesehatan di Samarinda. Opini-opini tersebut akan dikelompokkan menjadi sentimen positif dan negatif dengan menggunakan metode KNN dan fitur TF-IDF untuk meningkatkan efisiensi proses klasifikasi. Tujuan utama dari penelitian ini adalah menggunakan hasil analisis sentimen untuk mengevaluasi kualitas layanan BPJS Kesehatan di Samarinda saat ini. Hasil yang didominasi oleh opini positif akan menunjukkan kualitas layanan yang baik yang dapat ditingkatkan lebih lanjut, sementara kecenderungan opini negatif akan mengidentifikasi aspek-aspek yang perlu perbaikan dalam layanan tersebut.

2. Metodologi Penelitian

2.1. Alur Penelitian

Prosedur penelitian adalah langkah-langkah yang diambil oleh peneliti untuk menghimpun data atau informasi untuk kemudian dianalisis secara ilmiah. Terdapat 8 tahapan yang menjadi dasar bagi sebuah penelitian yang ditampilkan pada Gambar 1.



Gambar 1. Alur Penelitian

Dalam penelitian ini, algoritma yang digunakan adalah *K-Nearest Neighbor* (KNN) untuk menganalisis sentimen terhadap pelayanan Badan Penyelenggara Jaminan Sosial (BPJS) Kesehatan di Samarinda. Proses dilakukan melalui beberapa tahap : Pengumpulan data, Labeling Data oleh ahli bahasa (*expert*), *Pre-processing*, Pembobotan kata (TF-IDF), Pembagian data (*Split data*), Klasifikasi, dan Evaluasi.

2.2. Pengumpulan Data

Dalam penelitian ini pengambilan data dilakukan melalui proses crawling data ulasan Google Maps dengan memanfaatkan *library BeautifulSoup4* yang diimplementasikan dalam bahasa pemrograman *Python*. *BeautifulSoup4* digunakan sebagai alat untuk mengumpulkan data ulasan dari Google berdasarkan identifikasi unik sebuah tempat (*feature_id*) dan menganalisis informasi yang terkandung dalam ulasan tersebut, seperti rating dan sentimen pengguna. Dengan menggunakan *BeautifulSoup4*, peneliti dapat mengekstrak data ulasan yang relevan, mengidentifikasi sentimen dari ulasan (positif atau negatif), dan mengumpulkan informasi penting lainnya dari ulasan pengguna [13].

Beberapa langkah telah diambil untuk meminimalkan potensi bias dalam data yang dikumpulkan melalui web scraping. Salah satu upaya tersebut adalah dengan memastikan bahwa data yang diambil mencakup berbagai periode waktu dan berbagai jenis ulasan (positif dan negatif), sehingga hasilnya lebih representatif. Meskipun demikian, masih ada keterbatasan yang perlu diperhatikan, seperti kemungkinan data yang diambil tidak mencerminkan keseluruhan populasi pengguna atau adanya ulasan yang tidak akurat atau bias. Meskipun teknik web scraping memungkinkan pengumpulan data dalam jumlah besar secara efisien, hasil yang didapatkan tetap sangat tergantung pada kualitas data yang tersedia di platform

yang digunakan. Representativitas sampel menjadi perhatian penting, karena jika data yang diambil tidak mewakili populasi pengguna secara keseluruhan, hasil penelitian dapat menjadi kurang valid. Oleh karena itu, dalam penelitian ini, diakui bahwa keterbatasan ini dapat mempengaruhi hasil akhir. Hasil crawling data pada Gambar 2.

```

break # Hentikan loop jika token berikutnya kosong

# Gabungkan semua DataFrame menjadi satu
combined_df = pd.concat(dfs, ignore_index=True)

# Simpan DataFrame gabungan ke dalam file Excel
combined_df.to_excel("review_data.xlsx", index=False)

print("Total data yang sudah didapat:", total_data)
print("Data telah disimpan dalam review_data.xlsx")

get_reviews_data(feature_id)
Loop ke-33:
-----
Loop ke-34:
-----
Loop ke-35:
-----
Loop ke-36:
-----
Loop ke-37:
-----
Loop ke-38:
-----

```

Gambar 2. Hasil Pengumpulan Data

Data yang berhasil diekstrak kemudian disimpan dalam format file Excel, memudahkan analisis dan pengolahan data lebih lanjut.

2.3. Labelling Data

Dalam proses melakukan klasifikasi teks pada data komentar sebagai bagian dari skripsi tugas akhir, peneliti membutuhkan ahli bahasa (*expert*) yang memiliki pengalaman dalam pelabelan data dan memiliki pengetahuan mendalam tentang bahasa Indonesia. Untuk itu, peneliti mengajukan permintaan pada *website* project.co.id untuk mencari tenaga ahli yang sesuai dengan kriteria tersebut. Dalam pengajuan tersebut, peneliti menjelaskan bahwa dibutuhkan lulusan dari jurusan Bahasa Indonesia yang saat ini bekerja dalam bidang terkait seperti guru/dosen bahasa Indonesia, penulis, atau ahli bahasa. Calon tenaga ahli diminta untuk memasukkan penawaran dengan mencantumkan pekerjaan saat ini, pengalaman yang relevan dengan bahasa Indonesia, serta gelar akademik yang dimiliki.

