

# Twitter Sentiment Classification towards Telecommunication Provider Users in Indonesia

Fernanda Mulya Syah Putra<sup>1\*</sup>, Sindhu Rakasiwi<sup>2\*</sup>, Noval Ariyanto<sup>3\*</sup>

\* Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro, Semarang  
[fernandamulyasp@gmail.com](mailto:fernandamulyasp@gmail.com)<sup>1</sup>, [sindhu.rakasiwi@dsn.dinus.ac.id](mailto:sindhu.rakasiwi@dsn.dinus.ac.id)<sup>2</sup>, [noval.riyanjuan@gmail.com](mailto:noval.riyanjuan@gmail.com)<sup>3</sup>

## Article Info

### Article history:

Received 2025-01-31

Revised 2025-02-23

Accepted 2025-02-25

### Keyword:

Internet,  
Naive Bayes,  
Sentimen,  
Support Vector Machine,  
Twitter,

## ABSTRACT

Internet services have become essential for communication and information sharing. Nowadays, daily activities are conducted through the internet. This study aims to gain a better understanding of the components that influence user perception and satisfaction using textual, sentiment, and statistical analysis techniques. By applying machine learning algorithms such as Naïve Bayes and Support Vector Machine (SVM), this research analyzes customer perceptions of telecommunication service providers in Indonesia. The dataset consists of 300 tweets obtained from the Kaggle platform. The objective is to identify elements that affect customer satisfaction, particularly those related to network stability and service quality. Data preprocessing is carried out using methods such as case folding, normalization, stemming, and stopword removal to enhance sentiment analysis model performance. The results show that SVM outperforms Naïve Bayes in precision and recall, achieving an accuracy of 90% compared to Naïve Bayes' 87%. This demonstrates SVM's ability to classify positive and negative sentiments more accurately. Common topics found in the analysis include customer satisfaction with network stability and affordable pricing, while dissatisfaction arises from poor connectivity and slow customer service response. These findings provide valuable insights for service providers to improve service quality and enhance customer satisfaction. Real-time sentiment analysis using machine learning has great potential, and this study highlights how telecommunication companies can leverage strategic recommendations to improve service quality and retain customers.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

## I. PENDAHULUAN

Layanan internet telah menjadi kebutuhan fundamental dalam kehidupan modern, dengan transformasi digital merekonstruksi pola masyarakat dalam aspek komunikasi, bekerja, dan pencarian informasi [1]. Seiring dengan meningkatnya penggunaan internet di Indonesia, tuntutan akan kualitas layanan yang konsisten dan andal juga semakin tinggi. Meskipun penyedia layanan internet terus berupaya meningkatkan infrastruktur dan layanan mereka, masalah ketidakstabilan jaringan masih menjadi tantangan signifikan yang mempengaruhi produktivitas dan kepuasan pengguna [2]. Dalam konteks pelayanan pelanggan, responsivitas dan efektivitas penanganan keluhan menjadi faktor kritis yang mempengaruhi retensi pelanggan [3]. Kualitas layanan

pelanggan merupakan aspek fundamental yang secara langsung berdampak pada tingkat kepuasan dan loyalitas pengguna [4]. Fenomena perpindahan pelanggan (churn rate) di industri telekomunikasi menjadi indikator penting yang mencerminkan tingkat kepuasan terhadap layanan yang diberikan, dengan kualitas jaringan dan pelayanan pelanggan sebagai faktor determinan utama [5].

Media sosial, khususnya Twitter, telah menjadi platform signifikan bagi pengguna untuk mengekspresikan pengalaman dan keluhan mereka terhadap layanan internet [6]. Platform ini menyediakan sumber data yang kaya untuk analisis sentimen pelanggan secara real-time, memberikan gambaran komprehensif tentang persepsi publik terhadap kualitas layanan [7]. Kompleksitas dan heterogenitas data dari media sosial memerlukan pendekatan analitis yang sistematis

dan sophisticated untuk mengekstrak wawasan yang bermakna [8].

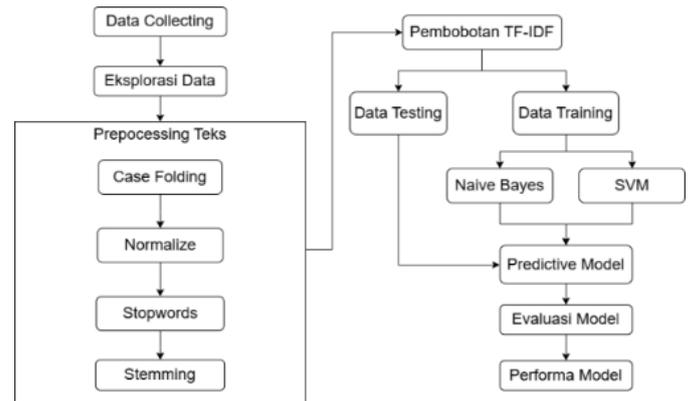
Penelitian terdahulu oleh [9] mengukur kualitas layanan provider PT. Telekomunikasi Indonesia (Persero) Tbk menggunakan metode SERVQUAL, yang menghasilkan nilai gap sebesar -1,539 antara ekspektasi dan realita layanan. Meskipun metode SERVQUAL dapat memberikan pengukuran dasar tentang kesenjangan layanan, pendekatan konvensional tersebut memiliki keterbatasan waktu dalam menganalisis data secara real-time dan menangkap kompleksitas keluhan pelanggan modern, namun dalam penelitian ini akan mengimplementasikan pendekatan pembelajaran mesin yang mengintegrasikan algoritma Naïve Bayes dan Support Vector Machine (SVM) untuk menganalisis pola keluhan spesifik terkait kestabilan jaringan dan kualitas layanan pelanggan.

