

Analisis Sentimen terhadap Akuisisi Saham Tokopedia oleh TikTok Menggunakan *Naïve Bayes* berdasarkan Komentar YouTube

Nur Iqbal Darmawan¹, Indriati², Budi Darma Setiawan³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹idqbal@student.ub.ac.id, ²indriati.tif@ub.ac.id, ³s.budidarma@ub.ac.id

Abstrak

Saham memiliki peran penting dalam pertumbuhan ekonomi, terutama ekonomi domestik dengan menerima deviden. Adanya fenomena meningkatnya Penanaman Modal Asing (PMA) mampu meningkatkan nilai pasar saham, namun berdampak pada keuntungan perseorangan domestik ketika porsi kepemilikan saham asing meningkat. Peristiwa PMA oleh TikTok menuai sebuah kontroversi karena mengakuisisi saham 75,01% Tokopedia. Adanya opini yang bersifat proaktif dan kontradiktif terhadap peristiwa tersebut dapat digunakan untuk menilai arah pandangan masyarakat secara garis besar. Penelitian ini bertujuan untuk menganalisis sentimen publik berupa respon positif dan negatif terhadap akuisisi saham Tokopedia oleh TikTok. Platform yang digunakan untuk mengumpulkan data adalah YouTube dengan memuat sebanyak 1000 dokumen komentar. Proses pengumpulan tersebut menggunakan metode *scraping* data. Algoritma yang digunakan dalam penelitian adalah *Naïve Bayes Classifier* (NBC). Tahapan penelitian terdiri dari pengumpulan dan pengolahan data, *text preprocessing*, pembobotan TF-IDF, penerapan NBC, pengujian validasi, dan evaluasi matriks. Hasil penelitian menunjukkan, pengujian validasi dengan *k-fold cross validation* pada perlakuan A atau mempertahankan negasi dan B atau menghilangkan negasi dengan rasio 630:70 (perlakuan 2) menghasilkan *score* terbaik berupa rerata akurasi, yakni 80.514% dan 79.348%. begitu juga dengan pengujian *confusion matrix*, pada perlakuan A atau mempertahankan negasi dan B atau menghilangkan negasi dengan rasio 700:70 (perlakuan 2) menghasilkan akurasi, presisi, *recall*, dan *F1-score* terbaik, yakni pada perlakuan A 80.51%, 82.54%, 77.4%, 79.89% dan perlakuan B 79.35%, 80.7%, 77.14%, 78.88%.

Kata kunci: *confusion matrix, k-fold cross validation, naïve bayes classifier, saham, TF-IDF*

Abstract

Stocks are fundamental to economic growth, especially in domestic economies through dividend receipt. The increase in Foreign Direct Investment (FDI) can raise stock market values, but it can also adversely impact domestic individual profits as the share of foreign stock ownership rises. TikTok's acquisition of a 75.01% stake in Tokopedia has sparked controversy, drawing both proactive and contradictory opinions. These opinions provide valuable insights into the general public sentiment. This study aims to analyze public sentiment into positive and negative responses to TikTok's acquisition of Tokopedia shares. Data was collected from YouTube, encompassing 1,000 comments, using data scraping methods. The algorithm employed for this study is the Naïve Bayes Classifier (NBC). The research process includes data collection and processing, text preprocessing, TF-IDF weighting, NBC implementation, validation testing, and evaluation metrics. The study results indicate that validation testing with k-fold cross-validation on treatments A or maintaining negation and B or eliminating negation with a 630:70 ratio (treatment 2) achieved the highest average accuracy scores of 80.514% and 79.348%. Additionally, the confusion matrix testing for treatments A or maintaining negation and B or eliminating negation with a 700:70 ratio (treatment 2) yielded the best accuracy, precision, recall, and F1-score, specifically for treatment A: 80.51%, 82.54%, 77.4%, 79.89%, and for treatment B: 79.35%, 80.7%, 77.14%, 78.88%.