2.4. Pre-Processing

Preprocessing adalah langkah awal dalam klasifikasi teks yang bertujuan untuk menyiapkan data teks sebelum digunakan dalam proses lanjutan. Pada tahap ini, data teks disesuaikan agar menghasilkan

informasi yang lebih berkualitas dan siap untuk digunakan dalam langkah-langkah berikutnya [14]. Langkah-langkah dilakukan dalam tahap *pre-processing* [15] :

1. *Case folding* adalah proses yang mengubah huruf kapital dalam dokumen menjadi huruf kecil sebagai standar.
2. *Cleaning* adalah tahap di mana karakter yang tidak diperlukan seperti URL, tanda @, #, https:, RT (*Retweet*), angka, simbol, dan emotikon dihapus dari dokumen.
3. *Tokenizing* adalah proses memecah kalimat dalam dokumen menjadi kata-kata, di mana tanda baca, simbol, dan karakter bacaan yang tidak bernilai dihilangkan.
4. *Stopword Removal* adalah langkah untuk menghilangkan kata-kata yang memiliki tingkat informasi rendah. Ini dilakukan jika kata-kata tersebut termasuk dalam kategori umum dan tidak signifikan seperti kata penghubung, waktu, dan sejenisnya.
5. *Stemming* adalah proses menghilangkan awalan dan akhiran kata sehingga menjadi bentuk dasarnya. Stemming sering menggunakan *library Sastrawi* dalam bahasa pemrograman *Python*.

2.5. Pembobotan Kata (TF-IDF)

Pada tahap ini, dilakukan pembobotan kata dalam teks menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF). TF-IDF adalah Salah satu metode pembobotan yang menggabungkan frekuensi term (TF) dan frekuensi dokumen terbalik (IDF) adalah TF-IDF. *Term frequency* (TF) mengukur seberapa sering sebuah kata muncul dalam suatu dokumen, sedangkan *inverse document frequency* (IDF) mengukur seberapa banyak dokumen dalam keseluruhan korpus yang mengandung kata tertentu [16]. Tujuan dari langkah ini adalah untuk menentukan bobot kata dalam sebuah dokumen atau seberapa sering kata tersebut muncul dalam dokumen tersebut [17].

Penggunaan TF dapat menggunakan rumus pada Persamaan (2.1).

$$tf_{ij} = \frac{f_d(i)}{\max f_d(j)} \quad (2.1)$$

TF menunjukkan dokumen (d) seberapa banyak kata (t) yang muncul. Dan terkait untuk rumus IDF bisa dilihat pada Persamaan (2.2).

$$idf_t = \log \frac{N}{df_t} \quad (2.2)$$

N melambangkan jumlah kata dalam teks, df adalah jumlah teks yang memiliki kata t. Dengan menggabungkan TF dan IDF dalam pengerjaan dapat membantu meningkatkan performa. Terkait rumus pembobotan TF-IDF bisa dilihat pada Persamaan (2.3).

$$W_{t,d} = tf_{d,t} \times idf_t \quad (2.3)$$

Keterangan :

- t = Kata kunci, term
- d = Dokumen
- $W_{d,t}$ = Bobot d terhadap t
- Tf = Banyaknya t (kata) yang dicari dalam dokumen
- Idf = Banyak t kebalikan dari kata yang dicari

2.6. Split Data

Pada tahap ini, proses *split data* dilakukan untuk membagi dataset yang digunakan dalam penelitian menjadi dua bagian: data latih (*training*) dan data uji (*testing*). Data latih digunakan untuk melatih algoritma, sementara data uji digunakan untuk mengevaluasi kinerja algoritma tersebut [18]. Dalam penelitian ini, data dibagi dengan rasio 90:10, 80:20, dan 70:30 untuk mengevaluasi pengaruh berbagai perbandingan rasio terhadap kinerja model. Hasil dari pembagian data ini akan menunjukkan bagaimana variasi rasio tersebut dapat mempengaruhi tingkat akurasi model dalam mengklasifikasikan sentimen.

2.7. Klasifikasi

Klasifikasi merupakan salah satu tahap penting dalam *text mining* yang bertujuan untuk mengelompokkan data atau objek baru ke dalam kelas atau label berdasarkan atribut-atribut tertentu. Proses ini melibatkan penggunaan teknik yang melihat variabel dari kelompok data yang sudah ada untuk menentukan aturan pengelompokan. Dengan mempelajari pola dari data yang sudah diberi label, klasifikasi memungkinkan kita untuk memprediksi kelas dari suatu objek yang belum diketahui sebelumnya [19]

2.8. K-Nearest Neighbors (KNN)

Klasifikasi KNN merupakan metode non-parametrik sederhana yang digunakan untuk klasifikasi. Meskipun algoritma ini sederhana, kinerjanya sangat baik dan menjadi metode tolok ukur yang penting. Klasifikasi KNN membutuhkan metrik dan integer positif (K). Aturan KNN memegang posisi sampel pelatihan beserta kelas mereka. Ketika menghadapi data masuk baru, tujuan dari algoritma ini adalah untuk mengklasifikasikan objek baru berdasarkan nilai atribut dan data latih yang ada [20]. Langkah-langkah klasifikasi algoritma KNN:

- a. Tentukan parameter nilai k = banyaknya jumlah tetangga terdekat.
- b. Hitung jarak antara data training dan data testing, rumusnya pada Persamaan (2.4).

$$euc = \sqrt{\left(\sum_{i=1}^n (p_i - q_i)^2\right)} \quad (2.4)$$

Keterangan :

p_i = sample data / data training
 q_i = data uji / data testing
 I = variabel data
 n = dimensi data

- c. Urutkan jarak-jarak tersebut dan tetapkan tetangga terdekat berdasarkan jarak minimum hingga ke- k .
- d. Periksa kelas dari tetangga terdekat.
- e. Gunakan mayoritas sederhana dari kelas tetangga terdekat sebagai nilai prediksi untuk data baru

2.9. Evaluasi

Pada tahap Evaluasi, dilakukan analisis Akurasi dengan menggunakan *confusion matrix* pada dokumen yang telah diklasifikasikan oleh algoritma *K-Nearest Neighbor* (KNN). Ketika mengevaluasi kinerja menggunakan *confusion matrix*, ada empat istilah yang mencerminkan hasil klasifikasi. Istilah-istilah tersebut meliputi *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). *True Negative* (TN) mewakili jumlah data negatif yang berhasil teridentifikasi secara benar, sementara *False Positive* (FP) adalah data negatif yang salah teridentifikasi sebagai data positif [21].

