

Penerapan Metode Support Vector Machines (SVM) dan Metode Naïve Bayes Classifier (NBC) dalam Analisis Sentimen Publik terhadap Konsep *Child-free* di Media Sosial Twitter

Maulana Ibrahim¹, Dafa Rizki Setiawan¹, Afif Putro Sulaiman¹, Raden Muhammad Vito Nugroho¹

¹Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang,.

Email : ramving26@gmail.com

Abstract- *Child-free* is a concept in which a person chooses not to have children or places and situations that are without the presence of a child. Along with the rapid flow of information, this *child-free* concept began to be discussed virally, especially on Indonesian social media, such as Twitter. Sentiment analysis is the mining of all people's expressions and views on a phenomenon or product online in the form of text. Through a large sample collection of opinions and expressions, we can capture the voices or views of society, understand the dynamics that are taking place, and even know the extent to which the issue begins to touch aspects of people's social life. This study aims to conduct sentiment analysis by comparing the performance of two different methods used to classify people's views in the form of text data crawled tweets from Twitter. The two methods compared are Support Vector Machines (SVM) and Naive Bayes Classifier (NBC). Another purpose of this study is to provide an overview of public sentiment on social media Twitter about the concept of *child-free*. The results of this study showed that the data experienced an imbalance so to overcome this problem, SMOTE is used, SMOTE managed to increase the sensitivity of the prediction of minor data. The classification method that produces the best prediction on test data using the F1-weighted average criterion is SMOTE-SVM with a value of 60.45%. The opinions that support *child-free* mostly have to do with parents' unpreparedness to take care of children, while opinions that reject *child-free* think that it is contrary to Islam and *child-free* decisions will make it difficult for old age because no one takes care of them.

Keywords: *child-free*, Naive Bayes Classifier, sentiment analysis, SMOTE, Support Vector Machines.

Abstrak- *Child-free* adalah konsep di mana seseorang memilih untuk tidak memiliki anak. Seiring dengan deras nya arus informasi, konsep *child-free* ini mulai ramai diperbincangkan, terutama di media sosial Indonesia, seperti Twitter. Analisis sentimen adalah penambangan ekspresi dan pandangan semua orang tentang suatu fenomena atau produk dalam bentuk teks. Melalui kumpulan sampel opini dan ekspresi yang besar, kita dapat menangkap suara atau pandangan masyarakat, memahami dinamika yang sedang terjadi, bahkan mengetahui sejauh mana isu tersebut mulai menyentuh aspek kehidupan sosial masyarakat. Penelitian ini bertujuan untuk melakukan analisis sentimen dengan membandingkan kinerja dua metode berbeda yang digunakan untuk mengklasifikasikan pandangan orang dalam bentuk data teks *tweet* dari Twitter. Dua metode yang dibandingkan adalah *Support Vector Machines* (SVM) dan *Naive Bayes Classifier* (NBC). Tujuan lain dari penelitian ini adalah untuk memberikan gambaran sentimen publik di media sosial Twitter tentang konsep *child-free*. Hasil penelitian ini menunjukkan bahwa data mengalami ketidakseimbangan sehingga untuk mengatasinya digunakan metode SMOTE, SMOTE berhasil meningkatkan sensitivitas prediksi data minor. Metode klasifikasi yang menghasilkan prediksi terbaik pada data uji menggunakan kriteria *F1-weighted average* adalah SMOTE-SVM dengan nilai mencapai 60,45%. Pendapat yang mendukung *child-free* kebanyakan berkaitan dengan ketidaksiapan orang tua untuk merawat anak, sementara pendapat yang menolak *child-free* berpikir bahwa hal tersebut bertentangan dengan anjuran agama dan keputusan *child-free* dipandang menyulitkan dimasa tua karena tidak ada anak-anak yang merawat orang tua.

Kata-kata kunci: analisis sentimen, *child-free*, *Naive Bayes Classifier*, SMOTE, *Support Vector Machines*.

1. PENDAHULUAN

Menurut Kamus Cambridge, *child-free* adalah konsep di mana seseorang memilih untuk tidak memiliki anak, atau tempat dan situasi yang tidak memiliki anak. Penerapan *child-free* sendiri bukanlah sesuatu yang baru, melainkan lumrah di banyak negara maju. Youtuber di Indonesia, Gita Savitri, pada tahun 2021 menyatakan di media sosialnya bahwa ia memilih *child-free* dalam rumah tangganya. Seiring dengan deras nya arus informasi, konsep *child-free* ini mulai ramai diperbincangkan, terutama di media sosial Indonesia, seperti Twitter. Twitter termasuk dalam 5 besar media sosial yang paling banyak digunakan di Indonesia, dengan 59% dari total pengguna

media sosial (Hootsuite, 2022). Pandangan masyarakat terhadap konsep ini tentu beragam, mulai dari yang setuju dan tidak setuju. Indonesia dikenal sebagai negara yang memiliki budaya timur yang luhur, penting untuk dapat mempelajari bagaimana dampak dari derasnya informasi dapat memengaruhi pola pikir masyarakat, terutama generasi yang sudah akrab dengan dunia maya seperti Twitter. Menambang ekspresi dan pandangan semua orang tentang suatu fenomena atau produk dalam bentuk teks disebut analisis sentimen. Melalui kumpulan sampel opini dan ekspresi yang besar, kita dapat menangkap suara atau pandangan masyarakat, memahami dinamika yang sedang terjadi, bahkan mengetahui sejauh mana isu tersebut mulai menyentuh aspek kehidupan sosial masyarakat.

