

## Analisis Sentimen Penggunaan Aplikasi Traveloka di Twitter Menggunakan Model Klasifikasi

Tiara Sartina Jayanti<sup>1)</sup>, Budiman<sup>2,\*</sup>, Chairul Habibi<sup>1)</sup>, Elia Setiana<sup>2)</sup>

<sup>1)</sup>Sistem Informasi, Teknologi dan Informatika, Universitas Informatika dan Bisnis Indonesia

<sup>2)</sup>Informatika, Teknologi dan Informatika, Universitas Informatika dan Bisnis Indonesia

Email: tiarasjayanti@gmail.com; budiman@unibi.ac.id\*; habibi\_cr@unibi.ac.id; elia.setiana@unibi.ac.id

---

Diterima:	Diterima Setelah Revisi:	Dipublikasikan:
15 November 2023	23 Februari 2024	29 Februari 2024

---

### Abstrak

Traveloka adalah platform travel online yang menyediakan jasa pemesanan tiket transportasi, akomodasi, tiket masuk objek wisata, dan lainnya. Penelitian ini akan melakukan analisis sentimen menggunakan lima metode dan melakukan analisis perbandingan antar metode tersebut. Tujuannya untuk mengetahui cara melakukan analisis sentimen dan melakukan analisis perbandingan serta mendapatkan hasil yang paling baik untuk analisis sentimen Traveloka di Twitter. Penelitian ini menggunakan Twitter untuk memperoleh data dan hanya berfokus pada tweet mengenai Traveloka. Analisis sentimen juga memberikan manfaat bagi Traveloka dalam memantau dan menganalisis respon dan tanggapan dari pengguna terhadap produk dan layanan mereka dari ulasan dan *feedback* yang diunggah oleh pengguna di media sosial seperti Twitter, Traveloka dapat memperoleh wawasan yang berharga mengenai kekuatan dan kelemahan layanan mereka. Dataset terdiri dari 85,6% sentimen positif dan 14,4% sentimen negatif. Dalam analisis ini Library yang digunakan yaitu Scikitlearn. Lima metode klasifikasi yang diterapkan yaitu, *Random Forest* (RF), *Support Vector Machine* (SVM), *Naive Bayes Classifier* (NBC), *K-Nearest Neighbor* (KNN), dan XGBOOST. Langkah-langkah dalam penelitian ini adalah crawling data, preprocessing data, pembobotan data, klasifikasi, uji model, evaluasi model, analisis perbandingan, dan analisis hasil. Hasilnya menunjukkan bahwa SVM memiliki akurasi lebih baik berdasarkan evaluasi metrik dengan nilai sebesar 90%. Namun, melalui uji model menggunakan AUC, XGBOOST memperoleh nilai tertinggi sebesar 71%.

**Kata Kunci:** Analisis Sentimen, *Random Forest* (RF), *Support Vector Machine* (SVM), *Naive Bayes Classifier* (NBC), *K-Nearest Neighbor* (KNN), XGBOOST, Traveloka.

### Abstract

*Traveloka is an online travel platform that provides booking services for transportation tickets, accommodation, tourist attraction entrance tickets, and others. This research will conduct sentiment analysis using five methods and conduct a comparative analysis between these methods. The goal is to find out how to do sentiment analysis and do a comparison analysis and get the best results for Traveloka sentiment analysis on Twitter. This research uses Twitter to get data and only focuses on tweets about Traveloka. Sentiment analysis also provides benefits for Traveloka in monitoring and analyzing user responses to their products and services from reviews and feedback posted by users on social media such as Twitter, Traveloka can gain valuable insights into the strengths and weaknesses of their services. This dataset consists of 85.6% positive sentiments and 14.4% negative sentiments. In this analysis, the library used is Scikitlearn. Five classification methods were used, namely, Random Forest (RF), Support Vector Machine (SVM), Naive Bayes Classifier (NBC), K-Nearest Neighbor (KNN), and XGBOOST. The steps in this research are data crawling, data*

*preprocessing, data weighting, classification, model testing, model evaluation, comparison analysis, and result analysis. The results show that SVM has better accuracy based on metric evaluation with a value of 90%. However, through model testing using AUC, XGBOOST obtained the highest value of 71%.*

**Keywords:** *Sentiment Analysis, Random Forest (RF), Support Vector Machine (SVM), Naive Bayes Classifier (NBC), K-Nearest Neighbor (KNN), XGBOOST, and Traveloka.*

## 1 PENDAHULUAN

Twitter merupakan akomodasi atau alat jejaring sosial yang mengizinkan penggunanya untuk mengunggah teks, gambar dan video. Unggahan-unggahan dalam media sosial khususnya Twitter berisi tentang opini pengguna baik itu mengenai kehidupan pribadi, suatu produk, topik, layanan hingga suatu merek. Informasi yang didapat melalui unggahan di Twitter terbatas pada jumlah karakter yang dapat di unggah dalam sekali tweet, seringkali informasi yang disajikan di Twitter bersifat singkat dan tidak lengkap. Jumlah pengguna aktif harian di platform Twitter meningkat 17% menjadi 145 juta pengguna (Clinton, 2019).

Traveloka adalah perusahaan platform travel online yang menyediakan akses untuk bisa menemukan dan membeli berbagai jenis kebutuhan perjalanan. Menurut artikel dari Databoks oleh Cindy Mutia Annur (2022), berdasarkan survei dari Populix, sebanyak 38% responden yang berencana liburan akhir tahun bermaksud memesan akomodasi melalui aplikasi online travel agent (OTA). Traveloka tercatat sebagai aplikasi OTA yang paling disukai responden, dengan presentase mencapai 67,5% (Databoks, 2022).

*Sentimen analysis* merupakan proses untuk mengenali apakah suatu kalimat memiliki tendensi positif, negatif atau netral. Positif berarti adanya aspek suka, setuju, dan sejenisnya terhadap suatu topik. Di sisi lain, negatif berarti ketidaksukaan, ketidaksetujuan, kekecewaan, dan sejenisnya dan netral berarti berada diantaranya yaitu tidak menunjukkan preferensi yang jelas dalam hal positif atau negatif terhadap topik tersebut (Herlawati, 2020:304). Pada penelitian ini akan menggunakan 5 metode klasifikasi diantaranya *Random Forest*, SVM, Naive Bayes, KNN, dan XGBoost.