1. Akurasi

Akurasi dapat dijelaskan sebagai ukuran seberapa dekat nilai prediksi dengan nilai sebenarnya. Semakin tinggi akurasi, semakin baik proses klasifikasi tersebut. Rumus untuk menghitung akurasi ditunjukkan dalam Persamaan (2.5).

$$Akurasi = \frac{TP+TN}{TP+TN+FP++FN} \quad (2.5)$$

Dimana:

TP = True Positif

TN= True Negatif

FP = False Positif

FN= False Negatif

Pada rumus di atas, cara menentukan akurasi dari sebuah data dapat dilihat dengan menghitung jumlah prediksi yang benar (*True Positive* dan *True Negative*) dan membaginya dengan jumlah total prediksi yang dilakukan.

3. Hasil dan Pembahasan

3.1. Pengumpulan Data

Pada penelitian ini, digunakan data ulasan terkait BPJS di kota Samarinda yang diambil dari Google Maps. Data yang berhasil dikumpulkan sebanyak 500 ulasan, dan disimpan dalam format CSV. Proses pengumpulan data dilakukan dengan metode *crawling* selama 5 menit pada tanggal 7 Juni 2024, dari pukul 21:20 WITA hingga pukul 21:25 WITA. Hasil pengumpulan data pada Tabel 1.

Tabel 1. Hasil Pengumpulan Data

No.	Name	Rating	Review	Time
1	Hasan Fajar	5	Pelayanan Luarbiasa, Cepat, tepat.. ramah	Jumat 31-05- 2024
Total				500

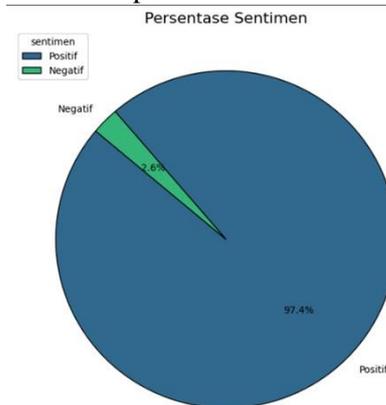
3.2. Labelling Data

Pelabelan data dilakukan oleh ahli bahasa (*expert*) untuk 500 data ulasan pada Google Maps. Data ulasan pada penelitian ini akan dikategorikan ke dalam dua kelompok utama yaitu positif, dan negatif. Dari data yang telah dilabeli, terlihat bahwa sebagian besar data menunjukkan sentimen positif. Terdapat dua kelompok ulasan setelah diberi label pada Tabel 2.

Tabel 2. Labelling Data

No	Review	Sentimen
1	Pelayanan Luarbiasa, Cepat, tepat.. ramah	Positif
Total		500

Dari total 500 data terdapat 97,4% yang memiliki sentiment positif, sedangkan 2,6% lainnya memiliki sentiment negatif. Visualisasi distribusi data pada Gambar 3.



Gambar 3. Visualisasi Sentimen

3.3. Pre-Processing

Sebelum data *review* digunakan, tahap *pre-processing* dilakukan untuk mendapatkan data bersih. Tahapan yang dilakukan antara lain *case folding*, *cleaning*, *tokenizing*, *stopword removal*, dan *stemming*. Berikut ini adalah sebelum dan setelah dilakukan *pre-processing*.

1. Case Folding

Tahap pertama dalam preprocessing adalah *case folding*. *Case folding* adalah proses mengonversi teks menjadi huruf kecil (*lowercase*) untuk menghilangkan variasi antara huruf besar dan huruf kecil dalam analisis teks. Hasil dari data *case folding* pada Tabel 3.

Tabel 3. Hasil Data Case Folding

No.	Case Folding
1	pelayanan luarbiasa, cepat, tepat.. ramah
Total	500

2. Cleaning

Tahap selanjutnya adalah penghapusan karakter yang tidak diperlukan dari teks. Langkah ini bertujuan untuk membersihkan teks dari karakter-karakter yang tidak relevan dan dapat mengganggu proses analisis.. Hal ini karena ulasan dalam bahasa Indonesia seringkali mengandung simbol, kalimat atau kata yang tidak baku, angka, hashtag, dan tautan URL. Hasil dari data *cleaning* pada Tabel 4.

Tabel 4. Hasil Data *Cleaning*

No.	<i>Cleaning</i>
1	pelayanan luarbiasa cepat tepat ramah
Total	500

3. *Tokenizing*

Tahap selanjutnya dalam *pre-processing* adalah *tokenizing*. Proses ini melibatkan pemecahan kalimat menjadi kata-kata individual atau token. Tujuannya adalah untuk mempersiapkan teks agar dapat dianalisis pada tingkat kata. Hasil dari *tokenizing* pada tabel 5.

