

Customer Service Sentiment Analysis of Internet Service Providers Using Support Vector Machine and Naïve Bayes Algorithms

Analisis Sentimen Layanan Pelanggan Provider Internet Dengan Algoritma Support Vector Machine Dan Naïve Bayes

Muhammad Arshiel Naufal Dzaki ¹⁾, Hindarto Hindarto ²⁾

¹ Program Studi Teknik Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

² Program Studi Teknik Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

*Email Penulis Korespondensi: hindarto@umsida.ac.id,

Abstract. Meningkatnya keluhan dan pujian pelanggan terhadap layanan internet menunjukkan pentingnya memahami opini publik secara menyeluruh. Jika hal ini tidak dimanfaatkan dengan baik, perusahaan provider internet dapat kehilangan peluang untuk memperbaiki layanan secara tepat sasaran, yang pada akhirnya menurunkan kepuasan pelanggan. Penelitian ini bertujuan menganalisis sentimen pelanggan terhadap perusahaan penyedia layanan internet Biznet menggunakan Text Mining dengan algoritma Naïve Bayes dan Support Vector Machine (SVM). Data diambil dari X.com (Twitter) menggunakan Tweepy, lalu diproses melalui pembersihan, normalisasi, tokenisasi, pelabelan sentimen dengan VADER, serta ekstraksi fitur menggunakan TF-IDF (Term Frequency–Inverse Document Frequency) untuk mengubah teks menjadi data numerik yang relevan. Hasil menunjukkan bahwa SVM dengan kernel Sigmoid memberikan akurasi tertinggi (94,29%), diikuti oleh SVM Linear (93,92%) dan Naïve Bayes Bernoulli (88,21%). Berdasarkan akurasi, precision, recall, dan F1-score, SVM dengan kernel Sigmoid menjadi metode terbaik untuk analisis sentimen layanan perusahaan penyedia internet Biznet. Analisis sentimen ini diharapkan dapat membantu perusahaan memahami opini pelanggan secara lebih mendalam, sehingga perusahaan provider internet dapat menyusun strategi peningkatan layanan yang tepat sesuai kebutuhan pengguna.

Keywords - author guidelines; Analisis Sentimen, Text Mining, Naïve Bayes, Support Vector Machine, X.com.

Abstrak. The increasing number of customer complaints and compliments regarding internet services highlights the importance of thoroughly understanding public opinion. If not properly leveraged, Biznet company may miss opportunities to improve their services effectively, ultimately reducing customer satisfaction. This study aims to analyze customer sentiment toward Biznet using Text Mining techniques with the Naïve Bayes and Support Vector Machine (SVM) algorithms. Data was collected from X.com (Twitter) using Tweepy, then processed through cleaning, normalization, tokenization, sentiment labeling using VADER, and feature extraction using TF-IDF (Term Frequency–Inverse Document Frequency) to convert text into relevant numerical data. The results show that the SVM with a Sigmoid kernel achieved the highest accuracy (94.29%), followed by the Linear SVM (93.92%) and Bernoulli Naïve Bayes (88.21%). Based on accuracy, precision, recall, and F1-score, the SVM with a Sigmoid kernel is the best method for sentiment analysis of internet provider company's services. This sentiment analysis is expected to help the company gain deeper insights into customer opinions, enabling the development of targeted strategies for service improvement that align with user needs.

Kata Kunci - petunjuk penulis; Sentiment Analysis, Text Mining, Naïve Bayes, Support Vector Machine, X.com.

I. PENDAHULUAN

pada zaman yang telah maju ini, masyarakat tidak bisa lepas dari yang namanya media sosial. Media sosial saat ini tidak hanya digunakan untuk mencari hiburan, tapi juga untuk menyuarakan opini, keluhan, serta pujian dalam bentuk apa pun yang mereka inginkan. Hal ini juga membuka peluang bagi perusahaan untuk melakukan riset, salah satunya melalui analisa data dari para pengguna media sosial. "Media sosial telah menjadi sumber data yang kaya untuk memahami opini publik melalui analisis sentimen, yang dapat membantu perusahaan dalam meningkatkan kualitas layanan mereka." [1]

