

Analisis Sentimen pada Twitter Mengenai Layanan Toko *Online* dengan Metode Naïve Bayes

I Kadek Candradinata¹, Erwin Budi Setiawan², Yuliant Sibaroni³

¹²³Fakultas Informatika, Universitas Telkom, Bandung

¹candradinata@students.telkomuniversity.ac.id, ²erwinbudisetiawan@telkomuniversity.ac.id

³yuliant@telkomuniversity.ac.id

Abstrak

Strategi pemasaran seperti toko *online* atau lebih sering disebut *e-commerce*, muncul seiring berkembangnya teknologi. Banyaknya pengguna *e-commerce*, tentunya akan membuat perusahaan kesulitan untuk mengerti keinginan penggunanya. Dengan mengetahui sentimen pengguna, maka perusahaan dapat mengetahui apakah sistem yang digunakan sudah baik untuk pengguna atau belum. Oleh karena itu, analisis sentimen pengguna diperlukan agar perusahaan dapat mempertahankan penggunanya. Untuk mendapatkan data sentimen, digunakanlah Twitter, karena Twitter memiliki jutaan pengguna di Indonesia. Data dibagi menjadi tiga kelas yaitu: positif, negatif, dan netral. Penelitian dimulai dengan mengumpulkan data berupa *Tweet* dari Twitter. Lalu dilakukan *preprocessing* yang terdiri dari: *Case Folding*, *Tokenisasi*, *Stopword*, dan *Stemming*. Pembobotan data menggunakan TF-IDF, klasifikasi menggunakan metode *Naïve Bayes Classifier*. Hasil penelitian menunjukkan rata-rata performansi tertinggi yang didapatkan oleh klasifikasi menggunakan metode Naïve Bayes dan pembobotan TF-IDF pada data uji 10%, yaitu Akurasi 66,64%, *Precision* 67,13%, dan *Recall* 68,44%. Metode *Naïve Bayes* memerlukan sumber daya yang tidak kecil dan waktu yang cukup lama untuk data yang banyak.

Kata kunci: analisis sentimen, twitter, *naïve bayes*, *e-commerce*

Abstract

Marketing strategies such as online shops or commonly called *e-commerce*, emerged as technology developed. The large number of *e-commerce* users, of course will make it difficult for companies to understand the desires of their users. By knowing user sentiment, the company can find out whether the system used is good for users or not. Therefore, an analysis of user sentiments is needed so that the company can maintain its users. To get sentiment data, Twitter is used, because Twitter has millions of users in Indonesia. The data is divided into three classes: positive, negative, and neutral. The research began by collecting data in the form of Tweets from Twitter. Then preprocessing consists of: *Case Folding*, *Tokenization*, *Stopwording*, and *Stemming*. Weighting data using TF-IDF, classification using the *Naïve Bayes Classifier* method. The results showed the highest average performance obtained by the classification using the *Naïve Bayes* method and weighting TF-IDF on the 10% test data, get 66.64% accuracy, 68.44% recall, and *Precision* 67.13%. The *Naïve Bayes* method requires resources that are not small and time-consuming for a lot of data.

Keywords: sentiment analysis, twitter, *naïve bayes*, *e-commerce*

1. Pendahuluan

Latar Belakang

Perkembangan teknologi dilakukan dengan tujuan meningkatkan taraf hidup manusia. Salah satu perkembangan yang berpengaruh besar terhadap kehidupan manusia yaitu internet. Hingga tahun 2018, pengguna internet di Indonesia telah mencapai sekitar 143 juta [1]. Keberadaan internet membuat pemasaran dapat dilakukan tanpa harus interaksi langsung antara penjual dan pembeli. Pemasaran menggunakan internet disebut dengan *e-commerce*. Terdapat banyak pengunjung *e-commerce* di Indonesia, bahkan Tokopedia yang merupakan salah satu contoh *e-commerce* memiliki ratusan juta pengunjung pada 2018 [2]. Perusahaan *e-commerce* perlu memiliki pemahaman terhadap sentimen pelanggan untuk memberikan pelayanan yang lebih baik. Dengan adanya media sosial yang merupakan pemanfaatan dari internet, sebagian besar pengguna media sosial dapat menyalurkan sentimen atau opini mereka di media sosial. Dapat disimpulkan bahwa media sosial merupakan pilihan tepat dalam mendapatkan data sentimen pelanggan.

Twitter merupakan salah satu media sosial dengan pengguna yang sangat banyak di Indonesia [3]. Banyaknya pengguna Twitter di Indonesia, tentunya opini pelanggan dapat ditemukan dalam jumlah yang besar. Dari opini tersebut, diharapkan *e-commerce* di Indonesia dapat berkembang ke arah yang lebih baik dengan terus mengkaji kepuasan pelanggan melalui sentimen pelanggan yang tersurat di media sosial. Opini dapat bersifat positif, negatif, ataupun netral. Dengan banyaknya jumlah opini yang dapat ditemukan dan terus bertambah, diperlukan sistem yang dapat mengklasifikasikan opini-opini tersebut.

