

ANALISIS SENTIMEN PENERAPAN PPKM PADA TWITTER MENGGUNAKAN NAÏVE BAYES CLASSIFIER DENGAN SELEKSI FITUR CHI-SQUARE

Pualam Wahyu Ratiasasadara^{1*}, Sudarno², Tarno³

^{1,2,3} Departemen Statistika, Fakultas Sains dan Matematika, Universitas Diponegoro ²

*e-mail: pualamwr@gmail.com

DOI: 10.14710/j.gauss.11.4.580-590

Article Info:

Received: 2022-09-02

Accepted: 2022-11-21

Available Online: 2023-02-25

Keywords:

PPKM; Twitter; Sentiment Analysis; Naïve Bayes Classifier; Featured Selection Chi-Square.

Abstract: Dissemination of information related to the implementation of PPKM takes place very quickly, especially on social media networks. Positive and negative news certainly has an impact on public opinion or sentiment on the implementation of PPKM. Sentiment analysis is needed to determine behavior or opinions in the form of reviews, ratings, or tendencies of the author towards a particular topic. In this study, the data used is public opinion on Twitter social media with the keyword "PPKM" from November 2, 2021 to November 8, 2021 and obtained data as many as 12,616 tweets which then deleted duplicate data to become 6,465 data. Data classification was performed using Naïve Bayes with Chi-Square feature selection and the data were classified into positive and negative classes. The results of the classification performance using Naïve Bayes with Chi-Square feature selection obtained an accuracy of 83% which means that the Naïve Bayes classification model with Chi-Square feature selection is quite effective in classifying public opinion on the implementation of PPKM

1. PENDAHULUAN

Pandemi Covid-19 menyebabkan perubahan perilaku masyarakat. Perubahan tersebut didukung dengan kemajuan teknologi komunikasi yang membuat pengguna media sosial meningkat. Informasi yang sedang banyak dibicarakan di tengah pandemi Covid-19 adalah penerapan PPKM. Hal tersebut dapat mendorong persebaran informasi dengan cepat melalui media sosial terutama Twitter. Twitter merupakan platform yang memuat sebuah informasi berupa *tweets* yang terdiri dari 280 karakter (Twitter, 2019). Diperkirakan Indonesia menjadi negara dengan pertumbuhan pengguna harian aktif Twitter paling banyak berdasarkan laporan finansial Twitter kuartal ke-3 tahun 2019 (Twitter, 2019). Berdasarkan pernyataan di atas, penulis akan meneliti bagaimana opini masyarakat di media sosial Twitter terhadap penerapan PPKM dengan analisis sentimen.

Penelitian ini melakukan klasifikasi opini pengguna Twitter ke sentimen positif dan sentimen negatif. Pengklasifikasian dilakukan menggunakan metode *Naïve Bayes* dengan seleksi fitur *Chi-Square*. Algoritma NBC merupakan metode klasifikasi yang populer digunakan untuk keperluan *data mining* karena algoritma NBC memiliki waktu pemrosesan singkat, mudah diimplementasikan, strukturnya cukup sederhana, serta memiliki efektifitas yang tergolong tinggi (Firmansyah & Puspitasari, 2021). Seleksi fitur berfungsi dalam mereduksi fitur yang kurang relevan pada proses klasifikasi oleh NBC. Penyeleksian fitur *Chi-Square* dilakukan dengan cara mengurutkan setiap fitur berdasarkan hasil seleksi fitur *Chi-Square* dari nilai yang terbesar hingga nilai yang terkecil (Ling *et al.*, 2014).

Berdasarkan hal tersebut, penelitian pada analisis sentimen mengenai penerapan PPKM akan dilakukan menggunakan metode klasifikasi *Naïve Bayes* dengan seleksi fitur *Chi-Square*. Penelitian tersebut menggunakan data *tweets* opini masyarakat yang terdapat pada media sosial Twitter dengan topik penerapan PPKM

2. TINJAUAN PUSTAKA

Analisis sentimen merupakan sebuah proses dalam menentukan sentimen serta mengelompokkan polaritas teks pada dokumen maupun kalimat sehingga kategori dapat ditentukan sebagai sentimen bernilai positif maupun negatif. Tujuan dari analisis sentimen yaitu untuk menentukan perilaku atau opini berupa ulasan, penilaian, atau kecenderungan dari penulis terhadap suatu topik tertentu (Basari *et al.*, 2013).

