

# Analisis Sentimen Data Twitter Menggunakan Teknik Pembobotan TF-IDF dan Algoritma Naïve Bayes

Siti Sholihah

Magister Teknik Informatika, Universitas Pamulang

*e-mail*: liasholih24@gmail.com

**Abstrak**—Pandemi Covid-19 hampir masuk tahun kedua di Indonesia, pemerintah terus berupaya menekan laju peningkatan penularan Covid-19 melalui berbagai media. Sosialisasi dan informasi melalui media sosial yang merupakan wadah paling cepat untuk tersampaikan kepada masyarakat. Berbagai istilah digunakan seperti adaptasi kebiasaan baru, *social distancing*, PSBB sampai PPKM sehingga memicu masyarakat untuk beropini di media sosial. Penelitian ini menganalisis sentimen masyarakat terkait opini peningkatan Covid-19 dari Twitter. Klasifikasi *tweet* menggunakan *Naive Bayes* dengan penambahan seleksi fitur. Penggunaan *confusion matrix* untuk mengetahui *performance* algoritma *Naive Bayes*. Berdasarkan pengujian, penelitian ini menghasilkan 76% dengan *accuracy* positif sebesar 72,727%, *accuracy* negatif sebesar 75% dan *accuracy* netral sebesar 78,947%. Sehingga disimpulkan penggunaan model klasifikasi *Naive Bayes* dengan fitur seleksi dapat meningkatkan akurasi.

**Kata Kunci**—Analisis Sentimen, Seleksi Fitur, *Twitter Crawling*, *Naive Bayes*, Klasifikasi, Emosi.

## I. PENDAHULUAN

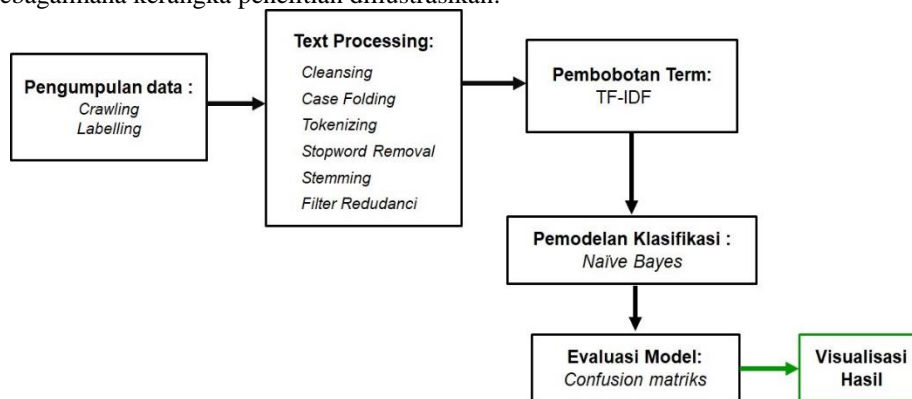
Pandemi yang disebabkan virus Covid-19 melanda berbagai Negara tak terkecuali Indonesia, sehingga penerapan berbagai kebijakan untuk mengurangi menyebarnya covid-19. Berbagai istilah muncul seperti *Social Distancing*, adaptasi kebiasaan baru atau *new normal*, termasuk PSBB (*Pembatasan Sosial Berskala Besar*) atau saat ini dikenal dengan PPKM. Namun ada beberapa sector yang tidak bias lepas dari rutinitas sehingga harus memulai beradaptasi dengan pemakaian masker, penggunaan *handsanitizer* atau penyemprotan berkala dengan disinfektan. Hal tersebut membuat banyak opini atau sentiment dari berbagai kalangan yang dituangkan diberbagai media social. Penelitian ini mengangkat objek tentang evaluasi algoritma yang digunakan untuk mengklasifikasikan sentiment masyarakat terhadap adaptasi kebiasaan baru atau *new normal* yang ramai diperbincangkan di media sosial.

Analisis sentiment dapat dimaknai langkah pemberian kelas dalam tingkatan emosi yang dapat tertuang pada cuitan di media sosial (Mubaroka, Adiwijayab, & Aldhi, 2017). Beragam opini engguna media social terkait kasus Covid-19. Sosial media menjadi wadah untuk melampiaskan perasaan di kalangan masyarakat, salah satunya pengguna media social. Sebuah sarana didunia masya yaitu cuitan pada Twitter men-trigger beredarnya informasi mengenai hal apapun termasuk pandemi yang disebabkan covid-19. Terkadang cuitan yang menjadi viral dapat menyebabkan pengungkapan makna yang kompleks (Hermanto & Noviriandini, 2021). Implementasi analisis sentiment berupa cuitan dalam twitter dapat menimbulkan beragam persepsi atau opini terhadap topik yang di tulis (Yuliyanti, Djatna, & Sukoco, 2017). Cuitan (*tweet*) yang berasal dari twitter tidak memiliki interferensi dan berisi banyak kesalahan (*noise*), sehingga diperlukan aplikasi atau sistem untuk memperoleh makna atau nilai yang terkandung dalam sebuah kalimat, penelitian tentang analisis dokumen tekstual paling tinggi akurasi menggunakan metode *Naive Bayes* dimana *performance* algoritma bergantung dari jumlah data. Klasifikasi yang baik dimana hasil akurasi menunjukkan tingkat yang semakin tinggi (Ratino, Hafidz, Anggraeni, & Gata, 2020).