Beberapa metode yang dapat digunakan untuk mengklasifikasikan opini ke dalam jenis sentimen tertentu adalah *Naïve Bayes Classification* (NBC) dan *Support Vector Machine* (SVM). Metode NBC adalah teknik prediksi berbasis probabilitas sederhana berdasarkan model fitur yang saling bebas (Kohavi, 1996), sedangkan SVM adalah salah satu algoritma pembelajaran mesin dengan pendekatan pembelajaran *supervised* yang bekerja dengan menemukan fungsi *hyperplane* atau pemisah terbaik untuk memisahkan kelas (Mohammed et al., 2016). Beberapa penelitian yang sebelumnya telah dilakukan, NBC dan SVM diketahui memiliki tingkat keakuratan yang tinggi dalam klasifikasi data teks. Sebuah penelitian tentang sentimen publik di media sosial twitter menghasilkan NBC sebagai metode dengan akurasi yang lebih baik, mencapai 91,65% dibandingkan dengan *Logistic Regression*, *Support*

Vector Machine, dan *K-Nearest Neighbors* (Sutoyo & Almaarif, 2020). Sementara itu, penelitian lain membandingkan beberapa metode dalam mengklasifikasikan data teks terkait stunting, hasil *Support Vector Machine* (SVM) jauh mengungguli metode lain dengan memperoleh nilai akurasi 98% (Mohammed et al, 2016).

Secara umum, sebagian besar kasus klasifikasi memiliki masalah jumlah pengamatan yang tidak seimbang. Himpunan data dikategorikan sebagai data kelas tidak seimbang ketika proporsi antara kelas respons tidak setara. Kelas respons yang tidak seimbang menyebabkan hasil prediksi menjadi akurat hanya pada satu kelas tertentu, yaitu kelas dengan respons terbanyak. Penanganan data kelas tidak seimbang dapat dilakukan dengan metode SMOTE, metode SMOTE menghasilkan data sintesis dari kelas minor (Chawla et al., 2002). Penelitian ini dilakukan dengan tujuan membandingkan penerapan metode NBC dengan SVM menggunakan SMOTE untuk mengatasi jumlah pengamatan yang tidak seimbang dalam mengklasifikasikan sentimen masyarakat terhadap konsep *child-free*. Selain itu, bertujuan untuk dapat mengetahui topik apa saja yang sedang dibahas dalam setiap sentimen, baik positif maupun negatif dalam pembahasan konsep *child-free* oleh pengguna *Twitter*.

2. METODOLOGI

Data yang digunakan dalam penelitian ini adalah data *tweet* dari media social twitter dengan kata kunci "childfree". Proses pengambilan data dilakukan dengan *scraping* pada 8 Agustus hingga 15 September 2022. Waktu tersebut ditentukan berdasarkan tren topik *child-free* di google. Pada interval waktu itu, seorang YouTuber, Gita Savitri memberikan pernyataan bahwa ia memutuskan untuk tidak memiliki anak, pernyataan tersebut telah membuat banyak komentar, dan pandangan setuju, tidak setuju atau netral pada konsep tersebut. Total data yang diperoleh sebanyak 11.000 *tweet*. Sebanyak 1129 *tweet* diambil sebagai sampel dari 11.000 *tweet* yang kemudian diproses menggunakan *data mining*. Teknik pengambilan sampel yang digunakan adalah penarikan contoh acak sederhana. Penarikan contoh acak sederhana adalah metode penarikan sampel berukuran k dari populasi berukuran N dengan cara yang sederhana, dimana nilai $k \leq N$, dan $k \in N$. Dalam penarikan contoh acak sederhana, semua anggota populasi memiliki kesempatan yang sama untuk dipilih sebagai anggota sampel (Scheaffer et al., 2012)

Analisis Sentimen

Analisis sentimen adalah studi yang memiliki fungsi menganalisis pendapat, sentimen,

penilaian, perilaku dan emosi dalam masyarakat melalui suatu objek seperti produk, pelayanan publik, organisasi, individu, isu, peristiwa atau topik. Analisis sentimen menggunakan data teks sebagai bahan baku utama untuk analisis (Muzaki & Witanti, 2021). Dalam analisis sentimen, suatu opini atau pendapat yang terdapat dalam teks akan diekstraksi dan diubah menjadi matriks yang berisi bobot kata. Matriks diharapkan mampu mewakili emosi, pandangan atau pendapat orang yang mengirimkan teks, dan akan digunakan untuk mengetahui kecenderungan pendapat seseorang terhadap suatu peristiwa atau masalah.