PPKM merupakan singkatan dari Pemberlakuan Pembatasan Kegiatan Masyarakat. PPKM merupakan sebuah istilah yang digunakan oleh pemerintah pada awal tahun 2021. Mulanya, kebijakan PPKM ini berlaku pada 11 Januari 2021 sampai 25 Januari 2021 yang mencakup wilayah DKI Jakarta serta 23 Kabupaten/Kota di enam provinsi dengan status resiko penyebaran tinggipenyebaran Covid-19. Karena dianggap belum efektif, oleh karena itu Presiden Joko Widodo mengumumkan PPKM dengan kategori level 1 sampai 4 dan berlaku mulai 26 Juli 2021.

Twitter *Crawling* merupakan proses penambangan data dalam jumlah besar dengan cepat berdasarkan kata kunci (Suharno & Listiyoko., 2018). Twitter menyediakan *Application Programming Interface* (API) yang memungkinkan pengguna dapat mengakses informasi dari Twitter dengan cakupan yang luas. Untuk melakukan hal tersebut, pengguna Twitter harus memiliki *API Key*, *API Secret*, *Access Token*, dan *Access Token Secret*.

Text Mining merupakan proses pengambilan informasi secara intensif yang bekerja dengan alat dan teknik tertentu dalam menganalisis suatu kumpulan dokumen teks (Feldman & Sanger., 2007). *Text mining* juga dipergunakan dalam mendeskripsikan sebuah teknologi yang mampu menganalisis data teks semi terstruktur maupun tidak terstruktur (Firdaus & Firdaus., 2021).

Pre-processing data merupakan tahap awal dalam mentransformasikan data masukan menjadi data dengan struktur yang sesuai serta siap untuk diproses (Aditya *et al.*, 2015). *Pre-processing* sangat penting dalam analisis sentimen, terutama dalam sebuah platform yang sebagian besar berisi kata atau kalimat yang tidak formal, tidak terstruktur, serta memiliki *noise* yang cukup besar (Mujilawati., 2016).

Proses pelabelan dokumen teks pada penelitian ini menggunakan metode *sentiment scoring* dengan memakai tiga kamus yaitu kamus sentimen, kamus *boosterwords*, dan kamus negasi. Kamus sentimen merupakan kamus yang berisikan sebuah kata yang telah diberi bobot dengan bobot 1 sampai -5, dan -1 sampai -5. Kamus *boosterwords* merupakan kamus yang berisikan kata yang mampu meningkatkan maupun mengurangi intensitas sentimen kata disebelahnya. Kamus negasi merupakan kamus yang berisikan kata yang dapat mengubah makna dari sebuah opini.

Stopwords removal bertujuan untuk menghilangkan kata-kata irelevan atau tidak berpengaruh dalam proses analisis sentimen. Kata yang dimaksud yaitu kata yang sering keluar namun dianggap tidak penting (Khosmah & Aribowo., 2020).

Stemming yaitu tahapan mengubah kata berimbuhan menjadi kata dasar, yaitu dapat dilakukan dengan cara membuang sisipan, imbuhan dan akhiran (Agastya., 2018). Tahap *stemming* pada penelitian ini menggunakan *package* “katadasaR” yang ditulis ulang oleh Nurandi dalam bahasa R yang berawal dari algoritma Nazief dan Adriani. Algoritma Nazief dan Adriani merupakan algoritma *stemming* untuk teks berbahasa Indonesia yang memiliki kemampuan persentase keakuratan lebih baik dari algoritma lainnya (Wardani & Nugraha., 2020).

Seleksi fitur atau pemilihan kata dilakukan untuk mereduksi fitur yang kurang relevan dalam proses klasifikasi *Naïve Bayes*. Penyeleksian fitur *Chi-Square* dilakukan dengan membentuk sebuah peringkat dari setiap fitur berdasarkan nilai *Chi-Square* dari yang tertinggi hingga terendah (Ling *et al.*, 2014). Perhitungan nilai *Chi-Square* pada setiap kata

t yang muncul pada setiap kelas c dapat dibantu dengan menggunakan Tabel Kontingensi pada Tabel 1.