Metodologi penelitian menggabungkan teknik pemrosesan bahasa alami dan analisis sentimen untuk mengklasifikasikan dan menganalisis sentimen pengguna, dengan fokus pada identifikasi pola spasial dan temporal dari permasalahan jaringan serta evaluasi efektivitas penanganan keluhan. Pendekatan pembelajaran mesin memungkinkan analisis yang lebih mendalam dan objektif dibandingkan dengan metode konvensional, memberikan wawasan yang komprehensif untuk pengambilan keputusan strategis [10].

Kontribusi utama penelitian ini adalah pengembangan model prediksi berbasis pembelajaran mesin untuk menganalisis sentimen pelanggan, khususnya dalam memahami tingkat kepuasan terhadap kualitas dan kestabilan jaringan dari layanan provider telekomunikasi. Hasil penelitian diharapkan dapat memberikan rekomendasi strategis bagi penyedia layanan internet untuk mengoptimalkan kualitas layanan dan sistem penanganan keluhan. Lebih lanjut, penelitian ini berkontribusi pada sistem pemantauan kualitas layanan yang adaptif dan scalable berbasis pembelajaran mesin, yang mampu menganalisis data keluhan pelanggan secara real-time dan memberikan insight yang dapat ditindaklanjuti.

## II. METODE

Penelitian ini menggunakan kerangka empat tahap untuk menganalisis data ulasan dan sentimen pengguna terhadap tiga penyedia. Tujuan pendekatan ini adalah untuk memahami faktor-faktor yang memengaruhi persepsi dan kepuasan konsumen, serta memilih model prediksi yang tepat. Setiap fase memiliki tujuan khusus untuk meningkatkan keberhasilan penelitian. Rincian metode penelitian akan ditunjukkan pada Gambar 1.



Gambar 1. Kerangka penelitian

### A. Data Collecting

Dataset yang digunakan dalam penelitian ini berasal dari platform Kaggle, berupa kumpulan tweet terkait penyedia layanan telekomunikasi. Dataset terdiri dari 300 data tweet dengan distribusi label berbeda antara positif dan negatif. Data tersebut memiliki tiga variabel utama: Id sebagai identifikasi unik setiap tweet, Sentiment yang mengkategorikan tweet ke dalam sentimen positif atau negatif berdasarkan pendapat konsumen, dan Teks Tweet yang berisi teks asli opini konsumen mengenai layanan telekomunikasi.

### B. Eksplorasi Data

Eksplorasi analisis data merupakan langkah fundamental dalam memahami karakteristik serta pola yang terdapat dalam suatu dataset [11]. Tahapan ini berfokus pada kajian mendalam terhadap feature extraction dan distribusi label, dimana proses tersebut memungkinkan identifikasi kata-kata yang memiliki frekuensi dominan dalam konteks sentimen serta pemahaman terhadap sebaran label yang ada [12]. Hasil dari proses eksplorasi ini berperan vital dalam penentuan pendekatan pemrosesan data yang tepat serta pemilihan metodologi analisis yang sesuai, sehingga dapat mendukung proses pengambilan keputusan yang komprehensif dan berbasis data.

### C. Preprocessing Teks

Preprocessing teks merupakan serangkaian tahapan penting dalam mengubah data teks mentah menjadi format yang lebih terstruktur dan siap digunakan dalam model pembelajaran mesin. Tahapan ini bertujuan untuk menstandarisasi format teks, dan mengekstrak informasi yang relevan dari data mentah. Proses ini sangat penting karena kualitas data yang dihasilkan akan mempengaruhi performa model pembelajaran mesin karena data yang telah melalui preprocessing yang baik dapat meningkatkan akurasi model, mengurangi kompleksitas komputasi, dan menghasilkan analisis yang lebih akurat dalam berbagai tugas seperti klasifikasi teks, analisis sentimen, atau pemrosesan bahasa alami lainnya [13].

1) *Case Folding*: Proses mengubah semua huruf dalam teks menjadi huruf kecil. Tujuannya untuk menyeragamkan

karakter huruf agar komputer dapat memproses teks dengan lebih efisien, tanpa membedakan huruf besar dan kecil yang memiliki makna sama.

2) *Normalize*: Tahap membersihkan teks dari karakter-karakter yang tidak diperlukan. Proses ini menghilangkan tanda baca, angka, atau simbol khusus lainnya, sehingga hanya menyisakan karakter huruf yang bermakna untuk dianalisis lebih lanjut.

