

Analisis Sentimen Program Mbkm Pada Media Sosial Twitter Menggunakan KNN Dan SMOTE

Komang Pramayasa¹, I Md Dendi Maysanjaya², I Gusti Ayu Agung Diatri Indradewi³

^{1,2,3}Program Studi Sistem Informasi, Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha,
 Singaraja, Buleleng, Bali, Indonesia

e-mail: pramayasa@undiksha.ac.id¹, dendi.ms@undiksha.ac.id², indradewi@undiksha.ac.id³

Received : July, 2023	Accepted : August, 2023	Published : August, 2023
-----------------------	-------------------------	--------------------------

Abstract

The Merdeka Belajar-Kampus Merdeka (MBKM) program is a relatively new program implemented in Indonesia since February 2020. Like a new program, the implementation of the MBKM program is also followed by various pro and con attitudes. Therefore, a sentiment analysis technique is needed to determine the public opinion towards the MBKM program. The purpose of this research is to find out the public sentiment towards the implementation of MBKM and optimize the performance of the KNN method through the SMOTE method in conducting sentiment analysis. This research takes data from Twitter social media. The stages carried out to achieve sentiment analysis results are (1) Data collection, (2) Data processing, (3) Model building, and (4) Closing or presenting results. Through these stages, the performance of the KNN method is produced with an accuracy value of 68.81%, precision 70.73%, recall 68.81%, and f1-score 68.42%. After that, the optimization results using the SMOTE method obtained accuracy results that increased to 76.13%, precision to 76.03%, recall to 76.13% and f1-score to 76.01%. In this study, it was found that community responses tended to be neutral towards the MBKM program.

Keywords: MBKM, sentiment analysis, KNN, SMOTE.

Abstrak

Program Merdeka Belajar-Kampus Merdeka (MBKM) merupakan program yang relatif baru diterapkan di Indonesia sejak Februari 2020 lalu. Layaknya program baru, implementasi program MBKM juga diikuti oleh berbagai sikap pro dan kontra. Oleh karena itu, diperlukannya sebuah teknik analisis sentimen untuk mengetahui kecenderungan opini masyarakat terhadap program MBKM. Tujuan penelitian ini adalah untuk mengetahui sentimen masyarakat terhadap implementasi MBKM serta melakukan optimasi terhadap performa metode KNN melalui metode SMOTE dalam melakukan analisis sentimen. Penelitian ini mengambil data dari media sosial Twitter. Tahapan yang dilakukan untuk mencapai hasil analisis sentimen adalah (1) Pengumpulan data, (2) Pemrosesan data, (3) Pembangunan model, dan (4) Penutup atau penyajian hasil. Melalui tahapan-tahapan tersebut, dihasilkanlah performa metode KNN dengan nilai accuracy sebesar 68,81%, precision 70,73%, recall 68,81%, serta f1-score 68,42%. Setelah itu, hasil optimasi menggunakan metode SMOTE mendapatkan hasil accuracy yang meningkat menjadi 76,13%, precision menjadi 76,03%, recall menjadi 76,13% serta f1-score menjadi 76,01%. Pada penelitian ini didapatkan bahwa respon masyarakat cenderung bersikap netral terhadap program MBKM.

Kata Kunci: MBKM, analisis sentimen, KNN, SMOTE.

1. PENDAHULUAN

Pendidikan merupakan upaya strategis yang berperan penting dalam meningkatkan kualitas dan kecerdasan bangsa. Pada jenjang Pendidikan tinggi, proses pembelajaran harus dilakukan secara terpusat pada mahasiswa (*student centered learning*) dengan tujuan agar mahasiswa mampu beradaptasi terhadap perubahan serta kemajuan ilmu pengetahuan dan teknologi, sehingga dapat menghasilkan lulusan yang profesional di bidangnya [1]. Menanggapi hal tersebut, Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi (Kemendikbudristek) meluncurkan sebuah program Merdeka Belajar-Kampus Merdeka (MBKM) yang merupakan salah satu perwujudan pembelajaran yang terpusat pada mahasiswa dengan memberikan “kemerdekaan” kepada mahasiswa untuk mencari dan menemukan pengetahuan yang sesuai dengan minat dan bakat mahasiswa [2].

Program MBKM dapat dikatakan sebagai program yang relatif baru diterapkan di Indonesia. Layaknya program baru, implementasi program MBKM secara tidak langsung juga diikuti oleh berbagai opini pro dan kontra. Opini yang dilontarkan oleh masyarakat terhadap implementasi program MBKM berasal dari berbagai sumber, salah satunya adalah media sosial Twitter. Twitter merupakan salah satu media sosial yang sering digunakan dalam mengungkapkan perasaan berupa pujian dan kritik dalam berbagai ranah terhadap berbagai isu dalam bentuk tulisan status atau *tweet* [3]. Beberapa penelitian yang berhasil menggunakan Twitter sebagai sumber *dataset* sentimen yakni penelitian yang dilakukan oleh [4], [5], dan [6]. Hal tersebut menunjukkan bahwa media sosial Twitter memiliki peluang yang besar untuk dapat dimanfaatkan sebagai media dalam mengumpulkan data sentimen.