Tabel 1. Tabel Kontingensi Perhitungan Nilai *Chi-Square*

KATA	KELAS	
	c	c^*
t	A	B
t^*	C	D

Nilai yang terdapat pada Tabel 4 merupakan nilai frekuensi observasi dari suatu kata terhadap kelas dengan keterangan sebagai berikut:

- A = banyaknya dokumen pada kelas c yang memuat kata t .
- B = banyaknya dokumen yang tidak ada di kelas c namun memuat kata t .
- C = banyaknya dokumen yang ada di kelas c namun tidak memuat kata t .
- D = banyaknya dokumen yang tidak ada di kelas c dan tidak memuat kata t .

Pada tahap ini, tiap kata yang diperoleh dihitung menggunakan Persamaan (1):

$$X^2_{(t,c)} = \frac{N(AD-CB)^2}{(A+C)(B+D)(A+B)(C+D)} \quad (1)$$

t merupakan *term* atau kata. c merupakan kelas sentimen dan N merupakan jumlah seluruh data pada dokumen teks.

Pembobotan kata (*term*) bertujuan untuk memberikan bobot pada setiap kata (*term*) sehingga dapat memudahkan proses klasifikasi (Nurjannah *et al.*, 2013). Pembobotan kata pada penelitian ini menggunakan metode *term frequency-inverse document frequency* (TF-IDF) dengan menggunakan modul *scikit-learn*. *Term Frequency* merupakan perhitungan pembobotan term dengan cara menghitung frekuensi kata (*term*) tertentu yang muncul dalam suatu dokumen. *Inverse document frequency* digunakan untuk mengurangi bobot dari kata (*term*) yang frekuensinya terlalu tinggi dalam berbagai dokumen. Dalam *TfidfVectorizer* terdapat beberapa parameter untuk diatur, seperti *smooth_idf* dan *norm*. Penelitian ini menggunakan *smooth_idf = True*, sehingga bobot *Inverse document frequency* (IDF) dapat dihitung dengan Persamaan (2):

$$idf_{t,d} = tf_{t,d} \times \left[\ln\left(\frac{N+1}{df_t+1}\right) + 1 \right] \quad (2)$$

idf_t adalah *inverse document frequency*. tf_t adalah *term frequency*, N adalah jumlah seluruh dokumen dan df_t jumlah dokumen yang mengandung kata/*term* t . Ide dalam menambahkan nilai satu pada rumus tersebut yaitu agar kata yang muncul di setiap dokumen tidak sepenuhnya diabaikan. Sehingga, perhitungan (*Term frequency-inverse document frequency*) TF-IDF dengan modul *scikit-learn* dapat dihitung dengan menggunakan dengan Persamaan (3):

$$W_{t,d} = \frac{idf_{t,d}}{\sqrt{\sum_{d=1}^n idf^2_{t,d}}} \quad (3)$$

$W_{t,d}$ merupakan *term frequency-inverse document frequency*, $idf_{t,d}$ merupakan nilai *Inverse Document frequency*, dan $\sum_{d=1}^n idf_{t,d}^2$ merupakan jumlah nilai IDF pada dokumen ke d .

Algoritma *Naïve Bayes Classifier* merupakan metode klasifikasi yang populer digunakan untuk keperluan *data mining* karena algoritma *Naïve Bayes Classifier* memiliki waktu pemrosesan singkat, mudah diimplementasikan, strukturnya cukup sederhana, serta memiliki tingkat efektifitas yang tergolong tinggi (Firmansyah & Puspitasari., 2021). *Naïve Bayes Classifier* didasarkan pada teorema *Bayes*, yaitu mengacu pada konsep probabilitas bersyarat (Rodiyansyah & Winarko., 2013). Teorema *Bayes* secara umum menggunakan Persamaan (4):

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

X merupakan kelas hasil klasifikasi, H merupakan data yang label kelasnya tidak diketahui, $P(H|X)$ merupakan probabilitas hipotesis H berdasarkan kondisi X (*probabilitas posterior*), $P(H)$ merupakan probabilitas hipotesis H (*probabilitas prior*), $P(X|H)$ merupakan probabilitas X berdasarkan kondisi pada hipotesis H , dan $P(X)$ merupakan probabilitas X .