Terdapat beberapa metode yang dapat digunakan untuk klasifikasi data sentimen, salah satunya Naïve Bayes. Naïve Bayes merupakan metode pembelajaran mesin yang memiliki model dalam bentuk probabilitas atau peluang [4]. Ketika ada tweet baru yang ingin diklasifikasikan, maka nilai probabilitas dari setiap fitur untuk masing-masing kelas dikalikan. Nilai probabilitas yang paling besar diantara kelas positif, negatif, dan netral, dijadikan kelas tweet baru tersebut. Selain itu, klasifikasi data menggunakan Naïve Bayes *Classifier*, karena metode tersebut memiliki akurasi yang tinggi dalam berbagai situasi di dunia nyata [5].

Penelitian mengenai analisis sentimen pada media sosial Instagram menggunakan metode klasifikasi Naïve Bayes, pernah dilakukan oleh Antonius Rachmat Chrismanto [6], menggunakan 25.000 data. Penelitian tersebut menghasilkan akurasi sebesar 77,25%. Berdasarkan penelitian tersebut, penelitian ini menggunakan data sebanyak 50.000 *tweet*.

Berdasarkan latar belakang, masalah yang dapat dirumuskan pada penelitian ini adalah bagaimana performansi metode naïve bayes dengan pembobotan TF-IDF pada tweet sentimen pengguna terhadap suatu *e-commerce*. Studi kasus yang dilakukan terbatas pada *e-commerce* Indonesia karena mesin yang dibuat digunakan untuk memprediksi teks berbahasa Indonesia. Data yang digunakan sebanyak 50.000 tweet dengan isi tweet yang merujuk pada *e-commerce* di Indonesia. Setelah data tersebut melalui klasifikasi Naïve Bayes, dilakukan pengukuran performansi menggunakan *Precision*, *Recall*, dan Akurasi. Penulis menggunakan Google Colab untuk menjalankan program dikarenakan banyaknya data sehingga membutuhkan sumber daya yang cukup besar, namun untuk tahap hingga preprocessing, penulis menggunakan PyCharm.

Melalui Twitter, pengguna dapat menyampaikan opini mereka mengenai layanan toko *online* yang mereka gunakan. Opini tersebut dijadikan data, untuk selanjutnya diklasifikasikan dan ditemukan pola yang terkandung di dalam data tersebut, Naïve bayes merupakan salah satu metode yang dapat digunakan untuk mendapatkan pola. Tujuan dari penelitian ini adalah untuk mengetahui apakah metode Naïve Bayes efektif terhadap data sebanyak 50.000 data yang berupa teks.

Organisasi penulisan ini dimulai dengan latar belakang, topik, batasan dan tujuan penelitian yang termasuk dalam pendahuluan. Selanjutnya ada studi terkait yang berisi tentang penelitian-penelitian yang berhubungan dengan analisis sentimen dan metode yang digunakan. Ketiga, sistem yang dibangun, gambaran umum sistem beserta penjelasan setiap tahapnya. Keempat, dituliskan hasil implementasi dan analisis berdasarkan penelitian yang dilakukan. Kelima adalah poin kesimpulan serta saran.

2. KAJIAN PUSTAKA

2.1 Text Mining

Text Mining adalah proses ekstraksi informasi berguna dari data tekstual. Dikenal juga sebagai *Text Data Mining*. Sarana mining didesain untuk menangani data terstruktur. *Text Mining* digunakan untuk menemukan informasi yang sebelumnya belum teridentifikasi dari sumber lain [7].

Text Mining adalah bidang interdisipliner yang mengacu pada pengambilan informasi, penambahan data, pembelajaran mesin, statistik, dan linguistik komputasi [8]. *Text mining* sebenarnya merupakan bagian dari data mining dimana proses yang dilakukan utamanya adalah melakukan ekstraksi pengetahuan dan informasi dari pola-pola yang terdapat dalam sekumpulan dokumen teks menggunakan alat analisis tertentu [9].

2.2 Analisis Sentimen

Analisis sentimen merupakan pengklasifikasian dokumen tekstual ke dalam beberapa kelas seperti: sentimen positif, sentimen negatif, ataupun netral, digunakan untuk mendapatkan suatu informasi tertentu dari data yang ada [10]. Sentimen merupakan pendapat atau pandangan yang didasarkan pada perasaan yang berlebihan terhadap sesuatu [11].

Analisis sentimen sendiri atau juga biasa disebut dengan opinion mining adalah salah satu bagian dari text mining. Bidang ini melakukan studi mengenai opini orang-orang, sentimen, evaluasi, tingkah laku dan emosi terhadap suatu entitas seperti produk, layanan, organisasi, individu, permasalahan, topik, acara dan atribut-atributnya [12].