*Naive Bayes Classifier* (NBC) adalah yang paling sering digunakan karena algoritma ini sangat cocok untuk short dan text. Algoritma *Naive Bayes Classifier* (NBC) menghitung probabilitas eksplisit untuk hipotesis dan kuat untuk kebisingan (*noise*) dalam input data. Secara statistik pengklasifikasi Bayes meminimalkan kemungkinan kesalahan klasifikasi (Larose, 2014). *Naive Bayes classifier* menggunakan *prior probability* (yaitu nilai probabilitas yang diyakini benar sebelum melakukan eksperimen) dari setiap label yang merupakan frekuensi masing-masing label pada training set dan kontribusi dari masing- masing fitur (Ratnawati, 2018). Performa algoritma klasifikasi dapat ditingkatkan dengan proses *feature selection* dengan tujuan mereduksi atribut- atribut yang tidak seesuai dengan kategorinya sehingga akurasi menjadi lebih baik. *Feature Selection* yang digunakan dalam penelitian ini adalah *Term Frequency-Inverse Document Frequency* (TF-IDF), algoritma ini diimplementasikan untuk menentukan seberapa penting sebuah kata untuk dokumen relatif terhadap corpus. Penelitian ini akan menguraikan evaluasi pemodelan klasifikasi sentimen pengguna twitter terhadap adaptasi kebiasaan baru atau lebih dikenal dengan istilah *new normal* dengan algoritma *Naive Bayes* sehingga diperoleh seberapa akurat algoritma *Naive Bayes* yang digunakan sebagai teknik pengklasifikasian pada data yang berasal dari twitter dengan jumlah yang besar. Pengujian untuk mengevaluasi model klasifikasi menggunakan *confusion matriks* dengan parameter yang dihitung yaitu *accuration*, *precision*, *recall* untuk setiap kelas yang dihasilkan oleh model.

## II. METODE PENELITIAN

Tahapan penelitian meliputi pengumpulan data cuitan (crawling) dan labelling, text processing, pembobotan term, pemodelan dan evaluasi model sebagaimana kerangka penelitian diilustrasikan.



Gambar 1.  
Kerangka Pemikiran

Proses mengambil data dari media sosial Twitter untuk pengumpulan dataset lebih dikenal dengan nama crawling. Pengumpulan data penelitian ini mengangkat objek tweet dari Twitter yang mengandung pembahasan tentang “COVID-19”, “PSBB”, “Adaptasi Kebiasaan Baru”, “New Normal” yang dicrawling sebanyak 10.000 tweet. Penelitian ini menggunakan API Standard V1.1 dengan tingkat akses hingga 400 kata kunci, dengan batasan 15 permintaan per detik untuk setiap pengguna, semua jendela permintaan dibatasi per 15 menit. Penelitian ini mengambil data set berdasarkan tweet dari region Indonesia dan berbahasa Indonesia yang kemudian diberi label positif, negatif dan netral.

Dataset tweet dari hasil crawling dipecah pada data training dan data testing. Kemudian diberi label secara manual terlebih dahulu dengan memberikan label positif, negatif atau netral pada setiap tweet. Selain mengumpulkan data training secara masal, dapat pula dilakukan proses input data training berupa single tweet pada form training data dalam sistem. Data training disimpan dalam dataset json agar dapat dipanggil kembali (recall) oleh system. Data testing dari hasil crawling disimpan untuk diolah ke dalam sistem sehingga output secara otomatis tampil berupa kelas sentiment.