Keywords: *confusion matrix, k-fold cross validation, naïve bayes classifier, stocks, TF-IDF*

1. PENDAHULUAN

Salah satu sektor ekonomi yang berperan penting dalam memberikan kontribusi positif terhadap pertumbuhan ekonomi di Indonesia adalah pasar modal. Pasar modal memiliki beberapa instrumen yang digunakan untuk berinvestasi, yakni saham, obligasi, reksa dana, dan lain sebagainya. Saham merupakan bentuk kepemilikan kecil aset pada suatu usaha, dimana investor sebagai pemegang saham akan mendapat keuntungan berupa deviden. Saham sendiri berperan penting dalam pertumbuhan ekonomi terutama masyarakat domestik.

Penanaman Modal Asing (PMA) menjadi fenomena yang saat ini sedang meningkat. Peningkatan PMA memberikan dampak positif dan juga dampak negatif bagi masyarakat domestik. Dampak positif dari adanya PMA adalah memberikan peningkatan nilai pasar saham dan juga likuiditas pasar naik. Sedangkan adanya PMA memberikan peningkatan porsi kepemilikan asing yang dikhawatirkan membuat kebijakan tidak menguntungkan domestik dan berpotensi terjadi volatilitas ekstrim.

Fenomena PMA menciptakan sebuah kontroversi yang ramai dibicarakan karena banyaknya isu serta opini masyarakat yang bersifat proaktif dan kontradiktif. Adanya kontroversi ini dapat dimanfaatkan untuk mengetahui arah pandangan masyarakat serta pengambilan keputusan terhadap langkah selanjutnya berdasarkan sentimen bermuatan positif maupun negatif berdasarkan opini masyarakat.

Penelitian berfokus pada klasifikasi sentimen public terhadap respon yang ditimbulkan dari peristiwa akuisisi 75.01% saham Tokopedia oleh TikTok dengan memuat dokumen komentar dari platform YouTube. Adapun pemilihan platform YouTube karena mampu memberi wadah diskusi sekaligus memberikan penjelasan disertai visual, dan memungkinkan pengguna segala rentang usia. Sehingga, data komentar tidak mengandung informasi yang sifatnya *segmented*.

Penelitian dilakukan dengan mengimplementasikan algoritma *Naïve Bayes Classifier* (NBC). NBC merupakan algoritma *machine learning* berbasis probabilitas yang didasari oleh teorema Bayes ciptaan Thomas Bayes dengan tujuan untuk klasifikasi data. NBC juga sering digunakan untuk


mengklasifikasi teks karena memiliki metode sederhana dengan hasil akurasi relatif tinggi dibandingkan dengan algoritma lain seperti SVM (Kristiyanti *et al*, 2018). Selain itu, untuk mengoptimalkan performa ketika pengujian, diterapkan metode pembobotan *Term Frequency – Inverse Document Frequency* (TF-IDF). Hal ini dibuktikan dengan penelitian oleh Sari dan Wibowo (2019), bahwa hasil analisis sentimen menggunakan algoritma *naïve bayes* tanpa pembobotan kata menghasilkan akurasi 96.44%, sedangkan jika diberikan pembobotan kata TF-IDF menghasilkan akurasi 98%.

Tahapan penelitian ini diawali dengan mengumpulkan komentar dengan teknik *scraping* data. Data diolah dengan beberapa teknik dalam *text preprocessing*, diantaranya adalah *case folding*, *tokenization*, *correcting words*, *stopwords removal*, dan *stemming*. Output dari *text preprocessing* ditransformasikan untuk pembobotan kata dengan metode TF-IDF. Selanjutnya, dilakukan pengimplementasian algoritma NBC untuk melatih data dan dilakukan pengujian validasi dengan metode *k-fold cross validation* untuk mengoptimalkan agar data tervalidasi. Lalu, pada pengujian data testing menggunakan *confusion matrix* untuk menghasilkan akurasi, presisi, *recall* dan *F1-score*. Namun, dalam pengujian menggunakan 2 perlakuan, yakni perlakuan A dan perlakuan B untuk mengetahui efek perbedaan penggunaan negasi dan tanpa negasi terhadap hasil akhir pengujian. Pada perlakuan A mempertahankan term berbentuk negasi yang memberikan makna dalam kata seperti 'tidak', dan perlakuan B menghilangkan negasi kata tersebut. Selain itu, pada proses pengujian validasi maupun *confusion matrix* juga digunakan 3 perlakuan berupa perbedaan jumlah data latih dengan rasio yang sama pada data latih, data validasi dan data uji, yakni 80:10:10. Adanya perlakuan tersebut bertujuan untuk mengetahui hasil akhir berupa score akurasi pada validasi dan akurasi, presisi, *recall*, dan *F1-score* pada *confusion matrix* memiliki hasil yang maksimal. Selain itu, untuk mengetahui sebaran frekuensi kata yang sering muncul juga divisualisasikan dengan *library war cloud*, sehingga representasi *terms* yang sering muncul antara sentimen positif dan negatif dapat diketahui. Adanya penelitian ini bertujuan untuk mendapatkan pandangan terhadap adanya suara yang berasal dari masyarakat, baik berupa sentimen positif maupun negatif untuk menimbang arah hingga