2.3 N-gram

N-gram adalah rangkaian token dengan panjang n . Dalam konteks komputasi linguistik, token ini dapat berupa kata-kata, meskipun mereka dapat berupa karakter atau himpunan bagian dari karakter. Nilai n hanya mengacu pada jumlah token. Metode n -grams ini digunakan untuk mengambil potongan-potongan karakter huruf sejumlah n dari sebuah kata yang secara kontinuitas dibaca dari teks sumber hingga akhir dari dokumen [13].

2.4 E-commerce

E-commerce atau toko *online* adalah cara pemasaran yang memanfaatkan media internet sebagai tempat untuk melakukan transaksi. Toko *online* memungkinkan pemasaran lebih luas karena penjual dan pembeli tidak perlu bertemu secara langsung untuk bertransaksi. Bahkan Tokopedia yang merupakan salah satu contoh perusahaan yang memfasilitasi transaksi secara *online* di Indonesia, memiliki ratusan juta pengunjung pada 2018 [2].

2.5 Preprocessing

Preprocessing yaitu mengolah data mentah dengan mengeliminasi atau mengubah bentuk agar lebih mudah diproses oleh sistem. Hal ini penting dilakukan karena data yang diambil dari Twitter tentunya tidak selalu menggunakan bahasa baku. Teknik yang dapat dilakukan dalam *preprocessing* yaitu:

Case Folding: Mengubah semua huruf menjadi huruf kecil (*lowercase*)

Punctuation Removal: Menghilangkan karakter lain selain huruf dan angka. Tautan dihilangkan sekaligus pada tahap ini,

Tokenisasi: Pemecahan kalimat menjadi kata atau frase.

Stopword: Seleksi kata yang penting dalam teks.

Stemming: Menghilangkan imbuhan, awalan, dan akhiran pada sebuah kata sehingga menjadi kata yang baku.

2.6 Pembobotan Term Frequency – Inverse Document Frequency (TF-IDF)

Penelitian ini menggunakan pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF). Pembobotan TF-IDF adalah perhitungan yang menggambarkan seberapa pentingnya kata (term) dalam sebuah dokumen dan korpus. Proses ini digunakan untuk menilai bobot relevansi term dari sebuah dokumen terhadap seluruh dokumen dalam korpus [14].

Metode ini merupakan metode yang digunakan menentukan seberapa jauh keterhubungan kata (term) terhadap dokumen dengan memberikan bobot setiap kata. Metode ini menggabungkan dua konsep yaitu frekuensi kemunculan sebuah kata di dalam sebuah dokumen dan inverse frekuensi dokumen yang mengandung kata tersebut [15].

$$IDF(w) = \log \left(\frac{N}{DF(w)} \right) \quad (1)$$

$$TF - IDF(w, d) = TF(w, d) \times IDF(w) \quad (2)$$

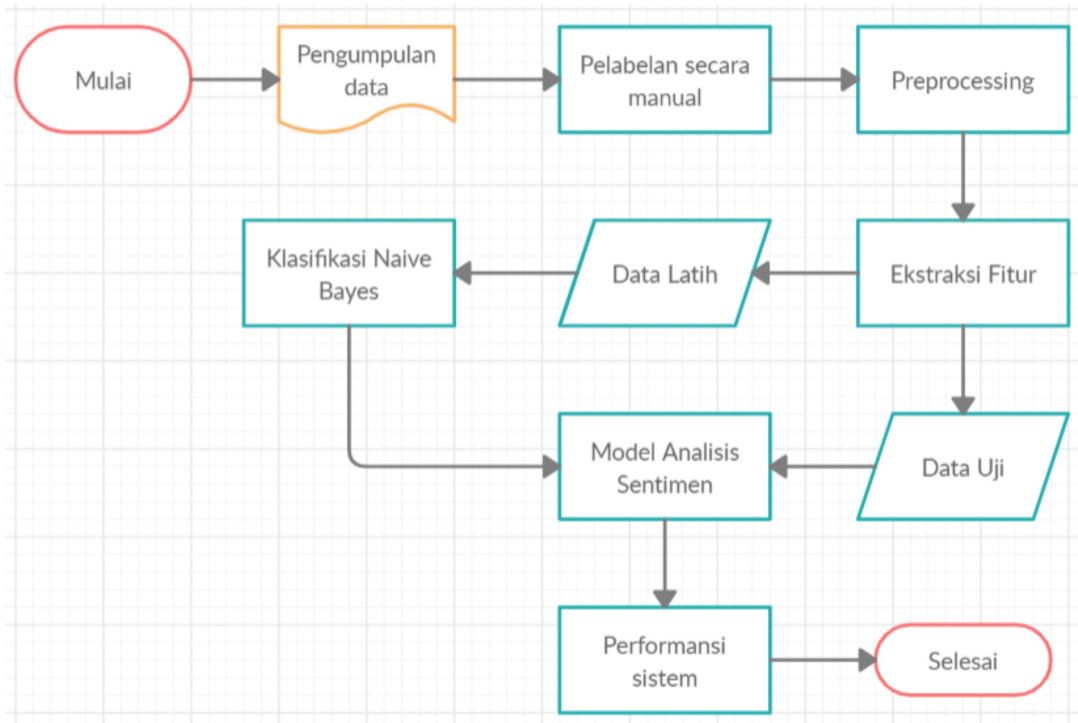
TF-IDF(w, d) adalah bobot kata dalam sebuah dokumen, w (*word*) adalah kata, d (*document*) adalah dokumen, TF(w, d) adalah frekuensi kemunculan kata dalam dokumen, IDF(*inverse document frequency*) adalah Inverse DF dari w , N adalah banyak dokumen, dan DF(w) adalah banyak kata dalam dokumen [10].