Tahapan text processing meliputi case folding, tokenizing, stopwords removal, stemming. Pembobotan term, penelitian ini menggunakan TF-IDF, pemodelan dilakukan dengan mengimplementasikan Naïve Bayes Classifier sedangkan evaluasi model menggunakan confusion matriks dan divisualisasikan dengan grafik. Tahapan text processing dimulai dengan cleansing untuk mengurangi noise dilakukan proses pembersihan. Kata yang dihilangkan dapat berupa karakter dari script HTML, kata kunci, emoticon, hashtag (#), username dan URL. Noise dapat mengganggu proses penilaian analisa sentiment. Selanjutnya dilakukan case folding, yang merupakan pengubahan semua huruf yang terdapat dalam dokumen menjadi huruf kecil atau lowercase dan menghilangkan karakter selain huruf. Selanjutnya dilakukan proses tokenizing, dimana pada proses ini dilakukan pemotongan atau pemisahan setiap kata yang terdapat dalam kalimat berdasarkan pemisah kata seperti spasi, koma (,) dan titik (.) (Yuliyanti & Rizky, 2020). Bagian yang hanya memiliki satu karakter non alfabet dan angka dibuang, sehingga menghasilkan kata-kata dalam array. Kemudian tahapan stopwords removal dilakukan, dimana semua kosakata yang tidak memiliki makna dihilangkan dari dalam dokumen sehingga menyisakan kata yang bermakna saja di dalam dokumen. Sebelum proses stopwords removal harus dibuat daftar stopwords list. Yang termasuk ke dalam daftar ini misalnya “oleh”, “pada”, “di”, “sebuah”, “karena” dan lain-lain. Jika ada kata yang termasuk dalam stopwords list maka dilakukan penghapusan dari deskripsi dan dianggap sebagai kata-kata yang mencirikan isi dari suatu dokumen atau kata kunci. Pada penelitian ini menggunakan kamus stopwords yang disediakan oleh library dari Node JS yaitu stopwords-iso/stopwords-id yang mendukung kamus stopwords berbahasa Indonesia.

Selanjutnya, penelitian ini melakukan proses stemming dengan menggunakan kamus kata dasar dari kata dasar untuk membandingkan dasar dan terkait. Data kata kunci diambil dari kamus online Bahasa Indonesia berjumlah 29.932. Stemming adalah proses mengelompokkan berbagai variasi morfologi suatu kata atau kalimat menjadi satu bentuk dasar (Siswandi, Permana, & Emarilis, 2021). Tahap terakhir yaitu filter redundansi untuk meningkatkan penghitungan frekuensi kata selama proses pembobotan, diperlukan penyaringan redundansi untuk mencari kata yang sama. Dalam arti tertentu, kata-kata dalam dokumen dibandingkan dengan kamus dalam database. Jika kata ini ditemukan, kata tersebut merupakan sinonim (Sukmana & Salsabilla, 2018).

Setelah proses text preprocessing, penelitian ini melakukan ekstraksi fitur untuk meminimalisir noise, sehingga akurasi tinggi. Data yang sudah siap diproses itu kemudian dihitung seberapa banyak kemunculan atau frekuensi kemunculan setiap katanya di dalam dokumen, yang dikenal dengan tahap pembobotan term menggunakan metode TF-IDF. Pembobotan term adalah pembobot untuk setiap kata dengan penggunaan TFIDF (Term Frequency – Inversed Document Frequency) (Gunawan, Pratiwi, & Pratama, 2018). Proses TF-IDF dengan menghitung bobot dengan mengintegrasikan term frequency (tf) dan inverse document frequency (idf). TF merupakan cara menghitung bobot tiap term dalam tweet. Jumlah dokumen yang mengandung suatu term tertentu dinamakan DF. Dokumen Frekuensi merupakan metode feature selection yang paling sederhana dengan waktu komputasi yang rendah. Inverse Document Frequency (IDF) TF fokus pada term di cuitan, maka IDF fokus dengan munculnya term di keseluruhan lokasi tweet dan term yang jarang muncul pada keseluruhan koleksi term dinilai berharga. Term Frequency Inverse Document.

Frequency mencantumkan bobot setelah menghasilkan term dalam tweet kemudian menghitungnya dengan mengintegrasikan tf dengan idf. Sebagaimana ditunjukkan pada Persamaan 1.

$$TF - IDF = TF * IDF = TF * \log( n/df) \quad (1)$$

TF : Frekuensi Teks  
 df : Frekuensi Dokumen  
 n : Jumlah Dokumen

Tahapan pembangunan model mengimplemntasikan algoritma Naïve Bayes, dimana tahap ini untuk mengetahui pola sentiment pada setiap tweet berdasarkan kelasnya sebagaimana diuraikan pada alur algoritma Naïve Bayes:

- 1) Pembacaan data latih
- 2) Penjumlahan dan probabilitas, dicari nilai *mean* untuk data numeric dan standar deviasi setiap parameter seperti ditunjukkan pada Persamaan 2.

$$\mu = \frac{\sum_{i=1}^n x_i}{n} \quad (2)$$

$\mu$  : rata-rata hitung (mean)  
 $x_i$  : nilai sampel ke-i n : jumlah sampel

- 3) Menemukan nilai dalam tabel mean, deviasi standar, dan probabilitas
- 4) Hasil klasifikasi