Biznet, sebagai salah satu penyedia layanan internet terkemuka di Indonesia, juga merasakan dampak dari tren meningkatnya aktivitas pelanggan di media sosial. Dalam beberapa waktu terakhir, muncul berbagai keluhan dari pelanggan terkait gangguan koneksi, kecepatan internet yang tidak stabil, serta respons layanan pelanggan yang dianggap kurang memuaskan. Dengan semakin banyaknya pengguna yang membagikan pengalaman mereka secara terbuka, Biznet memiliki kesempatan besar untuk memahami kebutuhan dan ekspektasi pelanggannya secara lebih mendalam. Analisis sentimen terhadap data dari media

sosial menjadi salah satu cara efektif untuk mengukur tingkat kepuasan pelanggan serta mengidentifikasi kekuatan dan kelemahan layanan Biznet. "Analisis sentimen memungkinkan penyedia layanan internet seperti Biznet untuk mengidentifikasi permasalahan layanan secara *real-time* dan meresponsnya dengan cepat." [2]

Salah satu metode yang digunakan dalam penelitian ini adalah analisis sentimen, yaitu teknik untuk mengidentifikasi dan mengklasifikasikan opini dalam teks berdasarkan kata-kata yang digunakan. Algoritma yang digunakan adalah Naïve Bayes dan *Support Vector Machine* (SVM) karena keduanya dikenal efektif dalam klasifikasi teks. Naïve Bayes memiliki keunggulan dalam menangani data berdimensi tinggi dengan pendekatan probabilitas yang sederhana, sementara SVM mampu menghasilkan akurasi tinggi dengan memaksimalkan margin antar kelas. Penelitian oleh Ananda (2021) [1] membuktikan bahwa SVM memberikan hasil akurasi tinggi dalam analisis sentimen terhadap layanan internet Biznet, sehingga mendukung pemilihan algoritma ini dalam penelitian ini. [3]

Sentimen adalah suatu penyampaian sikap yang diekspresikan melalui lisan maupun tulisan. Sentimen terbagi menjadi tiga sifat, yaitu sentimen positif yang berisi tentang suatu kepuasan dan kegembiraan, sentimen negatif yang berisi rasa kekecewaan dan kesedihan, dan sentimen netral, yaitu sentimen yang tidak menunjukkan sifat positif maupun negatif.

Text mining adalah suatu proses yang digunakan untuk mengelola teks, dimulai dari tahapan pengambilan data menggunakan metode crawling, memproses data, ekstraksi fitur, hingga menerapkan algoritma seperti *Naive Bayes* dan *Support Vector Machines* (SVM) untuk pemrosesan akhirnya. Hal ini dilakukan agar data yang kita ambil dapat digunakan dalam analisis sentimen dengan baik. "Dengan menggunakan teknik data mining, organisasi dapat menggali wawasan berharga dari data media sosial untuk mendukung pengambilan keputusan strategis." [4]


Provider internet yang akan diteliti seperti Biznet, berusaha meningkatkan pelayanannya untuk memenuhi harapan dari konsumen. Oleh karena itu, pemahaman dari suatu perusahaan akan sentimen yang dikeluarkan oleh penggunaannya sangat penting. Sentimen yang diberikan oleh pelanggan akan berdampak pada berkembangnya suatu perusahaan, baik itu sentimen positif, negatif, maupun sentimen yang bersifat netral sekalipun.

Penelitian ini bertujuan untuk mengimplementasikan data mining, terutama dalam melakukan analisis sentimen masyarakat terhadap provider internet di Indonesia. Dalam kasus ini, yang digunakan berasal dari sentimen layanan pelanggan dari provider Biznet yang didapat melalui X.com. Dengan memahami sentimen tersebut, diharapkan dapat meningkatkan kualitas pelayanan internet di Indonesia. Selain itu, penelitian ini juga dapat berkontribusi dalam bidang akademis dan industri.

Dengan masalah dan tujuan yang telah disebutkan sebelumnya, maka peneliti membuat sistem dalam bentuk sistem yang bernama "Implementasi Data Mining Untuk Analisis Sentimen Layanan Pelanggan Provider Internet Di Indonesia".