Pre-processing Data

Text Mining adalah teori tentang mengumpulkan teks dengan tujuan mengetahui dan mengambil informasi yang berguna (Christopher & Hinrich, 1999). Dalam proses text mining, pencarian kata-kata yang dapat mewakili teks akan dilakukan, sehingga dapat dilakukan pengolahan kata dan analisis lebih lanjut. Dalam proses *text mining* secara umum data teks masih dalam bentuk mentah, sehingga perlu dilakukan tahap *pre-processing* data yang bertujuan untuk menggeneralisasi struktur teks agar teks dapat dinilai, dianalisis, dan diklasifikasikan (Kurniawan et al., 2017). Tahapan *pre-processing* yang dilakukan yaitu 1) *cleansing* adalah proses yang dilakukan untuk membersihkan fitur yang tidak diperlukan dalam mengambil data di Twitter, seperti URL, Username, dan lain-lain; 2) *case folding*

adalah proses mengubah semua huruf besar kembali menjadi huruf kecil sehingga seragam; 3) *tokenizing* adalah proses memotong kalimat menjadi unit kata dengan spasi dan masuk sebagai pemisah untuk setiap kata; 4) penyaringan adalah proses yang dilakukan dengan menghapus kata-kata yang tidak perlu; 5) *stemming* adalah suatu proses yang memiliki tujuan untuk menghilangkan imbuhan yang terdapat dalam sebuah kata, proses ini mengubah semua kata kembali menjadi kata-kata dasar; normalisasi adalah proses menyamakan kata-kata yang memiliki arti yang sama, tetapi ditulis berbeda.

Term Frequency-Inverse Document Frequency (TF-IDF)

Metode *Term Frequency-Inverse Document Frequency (TF-IDF)* adalah metode untuk menghitung bobot setiap kata yang paling umum digunakan dalam pencarian informasi dan penambangan teks. Metode TF-IDF adalah metode untuk memberi bobot istilah kata pada dokumen (Kibriya et al., 2005). Ini sering digunakan sebagai faktor pembobotan dalam pencarian informasi dan penambangan teks. *Term Frequency* (TF) adalah perhitungan berapa kali kata *t* muncul dalam suatu dokumen/kalimat, sedangkan perhitungannya adalah sebagai berikut:

$$TF_{(t,d)} = \frac{f_{(t,d)}}{\sum f_{(t,d)}} \quad (1)$$

Inverse document frequency (IDF) adalah perhitungan apakah sebuah kata umum atau jarang digunakan dalam dokumen. Ini diperoleh dengan membagi jumlah kalimat dalam kalimat yang ditetapkan dengan jumlah kalimat yang mengandung istilah dan kemudian mengambil logaritma hasil bagi.

$$IDF_{(t)} = \log \frac{N}{DF_t} + 1 \quad (2)$$

TF akan menunjukkan betapa pentingnya kata *t* dalam dokumen *d*, sedangkan IDF akan menunjukkan seberapa umum kata *t* digunakan dalam satu set dokumen/kalimat. Semakin sering kata *t* muncul dalam dokumen dan semakin jarang kata *t* muncul dalam dokumen lain, semakin besar bobot kata tersebut. Maka rumus untuk TF-IDF adalah:

$$TF - IDF(t,d) = TF(t,d) \times IDF(t) \quad (3)$$

Synthetic Minority Oversampling Technique (SMOTE)

Pada penelitian ini diketahui bahwa data mengalami ketidakseimbangan kelas antara opini yang setuju, tidak setuju dan netral. Dengan demikian metode SMOTE digunakan untuk mengatasi permasalahan tersebut. Namun demikian, pada penelitian ini juga dilihat performa klasifikasi tanpa menggunakan SMOTE sebagai pembandingan. Metode SMOTE menggunakan prinsip oversampling, yaitu menambahkan data dari kelas minor sehingga jumlahnya seimbang dengan data dari kelas mayor. SMOTE akan menghasilkan data dari kelas minor dengan pendekatan *neighborliness* (Chawla et al., 2002). Misalkan diberikan data dengan jumlah variabel p maka

jarak antara $x^T = [x_1, x_2, \dots, x_p]$ dan

$$z^T = [z_1, z_2, \dots, z_p] \text{ adalah } d(x, y) = \sqrt{(x_1 - z_1)^2 + (x_2 - z_2)^2 + \dots + (x_p - z_p)^2} .$$

Untuk menghasilkan data dengan metode SMOTE maka digunakan

$$\text{persamaan berikut } x_{baru} = x_i + (x_{knn} -$$

$x_i)\gamma$, dimana x_{baru} adalah pengamatan baru yang dibangkitkan, x_i adalah pengamatan ke- i , x_{knn} adalah x terdekat dari x_i , dan γ adalah angka acak antara 0 dan 1. Untuk data nominal maka akan diisi dengan nilai mayoritas pada k -tetangga terdekat. Perhitungan jarak pada SMOTE jika terdapat variabel

kategorik maka akan diganti dengan standar deviasi kuadrat median dari variabel kontinu kelas minoritas jika nilai kategorik pada pengamatan i dan j berbeda.