*Random Forest* adalah metode klasifikasi yang menggabungkan decision tree dengan training berdasarkan informasi yang tersedia. Dalam *Random Forest*, proses klasifikasi dilakukan dengan membagi data secara acak ke dalam pohon keputusan (Wandani *et al.*, 2021). *Support Vector Machine (SVM)* merupakan suatu metode untuk proses klasifikasi support vector classification dan regresi. Jika dibandingkan dengan teknik-teknik klasifikasi yang lain, SVM dikenal dengan konsepnya yang lebih jelas secara sistematis. Kelebihan SVM lainnya, yaitu dapat mengklasifikasi dalam bentuk linear dan non-linear (Choirunnisa dkk, 2021). Naive Bayes adalah salah satu algoritma yang mampu melakukan proses klasifikasi dengan cepat. Naive Bayes juga sebagai salah satu algoritma dari klasifikasi yang sangat efisien dan efektif baik saat digunakan untuk menganalisis data berskala besar (Sihombing *et al.*, 2021). *K-Nearest Neighbors (KNN)* adalah salah satu algoritma klasifikasi yang mempunyai prinsip kerja bahwa mengklasifikasi suatu objek dalam data uji berdasarkan mayoritas kelas dari sejumlah k tetangga terdekatnya (neighbour) dalam training set (Wardani *et al.*, 2022). XGBOOST merupakan model linier yang efisien dalam memecahkan model linier dan mendukung sejumlah proses objektif seperti regresi, klasifikasi, dan peringkat (Christanto *et al.*, 2023).

Dengan menggunakan metode tersebut, penulis bertujuan melakukan analisis sentimen. Analisis sentimen juga memberikan manfaat bagi Traveloka dalam memantau dan menganalisis respon dan tanggapan dari pengguna terhadap produk dan layanan mereka dari ulasan dan *feedback* yang diunggah oleh pengguna di media sosial seperti Twitter, Traveloka dapat memperoleh wawasan yang berharga mengenai kekuatan dan kelemahan layanan mereka.


## 2 KAJIAN PUSTAKA

### 2.1 Analisis Sentimen

Menurut Harsono (2020) mengemukakan bahwa analisis sentimen merupakan salah satu cabang ilmu dari text mining, natural language program, dan artificial intelligence. Proses yang dilakukan oleh analisis sentimen untuk memahami, mengekstrak, dan mengolah data teks secara otomatis sehingga menjadi suatu informasi yang bermanfaat.

### 2.2 Text Mining

Text mining adalah penemuan dan ekstraksi yang menarik, tidak sepele yang diketahui dari teks bebas atau tidak terstruktur. Ini mencakup segala sesuatu untuk pengambilan informasi (yaitu, pengambilan dokumen atau situs web) untuk klasifikasi teks dan pengelompokan, untuk (agak lebih baru) entitas, hubungan, dan ekstraksi peristiwa (Kao & Poteet, 2021).



Gambar 1. Tahapan Text Mining

### 2.3 Random Forest

*Random Forest* adalah metode klasifikasi machine learning yang menggabungkan decision tree dengan training berdasarkan informasi yang tersedia. Dalam *Random Forest*, proses klasifikasi dilakukan dengan membagi data secara acak ke dalam pohon keputusan (Wandani *et al.*, 2021). *Random Forest* digunakan untuk menghasilkan output akhir dari sistem identifikasi. Prediksi didapatkan dengan mengamati mayoritas suara (voting) dari setiap kelas yang telah diberi label pada data sebelumnya (Novalita *et al.*, 2019)

### 2.4 Naive Bayes Classifier (NBC)

Klasifikasi bayes menggunakan teorema Bayes, yang ditemukan oleh Thomas Bayes di abad ke-18. Dalam teorema Bayes, probabilitas atau peluang bersyarat dinyatakan sebagai:

$$P(H|X) = \frac{P(X|H)P(H)}{P(X)} \quad (1)$$

Keterangan :

$P(H|X)$  probabilitas posterior : hipotesis A pada B (yang diamati)

$P(X|H)$  probabilitas kemungkinan : bukti bahwa hipotesis benar

$P(H)$  probabilitas sebelumnya : hipotesis sebelum mengamati bukti  
 $P(X)$  probabilitas margina : bukti

Bayes memprediksi data menggunakan probabilitas yang sangat sederhana dan didasarkan pada teori Bayesian dengan independensi yang kuat. Sehingga Bayes menggunakan model fitur mandiri dalam melakukan klasifikasi data. Pada model Naive Bayes, arti dari mandiri atau tidak memiliki kaitan terhadap fitur lain adalah sebuah fitur pada sebuah dataset yang sama (Aziz *et al.*, 2021).

### 2.5 *K-Nearest Neighbors (KNN)*

KNN adalah salah satu algoritma klasifikasi yang mempunyai prinsip kerja bahwa mengklasifikasi suatu objek dalam data uji berdasarkan mayoritas kelas dari sejumlah  $k$  tetangga terdekatnya (neighbour) dalam training set (Wardani *et al.*, 2022). Nilai  $k$  adalah bilangan bulat positif yang ditentukan oleh pengguna, semakin kecil nilai  $k$  maka akan semakin lemah terhadap pengaruh noise outlier, namun sebaliknya jika nilai  $k$  bernilai besar maka pengaruh noise/outlier akan semakin kecil tetapi ini akan membuat batasan antar kelas menjadi lebih kabur.

### 2.6 *Extreme Gradient Boosting package (XGBoost)*

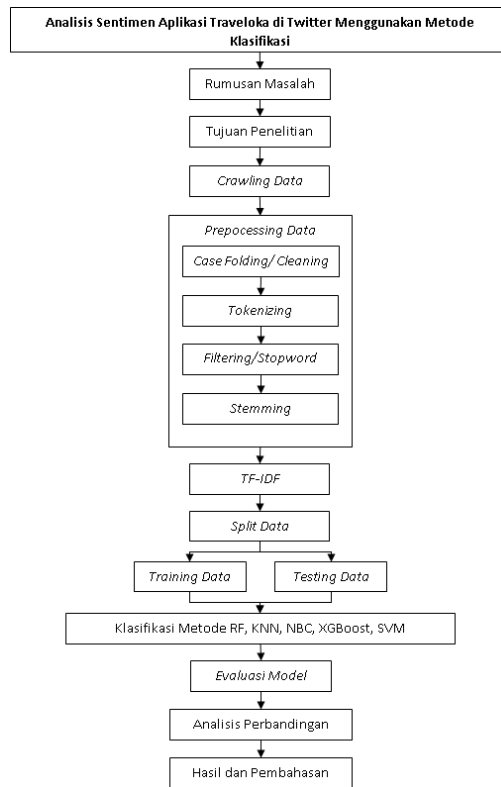
XGBoost merupakan model linier yang efisien dalam memecahkan model linier dan mendukung sejumlah proses objektif, seperti regresi, klasifikasi, dan peringkat (Christanto *et al.*, 2023). XGBOOST menerapkan mekanisme decision tree untuk membuat weak learner menjadi learner yang lebih baik. Weak learner itu sendiri adalah “model lemah” yang memiliki kinerja rendah dalam mengklasifikasikan data secara cepat, namun tetap lebih baik daripada menebak dengan acak. XGBOOST merupakan bentuk pengembangan dari algoritma gradient boosting yang menggunakan regularisasi untuk mengurangi overfitting (Ikegami & Darmawan, 2022).