3) *Stopwords*: Menghapus kata-kata umum yang sering muncul namun tidak memiliki arti penting dalam analisis. Kata-kata seperti "yang", "di", "ke", atau "dari" dihilangkan karena tidak memberikan kontribusi signifikan terhadap makna utama teks.

4) *Stemming*: Teknik mengubah kata berimbuhan menjadi kata dasarnya. Proses ini menghilangkan awalan, akhiran, sisipan, atau kombinasinya, sehingga diperoleh kata dasar yang dapat mewakili konsep yang sama meskipun dalam bentuk kata yang berbeda.

#### D. Pembobotan TF-IDF (Term Frequency-Inverse Document Frequency)

Pembobotan TF-IDF adalah metode yang memberikan nilai pada kata-kata berdasarkan seberapa sering muncul dalam sebuah dokumen dan seberapa unik kata tersebut di semua dokumen [14]. Dalam analisis sentimen terhadap tweet, TF-IDF membantu menekankan kata-kata yang penting untuk menentukan sentimen, terutama kata-kata yang sering muncul di tweet tertentu tetapi jarang di seluruh dataset [15]. Pendekatan ini membantu model seperti Naive Bayes atau SVM untuk lebih fokus pada kata-kata penting, sehingga analisis lebih akurat.

#### E. Splitting Data

Splitting data merupakan tahapan krusial dalam pengembangan model pembelajaran mesin, dimana keseluruhan data dibagi menjadi dua bagian dengan proporsi yang telah ditentukan. Dalam penelitian ini, dataset dipartisi menjadi 80% data latih yang berfungsi sebagai material pembelajaran bagi model Naive Bayes dan SVM dalam mengidentifikasi pola sentimen sebanyak 240 data, serta 20% data uji yang berperan dalam evaluasi performa model dengan 60 data. Strategi pembagian ini memungkinkan pengukuran objektif terhadap kemampuan model dalam melakukan prediksi sentimen pada data yang belum pernah dilihat sebelumnya, sehingga tingkat akurasi dapat divalidasi sebelum implementasi pada kasus nyata.

#### F. Naive Bayes

Naive Bayes merupakan algoritma klasifikasi berdasarkan teori probabilitas Bayesian yang mengasumsikan adanya independensi antar fitur. Algoritma ini sebagai perhitungan probabilitas posterior berdasarkan hubungan kelas-fitur. Rumus utama untuk Naive Bayes sebagai berikut:

$$P(C|X) = \frac{P(C|X)P(X)}{P(C)}$$

Dimana:

- $C$ : Kelas data yang belum diketahui atau yang ingin diprediksi.
- $X$ : Fitur yang digunakan untuk membentuk hipotesis tentang kelas  $y$ .
- $P(C|X)$ : Probabilitas bahwa kelas  $C$  terjadi, dengan mempertimbangkan data atau kondisi  $X$ .
- $P(X)$ : Probabilitas bahwa data atau fitur  $X$  terjadi, tanpa memperhitungkan kelas  $C$ .
- $P(C)$ : Probabilitas dari kelas  $C$ , yang biasanya disebut sebagai probabilitas apriori.

Naive Bayes dipilih karena kemampuannya dalam mengklasifikasikan teks berdasarkan frekuensi kemunculan kata dan probabilitas kondisional membuat Naive Bayes menjadi pilihan yang tepat untuk analisis sentimen pada data tweet [16].

#### G. Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang bertujuan mencari batas terbaik untuk memisahkan data menjadi dua kelas. SVM berfungsi meningkatkan jarak antara titik data terdekat dari kedua kelas dan batas tersebut. Rumus dasar SVM adalah:

$$f(Xd) = \sum_{t=1}^{ns} (ciyi\vec{x}_i \vec{x}_d + b)$$

Dimana:

- $ns$ : Vektor yang digunakan untuk mendefinisikan batas keputusan.
- $ci$ : Bobot yang diberikan untuk setiap titik data.
- $yi$ : Label yang terkait dengan data titik tertentu.
- $\vec{x}_i$ : Titik data yang berfungsi sebagai support vector dalam klasifikasi.
- $\vec{x}_d$ : Data yang akan diklasifikasikan
- $b$ : Nilai error atau bias

SVM dipilih dalam penelitian ini karena kemampuannya dalam menangani data tekstual dengan dimensi fitur yang tinggi, ketahanannya terhadap overfitting pada dataset kecil [17].

#### H. Evaluasi Model

Evaluasi model adalah proses untuk menilai kinerja model pembelajaran mesin guna memastikan model tersebut berfungsi secara optimal pada data yang tersedia. Evaluasi ini dilakukan untuk mengetahui seberapa baik model dapat mengenali pola dan menghasilkan prediksi yang akurat. Data yang dibagi menjadi data pelatihan untuk melatih model dan data pengujian untuk mengevaluasi hasil prediksinya pada





Gambar 3. Feature extraction data negatif

Meskipun jumlah keluhan negatif lebih dominan, yang mengindikasikan masih adanya aspek layanan yang membutuhkan perbaikan, jumlah apresiasi yang signifikan juga menunjukkan keberhasilan provider dalam memberikan layanan yang memuaskan bagi sebagian pelanggan. Pola distribusi ini memberikan wawasan berharga bagi penyedia layanan untuk terus meningkatkan kualitas layanan mereka sambil mempertahankan aspek-aspek yang telah mendapat pengakuan positif dari pelanggan.