Naïve Bayes Classifier (NBC)

Naïve Bayes Classifier adalah metode pembelajaran mesin yang menggunakan perhitungan probabilitas yang berakar pada teorema Bayes. Naïve Bayes didasarkan pada teorema Bayes yang digunakan untuk menghitung probabilitas masing-masing kelas dengan asumsi bahwa antar kelas saling bebas. Definisi lain *Naïve Bayes* adalah metode untuk memprediksi peluang masa depan berdasarkan pengalaman sebelumnya. *Naïve Bayes* memiliki tingkat akurasi dan kecepatan yang lebih tinggi ketika diterapkan pada database bernilai besar (Kohavi, 1996).

$$\hat{V}_{map} = \underset{V_j \in V}{\operatorname{argmax}} \hat{P}(V_j) \prod_j \hat{P}(x_i | V_j) \quad (4)$$


dengan \hat{V}_{map} nilai posterior atau hasil pengklasifikasian, $\hat{P}(V_j)$ adalah nilai peluang prior pada data latih dan $\prod_j \hat{P}(x_i | V_j)$ adalah perkalian bersyarat antara x_i pada kategori V_j (fungsi likelihood).

Support Vector Machine (SVM)

Support Vector Machine merupakan classifier yang kini banyak digunakan untuk berbagai keperluan klasifikasi. Selain klasifikasi, SVM juga digunakan untuk regresi (Mohammed et al., 2016). SVM adalah pengklasifikasi biner yang membagi data menjadi dua kelas dengan *hyperplane* seperti yang digambarkan pada GAMBAR 1. *Hyperplane* ini berada tepat di tengah-tengah dua kelas dengan jarak ke titik data terdekat untuk setiap kelas, disebut margin, dan titik data yang tepat pada jarak dari *hyperplane* disebut *support vector*. SVM Hyperplane dinyatakan dengan persamaan berikut

$$\hat{w} \cdot x + b = 0 \quad (5)$$

dengan \vec{w} adalah vektor pembobot, \mathbf{x} adalah vektor input dan b adalah intersep atau bias.



GAMBAR 1. Ilustrasi *hyperplane*

Cross Validation

Cross-validation (CV) adalah metode statistik yang dapat digunakan untuk mengevaluasi kinerja model atau algoritma dimana data dipisahkan menjadi dua subset yaitu data proses pembelajaran dan data validasi (Efron & Gong, 1983). *K-Fold Cross Validation* merupakan salah satu metode validasi silang yang paling umum digunakan. *K-Fold Cross Validation* mengelompokkan data ke dalam K grup data. Selanjutnya setiap kelompok yang terbentuk akan diuji dengan model yang digunakan. Sehingga

suatu model dapat diuji dalam berbagai input data dari proses yang dilakukan. Pada penelitian inidigunakan *5-Fold Cross Validation*.

Confusion Matrix

Confusion matrix adalah tabel yang digunakan untuk menggambarkan kinerja model klasifikasi pada kumpulan data pengujian yang label aktualnya diketahui. *Confusion matrix* memberikan informasi rinci tidak hanya tentang kesalahan yang dibuat oleh pengklasifikasi tetapi yang lebih penting adalah jenis kesalahan yang dibuat (Stehman, 1997). *Confusion matrix* memvisualisasikan keakuratan pengklasifikasi dengan membandingkan kelas aktual dan yang diprediksi. Klasifikasi ini menghasilkan empat hasil, yaitu *true Positif* (TP), *false Positif* (FP), *true Negatif* (TN), dan *false Negatif* (FN) lihat GAMBAR 2. TP menghasilkan nilai jumlah data yang bernilai positif dan diprediksi benar sebagai positif; FP menghasilkan nilai jumlah data yang bernilai negatif tetapi diprediksi sebagai positif. Sedangkan FN menghasilkan nilai jumlah data yang bernilai positif tetapi diprediksi sebagai negatif dan TN menghasilkan nilai jumlah data yang bernilai negatif dan diprediksi benar sebagai negatif (Stehman,1997).

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

GAMBAR 2. *Confusion Matrix*

Berdasarkan *confusion matrix*, dapat dilakukan pengukuran metrik untuk mendapatkan nilai

accuracy, precision, recall, dan F1- score (Christopher & Hinrich, 1999). *Precision* dan *recall* digunakan bersama untuk mengevaluasi performa model secara komprehensif. *F1- score* berfungsi sebagai metrik bermanfaat yang mempertimbangkan keduanya. *F1- score* adalah rata-rata harmonis *precision* dan *recall* untuk peringkasan kinerja model yang lebih seimbang. Jika dataset tidak seimbang dan tanpa mempertimbangkan proporsi kelasnya, maka *F1-macro average* akan menjadi pilihan yang baik karena memperlakukan semua kelas secara setara. Sedangkan dalam penelitian ini ukuran kinerja model yang digunakan adalah *F1-weighted average*, dimana ukuran kinerja model tersebut digunakan untuk data yang tidak seimbang tetapi mempertimbangkan proporsi kelas yang ada. Skor *F1-weighted average* dihitung dengan mengambil rata-rata semua skor F1 per kelas, juga mempertimbangkan proporsi masing-masing kelas. *F1-weighted average* digunakan dalam penelitian ini karena akan membandingkan performa SVM dan NBC saat menggunakan SMOTE dan saat tidak menggunakan SMOTE. Berikut ini adalah formula untuk memperoleh nilai *accuracy, precision, recall, F1- score, F1-macro average* dan *F1-weighted average*.