II. METODE

Penelitian ini dilakukan berdasarkan data cuitan dari Twitter dengan kata kunci "Biznet", dan tahapan-tahapannya digambarkan dalam Gambar 1. Berdasarkan diagram alir tersebut, proses penelitian ini terdiri dari beberapa tahap utama. Pertama, pengambilan data dilakukan menggunakan API Twitter. Data yang diperoleh kemudian melalui tahap preprocessing, yang meliputi cleansing (pembersihan data dari karakter tidak penting), *text normalization* (standarisasi bentuk kata), dan *tokenization* (pemecahan teks menjadi kata-kata atau token). Selanjutnya, data yang telah diproses diberi label sentimen pada tahap data labeling menggunakan metode VADER. Setelah itu, dilakukan data representasi menggunakan teknik TF-IDF untuk mengubah teks menjadi format numerik. Pada tahap klasifikasi, data yang telah direpresentasikan akan diklasifikasikan menggunakan dua algoritma, yaitu Naïve Bayes dan *Support Vector Machine* (SVM). Akhirnya, performa model dievaluasi pada tahap evaluation untuk menentukan model terbaik berdasarkan metrik akurasi, precision, recall, dan F1-score.



Gambar 1 Diagram alur

A. Pengumpulan Data

Data yang akan digunakan dalam penelitian adalah data X.com yang terdapat pada media sosial X.com dengan topik tentang “BIZNET” dengan total data yang didapat sebanyak 7272, sistem pengumpulan data menggunakan python dengan library Tweepy dengan hasil data akan disimpan dalam file berformat CSV

B. Pemrosesan Data

Pra-pemrosesan data adalah langkah krusial dalam proses penambahan data karena secara signifikan mempengaruhi kualitas data dan kinerja analisis selanjutnya [5], yang meliputi pembersihan data (*cleansing data*) untuk menghapus data yang tidak relevan seperti iklan, spam, atau ulasan yang tidak terkait dengan layanan Biznet guna meningkatkan keakuratan analisis [6], normalisasi teks (*text normalization*) yang bertujuan menyatukan format teks dengan mengubah huruf besar menjadi kecil, menghapus tanda baca, serta menyesuaikan kata tidak formal agar algoritma dapat lebih mudah menganalisis data [7], dan tokenisasi (*tokenization*) sebagai proses pemisahan kata dalam teks untuk mempermudah analisis dengan menghilangkan kata-kata netral serta menyederhanakan kata yang memiliki perulangan, yang merupakan langkah penting dalam *Natural Language Processing* untuk memecah teks menjadi unit terkecil (token) guna analisis lebih lanjut [8].

C. Pelabelan Data

dalam bidang *text mining* pelabelan data memiliki tujuan untuk mengelompokkan data kedalam bentuk kategori sentimen yang mana di dalam penelitian ini terbagi menjadi 3 bagian yakni sentimen positif, sentimen negatif dan sentimen yang bersifat netral, pengelompokan sentimen dilakukan dengan menggunakan library *VADER Sentiment Analysis*. *VADER (Valence Aware Dictionary and Sentiment Reasoner)* merupakan salah satu pendekatan *lexicon-based* yang secara efektif dapat digunakan untuk menganalisis sentimen pada data teks, terutama di media sosial."[9]. Hal ini dilakukan untuk meningkatkan efisiensi dalam melakukan analisa sentimen dari data yang telah didapatkan dari media sosial

D. Representasi Data

Representasi data adalah sebuah tahapan untuk merubah data yang berupa teks yang telah didapat menjadi sebuah format yang dapat dianalisa oleh *machine learning*, dalam kasus ini menggunakan metode *TF-IDF (Term Frequency-Inverse Document Frequency)*. "*TF-IDF (Term Frequency-Inverse Document Frequency)* adalah salah satu teknik penghitungan bobot term dalam dokumen yang bertujuan untuk merepresentasikan relevansi suatu term di dalam dokumen terhadap seluruh koleksi dokumen" [10].

E. Naive Bayes

Naive Bayes adalah algoritma klasifikasi probabilistik yang didasarkan pada Teorema Bayes, dengan asumsi bahwa setiap fitur (atau kata) pada data ulasan adalah independen satu sama lain. Algoritma ini sangat cocok untuk analisis teks karena mampu menangani data dalam jumlah besar dengan efisien. Dalam penelitian ini, *Naive Bayes* akan digunakan untuk memprediksi kelas sentimen dari ulasan pelanggan, yang dapat berupa positif, negatif, atau netral, berdasarkan distribusi kata-kata dalam ulasan tersebut. Keunggulan utama *Naive Bayes* adalah hasil yang baik meskipun dengan asumsi independensi fitur yang sederhana.[11] Berikut ini adalah salah satu persamaan yang akan digunakan :