**B. Preprocessing Teks**

1) *Case Folding*: Menyamakan format teks dengan mengubah seluruh huruf menjadi huruf kecil, sehingga tidak ada perbedaan antara huruf kapital dan huruf kecil. Contoh pada tabel I yang diberikan. Perubahan ini memudahkan dalam pemrosesan teks selanjutnya tanpa memperhatikan kapitalisasi.

TABEL I  
TEKS SEBELUM DAN SESUDAH MELAKUKAN CASE FOLDING

Teks	Hasil
Sebelum	Selamat pagi <PROVIDER_NAME> bisa bantu kenapa di dalam kamar sinyal 4G hilang yang 1 lagi panggilan darurat saja <URL>
Sesudah	selamat pagi <provider_name> bisa bantu kenapa di dalam kamar sinyal 4g hilang yang 1 lagi panggilan darurat saja <url>

2) *Normalize*: Mengganti kata-kata atau elemen dalam teks yang tidak penting atau terlalu spesifik menjadi bentuk yang lebih generik. Misalnya pada tabel II, "provider\_name" dan "url" digantikan dengan nama generik yang lebih relevan. Normalisasi membantu menyederhanakan teks untuk memfokuskan pada elemen penting.

TABEL II  
TEKS SEBELUM DAN SESUDAH MELAKUKAN NORMALIZE

Teks	Hasil
Sebelum	selamat pagi <provider_name> bisa bantu kenapa di dalam kamar sinyal 4g hilang yang 1 lagi panggilan darurat saja <url>
Sesudah	selamat pagi provider_name bisa bantu kenapa di dalam kamar sinyal 4g hilang yang lagi panggilan darurat saja url

3) *Stopwords*: Kata-kata yang tidak memiliki makna penting atau sering digunakan dalam teks, seperti "di",

"yang", dan "saja", dihapus untuk meningkatkan efisiensi pemrosesan teks. Hasilnya adalah teks yang lebih ringkas dan fokus pada informasi utama, seperti pada tabel III dengan menghapus stopwords, teks menjadi lebih padat dan mudah dianalisis.

TABEL III  
TEKS SEBELUM DAN SESUDAH MELAKUKAN STOPWORDS

Teks	Hasil
Sebelum	selamat pagi provider_name bisa bantu kenapa di dalam kamar sinyal 4g hilang yang lagi panggilan darurat saja url
Sesudah	selamat pagi provider_name bisa bantu kenapa kamar sinyal 4g hilang panggilan darurat

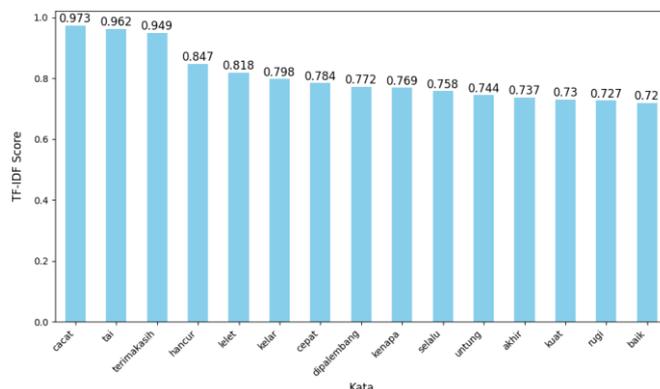
4) *Stemming*: Mengubah kata ke bentuk dasar atau akarnya, misalnya di tabel IV "panggilan" menjadi "panggil". Hasilnya adalah teks yang lebih singkat dan lebih mudah untuk analisis. Stemming membantu mengurangi variasi kata dan menyederhanakan proses pemrosesan data.

TABEL IV  
TEKS SEBELUM DAN SESUDAH MELAKUKAN STEMMING

Teks	Hasil
Sebelum	selamat pagi provider_name bisa bantu kenapa kamar sinyal 4g hilang panggilan darurat
Sesudah	selamat pagi provider_name bisa bantu kenapa kamar sinyal 4g hilang panggil darurat

**C. Pembobotan TF-IDF (Term Frequency-Inverse Document Frequency)**

Grafik yang ditampilkan dalam gambar 4 menunjukkan skor TF-IDF dari beberapa kata yang relevan, yang digunakan untuk menganalisis sentimen konsumen terhadap layanan provider. Kata-kata dengan skor tinggi, seperti "cacat," "terimakasih," dan "hancur," menunjukkan betapa signifikan kata tersebut dalam ulasan konsumen. Kata-kata ini dapat digunakan untuk mengidentifikasi sentimen konsumen, di mana kata negatif seperti "cacat" dan "hancur" mungkin menunjukkan keluhan, sementara kata positif seperti "terimakasih" bisa menandakan apresiasi terhadap layanan yang diberikan.



