

ANALISIS SENTIMEN TERHADAP KEBIJAKAN PEMERINTAH DALAM MENANGANI COVID-19 DENGAN PENDEKATAN *LEXICON* BASED

Ferzi Samal Yerzi¹, Yuliant Sibaroni²

^{1,2} Universitas Telkom, Bandung

¹ferzisamyrz@students.telkomuniversity.ac.id, ²yuliant@telkomuniversity.ac.id

Abstrak

Pemerintah sedang gencar mengeluarkan kebijakan-kebijakan yang cukup baru bagi masyarakat Indonesia dalam penanganan penyebaran COVID-19. Banyak masyarakat Indonesia yang memiliki beberapa aspirasi atau opini terkait kebijakan pemerintah tersebut yang ditulis pada platform sosial media *Twitter*. Aspirasi dari masyarakat tersebut dapat kita ambil dan kita ketahui sentimen dari seluruh masyarakat, sehingga dapat melihat kecondongan sentimen dari masyarakat terhadap kebijakan pemerintah tersebut. Banyak metode yang digunakan untuk menentukan sentimen masyarakat tersebut, salah satu cara yang umum dengan menggunakan metode *Support Vector Machine* dan pembobotan TF-IDF. Pada penelitian tugas akhir ini akan dilakukan penambahan fitur dengan metode leksikal yang memanfaatkan nilai polaritas dari kamus leksikal InSet dan Masdevid yang digabungkan dengan pembobotan kata TF-IDF. Dari hasil percobaan dengan menambahkan fitur metode leksikal, kamus InSet dapat meningkatkan akurasi menjadi 83% dibandingkan SVM tanpa penambahan fitur metode leksikal yang menghasilkan akurasi 82%.

Kata kunci : analisis sentimen, *support vector machine*, metode leksikal, covid-19, twitter

Abstract

The government is intensively issuing new policies for the people of Indonesia in handling the spread of COVID-19. Many Indonesians have aspirations or opinions related to the government's policies which are written on the Twitter social media platform. We can take the aspirations of the community and know the sentiments of the whole community, so that we can see the tendency of the sentiments of the people towards the government's policies. Many methods are used to determine the public's sentiments, one of the common ways is using the Support Vector Machine method and TF-IDF weighting. In this final study, additional features will be added using the lexical method that utilizes the polarity values from the InSet and Masdevid lexical dictionaries combined with the TF-IDF word weighting. From the experimental results by adding lexical features, the InSet dictionary can increase the accuracy to 83% compared to SVM without the addition of the lexical method features which produce 82% accuracy.

Keywords: *sentiment analysis, support vector machine, lexical method, covid-19, twitter.*

1. Pendahuluan

Latar Belakang

Dengan berkembangnya teknologi dan internet yang pesat, menggunakan media sosial bukan lah suatu hal yang sulit. Indonesia merupakan salah satu negara yang aktif dalam menggunakan media sosial. Salah satu aplikasi yang semakin hangat digunakan di Indonesia adalah *Twitter*. Pada tahun 2019 Indonesia memiliki 145 juta pengguna aktif *Twitter*[1]. Dengan banyaknya pengguna *Twitter* mulai artis, perusahaan, hingga institusi pemerintahan, banyak pengguna *Twitter* yang menuliskan pendapat atau opini mereka terhadap suatu topik permasalahan.

Topik COVID – 19 (Coronavirus Disease) sedang hangat dibicarakan di platform *Twitter*, adanya kebijakan-kebijakan dalam pemerintah yang cukup kontroversi mengakibatkan banyaknya opini yang disampaikan pada *Twitter*[2]. Dengan banyaknya penyampaian opini tersebut dapat dilakukannya ekstraksi informasi untuk melihat sentimen dari pengguna *Twitter* terhadap kebijakan pemerintah dalam menangani COVID-19. Dengan begitu, kebijakan pemerintah dalam menangani COVID-19 merupakan topik yang menarik untuk dilakukan sentimen analysis dan dibuatkan visualisasi data untuk setiap klasifikasi sentimen tersebut (positif-negatif), sehingga pemerintah dapat mempertimbangkan kembali kebijakan tersebut jika memiliki dominasi sentimen yang negatif.