2.7 Klasifikasi Naïve Bayes

Naïve Bayes merupakan pengklasifikasian probabilistik sederhana yang menghitung sekumpulan probabilitas dengan menjumlahkan frekuensi dan kombinasi nilai dari data yang diberikan. Naive Bayes merupakan pengklasifikasian dengan metode probabilitas dan statistik yang dikemukakan oleh ilmuwan Inggris Thomas Bayes, yaitu memprediksi peluang di masa depan berdasarkan pengalaman dimasa sebelumnya sehingga dikenal sebagai Teorema Bayes. Teorema tersebut dikombinasikan dengan Naïve dimana diasumsikan kondisi antar atribut saling bebas. Klasifikasi Naïve Bayes diasumsikan bahwa ada atau tidak ciri tertentu dari sebuah kelas tidak ada hubungannya dengan ciri dari kelas lainnya [16].

3. Sistem yang Dibangun

Sistem yang dibangun pada penelitian ini terdiri dari beberapa proses dengan gambaran umum pada Gambar 1.



Gambar 1. Sistem model analisis sentimen untuk toko online

3.1 Pengumpulan data

Pengumpulan data (*Crawling*) dilakukan dengan mengambil data dari *Tweet* mention akun @tokopedia, @TokopediaCare, @bukalapak, @BukaBantuan, @LazadaID, @LazadaIDCare, dan @ShopeeCare yang akan menjadi data latih dan data uji dengan mengklasifikasikannya secara manual. Contoh Pelabelan *Tweet* bisa dilihat pada Tabel 1.

Tabel 1. Contoh *Tweet* beserta label.

Tweet	Label
Min, @BukaBantuan sy ada transaksi 192510801756 sdh sy bayar, tapi barang kosong dan tgl kirim sudah kadaluarsa, tapi dana blom dikembalikan.	-1 (Negatif)
Selamat pagi @bukalapak @BukaBantuan bgmn caranya mencairkan saldo yg ada di Credits?	0 (Netral)
Terima kasih @bukalapak atas 1 rupiahnya.. https://t.co/VH5xMGyJI95	1 (Positif)

3.2 Preprocessing

Preprocessing terhadap data dilakukan dengan tahapan berikut:

Case Folding: Mengubah tiap huruf menjadi huruf kecil (*lowercase*).

Min, @BukaBantuan sy ada transaksi 192510801756 sdh sy bayar, tapi barang kosong dan tgl kirim sudah kadaluarsa, tapi dana blom dikembalikan.



min, @bukabantuan sy ada transaksi 192510801756 sdh sy bayar, tapi barang kosong dan tgl kirim sudah kadaluarsa, tapi dana blom dikembalikan.

Punctuation Removal: Menghilangkan karakter lain selain huruf dan angka, serta tautan.

min, @bukabantuan sy ada transaksi 192510801756 sdh sy bayar, tapi barang kosong dan tgl kirim sudah kadaluarsa, tapi dana blom dikembalikan.



min bukabantuan sy ada transaksi 192510801756 sdh sy bayar tapi barang kosong dan tgl kirim sudah kadaluarsa tapi dana blom dikembalikan