Gambar 4. Top 15 dari Score TF-IDF

#### D. Naïve Bayes

TABEL V  
Matrik Evaluasi Naïve Bayes

	Negative	Positive	Macro Avg	Weighted Avg
<b>Precision</b>	0.87	0.86	0.87	0.87
<b>Recall</b>	0.92	0.79	0.85	0.87
<b>F1-Score</b>	0.89	0.83	0.86	0.87
<b>Support</b>	36	24	-	-
<b>Accuracy</b>	<b>0.87</b>			

Model Naïve Bayes yang diterapkan dalam klasifikasi ulasan menunjukkan tingkat akurasi yang mengesankan, mencapai 87% pada tabel V. Ini berarti dari 60 data uji, 87% di antaranya berhasil diprediksi dengan benar oleh model. Tingkat akurasi yang tinggi ini mencerminkan kemampuan model dalam mengklasifikasikan ulasan dengan baik.

Dalam hal presisi, model ini mencatat nilai 0.87 untuk kelas negatif dan 0.86 untuk kelas positif. Ini menunjukkan bahwa 87% ulasan yang diprediksi sebagai negatif benar-benar negatif, sementara 86% ulasan yang diprediksi positif juga akurat. Tingkat presisi yang tinggi ini menandakan bahwa model jarang melakukan kesalahan dalam identifikasi kelas.

Namun, model ini menunjukkan performa yang lebih baik dalam mendeteksi ulasan negatif, dengan nilai recall sebesar 0.92. Sebaliknya, untuk ulasan positif, nilai recallnya hanya 0.79, yang menunjukkan bahwa beberapa ulasan positif mungkin salah dikategorikan sebagai negatif. Hal ini mengindikasikan bahwa meskipun model efektif dalam menangkap ulasan negatif, ada ruang untuk perbaikan dalam pengenalan ulasan positif.

Dari segi F1-score, yang mengukur keseimbangan antara presisi dan recall, model memperoleh skor 0.89 untuk kelas negatif dan 0.83 untuk kelas positif, dengan rata-rata 0.86. Nilai-nilai ini menunjukkan bahwa model memiliki keseimbangan yang baik dalam mengklasifikasikan kedua kelas.

Secara keseluruhan, model Naïve Bayes memberikan hasil yang cukup memuaskan dalam klasifikasi ulasan dengan akurasi yang tinggi. Namun, untuk meningkatkan kinerjanya dalam mengenali ulasan positif, langkah-langkah seperti penyeimbangan data atau penerapan model alternatif seperti Support Vector Machine (SVM) atau Random Forest dapat dipertimbangkan. Model-model ini mungkin lebih efektif dalam menangani distribusi data yang tidak seimbang.

#### E. Support Vector Machine (SVM)

Tabel VI menyajikan hasil klasifikasi yang diperoleh dari algoritma SVM, yang dikenal sebagai metode pembelajaran mesin yang efektif untuk tugas klasifikasi. SVM berfungsi dengan cara menemukan hyperplane optimal yang memisahkan kelas-kelas dalam data. Evaluasi terhadap model SVM menunjukkan performa yang sangat baik berdasarkan metrik akurasi, presisi, recall, dan F1-score.

Model ini mencapai akurasi 90%, yang berarti dari 60 sampel yang diuji, 90% berhasil diklasifikasikan dengan benar. Rata-rata presisi model adalah 93%, menunjukkan bahwa sebagian besar prediksi positif yang dihasilkan adalah akurat. Hal ini menandakan bahwa model jarang memberikan prediksi positif yang salah.

TABEL VI  
Matrik Evaluasi Support Vector Machine

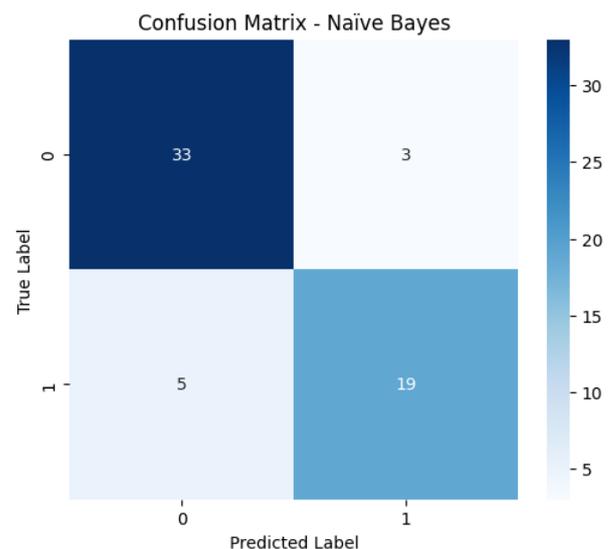
	Negative	Positive	Macro Avg	Weighted Avg
<b>Precision</b>	0.86	0.99	0.93	0.91
<b>Recall</b>	0.99	0.75	0.88	0.90
<b>F1-Score</b>	0.92	0.86	0.89	0.90
<b>Support</b>	36	24	-	-
<b>Accuracy</b>	<b>0.90</b>			

Namun, meskipun recall rata-rata model mencapai 88%, ada beberapa tantangan dalam menangkap semua sampel positif. Recall untuk kelas positif tercatat di angka 75%, yang menunjukkan bahwa masih ada beberapa sampel positif yang salah diklasifikasikan sebagai negatif.