### 2.7 *Support Vector Machine (SVM)*

SVM mencoba menemukan hyperline (batas keputusan) dengan memaksimalkan jarak antar kelas untuk memastikan generalisasi yang tinggi untuk data di masa mendatang (Suyanto, 2019:216). SVM akan memisahkan tiap tweet kedalam dua kelas yaitu tweet positif dan tweet negatif (Wahyudi & Kusumawardana, 2021)

## 3 METODE PENELITIAN

Penelitian ini menggunakan metode penelitian kuantitatif untuk mengukur dan menggambarkan fenomena yang terkait dengan analisis sentimen aplikasi Traveloka di Twitter. Metode kuantitatif digunakan untuk meneliti pada populasi atau sampel tertentu, pengumpulan data menggunakan instrumen penelitian, data penelitian berupa angka-angka, analisis bersifat statistik, bertujuan untuk menguji hipotesis yang telah ditetapkan (Sugiyono, 2020:16).

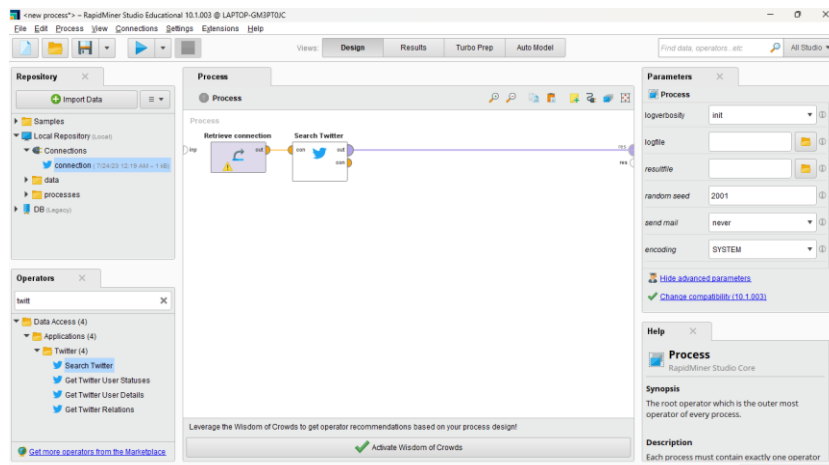


Gambar 2. Tahapan Penelitian.

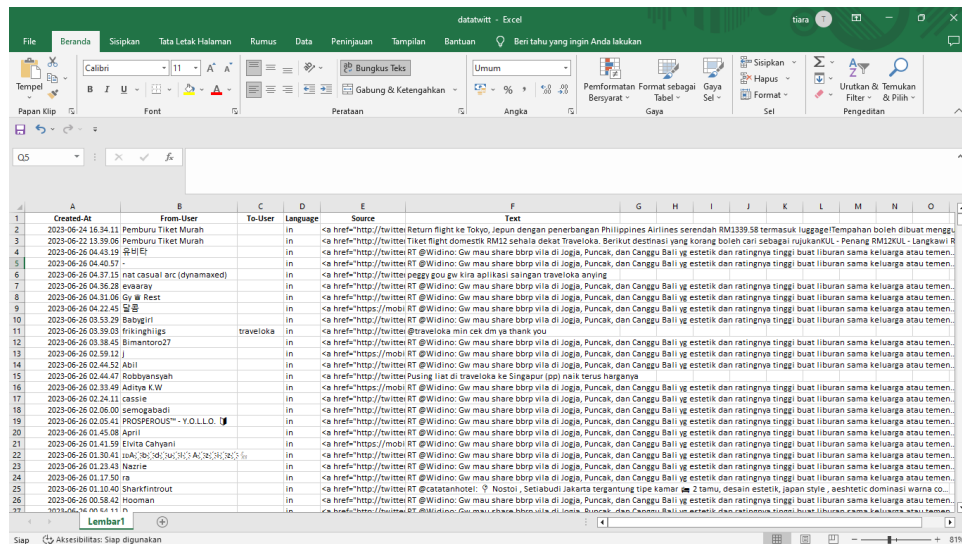
## 4 HASIL DAN PEMBAHASAN

### 4.1 Pengambilan data

Tahap pengumpulan data yang dilakukan melalui proses crawling pada platform media sosial Twitter, terdapat beberapa kata kunci yang digunakan yaitu Traveloka, pengalaman Traveloka, dan jasa Traveloka. Selain itu, data yang dikumpulkan hanya berupa data yang berbahasa Indonesia dan dari Indonesia. Pengambilan data dilakukan pada dua waktu yaitu pada bulan Juni dan Juli 2023 dan jumlah data yang diperoleh sebanyak 2.217. Proses crawling menggunakan aplikasi ketiga yaitu RapidMiner diberikan pada Gambar 3. Data dapat disimpan dalam bentuk csv maupun excel, seperti pada Gambar 4.



Gambar 3. Proses *Crawling*.



Gambar 4. Hasil Pengambilan Data.

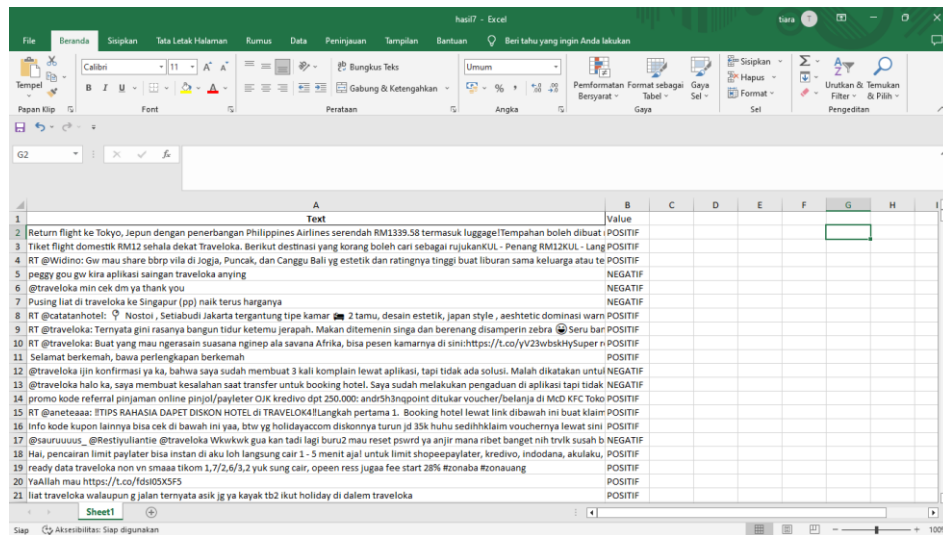
Selanjutnya proses *cleaning* yaitu membersihkan data yang duplikat dengan fungsi `drop_duplicate()` dalam python. Hasilnya data telah berkurang sebanyak 1.475 menjadi 742 data yang siap diolah dari 2.217 data.