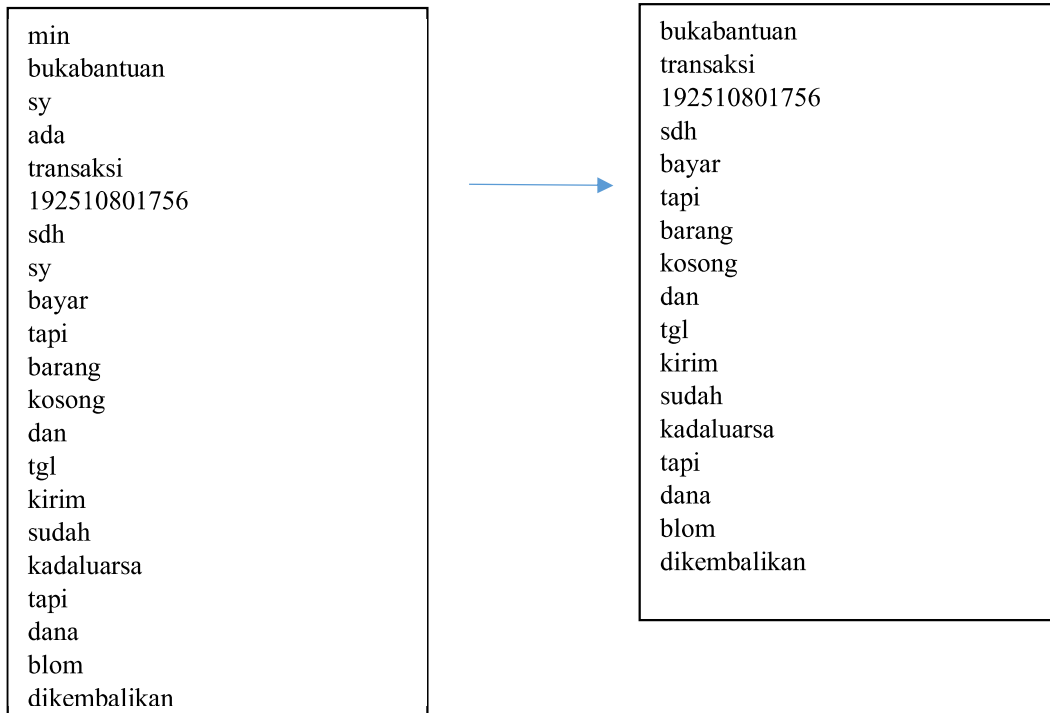
Tokenisasi: Pemecahan kalimat menjadi kata atau frase.

min bukabantuan sy ada transaksi 192510801756 sdh sy bayar tapi barang kosong dan tgl kirim sudah kadaluarsa tapi dana blom dikembalikan

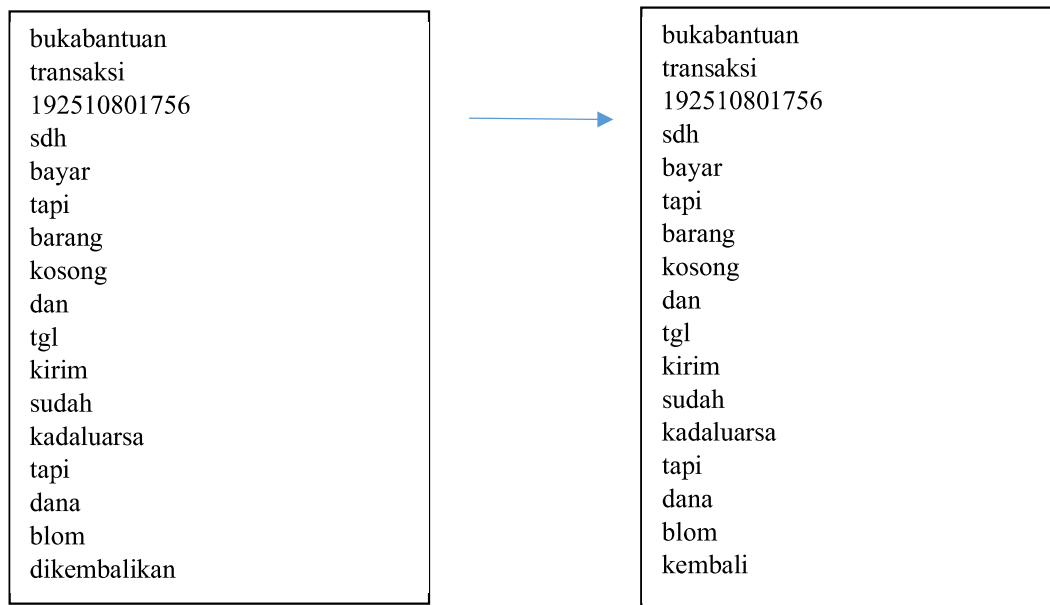


min
bukabantuan
sy
ada
transaksi
192510801756
sdh
sy
bayar
tapi
barang
kosong
dan
tgl
kirim
sudah
kadaluarsa
tapi
dana
blom
dikembalikan

Stopword: Seleksi kata yang penting dalam teks.



Stemming: Menghilangkan imbuhan, awalan, dan akhiran pada sebuah kata sehingga menjadi kata yang baku.