Model ini juga memperoleh F1-score sebesar 89%, yang mencerminkan keseimbangan yang baik antara presisi dan recall. Ini menunjukkan bahwa model tidak hanya dapat memprediksi dengan akurat, tetapi juga mampu menangkap contoh relevan dengan baik. Meskipun demikian, terdapat peluang untuk meningkatkan recall pada kelas positif melalui penyesuaian hyperparameter atau dengan menangani masalah ketidakseimbangan data.

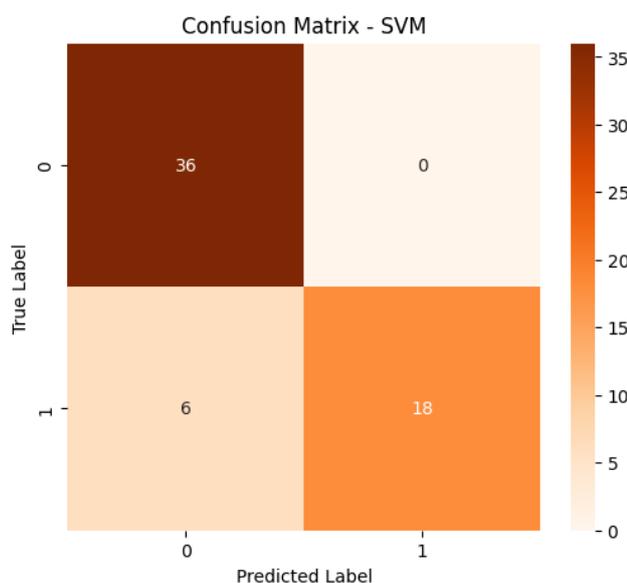
Secara keseluruhan, model SVM ini menunjukkan performa yang kuat dan dapat diandalkan dalam klasifikasi, menjadikannya pilihan yang baik untuk aplikasi yang memerlukan akurasi tinggi dalam pengenalan pola.

#### F. Perbandingan Evaluasi Model



Gambar 5. Confusion matrix Naïve Bayes

Gambar 5 yang disajikan adalah Confusion Matrix pada model Naïve Bayes, yang ditandai dengan warna biru, menunjukkan bahwa model ini berhasil melakukan 33 prediksi yang tepat untuk kelas negatif dan 19 prediksi yang tepat untuk kelas positif. Namun, terdapat beberapa kesalahan, yaitu 3 sampel negatif yang salah diklasifikasikan sebagai positif dan 5 sampel positif yang salah diklasifikasikan sebagai negatif. Meskipun demikian, kinerja model ini terbilang cukup seimbang dalam mengenali kedua kelas, meskipun masih ada beberapa kesalahan prediksi. Untuk meningkatkan akurasi, terutama pada kelas positif, bisa dilakukan penyesuaian model atau eksplorasi terhadap fitur-fitur yang lebih relevan.



Gambar 6. Confusion matrix Support Vector Machine

Gambar 6 menunjukkan model SVM yang berwarna oranye. Model ini lebih efektif dalam mengidentifikasi kelas negatif, dengan 36 prediksi yang tepat dan tanpa kesalahan klasifikasi untuk kelas tersebut. Namun, ada 6 kesalahan prediksi, di mana beberapa sampel positif salah dikategorikan sebagai negatif, meskipun terdapat 18 prediksi yang benar untuk kelas positif. Meski SVM baik dalam mengenali kelas negatif, masih ada tantangan dalam mengidentifikasi kelas positif.

TABEL VII  
PERBANDINGAN PERFORMA MODEL NAÏVE BAYES VS SUPPORT VECTOR MACHINE

Algoritma	Akurasi	Presisi	Recall	F1-Score
Naive Bayes	87%	87%	85%	86%
Support Vector Machine	90%	93%	88%	89%

Tabel VII menyajikan perbandingan kinerja antara dua algoritma pembelajaran mesin, yaitu Naïve Bayes dan SVM, berdasarkan empat metrik utama: akurasi, presisi, recall, dan F1-score. Naïve Bayes mencatat hasil sebagai berikut: akurasi 87%, presisi 87%, recall 85%, dan F1-score 86%. Sebaliknya,

SVM menunjukkan performa yang lebih unggul dengan akurasi 90%, presisi 93%, recall 88%, dan F1-score 89%. Hasil ini secara keseluruhan menunjukkan bahwa SVM memiliki kinerja yang lebih baik dibandingkan Naïve Bayes di semua metrik yang dievaluasi.

Penelitian ini mengungkapkan bahwa algoritma SVM lebih efektif dalam menganalisis sentimen konsumen, khususnya dalam memahami tingkat kepuasan terhadap kualitas dan kestabilan jaringan layanan provider telekomunikasi. Dengan akurasi model SVM yang mencapai 90%, jelas bahwa SVM dapat menangani data teks dengan pola dan distribusi yang kompleks dengan lebih efisien. Selain itu, SVM menunjukkan keunggulan dalam akurasi dan tingkat deteksi, terutama dalam mengidentifikasi emosi positif dan negatif secara konsisten. Keunggulan ini dapat diatribusikan pada kemampuan SVM dalam mengoptimalkan jarak antara kelas positif dan negatif, serta menghasilkan generalisasi yang lebih baik.