Multinomial Naïve Bayes merupakan pengembangan dari *Naïve Bayes Classifier* yang cocok digunakan untuk klasifikasi teks (Manning *et al.*, 2019). Kategori dokumen pada klasifikasi *Multinomial Naïve Bayes* tidak ditentukan hanya berdasarkan kata yang muncul saja, namun berdasarkan jumlah kemunculannya. Pada saat proses pengklasifikasian teks, maka pendekatan *Bayes* akan memilih kategori yang memiliki probabilitas paling tinggi (C_{MAP}) menggunakan Persamaan (5):

$$C_{MAP} = \arg \max_{c \in C} \frac{P(C_j)P(d|C_j)}{P(d)} \quad (5)$$

C_j merupakan kategori dokumen yang akan diklasifikasikan, $P(C_j)$ merupakan probabilitas dari kategori teks C_j , dan d merupakan banyaknya dokumen pada data pembelajaran. Nilai $P(d)$ dapat diabaikan karena nilainya adalah konstan untuk semua C_j . Sehingga persamaan C_{MAP} dapat ditulis dengan Persamaan (6):

$$C_{MAP} = \arg \max_{c \in C} P(C_j)P(d|C_j) \quad (6)$$

Probabilitas $P(C_j)$ dapat diestimasi dengan menghitung jumlah dokumen training pada setiap kategori C_j . Sedangkan untuk menghitung distribusi dokumen pada tiap kelas, $P(d|C_j)$ tidak dapat secara langsung ditentukan. Diasumsikan bahwa sebuah dokumen terdiri dari unit yang lebih kecil, biasanya merupakan kumpulan dari kata (f_1, f_2, f_3, \dots) (Fanissa *et al.*, 2018). Dengan pendekatan *Naïve Bayes* yang mengasumsikan bahwa setiap kata tidak bergantung pada satu sama lain, maka perhitungan dapat lebih disederhanakan dapat ditulis dengan Persamaan (7):

$$P(d|C_j) = \prod_{i=1}^n P(F_i|C_j) \quad (7)$$

Dengan menggunakan persamaan $P(d|C_j)$, maka persamaan C_{MAP} dapat ditulis dengan Persamaan (8):

$$C_{MAP} = \arg \max_{c \in C} P(C_j) \prod_{i=1}^n P(F_i|C_j) \quad (8)$$

Nilai $P(C_j)$ dan $P(F_i|C_j)$ dapat dihitung dengan Persamaan (9) dan Persamaan (10):

$$P(C_j) = \frac{|docs_j|}{|contoh|} \quad (9)$$

$$P(F_i|C_j) = \frac{1 + n_1}{|C_j| + n(kosakata)} \quad (10)$$

$P(F_i|C_j)$ merupakan probabilitas *term* atau fitur F_i pada sentimen C_j , $|docs_j|$ merupakan jumlah dokumen pada sentimen j , $|contoh|$ merupakan jumlah seluruh dokumen pada proses *training*, n_1 merupakan frekuensi *term* F_i pada sentimen C_j , $|C_j|$ merupakan jumlah semua *term* pada kategori C_j , dan $n(kosakata)$ merupakan jumlah kata unik pada semua data *training*. Sementara itu, untuk menghitung klasifikasi *Multinomial Naïve Bayes* menggunakan pembobotan kata TF-IDF (Deolika & Taufiq Luthfi., 2019) menggunakan Persamaan (11):

$$P(F_i|C_j) = \frac{1 + w_{ct}}{(\sum w^1 \in w_{ct'}) + B'} \quad (11)$$

w_{ct} merupakan bobot TF-IDF *term* t pada dokumen kelas c , $(\sum w^1 \in w_{ct'})$ merupakan jumlah bobot TF-IDF pada dokumen kelas c , dan B' merupakan jumlah IDF seluruh *term* pada dokumen. Pemberian nilai 1 berguna sebagai *Laplace Smoothing* supaya terhindar dari probabilitas nol (Manning *et al.*, 2009).

Evaluasi kinerja klasifikasi untuk mengukur performa klasifikasi. Pengukuran dilakukan dengan melihat tingkat akurasi dari klasifikasi. Evaluasi klasifikasi dilakukan dengan menggunakan *confusion matrix*. *Confusion matrix* merupakan alat yang berfungsi untuk menganalisis apakah klasifikasi yang dilakukan baik untuk mengenali *tuple* dari kelas yang berbeda (Han *et al.*, 2011). Indikator pada *confusion matrix* dapat dilihat pada Tabel 2.