Tabel 5. Hasil Data *Tokenizing*

No.	<i>Tokenizing</i>
1	['pelayanan', 'luarbiasa', 'cepat', 'tepat', 'ramah']
Total	500

4. *Stopword Removal*

Stopword removal digunakan untuk menghapus kata-kata yang tidak memiliki makna penting dalam teks, sehingga hanya kata-kata yang relevan dan signifikan yang tersisa untuk dianalisis. Hasil *stopword removal* pada Tabel 6.

Tabel 6. Hasil Data *Tokenizing*

No.	<i>Stopword Removal</i>
1	['pelayanan', 'luarbiasa', 'cepat', 'rama']
Total	500

5. *Stemming*

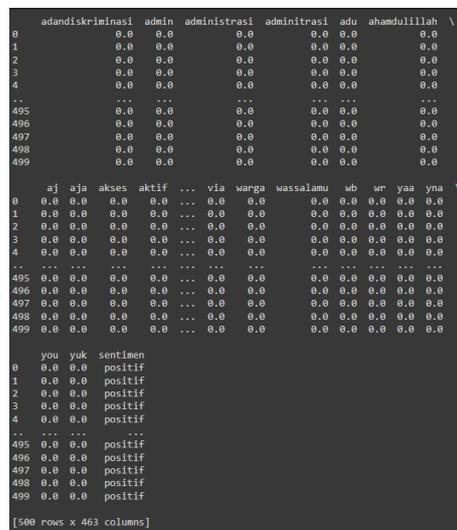
Tahap *stemming* merupakan proses mengubah kata berimbuhan menjadi akar kata. Pada tahap ini, akar kata dari setiap kata dicari menggunakan modul *Sastrawi* pada *Python*. Hasil dari *stemming* dapat dilihat pada Tabel 7.

Tabel 7. Hasil Data *Stemming*

No.	<i>Stemming Data</i>
1	layan luarbiasa cepat ramah
Total	500

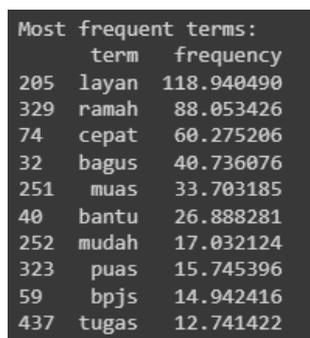
3.4. Pembobotan Kata (TF-IDF)

Pembobotan kata menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF) diterapkan untuk mengidentifikasi kata-kata penting dalam teks ulasan BPJS Kesehatan Samarinda di Google Maps. Dataset yang digunakan terdiri dari 500 baris dan 463 kolom, di mana setiap kolom mewakili kata unik dalam korpus data. Berdasarkan hasil pada Gambar 4, terlihat bahwa sebagian besar kata memiliki bobot rendah senilai 0, yang menunjukkan bahwa kata-kata tersebut jarang muncul dalam dokumen.



Gambar 4. Pembobotan Kata (TF-IDF)

Berdasarkan hasil analisis *Term Frequency* (TF), ditemukan kata-kata yang paling sering muncul dan memiliki bobot signifikan dalam korpus data. Gambar 5, menunjukkan bahwa kata "layan" memiliki frekuensi tertinggi dengan skor 118.940490, diikuti oleh kata "ramah" dengan skor 88.053426, dan "cepat" dengan skor 60.275206. Kata-kata lain yang juga memiliki bobot tinggi adalah "bagus" dengan skor 40.736076, "muas" 33.703185, "bantu" 26.888281, "mudah" 17.03212, "puas" 15.745396, "bpjs" 14.942416, dan "tugas" 12.741422. Frekuensi tinggi dari kata-kata ini menunjukkan topik yang dominan dan relevan dalam ulasan BPJS Kesehatan Samarinda di Google Maps.



Gambar 5. Scoring TF

3.5. Visualisasi

Kata-kata yang sering muncul dalam teks ulasan divisualisasikan menggunakan *wordcloud*. Dalam pembuatan *wordcloud*, peneliti menggunakan *library wordcloud* dan hasil ekstraksi fitur dengan metode TF-IDF. Semakin sering kata tersebut muncul dalam data, semakin besar ukurannya dalam *wordcloud*. Visualisasi kata-kata yang sering muncul dalam ulasan positif pada Gambar 6, sedangkan visualisasi kata-kata yang sering muncul dalam ulasan negatif pada Gambar 7.

mengklasifikasikan sekitar 99.3% data dengan benar. Pada rasio pengujian 80:20, model menunjukkan penurunan performa dengan akurasi sebesar 0.99, mengindikasikan bahwa sekitar 99% data diklasifikasikan dengan benar. Sementara pada rasio pengujian 90:10, akurasi model menunjukkan semakin menurun menjadi 0.98, yang berarti model mampu mengklasifikasikan sekitar 98% data dengan benar.

Perbedaan akurasi ini menunjukkan bahwa performa model sedikit bervariasi tergantung pada rasio pembagian data latih dan data uji. Pada rasio 70:30 dan 80:20, model menunjukkan performa yang lebih baik dibandingkan dengan rasio 90:10. Hal ini dapat disebabkan oleh berbagai faktor, seperti jumlah data latih yang lebih besar pada rasio 70:30 dan 80:20, yang memungkinkan model untuk mempelajari lebih banyak pola dari data. dan pada rasio 90:10, jumlah data latih yang lebih sedikit mungkin tidak cukup untuk menangkap variasi yang ada dalam data, sehingga menyebabkan penurunan akurasi. Secara keseluruhan, hasil ini menunjukkan pemilihan rasio yang tepat dalam pembagian data latih dan data uji untuk mendapatkan performa model yang optimal. Pemilihan rasio yang baik dapat membantu model mempelajari pola dengan lebih baik dan menghasilkan prediksi yang lebih akurat [22]. Dan dari ketiga rasio tersebut peneliti mengambil rasio yang terbaik yaitu 70:30 dimana 70% sebagai data latih sebanyak 350 data dan 30% data uji sebanyak 150 data.