	Text	Value
0	Return flight ke Tokyo, Jepun dengan penerbang...	POSITIF
1	Tiket flight domestik RM12 sehalo dekat Travel...	POSITIF
2	RT @Widino: Gw mau share bbrp vila di Jogja, P...	POSITIF
3	peggy gou gw kira aplikasi saingan traveloka a...	NEGATIF
4	@traveloka min cek dm ya thank you	NEGATIF
...	...	...
738	hi! , @diacblo open gestun all paylater, fee...	POSITIF
739	@cvltzire hi! , @diacblo open gestun all pay...	POSITIF
740	hi! , @diacblo open gestun all paylater, fee...	POSITIF
741	@cylacacila hi! , @diacblo open gestun all p...	POSITIF
742	@diacblo hi! , @diacblo open gestun all payl...	POSITIF

743 rows × 2 columns

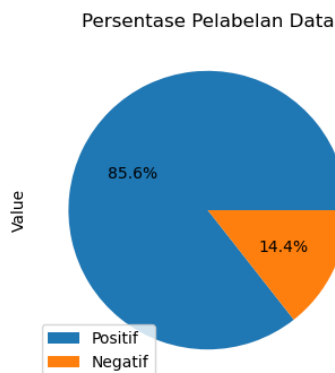
Gambar 5. Remove Duplicates.

Sebelumnya, data hasil crawling telah difokuskan hanya pada kolom Text saja. Pelabelan sentimen pada Gambar 6 dilakukan dengan cara manual oleh penulis dengan mengategorikan data ke dalam dua sentimen, yaitu positif dan negatif.

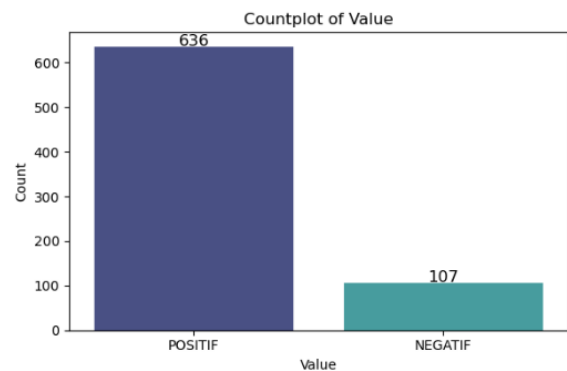


Gambar 6. Pelabelan data.

Diperoleh persentase terbesar yaitu, 85,6% untuk sentimen positif. Sedangkan sentimen negatif sebesar 14,4%.



Gambar 7. Persentase Pelabelan Data



Gambar 8. Diagram Pelabelan Data.

Gambar 7 dan 8 menunjukkan bahwa jumlah sentimen positif jumlahnya sebanyak 636 dan sentimen negatif sebesar 107. Hal ini menyatakan bahwa mayoritas data dimiliki oleh sentimen positif, dengan jumlah yang jauh lebih besar daripada sentimen negatif.

## 4.2 Pre-processing Data

### 4.2.1 Cleaning

Cleaning adalah teknik pembersihan data, diantaranya menghapus karakter-karakter yang tidak relevan, tanda baca, dan simbol khusus dari teks, serta menormalisasi menghapus URL.

Cleaning Result :

- 0 Pusing liat di traveloka ke Singapur pp naik t...
- 1 liat traveloka walaupun g jalan ternyata asik ...
- 2 Mungkin ada yg lebih oke Dari dulu selalu pake...
- 3 traveloka halo ka saya membuat kesalahan saat ...
- 4 telyufess aku biasa naik jackal holidays pesen...

Gambar 9. Cleaning Result

Sebelum	Sesudah
Pusing liat di traveloka ke Singapur (pp) naik terus harganya	Pusing liat di traveloka ke Singapur pp naik terus harganya
liat traveloka walaupun g jalan ternyata asik jg ya kayak tb2 ikut holiday di dalem traveloka	liat traveloka walaupun g jalan ternyata asik jg ya kayak tb2 ikut holiday di dalem traveloka

Gambar 10. Hasil *Cleaning*.

#### 4.2.2 Case Folding

*Case folding* adalah mengubah semua huruf dalam dokumen menjadi huruf kecil. Hanya huruf a sampai z, selain itu karakter lain dihilangkan sebagai huruf dan diperlakukan sebagai pemisah.

Case Folding Result:

```

0  pusing liat di traveloka ke singapur pp naik t...
1  liat traveloka walaupun g jalan ternyata asik ...
2  mungkin ada yg lebih oke dari dulu selalu pake...
3  traveloka halo ka saya membuat kesalahan saat ...
4  telyufess aku biasa naik jackal holidays pesen...
    
```

Gambar 11. *Case Folding*.

Sebelum	Sesudah
Pusing liat di traveloka ke Singapur (pp) naik terus harganya	pusing liat di traveloka ke singapur pp naik terus harganya
liat traveloka walaupun g jalan ternyata asik jg ya kayak tb2 ikut holiday di dalem traveloka	liat traveloka walaupun g jalan ternyata asik jg ya kayak tb2 ikut holiday di dalem traveloka

Gambar 12. Hasil *Case Folding*.

#### 4.2.3 Tokenizing

Tokenisasi adalah langkah pemotongan string masukan berdasarkan kata- kata yang membentuknya, atau proses pemecahan kata pada kalimat.

Tokenizing Result :

```

0  ['pusing', 'liat', 'di', 'traveloka', 'ke', 's...
1  ['liat', 'traveloka', 'walaupun', 'g', 'jalan'...
2  ['mungkin', 'ada', 'yg', 'lebih', 'oke', 'dari...
3  ['traveloka', 'halo', 'ka', 'saya', 'membuat',...
4  ['telyufess', 'aku', 'biasa', 'naik', 'jackal'...
    
```

Gambar 13. *Tokenizing*.

Sebelum	Sesudah
pusing liat di traveloka ke singapur pp naik terus harganya	["pusing", "liat", "di", "traveloka", "ke", "singapur", "pp", "naik", "terus", "harganya"]
liat traveloka walaupun g jalan ternyata asik jg ya kayak tb2 ikut holiday di dalam traveloka	["liat", "traveloka", "walaupun", "g", "jalan", "ternyata", "asik", "jg", "ya", "kayak", "tb2", "ikut", "holiday", "di", "dalam", "traveloka"]

Gambar 14. Hasil *Tokenizing*.

#### 4.2.4 Filtering

Hal pertama melakukan formalisasi untuk mengganti kata-kata yang tidak baku atau berupa kata singkatan dan lain-lainnya menggunakan slangword. Mengubah bahasa yang tidak formal menjadi bahasa yang lebih formal dan terstruktur.

Formalisasi Result :

```

0  ['pusing', 'lihat', 'di', 'traveloka', 'ke', '...'
1  ['lihat', 'traveloka', 'walaupun', 'tidak', 'j...
2  ['mungkin', 'ada', 'yang', 'lebih', 'oke', 'da...
3  ['traveloka', 'halo', 'kakak', 'saya', 'membua...
4  ['telyufess', 'aku', 'biasa', 'naik', 'jackal'...
```

Gambar 15. Formalisasi.