Tabel 2. Confusion Matrix

		Kelas Prediksi	
		Positif	Negatif
Kelas Aktial	Positif	TP	FN
	Negatif	FP	TN

Parameter yang dapat digunakan untuk performansi klasifikasi yaitu *accuracy*, *precision*, dan *recall* (Azis et al., 2020). Ukuran kinerja klasifikasi dapat dilihat pada Tabel 3.

Tabel 3. Ukuran Kinerja Klasifikasi

Ukuran	Rumus
<i>Overall Accuracy</i>	$\frac{TP + TN}{TP + FP + TN + FN}$
<i>Precision</i>	$\frac{TP}{TP + FP}$
<i>Recall</i>	$\frac{TP}{TP + FN}$

Wordcloud merupakan suatu metode yang berfungsi untuk menampilkan data teks secara visual dengan ukuran yang berbeda. *Wordcloud* merupakan metode *text mining* yang menampilkan grafis dari frekuensi kata yang lebih menonjol kata-kata yang lebih sering muncul dalam teks sumber. Semakin besar ukuran kata dalam visual, semakin umum kata tersebut dalam dokumen (Zuhri & Alamsyah., 2017).

3. METODE PENELITIAN

Data yang digunakan pada penelitian ini merupakan data kualitatif yang didapat dari proses *crawling* pada media sosial Twitter dari tanggal 2 November 2021 sampai 8 November 2021 dengan kata kunci “ppkm”. Berdasarkan proses tersebut didapatkan data *tweets* berbahasa Indonesia yaitu sebanyak 12.616 data. Data *tweets* yang diperoleh kemudian dibersihkan dari duplikat hingga tersisa menjadi 6.465 data.

Variabel yang digunakan pada penelitian ini terbagi menjadi dua, yaitu variabel bebas dan variabel terikat. Variabel bebas pada penelitian ini berupa opini masyarakat terhadap penerapan PPKM pada media sosial Twitter, sedangkan variabel terikat pada penelitian ini berupa kelas sentimen (positif dan negatif) dari opini masyarakat.

Analisis data pada penelitian ini dilakukan menggunakan software Rstudio 4.0.2, python, dan Microsoft Excel 2019. Adapun langkah-langkah analisis data yang dilakukan dalam penelitian ini adalah sebagai berikut:

1. Ekstrasi *tweets*
2. *Pre-Processing* data
3. *Sentiment Scoring*
4. *Stopwords Removal*
5. *Stemming*
6. Seleksi Fitur *Chi-Square*
7. Pembobotan Kata TF-IDF
8. Klasifikasi dengan algoritma *Naïve Bayes Classifier*
9. Interpretasi dalam bentuk visual menggunakan *WordCloud*

4. HASIL DAN PEMBAHASAN

Penulis mengumpulkan data *tweets* dalam jangka waktu satu minggu mulai dari 2 November 2021 sampai 8 November 2021 dengan kata kunci “PPKM” dan kategori *tweets* menggunakan bahasa Indonesia sebanyak 12.616 *tweets*. Proses dilanjutkan dengan menghilangkan duplikat pada data *tweets* hingga berkurang menjadi 6.465 *tweets*. Data tersebut kemudian disimpan dalam format CSV (*Comma Separated Value*).

Pre-processing data berfungsi mengubah data yang kurang terstruktur menjadi data terstruktur dengan tujuan mempermudah kerja mesin dalam proses membaca data.

1. *Case Folding*
Mengubah seluruh kapital atau huruf besar menjadi huruf kecil.
2. *Remove URL*
Menghapus URL atau yang biasa ditandai dengan “http://”.
3. *Unescape HTML*
Menghapus file HTML atau jejak karakter yang diduga sebagai markup.
4. *Remove Mention*
Menghapus simbol “@” dengan disusul username atau nama pengguna Twitter.
5. *Remove Punctuation*
Menghapus seluruh karakter yang tidak termasuk alfabet.
6. *Remove Number*
Menghapus angka maupun nomor yang terdapat pada dokumen teks.
7. *Normalisasi Kata*
Mengubah kata tidak baku menjadi kata baku.