Di sisi lain, algoritma Naïve Bayes menunjukkan performa yang cukup baik dalam menangani data yang lebih sederhana dan memiliki kecepatan komputasi yang tinggi. Namun, algoritma ini kurang optimal ketika dihadapkan pada data dengan korelasi antar fitur yang kompleks, yang sering kali ditemukan dalam data teks dari media sosial seperti Twitter.

Selain analisis kinerja model, penelitian ini juga mengidentifikasi tema utama dalam sentimen pengguna. Salah satunya adalah tingkat ulasan kepuasan konsumen terhadap kualitas dan kestabilan jaringan dari layanan provider telekomunikasi. Ulasan positif sering kali mencerminkan kepuasan terhadap harga yang terjangkau dan pilihan paket data yang fleksibel serta memiliki stabilitas jaringan yang baik, sementara kritik terhadap layanan pelanggan biasanya berkaitan dengan waktu respons yang lambat dan kurangnya solusi yang memadai. Hal ini menunjukkan perlunya penerapan pembelajaran mesin untuk mempercepat pengambilan keputusan yang lebih komprehensif.

Dari analisis ini, dapat disimpulkan bahwa SVM lebih unggul dalam mengenali kelas negatif, terbukti dari tidak adanya kesalahan klasifikasi pada kelas tersebut. Namun, model ini masih menghadapi tantangan dalam mengidentifikasi kelas positif. Wawasan ini memberikan penyedia layanan komunikasi informasi berharga untuk meningkatkan kualitas layanan berdasarkan sentimen pelanggan. Dengan demikian, penyedia layanan dapat memprioritaskan perbaikan pada area yang sering dikritik, seperti stabilitas jaringan dan layanan pelanggan, sambil memanfaatkan keunggulan pada aspek harga untuk mempertahankan pelanggan.

#### IV. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma Support Vector Machine (SVM) memiliki keunggulan signifikan dibandingkan Naïve Bayes dalam menganalisis sentimen pengguna Twitter terhadap penyedia layanan telekomunikasi

di Indonesia. Dari hasil evaluasi, SVM berhasil mencapai akurasi tertinggi sebesar 90%, sementara Naïve Bayes mencatatkan akurasi 87%. Keunggulan SVM terlihat jelas dalam kemampuannya untuk menangani data dengan pola yang lebih kompleks, memanfaatkan margin optimal untuk memisahkan sentimen positif dan negatif secara konsisten.

Lebih lanjut, SVM unggul dalam hal presisi yang mencapai 93% dan recall sebesar 88%, menandakan efektivitasnya dalam mengidentifikasi dan mendeteksi sentimen positif. Hasil F1-score SVM yang mencapai 89% menunjukkan adanya keseimbangan yang lebih baik antara presisi dan recall jika dibandingkan dengan Naïve Bayes yang mencatatkan 86%. Temuan ini menegaskan bahwa dengan penerapan teknik preprocessing teks yang tepat dan pemilihan model yang akurat, analisis sentimen dapat ditingkatkan secara signifikan.

Penelitian ini diharapkan dapat memberikan rekomendasi bagi penyedia layanan telekomunikasi dalam upaya meningkatkan kualitas layanan untuk konsumen. Dengan memahami kritik yang berkaitan dengan stabilitas jaringan dan biaya, penyedia layanan dapat merumuskan strategi perbaikan yang lebih efektif. Teknik preprocessing yang baik, seperti case folding, normalisasi, penghapusan stopwords, dan stemming, sangat penting untuk meningkatkan performa model dalam menganalisis data besar.

Untuk penelitian selanjutnya, disarankan agar data diperbarui secara berkala dan menambah variabel yang relevan untuk kepuasan pengguna. Selain itu, eksplorasi algoritma lain seperti Deep Learning dan Recurrent Neural Networks (RNN) dapat dilakukan untuk meningkatkan akurasi dalam menangani data teks yang kompleks. Dengan pendekatan ini, diharapkan analisis sentimen dapat memberikan wawasan yang lebih mendalam dan bermanfaat bagi penyedia layanan telekomunikasi dalam upaya meningkatkan stabilitas jaringan dan kualitas pelayanan mereka.