Nilai probabilitas dibandingkan dengan suatu sampel di kelasnya dan yang lain untuk menemukan kelas. Kemudian dilakukan penentuan kelas yang sesuai sampel dengan perbandingan nilai posterior tiap kelas dan memilih kelas dengan nilai Posterior tertinggi. Probabilitas prior dan teorema bayes sebagaimana ditunjukkan pada Persamaan 3 dan Persamaan 4. Pengklasifikasian dengan Naïve Bayes dibagi kedalam 2 proses, yaitu fase learning dan fase testing. Fase learning untuk menghasilkan model yang dijadikan refresnsi dalam mengklasifikasikan sentiment pada fase testing (Rahayu & Zharfan, 2015).

$$P(H) = \frac{N_j}{N} \quad (3)$$

P(H) : Peluang prior  
 NJ : Jumlah data pada suatu kelas N: Jumlah total data

$$P(H|X) = P \frac{(H/K).P(H)}{P(K)} \quad (4)$$

X : Data yang kelasnya belum diketahui  
 H : Hipotesis data merupakan suatu class spesifik  
 P(H|X) : Probabilitas Hipotesis H berdasarkan kondisi X (posterior probabilitas)  
 P(H) : Probabilitas hipotesis H (prior probabilitas)  
 P(X|H) : probabilitas X berdasarkan kondisi pada hipotesis  
 H P (X) : Probabilitas X

Penelitian ini melakukan evaluasi atau menguji validasi model bertujuan untuk menilai kinerja algoritma dengan menampilkan akurasi, precision dan recall menggunakan confusion matrix. Penggunaan Confusion Matrix untuk menghitung tingkat akurasi, dengan menghitung jumlah prediksi benar dan salah berdasarkan perbandingan data real atau prediksi target (Arini, Wardhani, & Octaviano, 2020). Pengujian data yang kemudian diprediksi kelas dibandingkan dengan kelas sesungguhnya dari data uji yang disimpan terlebih dahulu. Tahpan selanjutnya dapat direpresentasikan hasil nilai *accuration*, *precision*, *recall*, dan *f1-score* (Imron, 2018). Terdapat beberapa parameter pengujian berdasarkan perbandingan nilai prediksi dan nilai actual yaitu:

1. *Accuracy* dapat diartikan pengujian dari kedekatan nilai prediksi dengan nilai actual dalam kumpulan data.

$$Accuracy = \frac{N_{benar}}{N} \times 100\% \quad (5)$$

2. *Precision* adalah sebuah pengujian melalui perbandingan jumlah informasi yang sesuai diperoleh sistem dengan jumlah seluruh informasi yang terambil oleh system, walaupun tidak sesuai.

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

3. *Recall* dapat diperoleh dengan membandingkan jumlah informasi relevan yang diperoleh sistem dengan jumlah seluruh informasi relevan yang ada dalam label informasi.

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

### III. HASIL DAN PEMBAHASAN

#### A. Seleksi Fitur

Proses pembobotan penelitian ini menggunakan TF-IDF sebagaimana ditunjukkan pada Persamaan 1, dan flowchart yang diilustrasikan pada Gambar 3. Langkah pertama yaitu Menghitung jumlah kemunculan kata, kemudian menghitung jumlah dokumen dan query berisi kata (DF) lalu menghitung IDF menggunakan Persamaan 6 dan menghitung TF-IDF dengan Persamaan 7 dan hasil ditunjukkan pada Tabel 1.