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

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

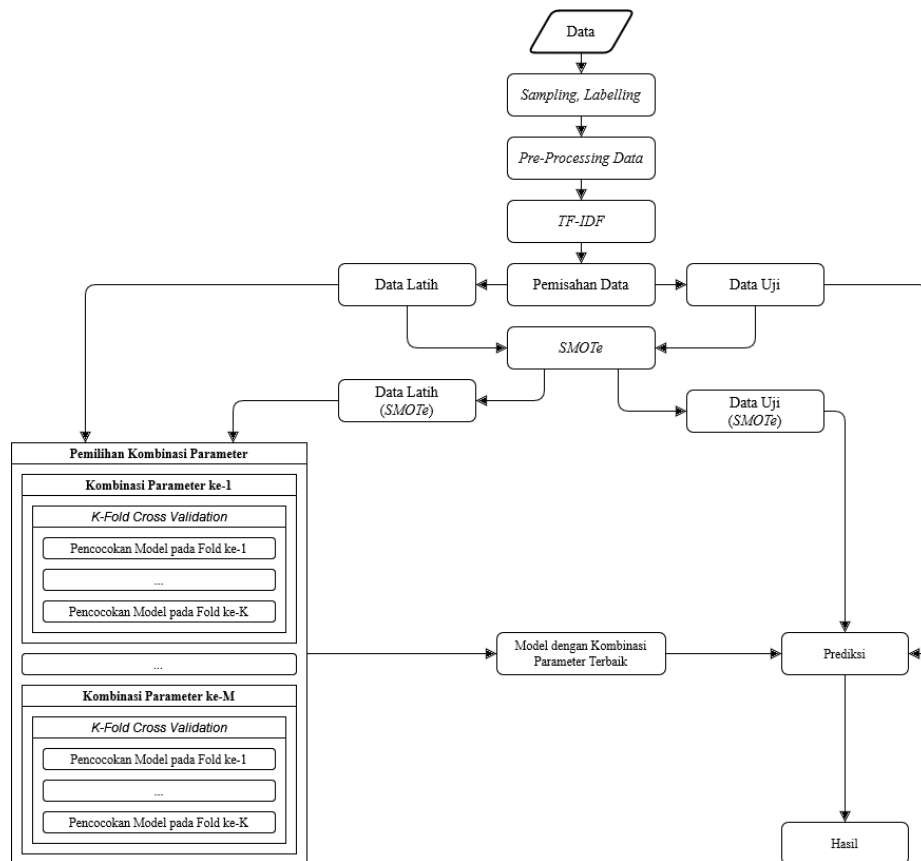
$$Precision = \frac{TP}{TP + FP} \quad (8)$$

$$Precision * Recall \quad F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (9)$$

$$F1 - Macro Average = \frac{\sum_{i=1}^k F1(Label i)}{n} \quad (10)$$

$$F1 - Weighted Average = \frac{\sum_{i=1}^k F1(Label i) * \frac{n_{Label i}}{n_{All Label}}}{k} \quad (11)$$

Secara umum, tahapan klasifikasi analisis sentimen yang dilakukan dapat dilihat pada GAMBAR 3.



GAMBAR 3. Diagram alir tahapan klasifikasi analisis sentimen

3. HASIL DAN PEMBAHASAN

Data sampel opini tentang *child-free* yang diperoleh dengan menggunakan proses *scraping* dari twitter berjumlah 1129 pengamatan, kemudian dilakukan *pre-processing data* sehingga diperoleh 994 *tweet* yang digunakan untuk klasifikasi analisis sentimen. Selanjutnya, setiap *tweet* diberi label secara manual untuk dikelompokkan sebagai opini positif, negatif dan netral. TABEL 1 memperlihatkan *tweet* yang telah diberi label. Data tersebut terdiri dari 193 *tweet* negatif, 359 *tweet* positif dan 442 *tweet* netral. *Pre-processing* yang dilakukan adalah *cleaning* data, normalisasi, *tokenizing*, *stemming* dan *case folding*. Tujuan dari proses ini adalah untuk mendapatkan teks yang relevan dan sesuai dengan input yang diinginkan. Selanjutnya, data dalam bentuk teks diubah menjadi matriks pembobotan kata dengan metode TF-IDF. TF-IDF merupakan salah satu pembobotan kata yang sering digunakan karena metode ini menggabungkan nilai bobot kata yang sering muncul dalam suatu dokumen/kalimat yang dikombinasikan dengan bobot kata dalam satu kumpulan kalimat atau kumpulan dokumen. Setelah matriks pembobotan kata terbentuk, dilakukan pembelajaran mesin dari data yang ada, data dibagi menjadi dua yaitu data latih 70% dan data uji 30% (Raschka, 2018) sehingga diperoleh untuk data latih sebanyak 688 *tweet* dan 306 *tweet* untuk data uji.