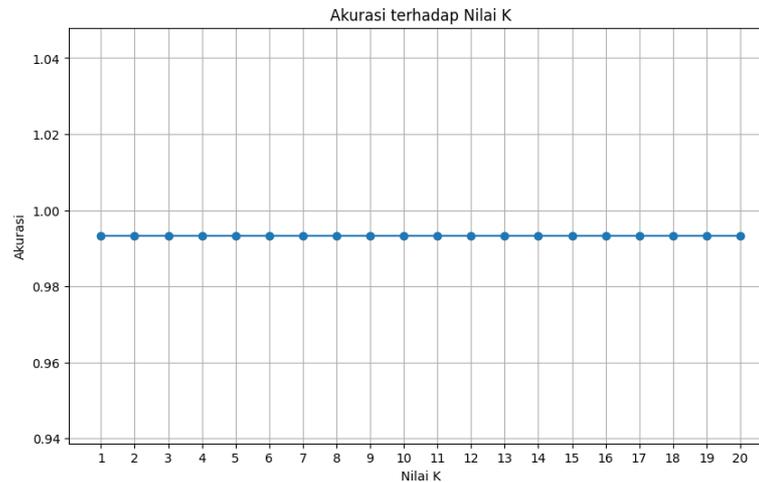
Setelah memilih rasio terbaik kemudian dilakukan pengujian untuk mencari akurasi terbaik pada nilai K dalam algoritma *K-Nearest Neighbors* (KNN), perhitungan jarak K yang digunakan menggunakan Euclidean Distance. Penggunaan beberapa nilai K bertujuan untuk membandingkan hasil akurasi dari setiap nilai K . Hal ini dilakukan baik saat uji validasi maupun evaluasi akhir untuk menentukan nilai K yang paling optimal di antara semua nilai yang diuji. Dengan membandingkan akurasi pada setiap nilai K , kita dapat mengetahui nilai K yang memberikan kinerja terbaik untuk model tersebut [23].

Hasil evaluasi akurasi dari model *K-Nearest Neighbor* (KNN) dengan berbagai nilai K dari 1 hingga 20. Setiap nilai K menghasilkan akurasi yang sama, yaitu 0.9933. Menunjukkan bahwa model KNN memiliki performa yang sangat baik dan stabil pada dataset yang digunakan, dan perubahan nilai K tidak mempengaruhi akurasi secara signifikan karena adanya ketidakseimbangan pada kelas di mana salah satu kelas mendapatkan jumlah sampel yang lebih banyak dibandingkan dengan kelas lainnya. Ketidakseimbangan ini bisa menyebabkan model lebih mudah untuk memprediksi kelas mayoritas dengan benar, sehingga meningkatkan akurasi keseluruhan tanpa benar-benar mencerminkan kemampuan model dalam memprediksi kelas minoritas dengan akurat [24]. Hasilnya pada Gambar 8.

```
Akurasi untuk berbagai nilai K:  
Nilai K: 1, Akurasi: 0.9933  
Nilai K: 2, Akurasi: 0.9933  
Nilai K: 3, Akurasi: 0.9933  
Nilai K: 4, Akurasi: 0.9933  
Nilai K: 5, Akurasi: 0.9933  
Nilai K: 6, Akurasi: 0.9933  
Nilai K: 7, Akurasi: 0.9933  
Nilai K: 8, Akurasi: 0.9933  
Nilai K: 9, Akurasi: 0.9933  
Nilai K: 10, Akurasi: 0.9933  
Nilai K: 11, Akurasi: 0.9933  
Nilai K: 12, Akurasi: 0.9933  
Nilai K: 13, Akurasi: 0.9933  
Nilai K: 14, Akurasi: 0.9933  
Nilai K: 15, Akurasi: 0.9933  
Nilai K: 16, Akurasi: 0.9933  
Nilai K: 17, Akurasi: 0.9933  
Nilai K: 18, Akurasi: 0.9933  
Nilai K: 19, Akurasi: 0.9933  
Nilai K: 20, Akurasi: 0.9933
```

Gambar 8. Hasil Akurasi Nilai K

Plot yang menunjukkan hubungan antara nilai K dan akurasi dalam model K -Nearest Neighbor (KNN). Sumbu horizontal merepresentasikan nilai K , yang berkisar dari 1 hingga 20. Sumbu vertikal merepresentasikan akurasi model. Dari plot tersebut, terlihat bahwa akurasi tetap sama untuk setiap nilai K yang diuji. Hasilnya pada Gambar 9.