Berdasarkan proses pelabelan data, diperoleh 344 *tweets* positif dan 690 *tweets* negatif. Hal ini menandakan jika sentimen negatif lebih mendominasi dibandingkan sentimen positif. Namun, terdapat kesalahan pelabelan sebanyak 250 *tweets* (24,18%) dari total 1034 *tweets*. Dari 250 *tweets* tersebut didapat 125 *tweets* yang seharusnya berlabel positif dan 125 *tweets* yang seharusnya berlabel negatif mendapat pelabelan yang tidak tepat. Hal ini disebabkan oleh hasil skor akhir yang dihitung oleh program berbeda dengan perhitungan manual terutama untuk tweet yang berbeda makna atau arti. Hal ini mungkin terjadi karena kasus sentimen bersifat subjektif. Setelah dilakukan pelabelan secara manual didapat 481 *tweets* (46,52%) berlabel positif dan 553 *tweets* (53,48%) berlabel negatif.

Pada dokumen teks tentunya banyak terdapat suatu kemungkinan adanya kata umum yang sering muncul dan tidak memiliki makna, sehingga tidak memiliki pengaruh atau tidak memberikan informasi dalam suatu dokumen teks. Hal tersebut perlu dihilangkan untuk menghasilkan tingkat akurasi yang lebih tinggi pada model klasifikasi. Pada penelitian ini menggunakan kamus *stopwords* Indonesia dan kamus *stopwords* manual. Pada kamus *stopwords* Indonesia terdapat 758 kata sedangkan pada kamus *stopwords* manual terdapat 145 kata.

Stemming dilakukan dengan mengubah kata berimbuhan menjadi kata dasar. *Stemming* dibutuhkan untuk meminimalisir indeks yang berbeda dengan menjadikan suatu kata yang memiliki makna yang sama menjadi bentuk yang sama juga, seperti “terbukti” dan “membuktikan” menjadi “bukti”, kemudian “dilonggarkan” dan “pelonggaran” menjadi “longgar”, dan sebagainya.

Penyeleksian fitur kata dilakukan dengan memilih fitur kata yang dipakai dalam proses pengujian klasifikasi, sedangkan kata yang tidak masuk dalam proses pengujian klasifikasi akan dihapus. Pemilihan fitur kata pada penelitian ini ditentukan dari kata yang memenuhi syarat untuk uji *Chi-Square* yaitu tidak boleh ada *cell* yang memiliki frekuensi harapan atau *expected count* kurang dari 5. Pada penelitian ini terdapat 556 kata, setelah dilakukan seleksi fitur *Chi-Square* diperoleh 136 kata yang memenuhi syarat. Setelah mendapatkan nilai *Chi-Square*, nilai tersebut dibentuk peringkat kemudian diurutkan dari nilai tertinggi hingga nilai terendah. Peringkat Nilai *Chi-Square* dapat dilihat pada Tabel 4.

Tabel 4. Peringkat Hasil Seleksi Fitur Chi-Square

No	Fitur	Kategori	Frekuensi	Chi-Square
1	Berhasil	Positif	81	38,27271
2	Covid	Negatif	146	35,43881
3	PCR	Negatif	119	24,53999
4	Senang	Positif	73	24,08600
5	Rugi	Negatif	73	23,69283
6	Bisnis	Negatif	78	17,12950
7	Sengsara	Negatif	47	16,73254
8	Turun	Negatif	76	16,53484
9	Sehat	Positif	29	16,12920
10	Positif	Positif	39	14,39604
⋮	⋮	⋮
136	Halang	Negatif	13	7,17E-05

Daftar hasil perhitungan nilai seleksi *Chi-Square* yang berdasarkan hipotesis independensi, dengan hipotesis awal menyatakan bahwa term *t* independen terhadap kategori *c*. Apabila nilai seleksi fitur *Chi-Square* lebih besar daripada nilai signifikan, sehingga penolakan hipotesis awal akan terpenuhi. Hipotesis akhir yang diperoleh menyatakan bahwa term *t* dependen (ada hubungan antara jenis kata dengan kelas sentimen) terhadap kategori *c*.

Pembobotan kata diperlukan dalam mentransformasikan kata atau *term* menjadi sebuah bilangan yang dapat dihitung dan diproses. Pembobotan kata TF-IDF dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pembobotan Kata TF-IDF Setelah Seleksi Fitur *Chi-Square*

<i>Tweet</i>	akibat	alasan	atur	banget	masyarakat	...	yakin
1	0	0	0	0	0,250928	...	0
2	0	0	0,408451	0	0,223549	...	0
3	0	0,302458	0	0	0,127185	...	0
4	0	0	0,247038	0,701528	0	...	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1034	0,441553	0	0	0	0	...	0

Pembagian data pelatihan (*training*) dan data uji (*testing*) yang digunakan pada penelitian ini sebesar 80%:20% dan tidak dilakukan pengacakan data. Perbandingan data latih (*training*) dan data uji (*testing*) dapat dilihat pada Tabel 6.