Sebelum	Sesudah
["pusing", "liat", "di", "traveloka", "ke", "singapur", "pp", "naik", "terus", "harganya"]	["pusing", "lihat", "di", "traveloka", "ke", "singapur", "pulang pergi", "naik", "terus", "harganya"]
["liat", "traveloka", "walaupun", "g", "jalan", "ternyata", "asik", "jg", "ya", "kayak", "tb2", "ikut", "holiday", "di", "dalam", "traveloka"]	["lihat", "traveloka", "walaupun", "tidak", "jalan", "ternyata", "asik", "juga", "iya", "kayak", "tiba-tiba", "ikut", "liburan", "di", "dalam", "traveloka"]

Gambar 16. Hasil Formalisasi.

*Stopword* digunakan menghapus kata-kata umum yang sering muncul dalam bahasa (*stopwords*) karena mereka tidak memberikan informasi penting untuk analisis.

Stopword Result :

```

0  ['pusing', 'lihat', 'traveloka', '...
1  ['lihat', 'traveloka', 'walaupun', 'tidak', 'j...
2  ['mungkin', 'ada', 'yang', 'lebih', 'oke', 'da...
3  ['traveloka', 'halo', 'kakak', 'saya', 'membua...
4  ['telyufess', 'aku', 'biasa', 'naik', 'jackal'...
```

Gambar 17. Stopword Result.

Sebelum	Sesudah
["pusing", "lihat", "di", "traveloka", "ke", "singapur", "pulang pergi", "naik", "naik", "terus", "harganya"]	["pusing", "lihat", "traveloka", "singapur", "pulang pergi", "naik", "terus", "harganya"]
["lihat", "traveloka", "walaupun", "tidak", "jalan", "ternyata", "asik", "juga", "iya", "kayak", "tiba-tiba", "ikut", "liburan", "di", "dalam", "traveloka"]	["lihat", "traveloka", "walaupun", "tidak", "jalan", "ternyata", "asik", "iya", "kayak", "tiba-tiba", "ikut", "liburan", "dalam", "traveloka"]

Gambar 18. Hasil Stopword.

#### 4.2.5 Stemming

Stemming bertujuan untuk mengubah kata-kata menjadi bentuk dasar atau kata dasar. Stem (akar kata) adalah bagian dari kata yang tersisa setelah dihilangkan imbuhan (Jumeilah, 2017).

```

'pusing' : pusing
'lihat' : lihat
'di' : di
'traveloka' : traveloka
'ke' : ke
'singapura' : singapura
'pulang pergi' : pulang pergi
'naik' : naik
'terus' : terus
'harganya' : harga
'walaupun' : walaupun
'tidak' : tidak
'jalan' : jalan
'ternyata' : nyata
'asik' : asik
'juga' : juga
'iya' : iya
'kayak' : kayak
'tiba-tiba' : tiba
```

Gambar 19 Stemming

Sebelum	Sesudah
["pusing", "lihat", "di", "traveloka", "ke", "singapur", "pulang pergi", "naik", "terus", "harganya"]	['pusing', 'lihat', 'di', 'traveloka', 'ke', 'singapur', 'pulang pergi', 'naik', 'terus', 'harga']
["lihat", "traveloka", "walaupun", "tidak", "jalan", "ternyata", "asik", "juga", "iya", "kayak", "tiba-tiba", "ikut", "liburan", "di", "dalam", "traveloka"]	['lihat', 'traveloka', 'walaupun', 'tidak', 'jalan', 'nyata', 'asik', 'juga', 'iya', 'kayak', 'tiba', 'ikut', 'libur', 'di', 'dalam', 'traveloka']

Gambar 20. Hasil *Stemming*.

### 4.3 TF-IDF

TF-IDF merupakan metode pembobotan untuk mengubah hasil preprocessing menjadi bentuk numerik. Hasilnya akan digunakan sebagai input untuk model analisis sentimen. Hasil dari proses TF-IDF ditunjukkan pada gambar, yaitu berupa sparse matrix yang memuat bobot TF-IDF dengan baris sebanyak jumlah review dan jumlah kolom sebanyak jumlah fitur (kata).

(0, 2317)	0.05265185433851024
(0, 2289)	0.23812741728270595
(0, 2228)	0.17945513976660546
(0, 2218)	0.23812741728270595
(0, 2040)	0.23812741728270595
(0, 2016)	0.23812741728270595
(0, 1895)	0.23812741728270595
(0, 1878)	0.23812741728270595
(0, 1780)	0.1082803872319848
(0, 1726)	0.23812741728270595
(0, 1426)	0.32501117486740516
(0, 1357)	0.23812741728270595
(0, 1154)	0.10711359827518932
(0, 1081)	0.23812741728270595
(0, 878)	0.171155070572608
(0, 794)	0.20031650235820428
(0, 636)	0.13502336565293832
(0, 564)	0.23812741728270595
(0, 471)	0.18580942719223598

Gambar 21. TF-IDF.

### 4.4 Split data

Proses *split data* yaitu dengan membagi *dataset* menjadi dua subset yaitu, data training dan data testing. Setelah dilakukan TF-IDF data dibagi dengan perbandingan 70:30. Data *training* dibagi 70% yang berjumlah 594 data dan 40% data *testing* dengan jumlah 149 data. Tujuan *split data* adalah untuk melatih model pada data training dan menguji kinerjanya pada data testing.

### 4.5 Classification Method

#### 4.5.1 Random Forest

Hasil dari klasifikasi menggunakan *Random Forest* terdiri dari metrik evaluasi yang menyajikan informasi tentang kualitas prediksi model dalam mengklasifikasikan data menjadi kelas

positif (1) dan kelas negatif (0). Nilai akurasi diperoleh untuk prediksi sebesar 87%. Precision yaitu untuk mengukur prediksi kelas positif yang tepat, pada kelas positif sebesar 89% dan untuk kelas negatif sebesar 60%. Recall untuk memprediksi kelas positif yang dapat dideteksi oleh model, pada kelas positif sebesar 97% dan kelas negatif 28%. F1-score yaitu rata-rata antara precision dan recall, pada kelas positif diperoleh 93% dan kelas negatif 38%.

	precision	recall	f1-score	support
0	0.60	0.28	0.38	32
1	0.89	0.97	0.93	191
accuracy			0.87	223
macro avg	0.74	0.62	0.66	223
weighted avg	0.85	0.87	0.85	223

Gambar 22. Hasil Metode *Random Forest*.

#### 4.5.2 Support Vector Machine

Classification Report SVM:				
	precision	recall	f1-score	support
0	0.85	0.34	0.49	32
1	0.90	0.99	0.94	191
accuracy			0.90	223
macro avg	0.87	0.67	0.72	223
weighted avg	0.89	0.90	0.88	223

Gambar 23. Hasil Metode *Support Vector Machine*.

Hasil dari metode *Support Vector Machine* yaitu dari metrik evaluasi yang menyajikan informasi tentang kualitas prediksi model dalam mengklasifikasikan data menjadi kelas positif (1) dan kelas negatif (0). Nilai akurasi diperoleh untuk prediksi sebesar 90%. Precision yaitu untuk mengukur prediksi kelas positif yang tepat, pada kelas positif sebesar 90% dan untuk kelas negatif sebesar 85%. Recall untuk memprediksi kelas positif yang dapat dideteksi oleh model, pada kelas positif sebesar 99% dan kelas negatif 34%. F1-score yaitu rata-rata antara precision dan recall, pada kelas positif diperoleh 94% dan kelas negatif 49%.