**Gambar 2.**  
 Flowchart Proses Pembobotan Term

**Tabel 1.**  
 Hasil Perhitungan TF, DF, IDF dan TF-IDF

Kata	TF									DF	IDF	TF-IDF								
	D1	D2	D3	D4	D5	D6	D7	D8	D9			D1	D2	D3	D4	D5	D6	D7	D8	D9
selamat	2	0	0	0	0	0	0	0	0	2	0.653 21251	1.306 42503	0	0	0	0	0	0	0	
sehat	1	1	0	1	0	0	0	0	0	3	0.477 12125	0.477 12125	0.477 12125	0.4771 2125	1	0	0	0	0	
rutin	1	0	0	0	0	0	0	0	0	1	0.954 24251	0.954 24251	0	0	0	0	0	0	0	
pulih	0	1	0	0	0	0	0	0	0	1	0.954 24251	0	0.954 24251	0	0	0	0	0	0	
protokol	1	0	0	1	0	0	0	0	0	2	0.653 21251	0.653 21251	0	0.653 21251	1	0	0	0	0	
pandemi	0	1	0	0	0	0	0	0	0	1	0.954 24251	0	0.954 24251	0	0	0	0	0	0	
lindungi	1	0	0	0	0	0	0	0	0	1	0.954 24251	0.954 24251	0	0	0	0	0	0	0	
lelah	0	2	0	0	0	0	0	0	0	2	0.653 21251	0	1.306 42503	0	0	0	0	0	0	
kondisi	0	1	0	0	0	0	0	0	0	1	0.954 24251	0	0.954 24251	0	0	0	0	0	0	
jaga	1	1	0	0	0	0	0	0	0	2	0.653 21251	0.653 21251	0.653 21251	0	0	0	0	0	0	
covid	1	0	1	0	0	0	0	0	0	2	0.653 21251	0.653 21251	0	0.653 21251	0	0	0	0	0	
ancam	1	0	0	0	0	0	0	0	0	1	0.954 24251	0.954 24251	0	0	0	0	0	0	0	
aktivitas	1	0	0	0	0	0	0	0	0	1	0.954 24251	0.954 24251	0	0	0	0	0	0	0	
adaptasi	1	0	0	0	1	1	0	0	0	3	0.477 12125	0.477 12125	0	0	0.477 12126	0.477 12127	0	0	0	

Berdasarkan Tabel 1, diilustrasikan sampel 9 dokumen yang berasal dari 9 tweet dari ribuan data yang sudah dicrawling untuk dihitung TF, DF, IDF dan TF-IDF. Tahapan pembobotan terni merupakan transformasi data dari data teks ke dalam sebuah matriks yang berisi numerik yang kemudian data dapat diolah dan diterapkan ke dalam model klasifikasi.

**B. Pemodelan Naïve Bayes**

Mengasumsikan bahwa efek fitur tertentu dalam kelas tidak bergantung pada fitur lainnya merupakan Naïve Bayes Classification. Asumsi ini menyederhanakan komputasi yang disebut kebebasan bersyarat kelas. Langkah pertama adalah memahami dan mengidentifikasi fitur dan label potensial. Klasifikasi ini memiliki dua tahap, tahap pembelajaran dan tahap evaluasi. Ketepatan analisis algoritma benar jika menghasilkan luaran yang benar jika menerima masukan sesuai dengan definisinya, dan dapat diterminasi (berakhir) (Sim, 2013).

Proses training pada penelitian ini seperti diilustrasikan dalam Tabel 2, dengan pengklasifikasi melatih modelnya pada dataset tertentu sebagaimana dihasilkan probabilitas yang merupakan hasil perhitungan setiap term yang ditambahkan dan dicari nilai paling tinggi dan dijadikan kelas untuk term seperti pada Tabel 3. Tahapan ini data telah berbobot seperti contoh pada Tabel 3 sebagai data latih sebagai referensi pembentukan model klasifikasi, kemudian pencarian nilai probabilitas kategori dan peluang

setiap kata dari data latih. Untuk mengakumulasi nilai peluar kategori dan kata dengan mengimplementasikan Persamaan 2 pada seriap term untuk setiap kelas dari data latih. Jumlah seluruh term dalam data latih yang dipakai pada perhitungan sebanyak 9 term dimana 3 term adalah positif, 4 term adalah negatif dan 2 term adalah netral. Data hasil pembobotan term pada Tabel 3 dilakukan perhitungan probabilitas setiap term. Sebagai contoh kata “selamat” pada Tabel 3 berdasarkan perhitungan probabilitas menggunakan Persamaan 3 dan 4.

**Tabel 2.**  
 Contoh Data Training

Kode	Sebelum Pra-Proses	Setelah Pra-Proses	Kelas
D1	@PT_Transjakarta: Selamat Pagi, selamat beraktivitas. Adaptasi Kebiasaan Baru menjadi rutinitas keseharian dengan menjaga protokol kesehatan dimulai dari diri sendiri untuk saling melindungi dari ancaman Covid-19.	selamat selamat aktivitas adaptasi rutin jaga protokol sehat lindung ancam covid	Positif
D2	@tia_alzahira: Ketika ditanya lelah nggak sih sama pandemi yang nggak terasa udah setahunberlalu?	lelah pandemi lelah kondisi pulih wajib disiplin protokoljaga sayang	Negatif
D3	@Cahyailahi6: Pemerintah Indonesia terima 83,9juta dosis vaksin covid-19	dosis vaksin covid	Netral
D4	@Dien_Drew1: Iya lagi naik”lagi nih kak .gmn yadilarang mudik mngkn taun lalu gak mudik .sdh lelah mereka kak dgn aturan”yg gak jelas gini	larang mudik mudiklelah aturan	?