$$P(X) = \frac{P(C).P(C)}{P(X)} \quad (1)$$

F. Support Vector Machine

Support Vector Machine (SVM) adalah algoritma klasifikasi yang bertujuan untuk menemukan hyperplane terbaik yang dapat memisahkan data ke dalam kelas yang berbeda. SVM sangat efektif untuk digunakan dalam klasifikasi teks, terutama ketika data memiliki dimensi tinggi (banyak fitur). Dalam penelitian ini, SVM dengan kernel linear akan digunakan untuk membandingkan kinerjanya dengan *Naive Bayes* dalam klasifikasi sentimen. SVM unggul dalam menangani data yang tidak seimbang serta memiliki keakuratan tinggi dalam berbagai kasus klasifikasi.[12] Berikut ini adalah persamaan 2 yang akan digunakan :

$$k(x_1, x_2) = x_1^t \cdot x_2 \quad (2)$$

G. Evaluasi

Evaluasi model adalah langkah penting untuk menilai performa dari algoritma yang digunakan dalam penelitian ini. Beberapa metrik evaluasi yang akan digunakan meliputi akurasi, *precision*, *recall*, F1-Score, dan confusion matrix. Akurasi mengukur persentase prediksi yang benar dibandingkan dengan total data yang diuji. *Precision* mengukur ketepatan prediksi positif dari model, yaitu seberapa banyak prediksi positif yang benar dibandingkan dengan semua prediksi positif. *Recall* mengukur sensitivitas model, yaitu seberapa baik model dapat mendeteksi kelas positif dari seluruh data positif yang sebenarnya. F1-Score merupakan rata-rata harmonis dari *precision* dan *recall*, memberikan keseimbangan antara keduanya.

Confusion Matrix menampilkan jumlah prediksi yang benar dan salah untuk masing-masing kelas, memberikan gambaran lebih jelas tentang kinerja model. Setelah evaluasi dilakukan, hasil dari *Naive Bayes* dan SVM akan dibandingkan untuk menentukan algoritma mana yang lebih efektif dalam menganalisis sentimen pelanggan terhadap layanan BIZNET. Perbandingan ini akan membantu dalam memilih model terbaik yang dapat diimplementasikan secara efektif dalam skenario dunia nyata.

$$\begin{aligned} \text{Akurasi} &= \frac{TP + TN}{TP + TN + FP + FN} \times 100 \\ \text{Precision} &= \frac{TP}{TP + FP} \times 100 \\ \text{Recall} &= \frac{TP}{TP + FN} \times 100 \\ \text{F1 - Score} &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \end{aligned} \quad (3)$$

Dalam mengukur dari kinerja persamaan terdapat variabel yang digunakan seperti *True Positive*(TP) mengindikasikan hasil klasifikasi yang tepat, sementara *True Negative*(TN) menunjukkan hasil klasifikasi yang tidak tepat. Di sisi lain, *False Positive*(FP) merujuk pada hasil klasifikasi yang sebenarnya tidak tepat, meskipun model mengklasifikasikannya dengan benar, dan *False Negative*(FN) menggambarkan hasil klasifikasi yang seharusnya benar tetapi dinyatakan salah oleh model. Metrik-metrik ini memainkan peran penting dalam mengevaluasi sejauh mana model dapat mengenali dan membedakan antara kelas-kelas yang berbeda, memberikan pemahaman yang mendalam terkait ketepatan dan ketelitian model klasifikasi yang telah dikembangkan[13].

III. HASIL DAN PEMBAHASAN

A. Data Set

Data yang digunakan pada penelitian ini adalah cuitan tentang pengguna layanan provider biznet yang didapat melalui twitter dengan total data sebanyak 7272 dan memiliki 13 atribut seperti *created_at*, *username*, *full_text* dan sebagainya yang disimpan dalam bentuk sebuah file CSV dengan sampel data seperti pada Tabel 1, data yang diperoleh selanjutnya akan memasuki tahapan pemrosesan data

Tabel 1 Sampel Data

No	Tweet
1	nowadays jaringan xl lebih lancar daripada biznet anying
2	Biznet ada ga si yg paket 250k max dha bersih gt???
3	@Ryuusoku000 Hai @Ryuusoku000 siang. Dm Kamu sudah mimin respon ya. Thx^mft
....	
7272	@TokkiCarotty @Biznet IYAAAH NIIH BIZZNUT JELEK MULU 1 MINGGU INI : (

B. Pemrosesan Data

Tahap pemrosesan data dilakukan untuk meningkatkan performa dari setiap algoritma yang akan digunakan dalam pemrosesan data dibagi menjadi 3 tahapan yaitu pembersihan data, normalisasi data dan tokenisasi. Setelah data melewati proses tersebut data yang didapatkan menjadi 4027, sampel hasil pemrosesan data seperti pada Tabel 2.