#### 4.5.3 Naive Bayes Classifier

Classification Report Naive Bayes:				
	precision	recall	f1-score	support
0	0.42	0.25	0.31	32
1	0.88	0.94	0.91	191
accuracy			0.84	223
macro avg	0.65	0.60	0.61	223
weighted avg	0.82	0.84	0.83	223

Gambar 24. Hasil Metode *Naive Bayes*.

Hasil dari metode *Naive Bayes Classifier* yaitu dari metrik evaluasi yang menyajikan informasi tentang kualitas prediksi model dalam mengklasifikasikan data menjadi kelas positif (1) dan kelas negatif (0). Nilai akurasi diperoleh untuk prediksi sebesar 84%. Precision yaitu untuk mengukur prediksi kelas positif yang tepat, pada kelas positif sebesar 88% dan untuk kelas negatif sebesar 42%. Recall untuk memprediksi kelas positif yang dapat dideteksi oleh model, pada kelas positif sebesar

94% dan kelas negatif 25%. F1-score yaitu rata-rata antara precision dan recall, pada kelas positif diperoleh 91% dan kelas negatif 31%.

#### 4.5.4 *K-Nearest Neighbors* (KNN)

```

Hasil Cross-Validation:
Nilai k = 1: Akurasi = 0.8385
Nilai k = 2: Akurasi = 0.7962
Nilai k = 3: Akurasi = 0.8692
Nilai k = 4: Akurasi = 0.8462
Nilai k = 5: Akurasi = 0.8673
Nilai k = 6: Akurasi = 0.8577
Nilai k = 7: Akurasi = 0.8692
Nilai k = 8: Akurasi = 0.8712
Nilai k = 9: Akurasi = 0.8750
Nilai k = 10: Akurasi = 0.8788
Nilai k = 11: Akurasi = 0.8846
Nilai k = 12: Akurasi = 0.8769
Nilai k = 13: Akurasi = 0.8827
Nilai k = 14: Akurasi = 0.8769
Nilai k = 15: Akurasi = 0.8788
Nilai k = 16: Akurasi = 0.8712
Nilai k = 17: Akurasi = 0.8692
Nilai k = 18: Akurasi = 0.8731
Nilai k = 19: Akurasi = 0.8731
Nilai k = 20: Akurasi = 0.8769
Nilai k terbaik adalah 11 dengan akurasi 0.8846

```

Gambar 25. Nilai K.

```

Classification Report KNN:
              precision    recall  f1-score   support

     0           0.69       0.34       0.46         32
     1           0.90       0.97       0.93        191

 accuracy                   0.88         223
 macro avg           0.79       0.66       0.70         223
 weighted avg        0.87       0.88       0.87         223

```

Gambar 26. Hasil Metode *K-Nearest Neighbors*.

Hasil dari metode *K-Nearest Neighbors* yaitu dari metrik evaluasi yang menyajikan informasi tentang kualitas prediksi model dalam mengklasifikasikan data menjadi kelas positif (1) dan kelas negatif (0). Nilai akurasi diperoleh untuk prediksi sebesar 88%. Precision yaitu untuk mengukur prediksi kelas positif yang tepat, pada kelas positif sebesar 90% dan untuk kelas negatif sebesar 69%. Recall untuk memprediksi kelas positif yang dapat dideteksi oleh model, pada kelas positif sebesar 97% dan kelas negatif 34%. F1-score yaitu rata-rata antara precision dan recall, pada kelas positif diperoleh 93% dan kelas negatif 46%.

#### 4.5.5 XGBOOST

```

Classification Report XGBoost:
              precision    recall  f1-score   support

     0           0.65       0.47       0.55         32
     1           0.92       0.96       0.94        191

 accuracy                   0.89         223
 macro avg           0.78       0.71       0.74         223
 weighted avg        0.88       0.89       0.88         223

```

Gambar 27. Hasil Metode *XGBOOST*.

Hasil dari metode XGBoost yaitu dari metrik evaluasi yang menyajikan informasi tentang kualitas prediksi model dalam mengklasifikasikan data menjadi kelas positif (1) dan kelas negatif (0). Nilai akurasi diperoleh untuk prediksi sebesar 89%. Precision yaitu untuk mengukur prediksi kelas positif yang tepat, pada kelas positif sebesar 92% dan untuk kelas negatif sebesar 65%. Recall untuk memprediksi kelas positif yang dapat dideteksi oleh model, pada kelas positif sebesar 96% dan kelas negatif 47%. F1-score yaitu rata-rata antara precision dan recall, pada kelas positif diperoleh 94% dan kelas negatif 55%.

#### 4.6 Evaluasi Model

Tahap evaluasi bertujuan untuk menilai nilai kegunaan dari model yang telah berhasil dibuat pada tahap sebelumnya. Evaluasi model menggunakan dua model yaitu confusion matrix dan AUC.


##### 4.6.1 Random Forest

*Confusion matrix* dilakukan untuk menunjukkan hasil kinerja model klasifikasi dari algoritma *Random Forest*.


$$\begin{bmatrix} 9 & 23 \\ 6 & 185 \end{bmatrix}$$

Gambar 28. *Confusion Matrix RF*.

Hasil yang diperoleh nilai confusion matrix pada *Random Forest* yaitu pada kelas 0, terdapat 9 TN (True Negative) artinya da 9 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan benar sebagai kelas 0 dan 23 FP (False Positive) artinya ada 23 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan salah sebagai kelas 1. Sementara pada kelas 1 terdapat 6 FN (False Negative) artinya ada 6 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan salah sebagai kelas 0 dan 185 TP (True Positive) artinya ada 185 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan benar. Secara keseluruhan, model ini memiliki performa yang baik dalam mengklasifikasikan kelas mayoritas pada kelas 1 dengan nilai precision, recall dan F1-score yang tinggi.



Gambar 29. Visualisasi *Confusion Matrix RF*.



Gambar 30 Visualisasi AUC *Random Forest*

Nilai AUC untuk model algoritma *Random Forest* adalah 0.6249181937172774. Nilai AUC tersebut bila dibulatkan bernilai 0.62 seperti pada Gambar 30. Nilai tersebut berada diatas 0,5, menunjukkan bahwa model memiliki kemampuan baik.