$$p("selamat"|"pos") = \frac{"selamat"|"pos" + 1}{("pos") + |kosakata|} = \left(\frac{1.306 + 1}{33 + 46}\right) = 0,0292$$

$$p("selamat"|"neg") = \frac{"selamat"|"neg" + 1}{("neg") + |kosakata|} = \left(\frac{0 + 1}{19 + 46}\right) = 0,0154$$

$$p("selamat"|"net") = \frac{"selamat"|"net" + 1}{("net") + |kosakata|} = \left(\frac{0 + 1}{23 + 46}\right) = 0,0145$$

Maka kata selamat mendapatkan nilai positif yang lebih besar dibandingkan dengan term lainnya. Hasil probabilitas kata lainnya terlihat pada Tabel 3 sebagai luarannya, probabilitas diperoleh dari nilai yang paling tinggi dan dijadikan kelas untuk term tersebut.

**Tabel 3.**  
 Perhitungan Probabilitas Kata

Kata	Jumlah frekuensi ( $n_k, pos/neg/net$ )			Probabilitas Kata $p(w_k pos/neg/net)$			Kata	Jumlah frekuensi ( $n_k, pos/neg/net$ )			Probabilitas Kata $p(w_k pos/neg/net)$		
	pos	neg	net	pos	neg	net		pos	neg	net	pos	neg	net
selamat	1,3064250	0	0	0,029195	0,0153846	0,0145	lindungi	0,9542425	0	0	0,024737	0,0153846	0,014
aktivitas	0,9542425	0	0	0,024737	0,0153846	0,014	ancam	0,9542425	0	0	0,024737	0,0153846	0,014
adaptasi	1,4313637	0	0	0,030776	0,0153846	0,014	covid	0,6532125	0	0,653212	0,020926	0,0153846	0,023
rutin	0,9542425	0	0	0,024737	0,0153846	0,014	lelah	0	0	1,306425	0,012658	0,0153846	0,033
jaga	0,6532125	0	0,653212	0,020926	0,0153846	0,023	pandemi	0	0	0,954242	0,012658	0,0153846	0,028
protokol	1,3064250	0	0	0,029195	0,0153846	0,014	kondisi	0	0	0,954242	0,012658	0,0153846	0,028
sehat	0,9542425	0	0,477121	0,024737	0,0153846	0,021	pulih	0	0	0,954242	0,012658	0,0153846	0,028
							wajib	0	0	0,954242	0,012658	0,0153846	0,028

Langkah-langkah pada proses testing menyerupai dengan alur proses training, yaitu:

- Proses 1: Pengujian memberikan data uji pada model dalam pelatihan. Contoh perhitungan pada proses 2 menggunakan D4.
- Proses 2: Setelah proses seleksi data testing dihitung nilai probabilitas tiap kata dalam data testing dengan hasil probabilitas term dari data training. Perhitungan probabilitas dilakukan dengan Persamaan 1. Probabilitas Data Testing (Positif) berdasarkan Tabel 1, menghasilkan 0.012 untuk peluang kata “larang”, “mudik”, “lelah” pada kelas positif. Sedangkan pada kelas negative mengasilkan nilai berturut-turut yaitu 0.0147, 0.035, 0.0154.

Probabilitas Data Testing (Positif) berdasarkan Tabel 1.

- $p("larang"|"pos") = (0 + 133 + 46) = 0,012$
- $p("mudik"|"pos") = (0 + 133 + 46) = 0,012$
- $p("lelah"|"pos") = (0 + 133 + 46) = 0,012$

Probabilitas Data Testing (Negatif) berdasarkan Tabel 1.

- $p("larang"|"neg") = \left(\frac{-0,4575749 + 1}{19 + 46}\right) = 0,0147$
- $p("mudik"|"neg") = \left(\frac{-0,4575749 + 1}{19 + 46}\right) = 0,035$
- $p("lelah"|"neg") = \left(\frac{0 + 1}{19 + 46}\right) = 0,0154$

Probabilitas Data Testing (Netral) berdasarkan Tabel 1.

- $p("larang"|"net") = \left(\frac{-0,4575749 + 1}{23 + 46}\right) = 0,0145$
- $p("mudik"|"net") = \left(\frac{-0,4575749 + 1}{23 + 46}\right) = 0,0145$
- $p("lelah"|"net") = \left(\frac{0 + 1}{23 + 46}\right) = 0,0334$

- Proses 3: Menghitung probabilitas kategori dengan Persamaan 2.
  - $P(testing|pos) = P(pos) \times P(larang|pos) \times P(mudik|pos) \times P(lelah|pos) \times P(testing|pos)$   
 $= 0,33 \times 0,0147 \times 0,034 \times 0,0154 = 2,53998E - 06$
  - $P(testing|neg) = P(neg) \times P(larang|neg) \times P(mudik|neg) \times P(lelah|neg) \times P(testing|neg)$   
 $= 0,44 \times 0,0147 \times 0,035 \times 0,0154 = 3,48625E - 06$
  - $P(testing|net) = P(net) \times P(larang|net) \times P(mudik|net) \times P(lelah|net) \times P(testing|net)$   
 $= 0,22 \times 0,0145 \times 0,0145 \times 0,0334 = 1,54492E - 06$