Tabel 2 Hasil Pemrosesan Sampel Data


Proses	Tweet
Teks asli	nowadays jaringan xl lebih lancar daripada biznet anying
pembersihan data	nowadays jaringan xl lebih lancar daripada biznet
normalisasi data	sekarang jaringan xl lebih lancar daripada biznet
Tokenisasi	"sekarang", "jaringan", "xl", "lebih", "lancar", "daripada", "biznet"
steaming	Sekarang jaringan xl lebih lancar dari biznet

C. Pelabelan Data

Cara yang digunakan untuk pelabelan data adalah cara otomatis menggunakan ADER Sentimen Analisis dengan memberikan skor pada masing masing sentimen. Jika skor ≥ 0.05 yang menandakan bahwa sentimen positif, jika skor ≤ -0.05 menandakan bahwa sentimen negatif, lalu untuk yang tidak masuk keduanya akan dianggap netral. Setelah dilakukan proses pelabelan data yang didapat pada masing masing kategori sebanyak 538 data positif, 229 negatif dan 3260 netral. Sampel dan jumlah hasil pelabelan data seperti pada Tabel 3 dan Gambar 2

Tabel 3 Sampel Pelabelan Data

Tweet	Sentiment	Overall_Sentiment
cinta banget biznet	0.4588	Positive
Tidak ada koneksi saat saya bangun, biznet monyet babi pake biznet rumah	-0.5994	Negative
	0.0000	Netral



Gambar 2 Label sentimen

D. Ekstraksi Fitur

Pada proses ekstraksi fitur memiliki tujuan untuk mempermudah algoritma klasifikasi untuk membaca data dengan cara mengubah data yang awalnya dalam bentuk teks menjadi numerik dengan bantuan *Term Frequency-Inverse Document Frequency* (TF-IDF) seperti pada Gambar 4 dengan cara mengukur seberapa penting sebuah kata dalam sebuah kalimat dengan semua data yang kemudian hasilnya digunakan untuk algoritma *naïve bayes* dan juga *support vector machine* dengan cara dibagi 80:20, di mana 80% digunakan untuk data latih dan 20% untuk data uji dalam eksperimen ini. Dimana data uji berguna sebagai evaluasi dan data sementara data latih berguna untuk mengidentifikasi pola.

Tabel 4 Sampel hasil TF-IDF

Term	TF	TF-IDF
pesa	0.074385621933	0.074385621933
n	3874	3874
bizne	0.066724292711	0.066724292711
t	1248	1248
respo	0.043892756390	0.043892756390
n	5603	5603
bantu	0.041866358480	0.041866358480
	1895	1895

E. Klasifikasi Naïve Bayes

Selanjutnya data yang telah dibagi, diolah Menggunakan algoritma *naïve bayes* dengan asumsi distribusi probabilistic yang berbeda, dengan hasil seperti pada Tabel 5 dengan menggunakan Multinomial *Naive Bayes* dengan Nilai akurasi sebesar 87.59%, di mana nilai presisi negatif 0%, nilai presisi netral 87%, nilai presisi positif 93%, nilai recall negatif 0%, nilai recall netral 100%, nilai recall positif 50%, dan nilai f1-score negatif 0%, nilai f1-score netral 93%, nilai f1-score positif 65%, Bernoulli *Naive Bayes* dengan Nilai akurasi sebesar 88.21%, di mana nilai presisi negatif 22%, nilai presisi netral 90%, nilai presisi positif 88%, nilai recall negatif 11%, nilai recall netral 97%, nilai recall positif 69%, dan nilai f1-score negatif 15%, nilai f1-score netral 93%, nilai f1-score positif 77% dan Complement *Naive Bayes* dengan Nilai akurasi sebesar 82.38%, di mana nilai presisi negatif 16%, nilai presisi netral 94%, nilai presisi positif 82%, nilai recall negatif 36%, nilai recall netral 85%, nilai recall positif 85%, dan nilai f1-score negatif 22%, nilai f1-score netral 89%, nilai f1-score positif 83%