Tabel 6. Perbandingan Data Latih (*training*) dan Data Uji (*testing*)

Sentimen	Data Latih (<i>training</i>)	Data Uji (<i>testing</i>)	Total
Positif	380	101	481
Negatif	447	106	553
Total	827	207	1034

Model klasifikasi yang telah diuji serta dibangun dengan menggunakan data latih (*training*) akan dievaluasi kinerjanya. Evaluasi kinerja klasifikasi yang akan digunakan

dalam penelitian ini adalah *Confusion Matrix*. Hasil dari *Confusion Matrix* model *Multinomial Naïve Bayes* dengan seleksi fitur *Chi-Square* dapat dilihat pada Tabel 7.

Tabel 7. Hasil *Confusion Matrix*

		Kelas Prediksi	
		Positif	Negatif
Kelas Aktial	Positif	88	21
	Negatif	14	84

$$\text{overall accuracy} = \frac{TP + TN}{TP + FP + TN + FN} = \frac{88 + 88}{88 + 21 + 14 + 84} = 83\%$$

Hasil perhitungan *overall accuracy* didapat tingkat akurasi dari algoritma *Multinomial Naïve Bayes* dengan seleksi fitur *Chi-Square* sebesar 83%. Angka tersebut cukup besar sehingga algoritma *Multinomial Naïve Bayes* dengan seleksi fitur *Chi-Square* dapat direkomendasikan sebagai klasifikasi yang baik dalam analisis sentimen penerapan PPKM pada Twitter.

Visualisasi dokumen teks dengan bentuk *wordcloud* digunakan untuk melihat secara visual dari kata yang sering muncul pada dokumen teks dalam sentimen positif maupun sentimen negatif. Visualisasi dokumen teks dengan bentuk *wordcloud* dapat dilihat pada Gambar 1 dan Gambar 2.



Gambar 1. *Wordcloud* Sentimen Positif



Gambar 2. *Wordcloud* Sentimen Negatif

5. KESIMPULAN

Dari hasil pembahasan dapat disimpulkan bahwa kemunculan frekuensi kata pada kelas sentimen memiliki peranan penting dalam seleksi fitur *Chi-Square*. Penyeleksian fitur *Chi-Square* menghasilkan 136 dari total 556 fitur atau kata yang memenuhi syarat uji *Chi-Square*. Klasifikasi dengan algoritma *Multinomial Naïve Bayes* dengan seleksi fitur *Chi-Square* mendapatkan tingkat akurasi sebesar 83%. Sehingga penggunaan *Chi-Square* sebagai seleksi fitur dapat dibilang cukup efektif pada model klasifikasi *Naïve Bayes*. Dari hasil pelabelan dokumen teks masyarakat Indonesia yang menggunakan media sosial Twitter cenderung memberikan opini atau sentiment negatif terhadap penerapan PPKM.

DAFTAR PUSTAKA

Aditya, B. R. 2015. Penggunaan Web Crawler Untuk Menghimpun Tweets dengan Metode Pre-Processing Text Mining. *Jurnal Infotel* Vol 7, No. 2. DOI: <https://doi.org/10.20895/infotel.v7i2.35>.

Agastya, I, M, A., 2018. Pengaruh Stemmer Bahasa Indonesia Terhadap Performa Analisis Sentimen Terjemahan Ulasan Film. *Jurnal TEKNOKOMPAK* Vol 12, No. 1, Hal: 18-23. DOI: <https://doi.org/10.33365/jtk.v12i1.70>.

Azis, H., Tangguh Admojo, F., & Susanti, E. 2020. Analisis Perbandingan Performa Metode Klasifikasi pada Dataset Multiclass Citra Busur Panah Performance Comparison