TABEL 1. *Tweet* yang telah diberi label sentimen

Tanggal (dd/mm/ yyyy)	<i>Tweet</i>	Se ntimen
-----------------------------	--------------	--------------

22/08/2021	beberapa orang sangat beruntung, punya pasangan yg sama2 ok untuk melakukanchildfree di Indonesia. :)	Po sitif
25/08/2021	@xxxxwahid10 kalo lo sendiri boleh menyebar dsn membanggakan kepercayaan lo keranah publik, kenapa orang" childfree dan lgbt engga?	Po sitif
23/08/2021	Heran ya kenapa pas bahas anak yg pertama muncul malah "mereka adalah yg akanngurusin aku waktu tua" bukan "tanggung jawab terhadap tumbuh kembang dan akhlak thdp mereka" dan ini yg bikin aku paham kenapa ada yg memilih child freehttps://t.co/NJtDCrTLAH	Po sitif
...
18/08/2021	plis deh alot banget perkara childfree di indonesia ampe besok my nonexistent baby brojol juga kayaknya ga bakal kelar ...† salty muluuuuuu capeeee ampe akubikim skripsi noh https://t.co/SmbL5iGZjH	Ne tral
11/08/2023	pengen diskusi childfree ke ortu deh kepo reaksinga gimana	Ne tral
20/08/2023	Konsep childfree lagi marak ya.. karena ada 1 orang yang bikin thread terus viral. Namanya juga Indonesia ada apa dikit langsung heboh dan seolah menjadi trend••	Ne tral
...
21/08/2021	Kamu bisa menentukan kebahagiaanmu, tp tidak dgn mengabaikan Allah, itu sama sekali ga keren, girls. Sehebat apapun km dan sebanyak apapun followers km. Say no#childfree	Ne gatif
17/08/2021	Andai yang memutuskan childfree tau betapa bahagianya melihat tawa dan menciumiaroma para bayi, maka kalian akan menangis darah berharap bisa punya anakm https://t.co/Tsh3FR6eSU	Ne gatif
20/08/2021	Jangan dianggap pemikiran childfree ini ga ada dampaknya sama sekali ke kehidupan.Dampaknya besar loh, liat aja tu negara2 yg kebanyakan wanitanya punya prinsip childfree. Mereka sekarang ketar ketir cari wanita yg mau punya anak, dan mau bayaruntuk itu.	Ne gatif

Data *tweet* yang diperoleh mengalami ketidakseimbangan jumlah data, dimana opini netral jauh lebih banyak daripada opini negatif dan opini positif, sehingga diterapkan metode SMOTE untuk mengatasi ketidakseimbangan data tersebut. Perbandingan hasil *F1-weighted average* menggunakan data latih dan data uji disajikan pada TABEL 2.

TABEL 2. F1-weighted average

Metode	Data latih	Data uji
Naïve Bayes	96,947%	56,948%
Support Vector Machine	99,273%	57,232%
SMOTE+Multinomial Naïve Bayes	96,947%	53,806%
SMOTE+Support Vector Machine	95,639%	60,450%

Dari TABEL 2 di atas, diperoleh nilai *F1-weighted average* tertinggi untuk data latih adalah menggunakan metode *Support Vector Machine* dengan nilai 99,273%, sedangkan pada data uji diperoleh nilai *F1-weighted average* tertinggi pada data metode *Support Vector Machine* yang dikombinasikan dengan SMOTE dengan nilai 60,45%. Informasi lebih lanjut tentang perbedaan hasil masing-masing metode di atas untuk menguji data disajikan pada TABEL 3, TABEL 4, TABEL 5, dan TABEL 6.

TABEL 3. Naïve Bayes Classifier

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i> ah	<i>Juml</i> <i>tweet</i>
Positif	58.333%	73.333%	64.979%	105
Negatif	38.235%	22.414%	28.261%	58
Netral	63.846%	62.406%	63.118%	133
<i>Macro</i>	53.472%	52.718%	52.119%	
<i>Average</i>				
<i>Weighted</i>	56.872%	58.446%	56.948%	
<i>Average</i>				

TABEL 4. SMOTE + *Naïve Bayes Classifier*

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i> ah	<i>Juml</i> <i>tweet</i>
Positif	57.377%	66.6%	61.674%	105
Negatif	30.9%	29.310%	30.088%	58
Netral	61.345%	54.887%	57.937%	133
<i>Macro</i>	49.877%	50.288%	49.890%	
<i>Average</i>				
<i>Weighted</i>	53.973%	54.0%	53.806%	
<i>Average</i>				

TABEL 5. *Support Vector Machine*

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i> ah	<i>Juml</i> <i>tweet</i>
Positif	63.551%	64.762%	64.151%	105
Negatif	30.000%	15.517%	20.4%	58
Netral	62.264%	74.436%	67.808%	133
<i>Macro</i>	51.939%	51.572%	50.805%	
<i>Average</i>				
<i>Weighted</i>	56.399%	59.4%	57.232%	
<i>Average</i>				