Tabel 5 Klasifikasi Naïve Bayes

Model	Akurasi	Kelas	Persisi	Recall	F1-Score
Multinomial NB	87,59%	Negatif	0%	0%	0%
		Netral	87%	100%	93%
		Positif	93%	50%	65%
Bernoulli NB	88,21%	Negatif	22%	11%	15%
		Netral	90%	97%	93%
		Positif	88%	69%	77%
Complement NB	82,38%	Negatif	16%	36%	22%
		Netral	94%	85%	89%
		Positif	82%	85%	83%

F. Klasifikasi Support Vector Machine

Data yang telah dibagi diolah menggunakan algoritma *Support Vector Machine* (SVM) dengan berbagai kernel untuk membandingkan performa klasifikasi dengan hasil seperti pada Tabel 6. SVM dengan Kernel Linear menghasilkan akurasi sebesar 93,92%, dengan performa terbaik pada kelas Netral (presisi 94%, recall 100%, f1-score 97%) dan performa yang cukup baik pada kelas Positif (presisi 99%, f1-score 84%). Namun, recall kelas Negatif hanya 53%, menunjukkan kesulitan dalam mendeteksi instance kelas tersebut.

SVM dengan Kernel RBF menghasilkan akurasi 91,32%, dengan performa terbaik pada kelas Netral (presisi 91%, recall 100%, f1-score 95%), tetapi recall kelas Negatif sangat rendah (27%), dan recall kelas Positif hanya 66%. SVM dengan Kernel Polynomial menghasilkan akurasi terendah, yaitu 89,45%. Meskipun presisi kelas Negatif mencapai 100%, recall-nya hanya 13%, dan recall kelas Positif juga rendah (58%). Performa terbaik tetap pada kelas Netral (presisi 89%, recall 100%, f1-score 94%). SVM dengan Kernel Sigmoid menghasilkan akurasi tertinggi, yaitu 94,29%, dengan performa seimbang di semua kelas.

Kelas Netral memiliki presisi 94%, recall 100%, dan f1-score 97%. Kelas Negatif memiliki recall 60% dan f1-score 72%, sementara kelas Positif memiliki presisi 96%, recall 76%, dan f1-score 85%.

Table 6 Klasifikasi SVM

Model	Akurasi	Kelas	Persisi	Recall	F1-Score
SVM Linear	93,92%	Negatif	89%	53%	67%
		Netral	94%	100%	97%
		Positif	99%	74%	84%
SVM RBF	91,32%	Negatif	92%	27%	41%
		Netral	91%	100%	95%
		Positif	99%	66%	79%
SVM Polynomial	89,45%	Negatif	100%	13%	24%
		Netral	89%	100%	94%
		Positif	98%	58%	73%
SVM Sigmoid	94,29%	Negatif	90%	60%	72%
		Netral	94%	100%	97%
		Positif	96%	76%	85%

G. Evaluasi

Evaluasi merupakan Langkah untuk mengetahui suatu performa dari algoritma yang digunakan dengan beberapa metrik evaluasi yang digunakan meliputi akurasi, *precision*, *recall*, *F1-Score* dan yang selanjutnya *confusion matrix*. Dengan Tabel 7 menyajikan hasil evaluasi untuk algoritma *Naïve Bayes* (*Multinomial*, *Bernoulli*, *Complement*) dan SVM (Linear, RBF, Polynomial, Sigmoid) berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-Score*.