#### 4.6.2 Support Vector Machine (SVM)

*Confusion matrix* dilakukan untuk menunjukkan hasil kinerja model dari algoritma *Support Vector Machine*


$$\begin{bmatrix} 11 & 21 \\ 2 & 189 \end{bmatrix}$$

Gambar 31. *Confusion Matrix SVM.*

Hasil yang diperoleh nilai confusion matrix pada SVM yaitu pada aktual kelas 0, terdapat 11 TN (True Negative) Ada 11 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan benar sebagai kelas 0 dan 21 FP (False Positive) artinya ada 21 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan salah sebagai kelas 1. Sementara pada aktual kelas 1 terdapat 2 FN (False Negative) artinya ada 2 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan salah sebagai kelas 0 dan 189 TP (True Positive) artinya Ada 189 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan benar. Secara keseluruhan, model ini memiliki performa yang baik dalam mengklasifikasikan kelas 1.



Gambar 32. Visualisasi Confusion Matrix SVM.



Gambar 33. Visualisasi AUC SVM.

Nilai AUC model algoritma SVM adalah 0.6666393979057592. Nilai AUC dibulatkan menjadi 0,67 seperti yang ditunjukkan pada Gambar 33. Nilai ini di atas 0,5 menunjukkan bahwa kinerja model baik

#### 4.6.3 Naive Bayes Classifier (NBC)


*Confusion matrix* digunakan untuk menunjukkan hasil performa model algoritma NBC.

$$\begin{bmatrix} 8 & 24 \\ 11 & 180 \end{bmatrix}$$


Gambar 34. *Confusion Matrix NBC.*

Hasil yang didapatkan nilai confusion matrix pada NBC yaitu pada aktual kelas 0, terdapat 8 TN (True Negative) artinya da 8 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan benar sebagai kelas 0 dan 24 FP (False Positive) artinya dan 24 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan salah sebagai kelas 1. Sementara pada aktual kelas 1 terdapat 11 FN (False Negative) artinya Ada 11 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan salah

sebagai kelas 0 dan 180 TP (True Positive) artinya Ada 180 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan benar.



Gambar 35 Visualisasi *Confusion Matrix* NBC



Gambar 36 Visualisasi *AUC* NBC

Algoritma NBC memiliki Area Under the Curve (AUC) sebesar 0.5962041884816753. Nilai tersebut dibulatkan menjadi 0,60, seperti yang terlihat pada Gambar 36. Nilai tersebut menunjukkan bahwa kinerja model berada di atas 0,5 yang mengindikasikan bahwa model bekerja dengan baik.


#### 4.6.4 *K-Nearest Neighbors* (KNN)

*Confusion matrix* digunakan untuk mengevaluasi kinerja model algoritma K-NN.


$$\begin{bmatrix} 11 & 21 \\ 5 & 186 \end{bmatrix}$$

Gambar 37. *Confusion matrix* KNN.

Hasil evaluasi model K-NN menunjukkan nilai confusion matrix sebagai berikut: untuk kelas aktual 0, terdapat 11 TN (True Negative) artinya ada 11 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan benar sebagai kelas 0 dan 21 FP (False Positive) artinya Ada 21 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan salah sebagai kelas 1. Sementara pada kelas aktual 1 terdapat 5 FN (False Negative) artinya ada 5 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan salah sebagai kelas 0 dan 186 TAPI (True Positive) artinya ada 186 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan benar.



Gambar 38. Visualisasi *Confusion Matrix* KNN.



Gambar 39. Visualisasi *AUC* KNN.

AUC dari algoritma K-NN adalah 0.6587859947643979. Nilai ini dibulatkan menjadi 0,66, dan dapat dilihat pada Gambar 4.31. Angka tersebut menunjukkan bahwa kinerja model berada di atas 0,5 yang menandakan bahwa model bekerja dengan baik

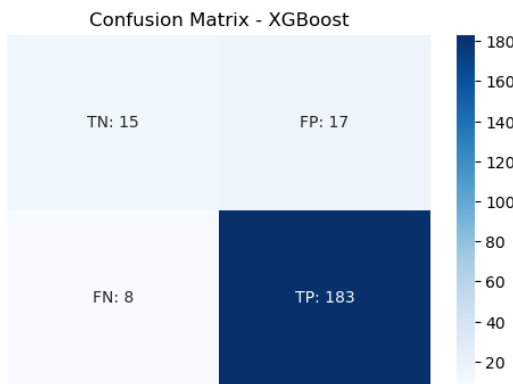
**4.6.5 XGBOOST**

*Confusion matrix* digunakan untuk mengukur hasil kinerja model dari algoritma XGBOOST


$$\begin{bmatrix} 15 & 17 \\ 8 & 183 \end{bmatrix}$$

Gambar 40. *Confusion matrix XGBOOST.*

Hasil yang diperoleh model XGBOOST adalah yaitu pada aktual kelas 0, terdapat 15 TN (True Negative) artinya ada 15 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan benar sebagai kelas 0 dan 17 FP (False Positive) artinya ada 17 contoh yang sebenarnya kelas 0 (Negatif) dan diprediksi dengan salah sebagai kelas 1, sementara pada aktual kelas 1 terdapat 8 FN (False Negative) artinya ada 8 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan salah sebagai kelas 0 dan 183 TP (True Positive) artinya Ada 183 contoh yang sebenarnya kelas 1 (Positif) dan diprediksi dengan benar.



Gambar 41. Visualisasi *Confusion Matrix XGBOOST*



Gambar 42. Visualisasi *AUC XGBOOST*

Nilai AUC untuk model algoritma XGBoost adalah 0.7134325916230366. Nilai AUC tersebut bila dibulatkan bernilai 0.71 seperti pada Gambar 42. Nilai tersebut berada di atas 0,5, menunjukkan bahwa model memiliki kemampuan baik.

**4.7 Analisis Perbandingan**

Algoritma	Accuracy	Precision	Recall	F1-score	AUC
Random Forest	80%	74%	62%	66%	62%
Support Vector Machine	90%	87%	67%	72%	67%
Naive Bayes Classifier	84%	65%	60%	61%	60%
K-Nearest Neighbors	88%	79%	66%	70%	66%
XGBOOST	89%	78%	71%	74%	71%

Gambar 43. Analisis Perbandingan.

Berdasarkan hasil evaluasi pada Gambar 43 menunjukkan bahwa *Support Vector Machine* memiliki kinerja lebih baik dengan nilai accuracy sebesar 90%, diikuti oleh XGBOOST sebesar 89%, KNN sebesar 88%, *Random Forest* sebesar 87% dan NBC sebesar 84% yang menempati posisi terakhir. Sedangkan hasil dari evaluasi model menggunakan AUC (Area under the ROC Curve) diperoleh bahwa kinerja paling baik dimiliki oleh XGBOOST dengan nilai sebesar 71%, diikuti oleh SVM sebesar 67%, KNN sebesar 66%, *Random Forest* sebesar 62%, dan Naive Bayes memperoleh nilai paling rendah dengan nilai 60%.

Hasilnya, menunjukkan bahwa sebagian besar tanggapan positif dari pengguna terkait layanan dalam aplikasi Traveloka memiliki potensi untuk memperkuat loyalitas pelanggan dan meningkatkan kepercayaan pelanggan terhadap Traveloka. Penerapan SVM dapat membantu meningkatkan pengalaman pengguna, sementara XGBoost dapat membantu meningkatkan pada bagian tertentu yang mungkin memerlukan perhatian lebih dalam pengalaman pengguna. Temuan ini dapat membantu Traveloka dalam meningkatkan kualitas secara menyeluruh beriringan dengan memperbaiki aspek penting lainnya.