TABEL 6. SMOTE + *Support Vector Machine*

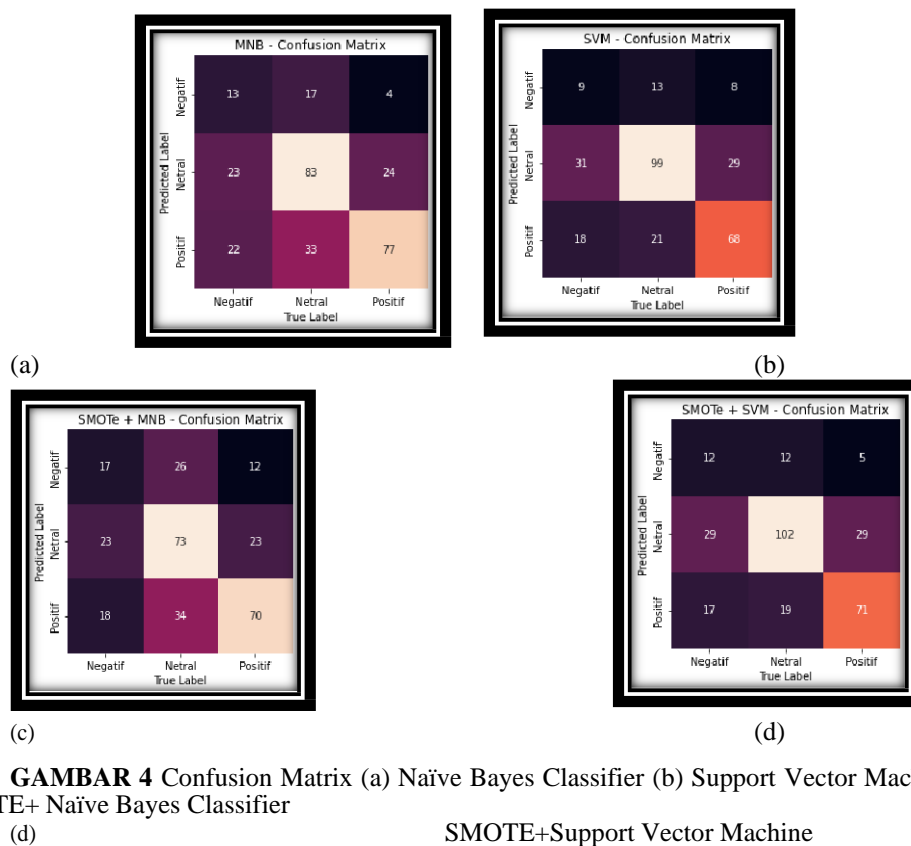
<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i> ah	<i>Juml</i> <i>tweet</i>
Positif	66.355%	67.619%	66.981%	105
Negatif	41.379%	20.69%	27.586%	58
Netral	63.750%	76.692%	69.625%	133
<i>Macro Average</i>	57.161%	55.000%	54.731%	
<i>Weighted</i>	60.291%	62.500%	60.450%	
<i>Average</i>				

Dari TABEL 2, TABEL 3, TABEL 4, dan TABEL 5 dapat dilihat bahwa nilai *recall* atau sensitivitas kelas negatif yang merupakan kelas minor dapat dilihat meningkat setelah penerapan SMOTE. Dapat


dilihat bahwa nilai *recall* pada SVM tanpa SMOTE adalah 20,45% sedangkan

menggunakan SMOTE+SVM adalah 27,586%. Nilai *recall* NBC juga meningkat dari 28,261% menjadi 30,088% menggunakan SMOTE+NBC. Dengan demikian SMOTE mampu meningkatkan prediktabilitas data dengan jumlah data tidak seimbang yang lebih kecil. Bahkan dengan SMOTE nilai *recall* pada sentimen negatif meningkat, nilainya masih cukup kecil jika dibandingkan dengan nilai *recall* pada sentimen positif dan netral.

Untuk membandingkan kinerja model yang terbentuk secara menyeluruh, *F1-weighted average* lebih tepat digunakan karena data yang digunakan mengalami ketidakseimbangan data, di mana ukuran sampel sentimen negatif hanya sekitar setengah dari sentimen positif dan sentimen netral. Dari keempat model di atas, hasil *F1-weighted average* tertinggi pada data uji adalah menggunakan metode SMOTE+SVM sebesar 60,45%. Model SMOTE+SVM dapat dikatakan berkinerja cukup baik dibandingkan dengan ketiga model lainnya karena nilai *F1-weighted average* yang dihasilkan pada data latih juga telah mencapai lebih dari 90% dan mencapai 60% untuk data uji, sedangkan model lainnya masih menghasilkan nilai *F1-weighted average* untuk data uji berkisar 50% meskipun pada data latih telah mencapai 90%. Dengan demikian nilai *F1-weighted average* yang relatif konsisten lebih tinggi adalah menggunakan metode SMOTE-SVM.



Evaluasi lebih lanjut dari kinerja model menggunakan *confusion matrix* pada keempat model yang dibandingkan mengungkapkan sentimen negatif lebih mungkin diprediksi sebagai sentimen netral. Sentimen netral lebih cenderung salah diprediksi sebagai sentimen positif. Sementara itu, sentimen positif cenderung diprediksi sebagai sentimen netral. Dengan demikian kita dapat menyimpulkan bahwa beberapa fitur yang termasuk dalam sentimen negatif dianggap termasuk dalam sentimen netral. Pada saat yang sama, beberapa fitur yang sebenarnya termasuk dalam sentimen netral dianggap sentimen positif juga.