Adanya opini atau umpan balik dari masyarakat tentu dapat dijadikan sebagai bahan evaluasi dan pertimbangan terhadap implementasi program di masa mendatang. Oleh karena itu, diperlukannya sebuah analisis sentimen terkait opini masyarakat terhadap program MBKM. Penelitian terkait analisis sentimen sudah banyak dilakukan sebelumnya, beberapa diantaranya adalah penelitian oleh [7] terkait analisis sentimen terhadap kinerja dosen menggunakan metode *K-Nearest Neighbor* yang menghasilkan tingkat akurasi mencapai 81%. [8] yang meneliti sentimen masyarakat terkait jasa

ekspedisi barang menggunakan metode *K-Nearest Neighbor* menghasilkan tingkat akurasi sebesar 79.21%. [9] membandingkan antara metode *Naïve Bayes*, *Neural Network*, KNN dan SVM dalam melakukan sentimen opini masyarakat, dengan hasil metode KNN memberikan nilai akurasi yang paling tinggi, yakni sebesar 90.76%. [10] melakukan penelitian analisis sentimen kepuasan pelanggan dengan menggunakan metode KNN yang menghasilkan performa akurasi metode KNN sebesar 74%. [11] melakukan penelitian terkait analisis agen travel dengan membandingkan metode KNN, SVM dan *Naïve Bayes*. Hasil penelitian menunjukkan metode KNN lebih unggul dibandingkan metode lainnya dengan hasil akurasi KNN sebesar 96.32%, SVM sebesar 93.34%, dan *Naïve Bayes* sebesar 47.60%.

Berdasarkan beberapa penelitian sebelumnya, metode KNN terbukti memiliki performa yang baik dalam melakukan klasifikasi data sentimen atau opini masyarakat. Oleh karena itu, pada penelitian ini akan digunakan metode KNN dalam melakukan klasifikasi sentimen.

Dalam *machine learning*, permasalahan yang sering terjadi adalah adanya data yang tidak seimbang (*imbalance data*). Data tidak seimbang berpotensi menyebabkan kesalahan klasifikasi pada kelas minoritas. Kelas minoritas akan cenderung lebih sulit untuk diklasifikasikan karena jumlah data pada kelas minoritas sangat sedikit. Sehingga, proses klasifikasi akan cenderung bias terhadap kelas mayoritas [12].

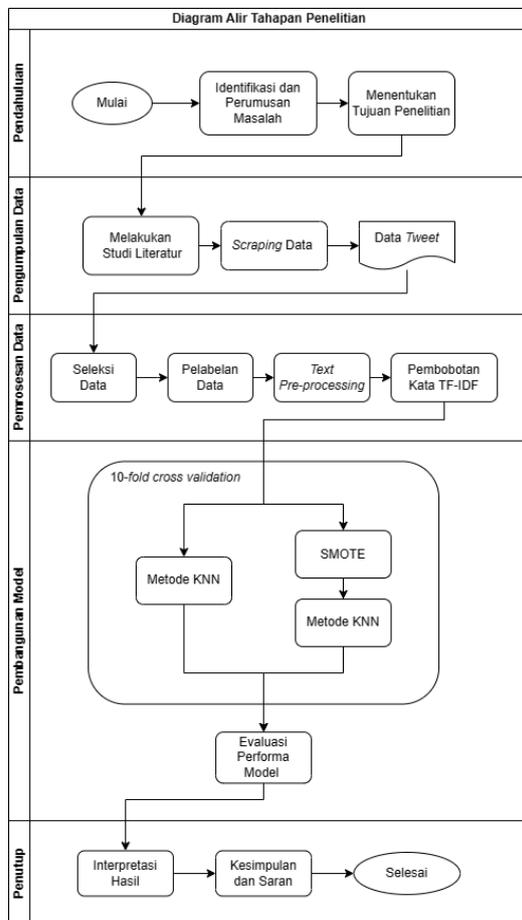
Teknik *resampling* dapat menjadi salah satu solusi dalam menangani kasus data tidak seimbang yang memiliki kelebihan, yakni cenderung lebih fleksibel dan dapat membantu model dalam melakukan klasifikasi dengan lebih mudah [13].

Synthetic Minority Oversampling Technique (SMOTE) merupakan salah satu metode *resampling* dengan tujuan untuk menyamakan distribusi kelas yang bekerja dengan cara mengambil sampel kelas minoritas dan melakukan penyisipan sampel sintesis untuk menambahkan jumlah data pada kelas minoritas [14]. Beberapa kelebihan yang dimiliki oleh metode SMOTE adalah tidak adanya informasi yang hilang pada sebuah kelas, dikarenakan tidak ada proses pengurangan data. Selain itu, SMOTE juga membuat kelas minoritas memiliki peluang lebih besar untuk dipelajari sehingga mampu meningkatkan nilai akurasi klasifikasi pada kelas minoritas [12].

Berdasarkan uraian latar belakang yang telah dipaparkan sebelumnya, maka dirancang sebuah penelitian yang berjudul Analisis Sentimen Program MBKM Pada Media Sosial Twitter Menggunakan KNN Dan SMOTE . Pada artikel ini, disusun beberapa stuktur penulisan. Pada bagian

2. METODE PENELITIAN

2.1. Tahapan Penelitian



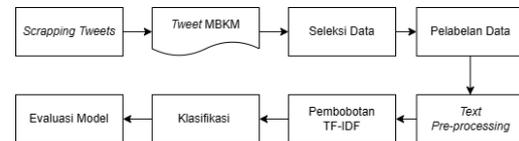
Gambar 1. Tahapan Penelitian

Tahapan pertama adalah tahapan pendahuluan yang bertujuan untuk melakukan identifikasi dan perumusan masalah yang akan diteliti. Selanjutnya tahapan pengumpulan data yang bertujuan untuk mengumpulkan data yang mendukung proses penelitian. Data yang digunakan pada penelitian ini adalah kumpulan *tweet* pada media sosial *Twitter* dengan menggunakan bantuan *API Key Twitter* serta *library Snsrape* pada *Python* untuk melakukan penarikan data. Selanjutnya setelah data terkumpul maka akan dilakukan tahapan *preprocessing data* yang bertujuan untuk menyiapkan data agar menjadi lebih terstruktur. Setelah data menjadi lebih terstruktur, maka

metode penelitian dijelaskan terkait metode yang digunakan dilanjutkan dengan pemaparan hasil dan pembahasan penelitian terakhir ditutup dengan kesimpulan dan saran.