Nilai probabilitas tertinggi kategori negatif sebesar 3,48625E-06, sehingga D4 dapat dikategorikan kedalam kelas Negatif. Sebagai contoh kata “selamat” pada Tabel 2 menunjukkan perhitungan nilai positif yang lebih besar dibandingkan dengan term lainnya. Hasil probabilitas kata lainnya terlihat pada Tabel 3 di bawah yang merupakan luaran perhitungan setiap term yang sudah ditambahkan, kemudian dicari nilai yang terbesar dan digunakan sebagai kelas untuk term tersebut.

C. Evaluasi Model menggunakan Confusion Matrix

Pada tahap evaluasi, pengklasifikasi menguji kinerja pengklasifikasi. Kinerja dievaluasi berdasarkan parameter seperti *acuration*, *precision* dan *recall*. Pengujian dilakukan dengan menggunakan 70 data berlabel. Parameter yang dihitung dalam pengujian ini yaitu *accuration*, *precision*, *recall*. Ketiga parameter tersebut dihitung dengan menggunakan metode Confusion Matrix. Metode ini umumnya digunakan untuk melakukan perhitungan keakurasian pada data mining. Hasil pengujian akurasi klasifikasi tweets dengan menggunakan 20 data training dan 50 data uji.

Tabel 4.

		Actual Class		
		Positif	Negatif	Netral
Predicted Class	Positif	8	2	1
	Negatif	1	15	4
	Netral	0	4	15
Total Kelas		9	21	20

Penelitian ini menghasilkan akurasi yang lebih tinggi meskipun tanpa seleksi fitur yaitu sebagaimana terlampir pada Tabel 5 melalui Persamaan 5, Persamaan 6 dan Persamaan 7 untuk menghasilkan performance algoritma.

Tabel 5.

Hasil Pengujian dengan confusion matrix tanpa seleksi fitur					
Class	N(truth)	N(classified)	Precision	Recall	N(truth)
Positif	9	11	70,127%	79,84%	9
Negatif	21	20	71,7%	70,12%	21
Netral	20	19	75,247%	72,58%	20

Tabel 6.

Hasil Pengujian dengan confusion matrix dengan seleksi fitur				
Class	N(truth)	N(classified)	Precision	Recall
Positif	9	11	72,727%	88,88%
Negatif	21	20	75%	71,4%
Netral	20	19	78,947%	75%

Hasil pengujian menunjukkan tingkat accuracy sebesar 63.21% tentang analisis sentimen opini publik mengenai covid-19 pada twitter menggunakan metode naïve bayes tanpa menggunakan seleksi fitur (Syarifuddin, 2020). Pada penelitian ini menghasilkan akurasi yang lebih tinggi meskipun tanpa seleksi fitur yaitu sebagaimana terlampir pada Tabel 5.

Berdasarkan pengujian akurasi menggunakan Persamaan 5, Persamaan 6 dan Persamaan 7 dimana hasil akurasi klasifikasi tweets dari sistem analisis sentimen dengan menggunakan Naïve Bayes classifier yang ditambah dengan seleksi fitur sebesar 76% dengan *accuracy* positif sebesar 72,727%, *accuracy* negatif sebesar 75% dan *accuracy* netral sebesar 78,947%. Penelitian sebelumnya sebagaimana ditunjukkan pada Tabel 5, menghasilkan akurasi yang lebih rendah dibandingkan dengan Tabel 6 yang sudah menggunakan seleksi fitur sebelum pemodelan dilakukan.

IV. KESIMPULAN

Simpulan peneliian menunjukan bahwa dengan penambahan seleksi fitur dapat meningkatkan nilai akurasi sebanyak 5% yaitu 78,947% dibandingkan tanpa menggunaka seleksi fitur. Pengaruh akurasi dalam metode Naïve Bayes bergantung kepada dataset, praproses dan optimasi metode sebelum penggunaan algoritma atau metode untuk klaifikasi. Pada dataset yang digunakan untuk training masih belum terlalu bervariasi, namun sudah menunjukkan hasil pembelajaran yang signifikan antara klasifikasi tanpa dan dengan menggunakan fitur seleksi. Dimana akurasi tertinggi pada klasifikasi Naïve Bayes tanpa seleksi fitur sebesar 75,247% sebgaimana ditunjukan padanTabel 5 sedangkan klasifikasi dengan penambahan seleksi fitur ditunjukkan pada Tabel 6 mencapai nilai sebesar 78,947% pada kelas netral. Penelitian ini lebih baik hasil performance model klasifikasinya jika dibandingkan dengan penelitian sebelumnya yang menghasilkan accuracy sebesar 63.21% tentang analisis sentimen mengenai covid-19 pada twitter dengan mengimplementasikan naïve bayes. Peningkatan sebesar 15% antara klasifikasi dengan penambahan fitur seleksi.