Gambar 9. Plot Akurasi Nilai K

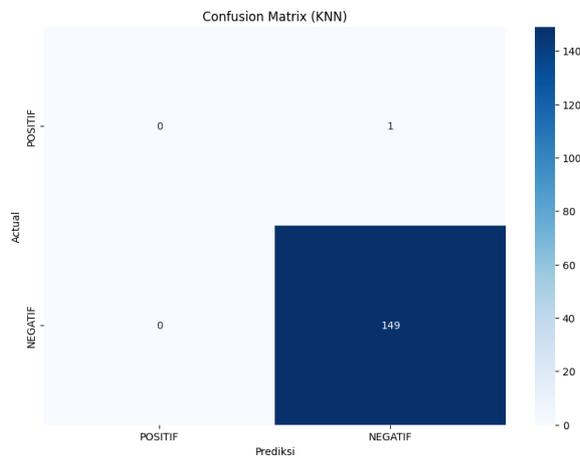
Hasil evaluasi akurasi dari model K -Nearest Neighbor (KNN) dengan berbagai nilai K , dari 1 hingga 20. Setiap nilai K menghasilkan akurasi yang sama, yaitu 0.9933. Menunjukkan bahwa model KNN memiliki performa yang sangat baik dan stabil pada dataset yang digunakan, dan perubahan nilai K tidak mempengaruhi akurasi secara signifikan. Stabilitas akurasi ini mengindikasikan bahwa model KNN sangat efektif dalam memprediksi label data uji dengan tingkat ketepatan yang konsisten. Meskipun hasil akurasi yang diperoleh sama untuk semua nilai K yang diuji, peneliti memutuskan untuk menggunakan nilai $K=5$ sebagai parameter final untuk model KNN.

Untuk mengevaluasi kinerja suatu model klasifikasi yang memprediksi sentimen dari teks. Evaluasi ini melibatkan perhitungan nilai-nilai seperti akurasi (*Accuracy*), Empat variabel (TN, TP, FN, FP) mewakili nilai dari setiap kategori dalam *confusion matrix*, yaitu *True Negative* (TN), *True Positive* (TP), *False Negative* (FN) dan *False Positive* (FP). Kemudian, dilakukan perhitungan persentase dari masing-masing kategori tersebut terhadap total jumlah data. Visualisasi yang dihasilkan merupakan nilai *confusion matrix* dengan label masing-masing kategori dan peneliti mengambil rasio yang terbaik yaitu 70:30 dimana 70% sebagai data latih sebanyak 350 data dan 30% data uji sebanyak 150 data dan nilai $K=5$. Akurasi model dihitung berdasarkan prediksi yang dihasilkan pada data uji pada Gambar 10.

Accuracy: 0.9933333333333333

Gambar 10. Hasil Akurasi Metode KNN

Akurasi dari model diatas adalah akurasi yang digunakan oleh peneliti menggunakan data yang diberi label oleh (*expert*) sebesar 0.993 atau 99.3%. Untuk tampilan *Confusion Matrix* akan ditampilkan pada Gambar 11.



Gambar 10. Hasil Confusion Matrix

Adapun perhitungan manual berdasarkan hasil Gambar 10 pada Tabel 9.

Tabel 9. Hasil Data Uji

		True Positive	False Negatif
Prediction	Positive	0	1
	Negatif	0	149
Total		150	

Akurasi adalah rasio dari jumlah prediksi yang benar (*True Positif dan True Negatif*) terhadap total jumlah prediksi.

Berdasarkan *Confusion Matrix* di atas :

- a) *True Positif* (TP) = 0
- b) *True Negatif* (TN) = 149
- c) *False Positif* (FP) = 1
- d) *False Negatif* (FN) = 0

Hasil perhitungan manual akurasi pada Persamaan (3.1).

$$Akurasi = \frac{0+149}{0+149+1+0} = \frac{149}{150} = 0.993\% \quad (3.1)$$

Hasil pengujian model menunjukkan akurasi sebesar 0,993 atau 99.3% pada data uji. Berarti dari 150 data yang diuji, model mampu memprediksi dengan benar 99 kasus. Akurasi ini dihitung berdasarkan jumlah prediksi yang benar (*True Positive dan True Negative*) dibagi dengan total jumlah kasus.

4. Kesimpulan

Berdasarkan hasil penelitian analisis sentimen pada ulasan Google Maps mengenai layanan BPJS Kesehatan di Samarinda yang menggunakan metode *K-Nearest Neighbor* dengan ekstraksi fitur TF-IDF, dapat disimpulkan bahwa mayoritas ulasan memiliki sentimen positif, yaitu sebesar 97,4%, sementara ulasan dengan sentimen negatif hanya 2,6%, labelling data dilakukan oleh seorang ahli bahasa (*expert*). Tahapan *pre-processing* seperti *case folding*, *cleaning*, *tokenizing*, *stopword removal*, dan *stemming* terbukti penting dalam mempersiapkan data ulasan untuk analisis lebih lanjut. Pembobotan TF-IDF dalam ekstraksi fitur terbukti efektif dalam mengidentifikasi kata-kata penting dan relevan dari ulasan pengguna. Dalam analisis sentimen, bobot TF-IDF berfungsi untuk menentukan relevansi kata dalam keseluruhan ulasan dengan menghitung frekuensi kata (TF) dan seberapa sering kata tersebut muncul di dokumen lain (IDF). Kata yang jarang muncul di dokumen lain akan memiliki bobot yang lebih tinggi, menandakan signifikansi dalam konteks tertentu. Bobot TF-IDF ini kemudian digunakan sebagai input untuk algoritma *K-Nearest Neighbor* (KNN), yang mengukur kemiripan ulasan berdasarkan bobot TF-IDF untuk mengklasifikasikan sentimen. Kombinasi TF-IDF dan KNN memastikan bahwa kata-kata unik dan penting berpengaruh besar dalam klasifikasi sentimen, sehingga meningkatkan akurasi analisis. Teknik ini membantu menangkap informasi yang paling penting dan berkontribusi signifikan terhadap sentimen yang diekspresikan dalam ulasan, dengan kata-kata yang sering muncul memiliki bobot tinggi terkait pengalaman dan layanan BPJS Kesehatan di Samarinda.