tahapan selanjutnya adalah tahapan pembangunan model yang terdiri dari dua skenario, yakni pembangunan model KNN dan model KNN yang telah dioptimasi dengan metode SMOTE. Terakhir, tahapan penutup yang bertujuan untuk memaparkan hasil serta kesimpulan terkait proses penelitian yang telah dilakukan. Dalam pelaksanaan tahapan penelitian digunakan sebuah *tools*, yakni *JupyterLab* dengan bahasa pemrograman *Python* untuk mempermudah proses penelitian.

2.2. Pengolahan dan Analisis Data



Gambar 2. Proses Pengolahan dan Analisis Data

Proses *scraping tweets* dilakukan untuk mendapatkan sekumpulan data *tweets* terkait topik pembahasan MBKM dengan menggunakan beberapa kata kunci, seperti “MBKM”, “Merdeka Belajar”, “Kampus Merdeka”, “Program MBKM”, “Program Kampus Merdeka”, ‘Implementasi MBKM’, ‘Implementasi Kampus Merdeka’ serta *hashtag #mbkm* dan *#kampusmerdeka* dalam rentang waktu 9 Februari 2021 sampai 17 Maret 2022.

Dari hasil *scraping tweets* maka dilakukan seleksi untuk memilah data *tweets* yang tidak sesuai dengan kriteria penelitian, seperti *tweet* duplikat, *tweet* yang tidak sesuai dengan topik MBKM (*out of topic*), *tweet* yang bukan merupakan bahasa indonesia, serta *tweet* yang berasal dari akun instansi pendidikan, pemerintahan, portal berita, iklan dan akun sejenis lainnya. Setelah itu, setiap *tweet* akan diberikan label kelas sentimen secara manual ke dalam kelas netral, positif, dan negatif.

Selanjutnya adalah proses *text-preprocessing* yang terdiri dari *casefolding* yang merupakan proses penyamaan seluruh kata dalam dokumen menjadi bentuk *lowercase*. *Cleansing* yang merupakan proses pembersihan dokumen dengan cara menghapus karakter yang tidak relevan, seperti simbol, tanda baca,

dan angka. *Tokenizing* yang merupakan proses pemisahan atau pemecahan sebuah kalimat dalam dokumen menjadi sebuah kata terpisah (*token*). *Normalize* yang merupakan proses mengubah kata dalam dokumen yang ditulis tidak sesuai dengan bentuk normalnya. *Stopword Removal* yang merupakan proses penghapusan kata yang tidak diperlukan atau tidak memiliki makna seperti kata sambung, kata ganti dan lain-lain. *Stemming* yang merupakan proses mengubah sebuah *term* menjadi kata dasar dengan menghilangkan awalan (*prefix*) dan imbuhan (*suffix*).

Selanjutnya adalah pembobotan kata dengan TF-IDF yang merupakan proses transformasi sebuah dokumen yang awalnya berbentuk data tekstual menjadi data numerik berdasarkan bobot dari tiap kata atau fitur [15]. Untuk mencari nilai TF-IDF, dapat menggunakan Persamaan (1-3) berikut [16]:

$$tf = f_{t,d} \quad (1)$$

$$idf_d = \log \left(\frac{N}{df_t} \right) \quad (2)$$

$$w_{(t,d)} = tf \times idf_d \quad (3)$$

Berdasarkan formula untuk mencari nilai TF-IDF, nilai tf merupakan nilai *term frequency*, nilai $f_{t,d}$ merupakan nilai frekuensi kemunculan *term t* dalam dokumen d , nilai idf_d merupakan nilai *inverse document frequency*, nilai N merupakan jumlah dokumen, nilai df_t merupakan frekuensi sebuah dokumen yang mengandung *term t*, dan nilai $w_{(t,d)}$ merupakan bobot *term t* pada dokumen d .

Data hasil pembobotan kata selanjutnya akan diklasifikasikan menggunakan metode KNN dengan menggunakan perhitungan jarak *cosine similarity*. Persamaan (4) merupakan persamaan untuk menghitung jarak *cosine similarity* [17].

$$CosSim(q, d) = \frac{\sum_{i=1}^t (w_{id} \times w_{iq})}{\sqrt{\sum_{i=1}^t w_{id}^2} \times \sqrt{\sum_{i=1}^t w_{iq}^2}} \quad (4)$$

Berdasarkan formula untuk mencari nilai jarak *cosine similarity*, nilai t merupakan jumlah *term*, nilai d merupakan data latih, nilai q merupakan data uji, nilai N merupakan jumlah dokumen, nilai w_{ij} merupakan bobot *term ke-l* pada dokumen latih d , nilai w_{iq} merupakan bobot *term ke-l* pada dokumen uji q , nilai $\sum_{i=1}^t (w_{ij} \times w_{iq})$ merupakan vector data latih d dan data uji q , nilai $\sqrt{\sum_{i=1}^t w_{ij}^2}$ merupakan panjang dokumen latih d , dan nilai $\sqrt{\sum_{i=1}^t w_{iq}^2}$ merupakan Panjang dokumen uji q .