3.3 Ekstraksi Fitur Menggunakan Pembobotan TF-IDF

Tahapan selanjutnya adalah pembobotan menggunakan *Term Frequency Inverse Document Frequency* (TF-IDF). Kata yang didapat akan menjadi *w* (*word*), sebuah kata dihitung jumlahnya pada dokumen sehingga mendapatkan $DF(w)$, lalu dimasukkan ke dalam persamaan (1). Untuk mendapatkan bobot sebuah kata, maka dibutuhkan frekuensi kata tersebut dalam sebuah dokumen kata itu berada, lalu dikalikan dengan $IDF(w)$ sesuai dengan persamaan (2). Contoh TF-IDF bisa dilihat pada Tabel 2.

Tabel 2. Contoh TF-IDF.

w	TF			Df	N/Df	IDF	Wi = TF x IDF		
	D1	D2	D3				D1	D2	D3
barang	0	0	4	4	0,75	-0.29	0	0	-1,15
kosong	0	2	0	2	1,5	0.41	0	0,81	0
kecewa	0	5	0	5	0,6	-0.51	0	-2,55	0
aman	1	0	0	1	3	1.10	1.10	0	0

Dari hasil TF-IDF tersebut agar dapat dilakukan klasifikasi menggunakan Naïve Bayes, maka dilakukan diskritisasi dengan acuan median atau mean atau kuartil 1 sebagai batasnya. Dengan aturan (misal menggunakan median) jika lebih dari median, maka “ya” dan kurang dari median maka “tidak”. Misalkan median yang didapat dari Tabel 2 adalah -0,897656945, maka hasil setelah diskritisasi bisa dilihat pada Tabel 3.

Tabel 3. Hasil Diskritisasi

	D1	D2	D3
barang	tidak	tidak	tidak
kosong	tidak	ya	tidak
kecewa	tidak	tidak	tidak
aman	ya	tidak	tidak

3.4 Klasifikasi Naïve Bayes

Setelah data training dan data uji melalui proses *preprocessing* dan pembobotan, kemudian dilakukan implementasi metode Naïve Bayes pada proses training untuk membangun model probabilitas dari data training. Selanjutnya dilakukan pengujian model klasifikasi yang dihasilkan pada proses training dengan menggunakan data *Tweet* baru (data uji). Klasifikasi menggunakan Naïve Bayes dilakukan dengan persamaan (3). Contoh Klasifikasinya bisa dilihat pada Tabel 4.

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \quad (3)$$

Tabel 4. Contoh klasifikasi menggunakan Naïve Bayes.

	barang	rusak	kecewa	Label
Tweet latih 1	tidak	tidak	tidak	Netral
Tweet latih 2	tidak	ya	tidak	Negatif
Tweet latih 3	ya	tidak	tidak	Negatif
Tweet uji	ya	ya	tidak	Negatif

3.5 Evaluasi Akurasi

Confusion Matrix merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi, bisa dilihat pada Tabel 5.

Tabel 5. Confussion Matrix

Kelas Data	Klasifikasi positif	Klasifikasi Netral	Klasifikasi Negatif
Positif	TP	FNetP	FN
Netral	FPNet	TNet	FNNet
Negatif	FP	FNetN	TN

Recall berguna untuk mengukur tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi.

$$\text{Recall Positif} = \frac{TP}{(TP+FN_{NetP}+FN)} \quad (4)$$

$$\text{Recall Negatif} = \frac{TN}{(FP+FN_{NetN}+TN)} \quad (5)$$

$$\text{Recall Netral} = \frac{TNet}{(FP_{Net}+TNet+FN_{Net})} \quad (6)$$

Precision berguna untuk mengukur akurasi antara informasi yang diminta oleh pengguna dengan hasil dari sistem.[17]

$$\text{Precision Positif} = \frac{TP}{(TP+FP+FP_{Net})} \quad (7)$$

$$\text{Precision Negatif} = \frac{TN}{(FN+FN_{Net}+TN)} \quad (8)$$

$$\text{Precision Netral} = \frac{TNet}{(FN_{NetP}+TNet+FN_{NetN})} \quad (9)$$

Akurasi digunakan untuk mengukur kemampuan *classifier*. Perhitungan akurasi menggunakan persamaan (10).

$$\text{Akurasi} = \frac{(TP+TNet+TN)}{(TP+FP_{Net}+FP+FN_{NetP}+TNet+FN_{NetN}+FN+FN_{Net}+TN)} \quad (10)$$

F-Measure merupakan keseimbangan antara recall dan precision dengan persamaan (11)

$$F - \text{Measure} = \frac{2 \cdot (\text{Recall Positif} \cdot \text{Precision Positif})}{(\text{Recall Positif} + \text{Precision Positif})} \quad (11)$$

4. Evaluasi

4.1 Hasil Pengujian

Pengujian ini dilakukan dengan tiga skenario, yaitu:

- i. Klasifikasi dengan median (nilai tengah), mean (rata-rata), dan kuartil 1 sebagai acuan diskritisasi pada pembobotan, diuji hanya hingga akurasi,
- ii. Klasifikasi dengan pembagian data persentase data uji 10% dan data uji 20% menggunakan hasil terbaik dari skenario (i),
- ii. Klasifikasi dengan pembagian data berdasarkan masing masing toko online menggunakan hasil terbaik dari skenario (ii).