- Analysis of Classification Methods on the Multiclass Dataset of Bows *Jurnal Techno*, Vol 19, No. 3. DOI: <https://doi.org/10.33633/tc.v19i3.3646>.
- Basari, A. S. H., Hussin, B., Ananta, I. G. P., & Zeniarja, J. 2013. Opinion mining of movie review using hybrid method of support vector machine and particle swarm optimization. *Procedia Engineering. Jurnal Procedia Engineering* Vol 53, Hal: 453-462. DOI: <https://doi.org/10.1016/j.proeng.2013.02.059>.
- Deolika, A., & Taufiq Luthfi, E. 2019. ANALISIS PEMBOBOTAN KATA PADA KLASIFIKASI TEXT MINING. *Jurnal Teknologi Informasi* Vol 3, No. 2.
- Fanissa, S., Fauzi, M, A., & Adinugroho, S. 2018. Analisis Sentimen Pariwisata di Kota Malang Menggunakan Metode Naive Bayes dan Seleksi Fitur Query Expansion Ranking. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer* Vol 2. No. 8, Hal: 2766-2770. DOI: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/1962>.
- Feldman, R., & Sanger, J. 2007. *The text mining handbook: advanced approaches in analyzing unstructured data*. Cambridge University Press, Volume 34 Number 1.
- Firdaus, A., & Firdaus, W. I. 2021. Text Mining Dan Pola Algoritma Dalam Penyelesaian Masalah Informasi : (Sebuah Ulasan). *Jurnal JUPITER* Vol 13, No. 1, Hal: 66-78.
- Firmansyah, Z., & Puspitasari, N. F. 2021. Analisis Sentimen Masyarakat Terhadap Vaksinasi Covid-19 Berdasarkan Opini Pada twitter Menggunakan Lagoritma Naive Bayes. *Jurnal Teknik Informatika* Vol 14, No. 2. DOI: <https://doi.org/10.15408/jti.v14i2.24024>.
- Han, J., Kamber, M., & Pei, J. 2011. *Data Mining: Concept and Techniques* (3rd ed.). Morgan Kaufmann Publishers.
- Khosmah, S., & Aribowo, A, S. 2020. Model Text-Preprocessing Komentar Youtube Dalam Bahasa Indonesia. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)* Vol 4, No. 4, Hal: 648-654. DOI: <https://doi.org/10.29207/resti.v4i4.2035>.
- Ling, J., Kencana, I, P, E, N., & Oka, T, B. 2014. Analisis Sentimen Menggunakan Metode Naive Bayes Classifier Dengan Seleksi Fitur Chi-Square. *E-Jurnal Matematika* Vol 3, No. 3, Hal: 92-99.
- Manning, C. D., Raghavan, P., & Schutze, H. 2008. *An Introduction to Information Retrieval*. Cambridge University Press, Page 253-270.
- Mujilahwati, S. 2016. Pre-Processing Text Mining Pada Data Twitter. *Jurnal Teknologi Informasi dan Komunikasi*.
- Nurjannah, M., & Fitri Astuti, I. 2013. Penerapan Algoritma Term Frequency-Inverse Document Frequency (TF-IDF) Untuk Text Mining. *Jurnal Informatika* Vol 8, No. 3. DOI: <http://dx.doi.org/10.30872/jim.v8i3.113>.
- Rodiyansyah, S. F., & Winarko, E. 2013. Klasifikasi Posting Twitter Kemacetan Lalu Lintas Kota Bandung Menggunakan Naive Bayesian Classification. *Jurnal IJCCS* Vol 7, No. 1. DOI: <https://doi.org/10.22146/ijccs.2144>.
- Suharno, F. A., & Listiyoko, L. 2018. Aplikasi Berbasis Web dengan Metode Crawling sebagai Cara Pengumpulan Data untuk Mengambil Keputusan. *Jurnal Teknologi Informasi*. DOI: <https://e-jurnal.lppmunsera.org/index.php/snartisi/article/view/813>.
- Twitter, A. R. (2019). *Report Twitter*. <https://help.twitter.com/id>. (diakses pada 10 Januari 2022).
- Twitter, S. (2019). *Support Twitter*. <https://help.twitter.com/id>. (diakses pada 10 Januari 2022).
- Wardani, N. W., & Nugraha, P. G. S. C. 2020. Stemming Teks Bahasa Bali dengan Algoritma Enhanced Confix Stripping. *International Journal of Natural Science and Engineering* Vol 4, No. 3. DOI: <https://doi.org/10.23887/ijnse.v4i3.30309>.

Zuhri, F. N., & Alamsyah, A. 2017. Analisis Sentimen Masyarakat Terhadap Brand Smartfren Menggunakan Naïve Bayes Classifier di Forum Kaskus. *E-Proceeding of Management* Vol 4, No. 1, Page: 242.