#### DAFTAR PUSTAKA

- [1] Z. Wang, Y. Fan, H. Lv, S. Deng, H. Xie, L. Zhanget al., "The gap between self-rated health information literacy and internet health information-seeking ability for patients with chronic diseases in rural communities: cross-sectional study", *Journal of Medical Internet Research*, vol. 24, no. 1, p. e26308, 2022. <https://doi.org/10.2196/26308>
- [2] J. Akanni, H. F.A., R. Alao, & C. Thomas, "Assessment of internet service provided using umts operators at the university of ilorin main campus", *Nigerian Journal of Technology*, vol. 39, no. 2, p. 500-505, 2020. <https://doi.org/10.4314/njt.v39i2.20>
- [3] D. Cahyati and R. Nurlinda, "Evaluasi kesuksesan sistem informasi aplikasi mobile collection dengan pendekatan model delone dan mclean", *Jurnal Doktor Manajemen (JDM)*, vol. 6, no. 2, p. 149, 2023. <https://doi.org/10.22441/jdm.v6i2.20248>
- [4] D. Ginting, F. Sutrisno, E. Yudhistyra, R. Astuti, & H. Hartanto, "Analisis faktor-faktor yang mempengaruhi kepuasan pengguna serta dampaknya terhadap loyalitas pengguna aplikasi mybca", *Media Informatika*, vol. 22, no. 3, p. 147-159, 2024. <https://doi.org/10.37595/mediainfo.v22i3.205>
- [5] I. Fitriyani and C. Hendriyani, "Implementasi customer data management dalam meningkatkan retensi pelanggan indihome di pt telkom", *ICIT Journal*, vol. 7, no. 2, p. 168-176, 2021. <https://doi.org/10.33050/icit.v7i2.1645>
- [6] S. Saleh and S. Saha, "Customer retention and churn prediction in the telecommunication industry: a case study on a danish university", *SN Applied Sciences*, vol. 5, no. 7, 2023. <https://doi.org/10.1007/s42452-023-05389-6>
- [7] M. Khalik, W. Mohammad, Z. Zilfana, & O. Themba, "The influence of service personalization, customer satisfaction, and customer retention in the telecommunications industry on data-driven marketing", *West Science Information System and Technology*, vol. 1, no. 02, p. 55-62, 2023. <https://doi.org/10.58812/wsist.v1i02.476>
- [8] S. Saleh and S. Saha, "Customer retention and churn prediction in the telecommunication industry: a case study on a danish university", *SN Applied Sciences*, vol. 5, no. 7, 2023. <https://doi.org/10.1007/s42452-023-05389-6>
- [9] M. M. Ulkhaq and M. P. Br. Barus, "Analisis Kepuasan Pelanggan dengan Menggunakan SERVQUAL: Studi Kasus Layanan IndiHome PT. Telekomunikasi Indonesia, Tbk, Regional 1 Sumatera", *j. sist. manaj. ind.*, vol. 1, no. 2, pp. 61-67, Dec. 2017, <https://doi.org/10.30656/jsmi.v1i2.365>
- [10] N. Ariyanto, H. A. Azies, and M. Akrom, Trans., "Ensemble Stacking of Machine Learning Approach for Predicting Corrosion Inhibitor Performance of Pyridazine Compounds", *International Journal of Advances in Data and Information Systems*, vol. 5, no. 2, pp. 198-215, Nov. 2024. <https://doi.org/10.59395/ijadis.v5i2.1346>
- [11] E. Kaya, X. Dong, Y. Suhara, S. Balcişoy, B. Bozkaya, & A. Pentland, "Behavioral attributes and financial churn prediction", *EPJ Data Science*, vol. 7, no. 1, 2018. <https://doi.org/10.1140/epjds/s13688-018-0165-5>
- [12] N. Rezki, S. Thamrin, & S. Siswanto, "Sentiment analysis of merdeka belajar kampus merdeka policy using support vector machine with word2vec", *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, vol. 17, no. 1, p. 0481-0486, 2023. <https://doi.org/10.30598/barekengvol17iss1pp0481-0486>
- [13] J. Munggaran, A. Alhafidz, M. Taqy, D. Agustini, & M. Munawir, "Sentiment analysis of twitter users' opinion data regarding the use of chatgpt in education", *Journal of Computer Engineering, Electronics and Information Technology*, vol. 2, no. 2, p. 75-88, 2023. <https://doi.org/10.17509/coelite.v2i2.59645>
- [14] M. Ahmad, S. Aftab, & I. Ali, "Sentiment analysis of tweets using svm", *International Journal of Computer Applications*, vol. 177, no. 5, p. 25-29, 2017. <https://doi.org/10.5120/ijca2017915758>
- [15] H. Jadia, "Comparative analysis of sentiment analysis techniques: svm, logistic regression, and tf-idf feature extraction", *International Research Journal of Modernization in Engineering Technology and Science*, 2023. <https://doi.org/10.56726/irjmets45265>
- [16] R. Setiabudi, N. Iswari, & A. Rusli, "Enhancing text classification performance by preprocessing misspelled words in indonesian language", *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 19, no. 4, p. 1234, 2021. <https://doi.org/10.12928/telkomnika.v19i4.20369>
- [17] A. Indriani and M. Muslim, "Svm optimization based on pso and adaboost to increasing accuracy of ckd diagnosis", *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, p. 119, 2019. <https://doi.org/10.24843/lkjiti.2019.v10.i02.p06>
- [18] S. Rajabana, S. Sukri, & M. Munawaroh, "Penerapan metode pembelajaran mesin berbasis fuzzy logic untuk prediksi kualitas layanan jaringan iot (internet of things)", *Jurnal Informatika Universitas Pamulang*, vol. 8, no. 2, p. 270-278, 2023. <https://doi.org/10.32493/informatika.v8i2.30572>