Setelah melakukan proses pembangunan model klasifikasi, selanjutnya adalah melakukan evaluasi performa model dengan *confusion matrix*. *Confusion matrix* digunakan dengan tujuan untuk melakukan evaluasi kinerja metode klasifikasi terkait sejauh mana metode klasifikasi dapat melakukan prediksi data dengan tepat [18].

Tabel 1: Confusion Matrix

Actual Class	Predict Class	
	Positive (P)	Negative (N)
Positive (P)	True Positive (TP)	False Positive (FP)
Negative (N)	False Negative (FN)	True Negative (TN)

Dari nilai-nilai yang terdapat pada *confusion matrix*, maka selanjutnya dapat dihasilkan nilai yang digunakan untuk melakukan evaluasi metode pengklasifikasian, yakni nilai *accuracy*, *precision*, *recall*, dan *f1-score* [19].

Nilai *accuracy*, *precision*, *recall*, dan *f1-score* dapat dihitung melalui Persamaan (5-8).

$$Accuracy = \frac{TN+TP}{TN+TP+FN+FP} \quad (5)$$

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

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

$$F1-score = \frac{2TP}{2TP+FN+FP} \quad (8)$$

3. HASIL DAN PEMBAHASAN

3.1. Hasil

Pada tahapan ini akan dilakukan implementasi tahapan penelitian, mulai dari pengumpulan data *tweets* sampai evaluasi model menggunakan *confusion matrix*.

1). Pengumpulan Data

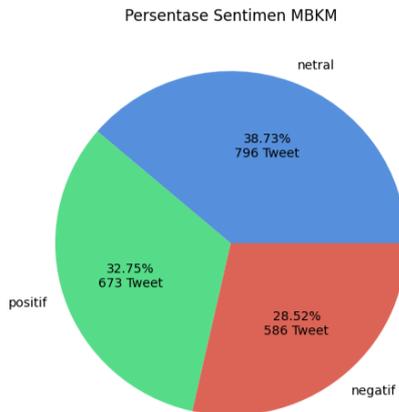
Pengumpulan data dilakukan dengan mengumpulkan data *tweets* pada media social Twitter terkait dengan topik MBKM dengan menggunakan kata kunci dan rentang waktu yang telah ditentukan sebelumnya. Berdasarkan tahapan pengumpulan data, maka didapatkan *tweets* terkait topik MBKM dengan jumlah 4.135 *tweets*.

2). Seleksi Data

Dari hasil pengumpulan data *tweets* sebanyak 4.135 *tweets*, selanjutnya dilakukan proses seleksi sehingga jumlah *tweet* saat ini menjadi 2.055 *tweets*.

3). Pelabelan Data

Selanjutnya diberikan label kelas sentimen netral, negatif, atau positif pada masing-masing *tweet* yang divalidasi oleh dua orang ahli dalam bidang Bahasa Indonesia. Dari total 2.055 *tweets*, didapatkan sentimen netral berjumlah 796 *tweets*, sentimen positif berjumlah 673 *tweets*, dan sentimen negatif berjumlah 586 *tweets*.



Gambar 3. Persentase Jumlah Sentimen

4). *Text-preprocessing*

Proses text-preprocessing terdiri dari *casefolding*, *cleansing*, *tokenizing*, *normalize*, *stopword removal*, dan *stemming*.

a). *Casefolding*

Berikut merupakan hasil proses *casefolding*.

Tabel 2: Hasil *Casefolding*

Sebelum	@wahyukris Program MBKM ternyata benar diimplementasikan secara "merdeka" 😊
Sesudah	@wahyukris program mbkm ternyata benar diimplementasikan secara "merdeka" 😊

b). *Cleansing*

Berikut merupakan hasil proses *cleansing*.

Tabel 3: Hasil *Cleansing*

Sebelum	@wahyukris program mbkm ternyata benar diimplementasikan secara "merdeka" 😊
Sesudah	program mbkm ternyata benar diimplementasikan secara merdeka

c). *Tokenizing*

Berikut merupakan hasil proses *tokenizing*.

Tabel 4: Hasil *Tokenizing*

Sebelum	program mbkm ternyata benar diimplementasikan secara merdeka
Sesudah	['program', 'mbkm', 'ternyata', 'benar', 'diimplementasikan', 'secara', 'merdeka']

d). *Normalize*

Berikut merupakan hasil proses *normalize*.

Tabel 5: Hasil *Normalize*

Sebelum	['program', 'mbkm', 'ternyata', 'benar', 'diimplementasikan', 'secara', 'merdeka']
Sesudah	['program', 'mbkm', 'ternyata', 'benar', 'diimplementasikan', 'secara', 'merdeka']

e). *Stopword Removal*

Berikut merupakan hasil proses *stopword removal*.

Tabel 6: Hasil *Stopword Removal*

Sebelum	['program', 'mbkm', 'ternyata', 'benar', 'diimplementasikan', 'secara', 'merdeka']
Sesudah	['program', 'mbkm', 'diimplementasikan', 'merdeka']

f). *Stemming*

Berikut merupakan hasil proses *stemming*.

Tabel 7: Hasil *Stemming*

Sebelum	['program', 'mbkm', 'diimplementasikan', 'merdeka']
Sesudah	['program', 'mbkm', 'implementasi', 'merdeka']

5). Ekstraksi TF-IDF

Pada tahapan ekstraksi fitur, proses yang akan dilakukan adalah menghitung bobot dari setiap *term* atau kata pada data yang telah melalui tahapan *preprocessing* sebelumnya menjadi sebuah matriks numerik. Tabel 8 merupakan hasil ekstraksi fitur TF-IDF.