kebijakan terkait dengan Penanaman Modal Asing hingga diharapkan kedepan fenomena tersebut tidak menimbulkan kontroversi.

2. METODOLOGI PENELITIAN

Tahapan penelitian diawali dengan pengumpulan data dan diolah dengan melakukan *filtering* terhadap jumlah target dokumen komentar serta melakukan *labelling* dokumen sesuai dengan kebutuhan penelitian, yakni dokumen sentimen positif dan negatif. Setelah itu, dilakukan *text preprocessing* dengan melakukan pembersihan hingga stemming. Lalu, *output* dari stemming dihitung pembobotan kata menggunakan TF-IDF. Kemudian, data divalidasi dan diuji dengan mengimplementasikan algoritma naïve bayes classifier. Tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan penelitian

2.1 Pengumpulan Data

Pengumpulan data dilakukan dengan teknik *scraping* yang memuat komentar pada platform Youtube. Teknik *scraping* merupakan salah satu cara untuk mendapatkan dokumen komentar secara otomatis serta menggunakan API Youtube sebagai pembuka aksesnya. Dokumen yang digunakan dalam penelitian berjumlah 1000 data komentar dengan rincian sebanyak 500 data bermuatan sentimen positif, dan 500 data bermuatan sentimen negatif.

2.2 Pelabelan Data

Proses pelabelan dilakukan secara manual sehingga menghasilkan *output* berupa klasifikasi sentimen positif dan sentimen negatif. Proses pelabelan dilakukan dengan bantuan panelis. Panelis pada penelitian ini sebagai individu yang secara khusus ditugaskan untuk melakukan penilaian secara objektif terhadap dokumen komentar yang bermuatan sentimen positif dan negatif, dimana panelis

telah diberi pedoman atau arahan untuk melakukan penilaian secara konsisten. Dokumen yang telah dinilai oleh panelis akan menentukan muatan sentimen pada label tergantung dari dominasi nilai keseluruhan panelis yang dapat dilihat pada Tabel 1.

Tabel 1. Pelabelan data

Dokumen	Pa 1	Pa 2	Pa 3	Label
Cinta Indonesia berarti cinta produk lokal	N	N	P	N
...

Ket: Pa = panelis, P = positif, N = negatif

2.3 Text Preprocessing

Text preprocessing merupakan proses pembersihan kata yang setelah text mining agar menghilangkan kata-kata berulang dan tidak bermakna. Text preprocessing penting ditambahkan untuk mengoptimalkan performa dalam pengujian, serta meminimalisir timbulnya noisy data, miss data, hingga redundansi (Ningtyas *et al*, 2018).