## 5 SIMPULAN

Berdasarkan hasil pengujian metode klasifikasi yang telah dilakukan yaitu XGBoost memiliki kinerja yang paling baik dalam mengklasifikasikan sentimen masyarakat terhadap aplikasi Traveloka di Twitter diikuti oleh SVM dalam hal akurasi, berikut adalah kesimpulan yang dapat diambil oleh peneliti:

1. Analisis sentimen masyarakat terhadap aplikasi Traveloka di Twitter menggunakan *Random Forest*, diperoleh data positif sebesar 85,6% berjumlah 636 data, serta 14,4% sentimen negatif berjumlah 107 data. Dataset dibagi menjadi 70:30. Pada metode klasifikasi *Random Forest* menghasilkan nilai accuracy sebesar 87% dan AUC 62%. Dari hasil evaluasi, dapat disimpulkan bahwa algoritma memiliki performa yang baik dengan tingkat keberhasilan akurasi tinggi, dan nilai AUC.
2. Analisis sentimen masyarakat terhadap aplikasi Traveloka di Twitter menggunakan SVM. Diketahui data positif sebesar 85,6% berjumlah 636 data, dan 14,4% sentimen negatif berjumlah 107 data. Dataset di bagi menjadi 70:30. Pada metode ini menghasilkan nilai akurasi sebesar 90% dan AUC 67%. Dapat disimpulkan bahwa performa model ini memiliki keberhasilan tinggi dalam tingkat akurasi dan nilai AUC dalam klasifikasi.
3. Analisis sentimen masyarakat terhadap aplikasi Traveloka di Twitter menggunakan NBC. Diketahui data positif sebesar 85,6% berjumlah 636 data, serta 14,4% sentimen negatif berjumlah 107 data. Dataset di bagi menjadi 70:30. Hasil evaluasi metrik menunjukkan nilai akurasi sebesar 84% dan AUC 60%. Dapat disimpulkan bahwa model memiliki akurasi yang baik dengan performa model cukup baik dengan evaluasi AUC.
4. Analisis sentimen masyarakat terhadap aplikasi Traveloka di Twitter menggunakan KNN. Diketahui data positif sebesar 85,6% berjumlah 636 data, serta 14,4% sentimen negatif berjumlah 107 data. Diperoleh nilai akurasi 84% dan AUC 66%. Kesimpulannya model memiliki akurasi yang baik, dan mampu mengenali data positif. Serta, performa AUC cukup baik dalam mengklasifikasi.
5. Analisis sentimen masyarakat terhadap aplikasi Traveloka di Twitter menggunakan XGBOOST. Diketahui data positif sebesar 85,6% berjumlah 636 data, serta 14,4% sentimen negatif berjumlah 107 data. Hasil evaluasi metrik menunjukkan nilai akurasi sebesar 89% dan AUC 71%. Disimpulkan bahwa hasil akurasi sangat baik dan uji model menggunakan AUC juga memiliki performa yang sangat baik.
6. Analisis Perbandingan dari metode RF, SVM, NBC, KNN, dan XGBOOST menghasilkan bahwa algoritma *Support Vector Machine* (SVM) memiliki nilai akurasi paling tinggi sebesar 90%. Namun, dalam pengklasifikasian uji model AUC algoritma XGBoost yang paling memiliki kinerja paling baik dengan memperoleh nilai 71%.

**DAFTAR PUSTAKA**

- Aziz, A., Fauziah, F., & Fitri, I. (2021). Analisis Sentimen Terhadap Kebijakan Pemerintah Tentang Larangan Mudik Hari Raya Idulfitri di Indonesia Tahun 2021 Menggunakan Metode Naïve Bayes. *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, 5(2), 842-851.
- Christanto, H., Rahmad, J., Sinurat, S. H., Sitompul, D. R. H., Sitomorang, A., Ziegel, D. J., & Indra, E. (2023). Analisis Perbandingan Decision Tree, Support Vector Machine, dan Xgboost dalam Mengklasifikasi Review Hotel Trip Advisor. *Jurnal Teknologi Informatika dan Komputer*, 9(1), 306-319.
- Clinton, B. (2019). Pengguna Aktif Harian Twitter Indonesia Diklaim Terbanyak. *Kompas.com*. <https://tekno.kompas.com/read/2019/10/30/16062477/pengguna-aktif-harian-twitter-indonesia-diklaim-terbanyak#:~:text=Pada%20laporan%20finansial%20Twitter%20kuartal%20ke-3%20tahun%202019%2C,yang%20pertumbuhan%20pengguna%20aktif%20harian%20Twitter-nya%20paling%20besar>.
- Databoks. (2022). Survei Populix: Traveloka Aplikasi Perjalanan Online Paling Banyak Disukai Konsumen. *Databoks*. <https://databoks.katadata.co.id/datapublish/2022/12/16/survei-populix-traveloka-aplikasi-perjalanan-online-paling-banyak-disukai-konsumen>
- Ikegami, A., & Darmawan, I. D. M. B. A. (2022). Analisis Sentimen dan Pemodelan Topik Ulasan Aplikasi Noice Menggunakan XGBOOST dan LDA. *JNATIA*, 1(1), 325–336.
- Jumeilah, F. S. (2017). Penerapan Support Vector Machine (SVM) untuk Pengkategorian Penelitian. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 1(1), 19-25. <https://doi.org/10.29207/resti.v1i1.11>
- Novalita, N., Herdiani, A., Lukmana, I., & Puspandari, D. (2019, March). Cyberbullying identification on twitter using random forest classifier. Dalam *Journal of Physics: Conference Series* (Vol. 1192, No. 1, p. 012029). IOP Publishing. <https://doi.org/10.1088/1742-6596/1192/1/012029>
- Sihombing, L. O., Hannie, H., & Dermawan, B. A. (2021). Sentimen Analisis Customer Review Produk Shopee Indonesia Menggunakan Algoritma Naïve Bayes Classifier. *Edumatic: Jurnal Pendidikan Informatika*, 5(2), 233-242. <https://doi.org/10.29408/edumatic.v5i2.4089>
- Suyanto. 2019. *Data Mining Untuk Klasifikasi dan Klusterisasi Data*. Bandung: Informatika Bandung.
- Wandani, A., Fauziah, F., & Andrianingsih, A. (2021). Sentimen Analisis Pengguna Twitter pada Event Flash Sale Menggunakan Algoritma K-NN, Random Forest, dan Naive Bayes. *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, 5(2), 651-665.
- Wardani, N. R., Saepudin, S., & Warman, C. (2022). Sentimen Analisis Kegiatan Trading Pada Aplikasi Twitter dengan Algoritma SVM, KNN Dan Random Forrest. *J-SAKTI (Jurnal Sains Komputer dan Informatika)*, 6(2), 863-870.