Model *K-Nearest Neighbor* yang diterapkan, dengan rasio data latih dan data uji sebesar 70:30 dan nilai $k=5$, menunjukkan tingkat akurasi yang sangat tinggi, yaitu 99,3%. Hasil ini menunjukkan bahwa metode *K-Nearest Neighbor* mampu mengklasifikasikan opini pengguna dengan sangat baik, membuktikan kemampuannya dalam memprediksi sentimen dengan tingkat kesalahan yang rendah. Hasil penelitian ini diharapkan dapat digunakan sebagai dasar untuk meningkatkan kualitas layanan BPJS Kesehatan di Samarinda melalui pemahaman yang lebih baik terhadap umpan balik pengguna. Penelitian ini juga menunjukkan potensi penerapan teknik serupa untuk analisis sentimen pada berbagai layanan publik lainnya.

5. Implikasi

Hasil penelitian menunjukkan bahwa akurasi klasifikasi menggunakan kombinasi TF-IDF dan KNN cukup tinggi, yang mengindikasikan bahwa metode ini efektif dalam menganalisis sentimen ulasan terkait BPJS Kesehatan Samarinda. Penelitian ini memiliki implikasi penting, terutama dalam memahami bagaimana sentimen positif dalam ulasan dapat mencerminkan kualitas layanan yang diberikan. Misalnya, ulasan dengan sentimen positif mungkin menunjukkan kepuasan pengguna terhadap pelayanan yang cepat, kemudahan akses, atau keramahan staf.

Untuk mendalami distribusi sentimen, analisis lebih lanjut dapat dilakukan dengan memecah ulasan positif dan negatif berdasarkan aspek layanan yang paling sering dibahas. Misalnya, ulasan positif mungkin lebih banyak membahas aspek-aspek seperti kecepatan layanan atau kemudahan proses administrasi, sementara ulasan negatif mungkin terkait dengan masalah seperti keterlambatan atau kesulitan dalam mendapatkan informasi.

Penggunaan visualisasi, seperti diagram batang atau pie chart, juga dapat membantu dalam menggambarkan distribusi sentimen secara lebih jelas. Hal ini akan memberikan gambaran yang lebih komprehensif tentang persepsi pengguna terhadap layanan BPJS Kesehatan Samarinda, serta

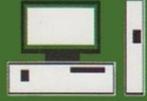
mengidentifikasi area yang mungkin memerlukan perbaikan. Dengan demikian, hasil ini tidak hanya menunjukkan keberhasilan metode klasifikasi, tetapi juga memberikan wawasan yang lebih mendalam tentang hubungan antara sentimen pengguna dan kualitas layanan.

6. Saran

Artikel ini berkontribusi pada penggunaan algoritma K-Nearest Neighbor (KNN) dan metode Term Frequency-Inverse Document Frequency (TF-IDF) untuk analisis sentimen terhadap ulasan Google Maps mengenai layanan BPJS Kesehatan Samarinda. Kombinasi KNN dan TF-IDF diharapkan dapat memberikan hasil klasifikasi sentimen yang lebih akurat dibandingkan dengan metode lainnya. Meskipun KNN dan TF-IDF telah digunakan dalam penelitian sebelumnya, studi ini menawarkan penerapan spesifik dalam konteks ulasan layanan publik yang jarang dieksplorasi secara mendalam. Namun, penulis perlu menjelaskan lebih rinci bagaimana penelitian ini memajukan keadaan riset saat ini di bidang ini. Sebagai arahan untuk riset masa depan, disarankan untuk mengeksplorasi algoritma klasifikasi lain seperti Support Vector Machines (SVM) atau Random Forest yang mungkin menawarkan akurasi atau efisiensi yang lebih baik. Selain itu, memperluas sumber data dengan mencakup ulasan dari platform lain seperti Twitter atau Facebook dapat memberikan gambaran sentimen yang lebih komprehensif. Terakhir, peningkatan model dengan menggabungkan metode pengolahan data teks lain seperti Word Embeddings atau menerapkan model pembelajaran mendalam (deep learning) dapat digunakan untuk analisis sentimen yang lebih kompleks dan kontekstual.