Text preprocessing menerapkan beberapa teknik diantaranya adany case folding, tokenization, correcting words, stopwords removal, dan stemming. Case folding merupakan teknik mengubah semua karakter huruf dalam dokumen teks menjadi huruf kecil. Tujuannya adalah untuk membantu teks lebih mudah diolah dan diproses secara konsisten (Gunawan *et al*, 2018). Output case folding dipecah menjadi satuan terms membentuk token dari kesatuan dokumen untuk memisahkan teks agar lebih mudah dalam membantu sebaran sentimen yang memiliki makna, selain itu juga menghilangkan simbol dalam dokumen (Sarkar, 2016). Correcting words merupakan teknik untuk mengkonversi kata tidak baku menjadi kata baku sesuai KBBI, seperti kata singkat ‘akhirnyaaa’ menjadi ‘akhirnya’, dan diimplementasikan ke seluruh korpus sentimen positif dan negatif (Sarkar, 2016). Selanjutnya, melakukan stopwords removal dengan menghapus konjungsi atau kata hubung yang muncul tiap dokumen yang tidak memiliki makna, seperti ‘dan’, namun terdapat kata yang perlu dipertimbangkan seperti kata negasi ‘tidak’ agar tidak merubah makna sentimen (Sarkar, 2016). Tahap terakhir adalah melakukan stemming ntuk mereduksi kata yang mengandung imbuhan menjadi kata dasar untuk mencegah adanya variasi kata yang membuat analisis teks tidak konsisten, seperti ‘menyuntik’ menjadi ‘suntik’ (Gunawan *et al*,

2018).

2.4 Pembobotan Term Frequency-Inverse Document Frequency (TF-IDF)

Metode TF-IDF merupakan jenis pembobotan dengan menggabungkan TF dan IDF yang mampu memberikan bobot kata berdasarkan frekuensi kemunculan kata dalam suatu dokumen, dengan mempertimbangkan keunikan kata dalam keseluruhan sumber data dan inverse jumlah dokumen yang terdapat target kata. frekuensi kata yang muncul merupakan indikator signifikan dalam dokumen. Perhitungan bobot kata dilakukan dengan menghitung nilai Term Frequency (TF) melalui perhitungan jumlah kemunculan kata tiap dokumen. Selanjutnya dihitung IDF dengan memberikan bobot tinggi ketika kata jarang muncul (Manning *et al*, 2008). Lalu, untuk mengetahui nilai bobot TF-IDF dilakukan dengan mengalikan dua matrix, yakni TF dan IDF dengan persamaan 1.

$$W_{d,t} = tf_{d,t} \times \log\left(\frac{N}{df_t}\right) \quad (1)$$

Keterangan:

$W_{d,t}$ = Bobot dari *term-t* dalam dokumen-d
 $tf_{d,t}$ = Frekuensi kata dari *term-t* dalam dokumen-d
 N = Jumlah total dokumen
 df_t = Jumlah dokumen yang mengandung *term-t*

2.5 Naïve Bayes Classifier

Metode bayesian diterapkan dengan menggabungkan informasi eksternal ke analisis data, mulai dari sebelum distribusi (prior) hingga distribusi posterior (Kantardzic, 2020). Naive Bayes Classifier (NBC) sendiri merupakan algoritma untuk memprediksi berbasis probabilitas sederhana dengan mempertimbangkan pandangan independensi yang kuat. NBC menghitung probabilitas melalui ketentuan bahwa kelas Keputusan adalah benar karena adanya vector informasi objek yang mengasumsikan bahwa atribut objek independent (Khadafi *et al*, 2022).

Langkah awal adalah menghitung probabilitas prior dengan menghitung tiap kelas berdasarkan dari jumlah dokumen dengan persamaan 2. Selanjutnya, dihitung probabilitas likelihood atau probabilitas yang menggambarkan seberapa sering muncul dalam kelas positif maupun negatif dengan persamaan 3. Lalu, probabilitas prior dan likelihood dikalikan sehingga membentuk probabilitas

posterior dengan persamaan 4. Langkah terakhir adalah menghitung dengan Naïve Bayes dengan persamaan 5.

$$P(W_j) = \left(\frac{N_{wj}}{N_c}\right) \quad (2)$$

Keterangan:

$P(W_j)$ = Probabilitas prior
 N_{wj} = Jumlah dokumen kelas *wj*
 N_c = Jumlah total dokumen data latih

$$P(X_i|W_j) = \left(\frac{N_{xi,wj}+1}{N_{wj}+|v|}\right) \quad (3)$$

Keterangan:

$P(X_i|W_j)$ = Probabilitas likelihood
 $N_{xi,wj}$ = Frekuensi kemunculan dalam kelas *wj*
 N_{wj} = Jumlah term yang muncul pada kelas *wj*
 $|v|$ = Jumlah total term data latih

$$P(X_j|W_i) = P(W_j) \times P(X_1|W_j) \times \dots \times P(X_n|W_j) \quad (4)$$

Keterangan:

$P(X_i|W_j)$ = Probabilitas likelihood
 $P(W_j)$ = Probabilitas prior
 $P(X_j|W_i)$ = Probabilitas posterior

$$P(W|X) = \frac{P(X|W).P(W)}{P(X)} \quad (5)$$

Keterangan:

X = Vector fitur atau input untuk prediksi W
 W = Label atau kelas yang diprediksi
 $P(W|X)$ = Probabilitas kelas berdasarkan vector input yang diketahui (posterior)
 $P(X|W)$ = Probabilitas tiap input berdasarkan kondisi pada kelas
 $P(W)$ = Probabilitas kelas yang dicari (prior) dari keseluruhan data
 $P(X)$ = Probabilitas observasi vector input atau input dari keseluruhan data

2.6 K-Fold Cross Validation

K-Fold cross validation merupakan salah satu jenis cross validation dengan memecah data menjadi *k* subsets bagian dengan ukuran yang sama. Tujuannya untuk meminimalisir masalah bias yang terdapat pada data (Mardiana *et al*, 2022). Proses k-fold cross validation pada penelitian ini dilakukan dengan membagi 10 subset (*k*=10), penerapannya pada data latih 500 dengan rasio data latih dan validasi 0.1 atau 450:50, maka *k*-1 berisikan 25 dokumen sentimen positif dan negatif hingga *k*-9 sebagai data latih, dan *k*-10 berisikan 25 dokumen sentimen positif dan negatif sebagai data validasi. proses tersebut berulang hingga tiap subset menjadi data validasi dan 9 kali menjadi data latih. Dari proses pengujian tersebut membentuk sebuah iterasi, dimana tiap iterasi menghasilkan sebuah output berupa score

akurasi.

2.7 Confusion Matrix

Confusion matrix adalah sebuah metode evaluasi matrix yang mampu menggambarkan performa atau kinerja dari klasifikasi (Wang *et al*, 2022). Selain itu, confusion matrix juga berfungsi untuk memvisualisasikan hasil akurasi, presisi, recall, dan F1-score berdasarkan tabel confusion matrix yang berisikan elemen matrix berupa True Positif (TP) atau jumlah elemen aktual diklasifikasikan dengan prediksi benar, True Negatif (TN) atau jumlah elemen aktual salah diklasifikasikan dengan prediksi salah, False Positif (FP) atau jumlah elemen aktual salah diklasifikasikan dengan prediksi benar, dan False Negatif (FN) atau jumlah elemen aktual benar diklasifikasikan dengan prediksi salah (Luque *et al*, 2019).

Indikator keberhasilan classifier pada penelitian diukur dengan akurasi, presisi, recall, dan F1-score sebagai output dari confusion matrix. Perhitungan dari indikator tersebut dapat dilihat pada persamaan 6, persamaan 7, persamaan 8, dan persamaan 9.

$$Accuracy = \frac{TP+TN}{TP+FN+TN+FP} \quad (6)$$

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

$$F - measure = 2 \times \frac{Presisi \times Recall}{Presisi+Recall} \quad (9)$$

3. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan 3 output pengujian, diantaranya adalah pengujian pengaruh variasi jumlah data latih terhadap hasil confusion matrix dengan penambahan perlakuan A atau mempertahankan negasi dan perlakuan B atau menghilangkan negasi, pengujian validasi dengan metode k-fold cross validation dengan menambahkan perlakuan A dan perlakuan B, dan visualisasi sebaran terms tiap sentimen. Data input yang digunakan dalam penelitian adalah data hasil text preprocessing yang telah dilakukan pembobotan TF-IDF.