Hasil klasifikasi untuk skenario (i) ditunjukkan pada Tabel 6.

Tabel 6. Akurasi hasil klasifikasi menggunakan median, mean, dan kuartil 1 sebagai acuan diskritisasi.

	Median	Mean	Kuartil 1
Akurasi	66,64%	62,56%	61,01%

Terlihat dari Tabel 6 bahwa median merupakan hasil terbaik dengan akurasi 66,63%. Sehingga, median digunakan sebagai acuan diskritisasi setelah pembobotan untuk skenario (ii).

Tabel 7. Performansi dengan data uji 10% dan 20%.

	Data uji 10%	Data uji 20%
Akurasi	66,64%	66,48%
Precision	67,13%	66,85%
Recall	68,44%	68,16%
F-Measure	67,68%	67,49%

Berdasarkan kedua skenario uji, performansi tertinggi didapatkan oleh penggunaan data uji 10% dengan median sebagai acuan diskritisasi, bisa dilihat pada Tabel 7. Rincian hasil klasifikasi dengan performansi terbaik terdapat pada Tabel 8.

Tabel 8. Hasil klasifikasi dengan akurasi tertinggi

Kelas Data	Klasifikasi positif	Klasifikasi Netral	Klasifikasi Negatif
Positif	914	283	161
Netral	354	1130	596
Negatif	75	161	1212

$$Akurasi = \frac{(914 + 1130 + 1212)}{(914 + 283 + 161 + 354 + 1130 + 596 + 75 + 161 + 1212)} = 66,64\%$$

Precision dan recall untuk hasil klasifikasi Naïve Bayes dengan pembobotan tf-idf adalah sebagai berikut:

Tabel 9. Performansi presisi dan recall naive bayes dengan pembobotan tf-idf

	Positif	Netral	Negatif
Precision	68,06%	71,80%	61,55%
Recall	67,30%	54,33%	83,70%

F-Measure untuk hasil klasifikasi Naïve Bayes dengan pembobotan TF-IDF adalah sebagai berikut:

$$F - Measure = \frac{2 \times (68,06 \times 67,30)}{(68,06 + 67,30)} = 67,68\%$$

Setelah ditemukan bahwa penggunaan median sebagai acuan diskritisasi dan pembagian data 90:10 yang terbaik, maka dilakukan skenario ketiga yaitu uji terhadap data masing – masing toko. Tabel 10 menunjukkan jumlah data sentimen masing – masing toko.

Tabel 10. Prediksi sentimen terhadap masing - masing toko

	Positif	Negatif	Netral
Bukalapak	20	22	1210
Tokopedia	40	13	1032
Lazada	17	69	1305
Shopee	1181	8	59

Terdapat kata - kata yang banyak digunakan pengguna toko online berdasarkan data bisa dilihat di Tabel 11.

Tabel 11. Kata - kata yang paling sering muncul dalam data

	Bukalapak		Tokopedia		Lazada		Shopee	
	Positif	Negatif	Positif	Negatif	Positif	Negatif	Positif	Negatif
Kata - kata	Ya	Tidak	Sudah	Tidak	Bisa	Maaf	Mau	Pesanan
	Bisa	Kendala	Bisa	Maaf	Sudah	Pesanan	Bisa	Maaf
	Semangat	Belum	Mau	Belum	Banget	Kendala	Banget	Belum
	Banget	Ketidaknyamanannya	Banget	Kenapa	Respon	Ketidaknyamanannya	Semoga	Barang
	Semoga	Kok	Respon	Mohon	Baik	Belum	Semangat	Tolong
	Kasih	Pembayaran	Semangat	Banget	Bantu	Proses	Beruntung	Dana
	Beruntung	Tolong	Makasih	Bantu	Semoga	Dana	Menang	Paket
	Mantul	Menunggu	Semoga	Kendala	Mohon	Pengiriman	Good	Mohon
	Good	Pengiriman	Mantul	Pembayaran	Diskon	Tunggu	Makasih	Beli
	Selamat	Komplain	Beruntung	Pengiriman	Makasih	Refund	Belanja	Ongkir

4.2 Analisis Hasil Pengujian

Berdasarkan skenario-skenario pengujian yang dilakukan, didapatkan bahwa perbedaan angka acuan dalam diskritisasi pembobotan, dapat berpengaruh secara signifikan terhadap akurasi. Angka acuan diskritisasi yang terbaik untuk data penelitian ini adalah median atau nilai tengah data. Sedangkan, perbedaan perbandingan data uji dengan data latih tidak berpengaruh signifikan terhadap performansi.