Daftar Pustaka

- [1] L. Linda, Y. Haskas, E. Kadrianti, and S. Nani Hasanuddin Makassar, "PERBEDAAN PERSEPSI PENGGUNA JASA BPJS DAN NON BPJS (UMUM) TENTANG KUALITAS PELAYANAN KEPERAWATAN DIRSUD TIMIKA-PAPUA."
- [2] Annisa Medina Sari, "Perbedaan Fakes BPJS Tingkat 1,2,3 Yang Harus Diketahui."
- [3] BPJS Kesehatan, "<https://bpjs-kesehatan.go.id/>."
- [4] Antara Kaltim, "Tingkat kepesertaan BPJS Kesehatan Samarinda mencapai 100,89 persen."
- [5] R. Puspita and A. Widodo, "Perbandingan Metode KNN, Decision Tree, dan Naïve Bayes Terhadap Analisis Sentimen Pengguna Layanan BPJS," *Jurnal Informatika Universitas Pamulang*, vol. 5, no. 4, p. 646, Dec. 2021, doi: 10.32493/informatika.v5i4.7622.
- [6] Khadijah Nur Azizah, "7 Tahun BPJS Kesehatan, Peserta Masih Keluhkan Antrean Berjam-jam."
- [7] CNN INDONESIA, "Kisah Pengidap Tumor Asal Sulses Lancar Operasi Berkat JNN-KIS."
- [8] IDN Times Kaltim, "Ribet, Warga Keluhkan Pelayanan BPJS Kesehatan di Samarinda."
- [9] H. Parasian Doloksaribu and Y. T. Samuel, "KOMPARASI ALGORITMA DATA MINING UNTUK ANALISIS SENTIMEN APLIKASI PEDULILINDUNGI," vol. 16, no. 1, 2022, doi: 10.47111/JTI.
- [10] A. Z. Amrullah, A. Sofyan Anas, M. Adrian, and J. Hidayat, "Analisis Sentimen Movie Review Menggunakan Naive Bayes Classifier Dengan Seleksi Fitur Chi Square," *Jurnal*, vol. 2, no. 1, 2020, doi: 10.30812/bite.v2i1.804.
- [11] M. Al Khadafi, K. Paranita Kartika, and F. Febrinita, "PENERAPAN METODE NAÏVE BAYES CLASSIFIER DAN LEXICON BASED UNTUK ANALISIS SENTIMEN CYBERBULLYING PADA BPJS," 2022.
- [12] S. S. Salim and J. Mayary, "ANALISIS SENTIMEN PENGGUNA TWITTER TERHADAP DOMPET ELEKTRONIK DENGAN METODE LEXICON BASED DAN K – NEAREST



- NEIGHBOR,” *Jurnal Ilmiah Informatika Komputer*, vol. 25, no. 1, pp. 1–17, 2020, doi: 10.35760/ik.2020.v25i1.2411.
- [13] I. N. Amanny Ulfah Nabiylah Ramadhanty, “IMPLEMENTASI WEB SCRAPING PADA SITUS JURNAL SINTA MENGGUNAKAN FRAMEWORK SELENIUM WEBDRIVER PYTHON,” 2023.
- [14] 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, p. 406, Apr. 2021, doi: 10.30865/mib.v5i2.2835.
- [15] Ratih Puspitasari, Y. Findawati, and M. A. Rosid, “SENTIMENT ANALYSIS OF POST-COVID-19 INFLATION BASED ON TWITTER USING THE K-NEAREST NEIGHBOR AND SUPPORT VECTOR MACHINE CLASSIFICATION METHODS,” *Jurnal Teknik Informatika (Jutif)*, vol. 4, no. 4, pp. 669–679, Aug. 2023, doi: 10.52436/1.jutif.2023.4.4.801.
- [16] A. N. Assidyk, E. B. Setiawan, S. Si, I. Kurniawan, S. Pd, and M. Si, “Analisis Perbandingan Pembobotan TF-IDF dan TF-RF pada Trending Topic di Twitter dengan Menggunakan Klasifikasi K-Nearest Neighbor,” 2020.
- [17] T. Fadiyah Basar, D. E. Ratnawati, and I. Arwani, “Analisis Sentimen Pengguna Twitter terhadap Pembayaran Cashless menggunakan Shopeepay dengan Algoritma Random Forest,” 2022. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [18] A. Putri, C. Syaficha Hardiana, E. Novfuja, F. Try Puspa Siregar, Y. Fatma, and R. Wahyuni, “Comparison of K-NN, Naive Bayes and SVM Algorithms for Final-Year Student Graduation Prediction Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir,” *Institut Riset dan Publikasi Indonesia (IRPI) MALCOM: Indonesian Journal of Machine Learning and Computer Science Journal Homepage*, vol. 3, no. 1, pp. 20–26, 2023.
- [19] D. Azzahra Nasution, H. H. Khotimah, and N. Chamidah, “PERBANDINGAN NORMALISASI DATA UNTUK KLASIFIKASI WINE MENGGUNAKAN ALGORITMA K-NN,” 2019.
- [20] P. Putra, A. M. H Pardede, and S. Syahputra, “ANALISIS METODE K-NEAREST NEIGHBOUR (KNN) DALAM KLASIFIKASI DATA IRIS BUNGA,” *Jurnal Teknik Informatika Kaputama (JTIK)*, vol. 6, no. 1, 2022.
- [21] M. K. Rifa, M. H. Totohendarto, and M. R. Muttaqin, “Analisis Sentimen Pengguna E-Wallet Dana Dan Gopay Pada Twitter Menggunakan Metode Support Vector Machine (SVM),” *IJCCS*, vol. x, No.x, pp. 1–5, 2023.
- [22] R. Kurniawan and D. Anubhakti, “IMPLEMENTASI ALGORITMA SUPPORT VECTOR MACHINEDALAM MEMREDIKSI HARGA SAHAM PT. KRAKATAU STEEL TBK,” vol. 2, no. 2, 2023.
- [23] I. H. Herman, D. Widiyanto, and I. Ernawati, *PENGGUNAAN K-NEAREST NEIGHBOR (KNN) UNTUK MENGIDENTIFIKASI CITRA BATIK PEWARNA ALAMI DAN PEWARNA SINTETIS BERDASARKAN WARNA*. 2020.
- [24] R. Nur Ariyanti and R. Cahya Wihandika, “Identifikasi Jenis Attention Deficit Hyperactivity Disorder (ADHD) Pada Anak Usia Dini Menggunakan Metode Modified K-Nearest Neighbor (MKNN),” 2019. [Online]. Available: <http://j-ptiik.ub.ac.id>