3.1 Pengujian Pengaruh Jumlah Data Latih

Pengujian pengaruh jumlah data latih dilakukan dengan memberikan variasi rasio data latih dan data uji, yakni 500:50, 700:70, dan 900:100. Data yang digunakan adalah data hasil preprocessing yang telah dilakukan

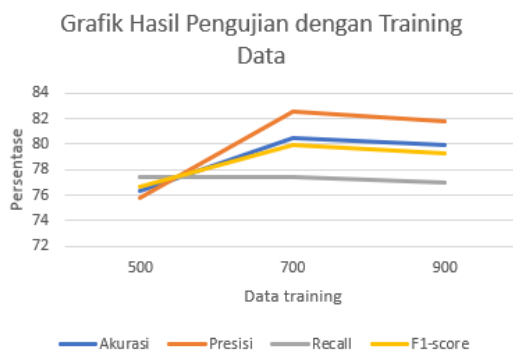
pembobotan TF-IDF. Selain itu, proses pengujian juga dilakukan dengan memberikan 2 perlakuan, yakni perlakuan A dengan mempertahankan term berbentuk negasi yang mampu memberikan makna dalam kata jika dihilangkan seperti ‘tidak’ dan perlakuan B dengan menghilangkan term berbentuk negasi ketika proses stopwords removal. Hasil pengujian dapat dilihat pada Tabel 2.

Tabel 2. Hasil pengujian pengaruh rasio jumlah data latih terhadap confusion matrix

Jumlah training data	Perlakuan A				Perlakuan B			
	Akurasi (%)	Presisi (%)	Recall (%)	F1-score (%)	Akurasi (%)	Presisi (%)	Recall (%)	F1-score (%)
500	76.36	75.8	77.45	76.62	77.09	77.09	77.09	77.09
700	80.51	82.54	77.4	79.89	79.35	80.7	77.14	78.88
900	79.9	81.74	77	79.3	79.3	80.2	77.8	78.98


Ket: Perlakuan A = mempertahankan negasi, Perlakuan B = menghilangkan negasi

Berdasarkan hasil pengujian tersebut, pada perlakuan A dengan rasio data 700:70 mendapatkan hasil confusion matrik tertinggi, berupa akurasi, presisi, recall, dan F1-score dengan nilai sebesar 80.51%, 82.54%, 77.4%, dan 79.89% dibanding dengan variasi rasio 500:50 dengan hasil 76.36%, 75.8%, 77.45%, dan 76.62% serta rasio 900:100 dengan hasil 79.9%, 81.74%, 77%, dan 79.3%, dapat dilihat pada Gambar 2.



Gambar 2. Grafik hasil pengujian variasi rasio data latih pada perlakuan A

Begitu juga dengan perlakuan B pada rasio 700:70 mendapatkan hasil confusion matrix tertinggi, berupa akurasi, presisi, recall, dan F1-score dengan nilai sebesar 79.35%, 80.7%, 77.14%, dan 78.88% dibanding dengan variasi rasio 500:50 dengan hasil 77.09%, 77.09%, 77.09%, dan 77.09% serta rasio 900:100 dengan hasil 79.3%, 80.2%, 77.8%, dan 78.98%, dapat dilihat pada Gambar 3.



Gambar 3. Grafik hasil pengujian variasi rasio data latih pada perlakuan B

Dari hasil tersebut membuktikan bahwa dengan semakin banyak variasi rasio pada data latih tidak membuat hasil akurasi semakin membaik, sehingga dibutuhkan rasio data latih dan uji secara seimbang, selain itu hasil juga dapat ditingkatkan dengan meningkatkan kualitas data serta memperbanyak dokumen data. Selain itu, pada perlakuan dengan mempertahankan term negasi maupun menghilangkan term negasi ‘tidak’ tidak memberikan dampak secara signifikan terhadap hasil.

3.2 Pengujian K-Fold Cross Validation

Pengujian k-fold cross validation dilakukan dengan menerapkan nilai k sebanyak 10, sehingga menghasilkan score akurasi pada 10 subset. Input data yang digunakan adalah data hasil preprocessing yang telah diberikan pembobotan TF-IDF. Proses pengujian juga menerapkan 2 perlakuan, yakni perlakuan A dengan mempertahankan term negasi, dan perlakuan B dengan menghilangkan term negasi ‘tidak’. Hasil pengujian k-fold dapat dilihat pada Tabel 3.