Tabel 8: Hasil Ekstraksi TF-IDF

No	abai	abdi	absen	ajar	...	Kampus	mbkm	merdeka	program
D1	7.935	0.000	0.000	0.000	...	1.578	0.000	1.511	1.792
D2	0.000	6.837	0.000	2.595	...	0.000	0.000	3.023	0.000
D3	0.000	0.000	7.935	0.000	...	0.000	1.851	0.000	0.000
D4	0.000	0.000	0.000	5.191	...	1.578	1.851	4.534	1.792
D5	0.000	0.000	0.000	0.000	...	0.000	3.702	0.000	0.000

Keterangan:

D1 = 'program', 'magang', 'kampus', 'merdeka', 'bagus', 'cocok', 'gemar', 'arti', 'iseng', 'lingkung', 'suportif', 'abai', 'internal', 'uang', 'utama', 'lanjut'

D2 = 'merdeka', 'ajar', 'abdi', 'honoror', 'merdeka', 'dilema', 'honoror'

D3 = 'praktikum', 'luring', 'lupa', 'kelas', 'mbkm', 'absen'

D4 = 'terimakasih', 'berkat', 'menteri', 'nadiem', 'makarim', 'indonesia', 'inovator', 'didik', 'program', 'merdeka', 'ajar', 'kampus', 'merdeka', 'mbkm', 'bangga', 'menteri', 'didik', 'budaya', 'riset', 'teknologi', 'merdeka', 'ajar'

D5 = 'ambil', 'mbkm', 'nyesal', 'jadwal', 'mbkm', 'matakuliah', 'wajib', 'stres'

6). Model Klasifikasi

Masing-masing skenario model akan dibangun dengan menggunakan teknik *10-fold cross validations*. Pada tahapan ini dilakukan pengujian terhadap parameter *k* pada metode KNN yang berbeda-beda untuk mengetahui nilai parameter optimal dengan rentangan $k=3$ sampai $k=20$. Dalam menentukan nilai parameter *k*, tidak terdapat syarat yang baku, tetapi nilai parameter *k* sebaiknya melebihi dari jumlah kelas yang ada dan tidak lebih besar dari jumlah data latih [20].

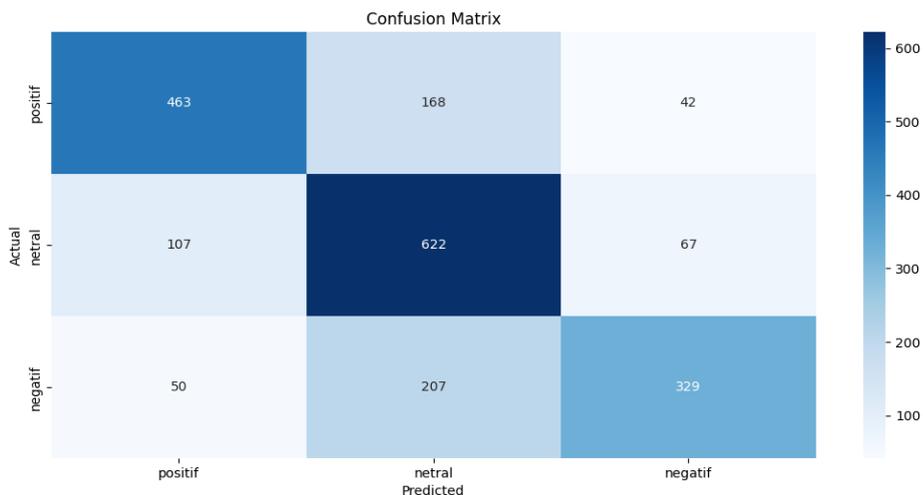
Berikut merupakan hasil performa model skenario pertama, yakni dengan menggunakan metode KNN.

Tabel 9: Hasil Performa KNN

K	Accuracy	Precision	Recall	F1-score
3	0.648	0.655	0.648	0.647
4	0.668	0.677	0.668	0.667
5	0.664	0.673	0.664	0.663
6	0.676	0.688	0.676	0.676
7	0.680	0.693	0.680	0.679

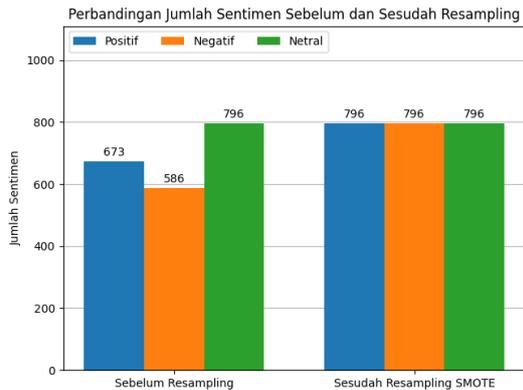
K	Accuracy	Precision	Recall	F1-score
8	0.676	0.688	0.676	0.676
9	0.676	0.690	0.676	0.676
10	0.675	0.687	0.675	0.674
11	0.672	0.682	0.672	0.671
12	0.675	0.685	0.675	0.674
13	0.673	0.684	0.673	0.672
14	0.681	0.691	0.681	0.679
15	0.685	0.698	0.685	0.684
16	0.684	0.697	0.684	0.683
17	0.683	0.695	0.683	0.681
18	0.682	0.695	0.682	0.680
19	0.688	0.703	0.688	0.686
20	0.687	0.703	0.687	0.685

Dilihat dari nilai akurasi yang dihasilkan masing-masing parameter KNN pada Tabel 9, maka parameter yang memiliki nilai optimal adalah $k=19$ dengan nilai *accuracy* 68.81%. Selanjutnya dihitung nilai *confusion matrix* pada parameter $k=19$ yang ditunjukkan pada Gambar 4.