Tabel 7 Hasil Perhitungan Algoritma

Algoritma	Akurasi	Persisi	Recall	F1-Score
Multinomial Naïve Bayes	87,59%	93%	50%	65%
Bernoulli Naïve Bayes	88,21%	88%	69%	77%

Complement	82,3	82%	85	83%
Naïve Bayes	8%		%	
SVM (Linear Kernel)	93,9	99%	74	84%
	2%		%	
SVM (RBF Kernel)	91,3	99%	66	79%
	2%		%	
SVM (Polynomial Kernel)	89,4	98%	58	73%
	5%		%	
SVM (Sigmoid Kernel)	94,2	96%	76	85%
	9%		%	


Untuk *confusion matrix* terdapat tabel untuk merepresentasikan kegunaan setiap kolom, tabel dapat dilihat pada Tabel 8

Tabel 8 Confusion Matrix


Prediksi / Aktual	Positif (Prediksi)	Netral (Prediksi)	Negatif (Prediksi)
Positif (Aktual)	True Positive (TP): Data yang sebenarnya positif dan berhasil diprediksi sebagai positif.	False Negative (Positif → Netral): Data yang sebenarnya positif tetapi salah diprediksi sebagai netral.	False Negative (Positif → Negatif): Data yang sebenarnya positif tetapi salah diprediksi sebagai negatif.
Netral (Aktual)	False Positive (Netral → Positif): Data yang sebenarnya netral tetapi salah diprediksi sebagai positif.	True Neutral (TNt): Data yang sebenarnya netral dan berhasil diprediksi sebagai netral.	False Negative (Netral → Negatif): Data yang sebenarnya netral tetapi salah diprediksi sebagai negatif.
Negatif (Aktual)	False Positive (Negatif → Positif)	False Positive (Negatif → Netral)	True Negative (TN): Data

	Positif): Data yang sebenarn ya negatif tetapi salah diprediks i sebagai positif.	Netral): Data yang sebenarn ya negatif tetapi salah diprediks i sebagai netral.	yang sebenarn ya negatif dan berhasil diprediks i sebagai negatif.
--	---	---	--



Berdasarkan presentasi di atas maka *confusion matrix* dari setiap algoritma dapat ditampilkan dimulai dari Gambar 3 untuk Multinomial Naïve Bayes, Gambar 4 untuk Bernoulli Naïve Bayes, Gambar 5 untuk Complement Naïve Bayes, Gambar 6 untuk SVM kernel linear, Gambar 7 untuk SVM Kernel RBF, Gambar 8 untuk SVM Kernel Polynomial dan Gambar 9 untuk SVM Kernel Sigmoid,




Gambar 3 Multinomial Naïve Bayes




Gambar 4 Bernoulli Naive Bayes

Gambar 5 *Complement Naive Bayes*


Gambar 6 SVM dengan linear kernel



Gambar 7 SVM dengan RBF kernel



Gambar 8 SVM dengan polynomial kernel



Gambar 9 SVM dengan sigmoid kernel

Berdasarkan hasil evaluasi, SVM dengan Sigmoid Kernel mencatat akurasi tertinggi (94,29%) dan *F1-Score* yang seimbang untuk kelas Positif (85%). Hal ini menunjukkan bahwa algoritma ini mampu menangani ketidakseimbangan kelas dengan baik. Di sisi lain, *Multinomial Naive Bayes* memiliki recall yang rendah untuk kelas Positif (50%), menunjukkan bahwa model ini kesulitan mendeteksi instance positif. *Complement Naive Bayes* menunjukkan peningkatan recall (85%) dibandingkan varian *Naive Bayes* lainnya, tetapi akurasi lebih rendah (82,38%). Dari *Confusion Matrix*, terlihat bahwa SVM dengan Sigmoid Kernel mampu memprediksi 27 instance kelas Negatif dengan benar, meskipun masih terdapat 17 instance yang diprediksi salah sebagai Netral. Untuk kelas Positif, 81 instance diprediksi benar, dengan 26 instance salah prediksi.

IV. KESIMPULAN

Penelitian ini dilakukan untuk membantu Biznet dalam memahami sentimen pelanggan terhadap layanan internet mereka berdasarkan data dari media sosial, khususnya X.com (Twitter). Dengan semakin banyaknya keluhan dan opini publik yang disampaikan secara terbuka, analisis sentimen menjadi penting untuk mengidentifikasi kekuatan dan kelemahan layanan secara *real-time*.