DAFTAR PUSTAKA

[1] Arini, Wardhani, L. K., and Octaviano, D., "Perbandingan Seleksi Fitur Term Frequency & Tri-Gram Character menggunakan Algoritma Naïve Bayes Classifier pada Tweet Hashtag #2019gantipresiden," *KILAT*, pp. 103-114, 2020.

- [2] B. Gunawan, H. S. Pratiwi, and E. E. Pratama, "Sistem Analisis Sentimen pada Ulasan Produk menggunakan Naive Bayes," *Jurnal Edukasi dan Penelitian Informatika*, pp. 113-118, 2018.
- [3] Hermanto, and A. Noviriandini, "Analisa Sentimen Terhadap Belajar Online Pada Masa COVID-19," *Jurnal Informatika Kaputama (JIK)*, pp. 129-131, 2021.
- [4] A. Imron, "Analisis Sentimen terhadap Tempat Wisata di Kabupaten Rembang menggunakan Metode Naive Bayes Classifier," Universitas Islam Indonesia, Yogyakarta, 2018.
- [5] D. T. Larose, *Discovering Knowledge in Data: An Introduction to Data Mining*, John Wiley & Sons, Inc., 2014.
- [6] B. Liu, *Sentiment Analysis and Opinion Mining*, Morgan & Claypool Publisher, 2012. [Online]. Available: <https://doi.org/10.2200/S00416ED1V01Y201204HLT016>
- [7] M. S. Mubaroka, Adiwijaya, and M. D. Aldhi, "Aspect-based sentiment analysis to review products using Naïve Bayes," *International Conference on Mathematics: Pure, Applied and Computation*, AIP Publishing, pp. 1-8, 2017.
- [8] M. I. Rahayu, and F. T. Zharfan, "Analisis Sentimen Laporan Perkembangan Anak Didik Taman Kanak," *Jurnal Teknologi Informasi dan Komunikasi*, pp. 30-36, 2015.
- [9] Ratino, N. Hafidz, S. Anggraeni, and W. Gata, "Sentimen Analisis Informasi Covid-19 menggunakan Support Vector Machine dan Naïve Bayes," *Jurnal JUPITER*, pp. 01-11, 2020.
- [10] F. Ratnawati, "Implementasi Algoritma Naive Bayes Terhadap Analisis Sentimen Opini Film Pada Twitter," *Jurnal Inovtek Polbeng - Seri Informatika*, pp. 51-59, 2018.
- [11] A. Saleh, "Klasifikasi Gejala Depresi Pada Manusia dengan Metode Naïve Bayes menggunakan Java," Digital Library STMIK AKAKOM, 23-Dec-2015. [Online]. Available: <http://eprints.akakom.ac.id/id/eprint/452>
- [12] A. X. Sim, "Pengenalan Desain dan Analisis Algoritma," [www.dev.bertzzie.com](http://www.dev.bertzzie.com), 01-Jul-2013. [Online]. Available: <http://dev.bertzzie.com/knowledge/analisis-algoritma/PengenalanDesaindanAnalisisAlgoritma.html#algoritma-yang-baik>
- [13] A. Siswandi, A. Y. Permana, and A. Emarilis, "Stemming Analysis Indonesian Language News Text with Porter," *Journal of Physics: Conference Series*, pp. 01-07, 2021.
- [14] R. N. Sukmana, and Z. S. Salsabilla, "Filter Bahasa Kasar menggunakan Algoritma Naïve Bayes," *Jurnal Teknologi Informasi dan Komunikasi*, pp. 1-5, 2018.
- [15] M. Syarifuddin, "Analisis Sentimen Opini Publik Mengenai Covid-19 Pada Twitter Menggunakan Metode Naïve Bayes Dan KNN," *Inti Nusa Mandiri*, pp. 23-28, 2020.
- [16] S. Yuliyanti, and Rizky, "Implementasi Algoritma Rabin Karp untuk Mendeteksi Kemiripan Dokumen STMIK Bandung," *Bangkit Indonesia*, pp. 1-6, 2020.
- [17] S. Yuliyanti, T. Djatna, and H. Sukoco, "Sentiment Mining of Community Development Program Evaluation Based on Social Media," *TELKOMNIKA*, pp. 1858-1864, 2017.