Gambar 4. Confusion Matrix KNN

Selanjutnya, pada skenario model kedua dilakukan optimasi pada metode KNN dengan menerapkan metode SMOTE untuk menyeimbangkan distribusi kelas sentimen.



Gambar 5. Perbandingan Hasil *Resampling*

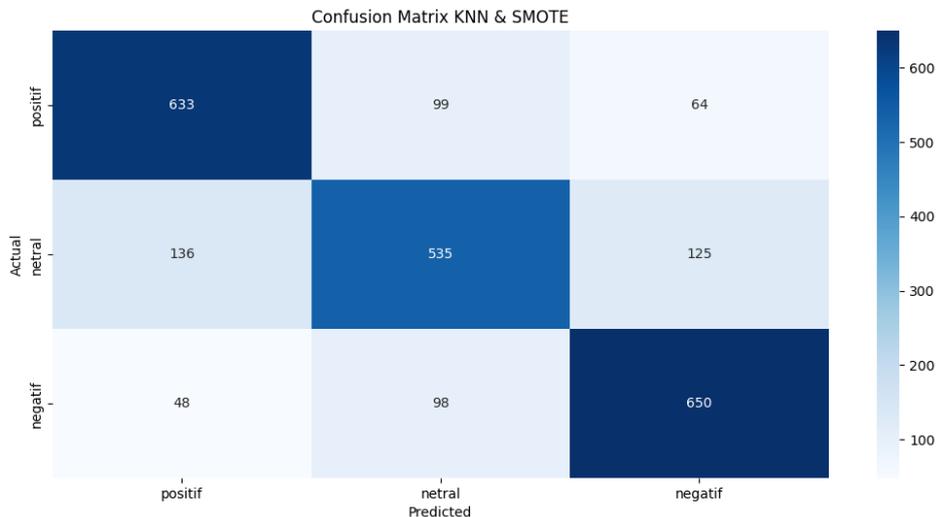
Berdasarkan Gambar 5, setelah dilakukannya proses *resampling*, masing-masing jumlah sentimen menjadi seimbang, yakni dengan jumlah 796 *tweets* pada tiap sentimen. Sehingga saat ini *dataset* berjumlah 2.388 *tweets*. Setelah distribusi data seimbang, maka berikut merupakan hasil pelatihan model optimasi SMOTE.

Tabel 10: Hasil Performa KNN&SMOTE

K	Accuracy	Precision	Recall	F1-score
3	0.727	0.731	0.727	0.727
4	0.731	0.734	0.731	0.730

K	Accuracy	Precision	Recall	F1-score
5	0.735	0.738	0.735	0.734
6	0.738	0.741	0.738	0.737
7	0.743	0.746	0.743	0.742
8	0.745	0.748	0.745	0.745
9	0.745	0.747	0.745	0.743
10	0.750	0.752	0.750	0.749
11	0.750	0.752	0.750	0.749
12	0.752	0.754	0.752	0.750
13	0.754	0.756	0.754	0.752
14	0.753	0.754	0.753	0.751
15	0.761	0.763	0.761	0.760
16	0.757	0.758	0.757	0.756
17	0.758	0.759	0.758	0.757
18	0.756	0.757	0.756	0.755
19	0.757	0.758	0.757	0.755
20	0.754	0.754	0.754	0.752

Dilihat dari nilai akurasi yang dihasilkan masing-masing parameter KNN pada Tabel 10, maka parameter yang memiliki nilai optimal pada metode SMOTE adalah $k=15$ dengan nilai *accuracy* sebesar 76.13%. Selanjutnya dihitung nilai *confusion matrix* pada parameter $k=15$ yang ditunjukkan pada Gambar 6 berikut.



Gambar 6. *Confusion Matrix* KNN&SMOTE

Dapat dilihat pada Gambar 6 bahwa dari total jumlah *dataset*, data yang dapat diklasifikasikan dengan benar sejumlah 1.818 *tweet*. Model klasifikasi dapat dengan benar memprediksi sejumlah 633 *tweets* negatif, 535 *tweets* netral, dan 650 *tweets* positif.

3.2. Pembahasan

Berdasarkan proses pelatihan model klasifikasi, dilakukannya dua buah skenario pelatihan model dikarenakan terdapat

ketidakseimbangan data. Adanya permasalahan data tidak seimbang dikhawatirkan berdampak terhadap performa model yang dilatih, oleh karena itu diusulkannya skenario kedua, yakni dengan mengimplementasikan teknik *resampling*, khususnya *oversampling* pada *dataset* dengan metode SMOTE.

Hasil evaluasi model pada skenario pertama menunjukkan bahwa kesalahan klasifikasi model paling banyak terjadi pada sentimen negatif yang diklasifikasikan secara tidak tepat sebagai

sentimen positif dan netral, sehingga nilai *recall* menjadi sangat rendah, yakni 56.14%. Selain itu, kesalahan klasifikasi juga terjadi pada sentimen positif dan negatif yang diklasifikasikan secara tidak tepat sebagai sentimen netral, sehingga nilai *precision* dari sentimen netral menjadi rendah, yakni sebesar 62.39%.