GAMBAR 5 Kata-kata yang sering muncul pada sentimen negatif

GAMBAR 5 menyajikan informasi kata yang paling sering muncul dari *tweet* opini positif atau mendukung *child-free*. Dapat dilihat bahwa pembahasan sentimen positif yang paling sering muncul pada topik ini antara lain, Gitasav, pasangan, merawat, memilih dan anak-anak. Dalam sentimen positif atau mendukung *child-free* muncul anggapan bahwa tiap pasangan berhak untuk memilih *child-free*, memiliki anak adalah bentuk tanggung jawab yang tidak semua pasangan mampu ambil, selain itu ketidaksiapan orang tua untuk mengasuh anak mendorong untuk mendukung *child-free*. Sedangkan pada sentimen negatif yang berarti menolak *child-free*, beberapa diskusi yang sering muncul adalah *child-free* bertentangan dengan ajaran agama, ada juga anggapan bahwa ketika seseorang memutuskan untuk tidak memiliki anak maka ia akan mengalami kesulitan di usia tua karena tidak ada yang merawatnya, selain itu ada juga yang berpendapat bahwa *child-free* bisa membuat peradaban manusia punah.

4. KESIMPULAN

Pada klasifikasi analisis sentimen opini *child-free* yang diambil dari twitter, dapat disimpulkan bahwa penggunaan SMOTE untuk mengatasi ketidakseimbangan data baik pada model NBC dan SVM dapat meningkatkan nilai *recall* atau sensitivitas prediktif dari kelas yang lebih sedikit. Metode klasifikasi yang lebih baik untuk memprediksi sentimen terhadap konsep *child-free* pada twitter dalam kasus ini adalah metode *Support Vector Machine* yang dikombinasikan dengan SMOTE. Selain itu, diperoleh informasi bahwa pendapat yang mendukung *child-free* sebagian besar berkaitan dengan ketidaksiapan orang tua untuk mengurus anak, sedangkan pendapat yang menolak *child-free* menganggap bahwa hal ini bertentangan dengan agama dan keputusan *child-free* akan menyulitkan di hari tua karena tidak ada yang merawatnya.

REFERENSI

- Efron, B., & Gong, G. (1983). A leisurely look at the bootstrap, the jackknife, and cross-validation. *The American Statistician*, 37(1), 36-48.
- Christopher, D. M., & Hinrich, S. (1999). Foundations of statistical natural language processing.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
- Social, W. A. Hootsuite. (2022). Hootsuite (We are Social): Indonesian Digital Report 2022. *Digital Sosial Indonesia*.
- Kurniawan, B., Fauzi, M. A., & Widodo, A. W. (2017). Klasifikasi Berita Twitter Menggunakan Metode Improved Naïve Bayes. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer e- ISSN*, 2548, 964X.
- Kusumaningrum, R., Indihatmoko, T. A., Juwita, S. R., Hanifah, A. F., Khadijah, K., & Surarso, B. (2020). Benchmarking of multi-class algorithms for classifying documents related to stunting. *Applied Sciences*, 10(23), 8621.
- Kibriya, A. M., Frank, E., Pfahringer, B., & Holmes, G. (2005). Multinomial naive bayes for text categorization revisited. In *AI 2004: Advances in Artificial Intelligence: 17th Australian Joint Conference on Artificial Intelligence, Cairns, Australia, December 4-6, 2004. Proceedings 17* (pp. 488-499). Springer Berlin Heidelberg.
- Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). *Machine learning: algorithms and applications*. Crc Press.

- Muzaki, A., & Witanti, A. (2021). Sentiment analysis of the community in the twitter to the 2020 election in pandemic covid-19 by method naive bayes classifier. *Jurnal Teknik Informatika (Jutif)*, 2(2), 101-107.
- Kohavi, R. (1996, August). Scaling up the accuracy of naive-bayes classifiers: A decision-tree hybrid. In *Kdd* (Vol. 96, pp. 202-207).
- Raschka, S. (2018). Model evaluation, model selection, and algorithm selection in machine learning. *arXiv preprint arXiv:1811.12808*.
- Stehman, S. V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote sensing of Environment*, 62(1), 77-89. Sabran
- i, A., & Bimantoro, F. (2020). Multinomial Naïve Bayes untuk Klasifikasi Artikel Online tentang Gempadi Indonesia. *Jurnal Teknologi Informasi, Komputer, dan Aplikasinya (JTika)*, 2(1), 89-100. Scheaffer, R. L. (2012). William Mendenhall, R. Lyman Ott, Gerow GK. *Elementary Survey Sampling. Seventh ed. Julet M, editor. Boston: Richard Stratton*.
- Sutoyo, E., & Almaarif, A. (2020). Twitter sentiment analysis of the relocation of Indonesia's capital city. *Bulletin of Electrical Engineering and Informatics*, 9(4), 1620-1630.