Setelah sistem terbangun, dilakukan pengujian terhadap data masing – masing toko online, ditemukan bahwa sistem yang dibangun dapat memprediksi kesimpulan sentimen tiap toko sesuai dengan data aktual.

5. Kesimpulan dan Saran

Kesimpulan yang didapatkan dari hasil penelitian ini bahwa penggunaan Naïve Bayes terhadap data yang banyak memerlukan waktu yang cenderung lama dan sumber daya perangkat yang tidak sedikit. Banyaknya data membuat fitur yang didapatkan lebih banyak, sehingga sangat berpengaruh kepada metode Naïve Bayes yang menggunakan seluruh fitur dari data. Perbedaan data uji 5.000 (10%) data dengan 10.000 (20%) data tidak berpengaruh signifikan karena data latih tetap memiliki data yang sangat banyak. Hasil performansi dengan data uji 10% mendapatkan akurasi 66,64%, *Precision* 67,13%, dan *recall* 68,44%.

Saran yang dapat dipertimbangkan untuk penelitian selanjutnya adalah mempersiapkan sumber daya yang cukup untuk menjalankan klasifikasi lebih cepat dan efisien. Hal ini disarankan agar dapat melakukan berbagai percobaan tanpa terhambat waktu atau perangkat.

Daftar Pustaka

- [1] Fatimah Kartini Bohang, “Berapa Jumlah Pengguna Internet Indonesia?,” *Kompas.com*, p. 16453177, 2018.
- [2] “Ini e-Commerce Indonesia Paling Diminati pada Triwulan IV 2018,” 2018.
- [3] R. M. Huda, “Indonesia Pengguna Twitter Terbesar Ketiga Dunia,” *Setara.net*, p. 1, 2017.
- [4] I. Sunni and D. H. Widyantoro, “Analisis Sentimen dan Ekstraksi Topik Penentu Sentimen pada Opini Terhadap Tokoh Publik,” *Tugas Akhir*, vol. 1, no. 2, pp. 200–206, 2012.
- [5] S. A. Pattekari and A. Parveen, “Prediction system for heart disease using Naive Bayes,” *Int. J. Adv. Comput. Math. Sci.*, vol. 3, no. 3, pp. 2230–9624, 2012.
- [6] A. R. Chrismanto and Y. Lukito, “Identifikasi Komentar Spam Pada Instagram,” *Lontar Komput. J. Ilm. Teknol. Inf.*, no. December, p. 219, 2018.
- [7] S. Vijayarani, J. Ilamathi, and Nithya, “Preprocessing Techniques for Text Mining - An Overview,” *Int. J. Comput. Sci. Commun. Networks*, vol. 5, no. 1, pp. 7–16, 2018.
- [8] M. Apriandito, A. Saputra, and A. Alamsyah, “Analisa obrolan pelanggan menggunakan metode text mining untuk manajemen hubungan pelanggan (studi kasus: paperlust.co) analysis of customer chat using text mining for customer relationship management (case study: paperlust.co),” pp. 1–5.
- [9] R. Feldman and J. Sanger, *The Text Mining Handbook*. Cambridge: Cambridge University Press, 2006.
- [10] M. K. Neighbor, G. Rizka, E. Budi, S. S. Si, D. P. S. S, and M. Pd, “Klasifikasi Sentimen Terhadap Gubernur DKI Jakarta Menggunakan.”
- [11] K. P. dan Kebudayaan, “No Title,” *Kamus Besar Bahasa Indonesia*. .
- [12] L. B., “Sentiment Analysis and Opinion Mining.” Morgan & Claypool, 2012.
- [13] R. K. Wibowo and K. Hastuti, “Penerapan Algoritma Winnowing Untuk Mendeteksi Kemiripan Teks pada Tugas Akhir Manusia,” *Techno.COM*, vol. 15, no. 4, pp. 303–311, 2016.
- [14] T. D. Lcs, M. N. Saadah, R. W. Atmagi, D. S. Rahayu, and A. Z. Arifin, “Sistem Temu Kembali Dokumen Teks dengan Pembobotan,” vol. 11, no. 1, pp. 19–22, 2013.
- [15] B. Herwijayanti, D. E. Ratnawati, and L. Muflikhah, “Klasifikasi Berita Online dengan menggunakan Pembobotan TF-IDF dan Cosine Similarity,” vol. 2, no. 1, pp. 306–312, 2018.
- [16] T. Informatika, U. Malikussaleh, and A. Utara, “PENERAPAN ALGORITMA NAIVE BAYES,” vol. 8, no. 1, pp. 884–898, 2014.
- [17] M. Sokolova and G. Lapalme, “A systematic analysis of performance measures for classification tasks,” *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427–437, 2009.