Kesalahan yang terjadi pada model klasifikasi KNN paling banyak dialami pada kelas sentimen negatif dan netral. Hal ini disebabkan oleh ketidakseimbangan jumlah kelas sentimen. Adanya data tidak seimbang cenderung menyebabkan kesalahan prediksi terjadi pada kelas minoritas dan akan bias terhadap kelas mayoritas. Oleh karena itu, model KNN cenderung tidak dapat melakukan prediksi dengan tepat pada kelas sentimen negatif dan cenderung berfokus pada kelas sentimen netral.

Berdasarkan kasus tersebut, maka dilakukannya optimasi pada model klasifikasi dengan menerapkan teknik *resampling* menggunakan pendekatan *oversampling* untuk menyamakan distribusi jumlah masing-masing kelas sentimen sehingga model dapat lebih optimal dalam melakukan prediksi *tweets*. Tabel 11 berikut merupakan perbandingan performa antara model KNN dan SMOTE.

Tabel 11: Perbandingan Performa Model

Performa	KNN	SMOTE	Peningkatan
<i>Accuracy</i>	68.81%	76.13%	7.32%
<i>Precision</i>	70.04%	76.01%	5.97%
<i>Recall</i>	68.81%	76.13%	7.32%
<i>F1-Score</i>	68.65%	76.01%	7.36%
Rata-Rata			6.99%

Tabel 11 menunjukkan bahwa terjadi peningkatan performa model setelah dilakukannya *resampling* dengan SMOTE. Nilai *accuracy* yang awalnya 68.81% meningkat sebesar 7.32% menjadi 76.13%. Nilai *precision* yang awalnya 70.04% meningkat sebesar 5.97% menjadi 76.01%. Nilai *recall* yang awalnya 68.81% meningkat sebesar 7.32% menjadi 76.13%. Dan nilai *f1-score* yang awalnya 68.65% meningkat sebesar 7.36% menjadi 76.01%. Hal ini menandakan bahwa teknik *resampling* SMOTE berhasil meningkatkan performa model klasifikasi dengan rata-rata peningkatan performa sebesar 6.99%.

Berdasarkan *tweets* terkait topik program MBKM yang berhasil dikumpulkan, berikut merupakan visualisasi sentimen masyarakat terhadap program MBKM.



Gambar 7. Word Cloud Sentimen Positif

Gambar 7 menunjukkan visualisasi *word cloud* pada sentimen positif. Kata yang paling sering muncul pada sentimen positif adalah “mahasiswa”, “keren”, “bagus”, “magang”, “semester”, “senang”, dan “pengalaman”.



Gambar 8. Word Cloud Sentimen Netral

Gambar 8 menunjukkan visualisasi *word cloud* pada sentimen netral. Kata yang paling sering muncul pada sentimen netral adalah “magang”, “semester”, “studi independen”, “msib”, “sks”, dan “mahasiswa”.



Gambar 9. Word Cloud Sentimen Negatif

Gambar 9 menunjukkan visualisasi *word cloud* pada sentimen negatif. Kata yang paling sering muncul pada sentimen negatif adalah “magang”, “semester”, “konversi”, “matakuliah”, “anjing”, “ribet”, dan “mahasiswa”.

Secara keseluruhan, respon masyarakat terhadap program Merdeka Belajar-Kampus Merdeka (MBKM) menunjukkan bahwa kelas sentimen netral memiliki jumlah yang paling banyak yakni sebesar 796 *tweet*, hal ini berarti respon masyarakat cenderung bersikap netral terhadap program MBKM.

4. KESIMPULAN

Berdasarkan hasil klasifikasi model, penggunaan metode SMOTE terbukti dapat meningkatkan performa pada metode KNN. Model yang awalnya memiliki nilai *accuracy* sebesar 68.81%, *precision* sebesar 70.73%, *recall*

sebesar 68.81% dan *f1-score* sebesar 68.42%, setelah dioptimasi terjadi peningkatan *accuracy* sebesar 7.32% menjadi 76.13%, *precision* sebesar 5.97% menjadi 76.03%, *recall* sebesar 7.32% menjadi 76.13% dan *f1-score* sebesar 7.36% menjadi 76.01%.

Berdasarkan data sentimen MBKM pada media sosial Twitter dalam rentang waktu 9 Februari 2021 hingga 17 maret 2022 menunjukkan bahwa respon masyarakat cenderung bersikap netral.

Untuk menunjang penelitian pada masa mendatang, maka saran yang dapat dipertimbangkan adalah penelitian selanjutnya dapat menerapkan metode seleksi fitur untuk menyeleksi beberapa fitur yang tidak relevan dan kurang memberikan pengaruh yang signifikan sehingga diharapkan dapat meningkatkan performa metode klasifikasi dalam menangani kasus klasifikasi teks.