Melalui tahapan *text mining* yang meliputi pengambilan data, pembersihan, tokenisasi, pelabelan sentimen, dan ekstraksi fitur menggunakan TF-IDF, dilakukan klasifikasi menggunakan algoritma *Naive Bayes* dan *Support Vector Machine* (SVM). Dari total 7.272 tweet, sebanyak 4.027 tweet berhasil diproses dan dianalisis. Hasil klasifikasi menunjukkan bahwa SVM dengan kernel Sigmoid memberikan performa terbaik dengan akurasi tertinggi sebesar 94,29% dan F1-score seimbang untuk setiap kelas, khususnya kelas

positif. Hal ini menunjukkan bahwa algoritma ini mampu menangani ketidakseimbangan data sentimen dengan baik. Di sisi lain, Multinomial Naïve Bayes memiliki kelemahan dalam mendeteksi sentimen positif, sementara Complement Naïve Bayes menunjukkan peningkatan recall namun akurasi lebih rendah. Berdasarkan hasil evaluasi ini, SVM dengan kernel Sigmoid direkomendasikan sebagai metode terbaik dalam mendukung analisis sentimen layanan pelanggan Biznet, sehingga perusahaan dapat merespons opini pelanggan secara lebih tepat dan meningkatkan kualitas layanan secara berkelanjutan.

REFERENSI

- [1] F. D. Ananda And Y. Pristyanto, “Analisis Sentimen Pengguna Twitter Terhadap Layanan Internet Provider Menggunakan Algoritma Support Vector Machine,” *Matrik J. Manajemen, Tek. Inform. Dan Rekayasa Komput.*, Vol. 20, No. 2, 2021, Doi: 10.30812/Matrik.V20i2.1130.
- [2] B. W. Sari And F. F. Haranto, “Implementasi Support Vector Machine Untuk Analisis Sentimen Pengguna Twitter Terhadap Pelayanan Telkom Dan Biznet,” *J. Pilar Nusa Mandiri*, Vol. 15, No. 2, 2019, Doi: 10.33480/Pilar.V15i2.699.
- [3] S. Rahayu And K. Handoko, “Implementasi Data Mining Untuk Memprediksi Pengaruh Media Sosial Terhadap Semangat Belajar Anak,” *J. Comasie*, Vol. 11, No. 02, 2024.
- [4] M. Bohlouli, J. Dalter, M. Dornhöfer, J. Zenkert, And M. Fathi, “Knowledge Discovery From Social Media Using Big Data-Provided Sentiment Analysis (Somabit),” 2015. Doi: 10.1177/0165551515602846.
- [5] S. B. Kotsiantis, I. D. Zaharakis, And P. E. Pintelas, “Machine Learning: A Review Of Classification And Combining Techniques,” *Artif. Intell. Rev.*, Vol. 26, No. 3, 2006, Doi: 10.1007/S10462-007-9052-3.
- [6] E. Rahm And H. Do, “Data Cleaning: Problems And Current Approaches,” *Ieee Data Eng. Bull.*, Vol. 23, No. 4, 2000.
- [7] D. Jurafsky And J. H. Martin, “Speech And Language Processing An Introduction To Natural Language Processing, Computational Linguistics, And Speech Recognition With Language Models Third Edition Draft Summary Of Contents.”
- [8] C. D. Manning, P. Raghavan, And H. Schütze, *Introduction To Information Retrieval*. 2008. Doi: 10.1017/Cbo9780511809071.
- [9] C. J. Hutto And E. Gilbert, “Vader: A Parsimonious Rule-Based Model For Sentiment Analysis Of Social Media Text,” In *Proceedings Of The 8th International Conference On Weblogs And Social Media, Icwsm 2014*, 2014. Doi: 10.1609/Icwsm.V8i1.14550.
- [10] A. Rajaraman And J. D. Ullman, *Mining Of Massive Datasets*, Vol. 9781107015357. 2011. Doi: 10.1017/Cbo9781139058452.
- [11] A. McCallum And K. Nigam, “A Comparison Of Event Models For Naive Bayes Text Classification,” *Aaai/Icml-98 Work. Learn. Text Categ.*, 1998, Doi: 10.1.1.46.1529.
- [12] C. Cortes And V. Vapnik, “Support-Vector Networks,” *Mach. Learn.*, Vol. 20, No. 3, 1995, Doi: 10.1023/A:1022627411411.
- [13] J. W. Iskandar And Y. Nataliani, “Perbandingan Naïve Bayes, Svm, Dan K-Nn Untuk Analisis Sentimen Gadget Berbasis Aspek,” *J. Resti (Rekayasa Sist. Dan Teknol. Informasi)*, Vol. 5, No. 6, 2021, Doi: 10.29207/Resti.V5i6.3588.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