Tabel 3. Hasil pengujian k-fold cross validation

Iterasi pengujian ke-n	Perlakuan A	Perlakuan B
	Score (%)	Score (%)
1	67.53	72.72
2	71.42	67.53
3	75.32	72.72
4	81.81	83.12
5	85.71	83.12
6	84.41	81.81
7	85.71	79.22
8	79.22	79.22
9	83.11	84.41
10	90.9	89.61
Rata-rata	80.514	79.348
Ket: Perlakuan A = mempertahankan negasi, Perlakuan B = menghilangkan negasi		

Berdasarkan dari hasil tersebut, perlakuan A dan juga perlakuan B tidak memiliki dampak yang tidak signifikan, dapat dilihat pada hasil score akurasi pada perlakuan A sebesar 80.514% dan juga perlakuan B sebesar 79.348%. hasil tersebut menunjukkan keadaan yang sama dengan pengujian variasi data latih terhadap hasil confusion matrix, artinya adanya kedua perlakuan tersebut tidak menunjukkan pengaruh terhadap hasil. Hal ini terjadi karena terdapat faktor yang mempengaruhi, diantaranya adalah term ‘tidak’ pada penelitian ini tidak memberikan perubahan makna yang membuat adanya perubahan sentimen.

3.3 Persebaran Kata Setiap Kelas Sentimen

Sebaran terms pada tiap sentimen juga diterapkan pada perlakuan A dan perlakuan B. visualisasi sebaran sentimen positif perlakuan A memunculkan terms dengan frekuensi tertinggi, diantaranya Tokopedia, tidak, produk, untung yang dapat dilihat pada Gambar 4. Pada sentimen negatif perlakuan A memunculkan terms dengan frekuensi tertinggi, diantaranya adalah TikTok, pemerintah, negara, China yang dapat dilihat pada Gambar 5. Sedangkan visualisasi sebaran sentimen positif pada perlakuan B memunculkan terms dengan frekuensi tertinggi, diantaranya adalah Tokopedia, jual, shopee, dan Indonesia yang dapat dilihat pada Gambar 6. Pada sentimen negatif perlakuan B memunculkan terms dengan frekuensi tertinggi, diantaranya adalah Tiktok, perintah, negara, dan lokal yang dapat dilihat pada Gambar 7.



Gambar 4. Sebaran terms sentimen positif perlakuan A



Gambar 5. Sebaran terms sentimen negatif perlakuan A



Gambar 6. Sebaran terms sentimen positif perlakuan B



Gambar 7. Sebaran terms sentimen negatif perlakuan B

Berdasarkan dari hasil diatas, frekuensi kemunculan dengan size font terbesar merupakan terms dengan frekuensi kemunculan paling banyak. Terdapat perbedaan sebaran antara frekuensi term ‘jual’ yang muncul pada sentimen negatif perlakuan A atau mempertahankan negasi dan B atau menghilangkan negasi, ditunjukkan adanya perbedaan size font yang berubah secara signifikan. Hal tersebut terjadi karena adanya pengaruh frekuensi dari kemunculan terms yang bergandengan dengan negasi ‘tidak’ dan juga adanya pengaruh perubahan pola kalimat ketika adanya penghilangan negasi. Adanya pengaruh size font terhadap banyaknya frekuensi kemunculan term juga didukung oleh penelitian Purbayanto dan Suharsono (2023), bahwa semakin banyak jumlah term yang muncul di word cloud, maka semakin besar size font yang

divisualisasikan.

4. KESIMPULAN

Berdasarkan dari penelitian yang telah dilakukan, didapatkan beberapa hasil yang dapat ditarik Kesimpulan, yakni:

- a. Hasil pengujian k-fold cross validation dengan perlakuan rasio kedua, data latih dan validasi pada 630:70 menghasilkan output dari akurasi terbaik pada kedua perlakuan, yakni pada perlakuan A atau mempertahankan negasi mendapatkan rerata akurasi 80.514% dan perlakuan B atau menghilangkan negasi mendapat rerata akurasi 79.348%. Selain itu, pengujian rasio data latih terhadap hasil confusion matrix juga mendapatkan hasil tertinggi pada perlakuan rasio kedua 700:70. Berdasarkan hasil penelitian, disimpulkan bahwa dengan semakin banyak data latih tidak membuat akurasi semakin baik, sehingga dibutuhkan rasio antara data latih dan data uji yang seimbang dan dioptimalkan dengan kualitas data. Selain itu, adanya perlakuan menghilangkan negasi dan menetapkan negasi tidak memiliki pengaruh yang signifikan, hal ini dapat terjadi karena negasi pada term tidak begitu mempengaruhi makna tiap dokumen pada penelitian ini.
- b. Hasil visualisasi persebaran sentimen positif dan negatif pada perlakuan A atau mempertahankan negasi dan perlakuan B atau menghilangkan negasi tidak memiliki pola atau sebaran yang berbeda secara signifikan, hanya pada beberapa term mengindikasikan terdapat penurunan frekuensi kemunculan term tertentu seperti ‘jual’. Hal tersebut terjadi karena beberapa faktor, diantaranya adalah adanya pengaruh dari penghilangan kata negasi dari step *stopwords removal* yang terdapat pada dokumen, sehingga menimbulkan adanya penurunan dominasi term dari konteks tiap sentimen.

5. DAFTAR PUSTAKA

Gunawan, B., Pratiwi, H., Pratama, E. 2018. Sistem Analisis Sentimen pada Ulasan Produk Menggunakan Metode Naive Bayes. *Jurnal Edukasi dan Penelitian Informatika* 4(2): 113-119

Kantardzic, Mehmed. 2020. *Data Mining:*

- Concepts, Models, Methods, and Algorithms*. IEEE Press: New Jersey
- Khadafi, M., Kartika, K., Febrinita, F. 2022. Penerapan Metode Naïve Bayes Classifier dan Lexicon Based untuk Analisis Sentimen Cyberbullying pada BPJS. *Jurnal Mahasiswa Teknik Informatika* 6(2): 725-735
- Kristiyanti, S., Umam, A., Wayhudi, M., Amin, R., Marlinda, L. 2018. Comparison of SVM & Naïve Bayes Algorithm for Sentiment Analysis Toward West Java Governor Candidate Period 2018-2023 Based on Public Opinion on Twitter. *The 6th International Conference on Cyber and IT Service Management*: 7-9
- Luque, A., Carrasco, A., Martin, A., Heras, A. 2019. The Impact of Class Imbalance in Classification performance Metrics Based on the binary Confusion Matrix. *Pattern Recognition Journal* 91: 216-231
- Manning, C., Raghavan, P., dan Schütze, H. 2008. *Introduction to Information Retrieval*. Cambridge University Press: New York
- Mardiana, L., Kusnandar, D., Setyahadewi, N. 2022. Analisis Diskriminan dengan K-Fold Cross Validation untuk Klasifikasi Kualitas Air di Kota Pontianak. *BIMASTER* 11(1): 97-102
- Ningtyas, A., Solichin, A., dan Pradana, R. 2023. Analisis Sentimen Komentar YouTube Tentang Prediksi Resesi Ekonomi Tahun 2023 Menggunakan Algoritma Naïve Bayes. *Jurnal Bit* 20(1): 9-16
- Purbayanto, B., dan Suharsono, T. 2023. Analisis Sentimen Penggunaan X Terhadap Chatgpt dengan Algoritma Naïve Bayes. *Jurnal Telematika* 18(2): 63-71
- Sari, F., dan Wibowo, A. 2019. Analisis Sentimen Pelanggan Toko Online JD.ID Menggunakan Metode Naïve Bayes Classifier Berbasis Konversi Ikon Emosi. *Jurnal SIMETRIS* 10(2): 681-686
- Sarkar, Dipanjan. 2016. *Text Analytics with Python: A Practical Real-World Approach to Gaining Actionable Insights from Your Data*. Apress: India
- Wang, Yadong., Jia, Yanlin., Tian, Yuhang., Xiao, Jin. 2022. Deep Reinforcement Learning with the Confusion-matrix-based Dynamic Reward Function for Customer Credit Scoring. *Expert Systems with Application* 200: 1-17