DAFTAR PUSTAKA

- [1] L. W. Santoso dan Yulia, "Predicting Student Performance in Higher Education using Multi-Regression Models," *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 18, no. 3, hal. 1354–1360, 2020, doi: 10.12928/TELKOMNIKA.v18i3.14802.
- [2] Dirjen Pendidikan Tinggi Kementerian Pendidikan dan Kebudayaan, "Buku Panduan MBKM," *Buku Pandu. Merdeka Belajar-Kampus Merdeka*, hal. 1–42, 2020.
- [3] I. B. G. Sarasvananda, D. Selivan, M. L. Radhitya, dan I. N. T. A. Putra, "Analisis Sentimen Pada Pembelajaran Daring di Indonesia Melalui Twitter Menggunakan Naïve Bayes Classifier," *SINTECH (Science Inf. Technol. J.*, vol. 5, no. 2, hal. 227–233, 2022.
- [4] M. Singh dan S. Gupta, "Sentiment Analysis using Naive Bayes Classifier and Information Gain Feature Selection over Twitter," *Int. J. Comput. Trends Technol.*, vol. 68, no. 5, hal. 84–91, 2020, doi: 10.14445/22312803/ijctt-v68i5p117.
- [5] M. Siti dan A. B. Pohan, "Sentiment Analysis Against the Dana E-Wallet on Google Play Reviews Using the K-Nearest Neighbor Algorithm," *J. PILAR Nusa Mandiri*, vol. 17, no. 1, hal. 53–58, 2021, [Daring]. Tersedia pada: www.bsi.ac.id
- [6] H. Syahputra, "Sentiment Analysis of Community Opinion on Online Store in Indonesia on Twitter using Support Vector Machine Algorithm (SVM)," *J. Phys. Conf. Ser.*, vol. 1819, no. 1, 2021, doi: 10.1088/1742-6596/1819/1/012030.
- [7] N. S. N. Salam, A. A. Supianto, dan A. R. Perdanakusuma, "Analisis Sentimen Opini Mahasiswa Terhadap Saran Kuesioner Penilaian Kinerja Dosen dengan Menggunakan TF-IDF dan K-Nearest Neighbor," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 6, hal. 6148–6156, 2019, [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/5649>
- [8] A. Salam, J. Zeniarja, dan R. S. U. Khasanah, "Analisis Sentimen Data Komentar Sosial Media Facebook Dengan K-Nearest Neighbor (Studi Kasus Pada Akun Jasa Ekspedisi Barang J&T Ekspres Indonesia)," in *SINTAK*, 2018, hal. 480–486.
- [9] M. W. Pertiwi, "Analisis Sentimen Opini Publik Mengenai Sarana dan Transportasi Mudik Tahun 2019 Pada Twitter Menggunakan Algoritma Naïve Bayes, Neural Network, K-NN dan SVM," *Inti Nusa Mandiri*, vol. 14, no. 1, hal. 27–32, 2019.
- [10] E. H. Muktafin dan P. Kusriani, "Sentiments analysis of customer satisfaction in public services using K-nearest neighbors algorithm and natural language processing approach," *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 19, no. 1, hal. 146–154, 2021, doi: 10.12928/TELKOMNIKA.V19I1.17417.
- [11] A. D. Poernomo dan Suharjo, "Indonesian online travel agent sentiment analysis using machine learning methods," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 14, no. 1, hal. 113, 2019, doi: 10.11591/ijeecs.v14.i1.pp113-117.
- [12] N. P. Y. T. Wijayanti, E. N. Kencana, dan I. W. Sumarjaya, "SMOTE: Potensi dan Kekurangannya Pada Survei," *E-Jurnal Mat.*, vol. 10, no. 4, hal. 235, 2021, doi: 10.24843/mtk.2021.v10.i04.p348.
- [13] S. Maldonado, J. López, dan C. Vairetti, "An Alternative SMOTE Oversampling Strategy for High-dimensional Datasets,"

- Appl. Soft Comput. J.*, vol. 76, hal. 380–389, 2019, doi: 10.1016/j.asoc.2018.12.024.
- [14] A. Nurhopipah dan C. Magnolia, “Perbandingan Metode Resampling Pada Imbalanced Dataset Untuk Klasifikasi Komentar Program MBKM,” *J. Publ. Ilmu Komput. Dan Multimed.*, vol. 1, no. 2, hal. 9–22, 2022.
- [15] J. A. Septian, T. M. Fahrudin, dan A. Nugroho, “Analisis Sentimen Pengguna Twitter Terhadap Polemik Persepakbolaan Indonesia Menggunakan Pembobotan TF-IDF dan K-Nearest Neighbor,” *INSYST J. Intell. Syst. Comput.*, vol. 1, no. 1, hal. 43–49, 2019, [Daring]. Tersedia pada: <https://t.co/9Wl0aWpfd5>
- [16] F. N. Rozi dan D. H. Sulistyawati, “Klasifikasi Berita Hoax Pilpres Menggunakan Metode Modified K-Nearest Neighbor dan Pembobotan Menggunakan Ff-IDF,” *Konvergensi*, vol. 15, no. 1, hal. 1–10, 2019, doi: 10.30996/konv.v15i1.2828.
- [17] W. E. Nurjanah, R. S. Perdana, dan M. A. Fauzi, “Analisis Sentimen Terhadap Tayangan Televisi Berdasarkan Opini Masyarakat pada Media Sosial Twitter menggunakan Metode K-Nearest Neighbor dan Pembobotan Jumlah Retweet,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput. Univ. Brawijaya*, vol. 1, no. 12, hal. 1750–1757, 2017.
- [18] M. I. Ramadhon, “Analisis Sentimen Terhadap Pemindahan Ibu Kota Indonesia Pada Media Sosial Twitter Menggunakan Metode Algoritma K-Nearest Neighbor (K-Nn),” 2020.
- [19] R. A. Bagate dan R. Suguna, “Sarcasm detection of tweets without #sarcasm: Data science approach,” *Indones. J. Electr. Eng. Comput. Sci.*, vol. 23, no. 2, hal. 993–1001, 2021, doi: 10.11591/ijeecs.v23.i2.pp993-1001.
- [20] N. A. Madyaningrum dan Sulastri, “Analisa Prediksi Kekambuhan Kanker Payudara Dengan Menggunakan K-Nearest Neighbor,” *Proceeding SINTAK 2019*, vol. 3, hal. 180–185, 2019.