Analisis sentimen atau *opinion mining* adalah sebuah kegiatan yang dilakukan dengan komputasi dengan pendekatan secara statistik atau pendekatan secara leksikal untuk melakukan analisis emosi, sentimen, atau opini dari seseorang yang umumnya berupa teks[3]. Hasil dari sentimen analisis memiliki tiga klasifikasi, yaitu: Positif, Negatif, dan Netral. Untuk melakukan penelitian dengan pendekatan leksikal, peneliti membutuhkan corpus atau kamus yang berisikan kata-kata yang memiliki arti sentimen dan nilai polaritas dari setiap kata

tersebut, sentimen positif atau negatif umumnya masing-masing ditandai oleh bilangan positif dan bilangan negatif. Penelitian dengan pendekatan leksikal berbahasa Indonesia yang tidak memiliki nilai beban polaritas sentimen. Akurasi yang didapat pada penelitian tersebut lebih baik menggunakan leksikal berbahasa Indonesia dengan akurasi 65.4% [3]. Penelitian dengan menggunakan *Support Vector Machine* dan memanfaatkan fitur leksikal dengan melakukan pembobotan nilai polaritas secara manual. Akurasi yang didapat pada penelitian tersebut adalah 79% [4]. Namun pada kedua penelitian tersebut nilai beban polaritas setiap kata pada leksikal Indonesia dihitung secara manual dimana penelitian pertamadengan menggunakan metode yang sama seperti *Sentiwordnet* sementara pada penelitian kedua menggunakan metode mengambil banyaknya kata yang positif atau negatif dalam suatu kalimat. Untuk menghindari perhitungan manual dalam menentukan nilai polaritas pada setiap kata, sebuah dengan mengambil *tweet* dan membuat kamus leksikal yang diberikan nilai polaritas oleh ahli linguistik dengan nama kamus Masdevid [5]. Riset publikasi kamus leksikal bahasa Indonesia yang memiliki nilai beban polaritas dengan memanfaatkan kata-kata sinonim sebagai penguat nilai polaritas dengan nama kamus InSet[6]. Dengan adanya kamus leksikal tersebut, perhitungan nilai polaritas pada setiap kata tidak dilakukan secara manual, karena pada kamus tersebut sudah terdapat nilai polaritas pada setiap kata, sehingga untuk menggunakan kamus tersebut hanya mengambil nilai-nilai polaritas saja.

Dengan begitu, dalam tugas akhir ini melakukan penelitian analisis sentimen dengan memanfaatkan kamus leksikal berbahasa Indonesia bernama InSet dan Masdevid. Nilai akhir beban polaritas dari kamus dijadikan fitur tambahan dalam model pembelajaran mesin *Support Vector Machine* (SVM) dan melihat pengaruh performansi dari penambahan fitur leksikal. Serta menentukan sistem yang melakukan prediksi terbaik berdasarkan akurasi Dengan menggunakan sistem yang terbaik, dilakukan prediksi menggunakan data yang baru dan melihat perbandingan sentimen masyarakat terhadap kebijakan pemerintah dalam menangani COVID-19. Dengan adanya penelitian ini diciptakan sistem yang dapat melakukan klasifikasi pada *tweet* serta visualisasi data dalam bentuk *wordcloud* pada masing-masing sentimen. Pemerintah dapat melihat kumpulan kata yang sering diucapkan agar dapat melihat kebijakan apa yang memiliki opini positif dan kebijakan yang memiliki sentimen negatif dan diharapkan pemerintah dapat melakukan rekonstruksi kebijakan tersebut jika memiliki sentimen dengan dominasi negatif yang besar. Dipilihnya *Support Vector Machine* dalam penelitian ini karena SVM merupakan salah satu model pembelajaran mesin yang efisien dalam mengolah data teks yang besar[4].

Metode dalam penelitian ini dilakukan dengan cara memanfaatkan kamus leksikal bahasa Indonesia yang memiliki polaritas untuk menentukan nilai polaritas pada setiap kalimat, dimana nilai tersebut dijadikan sebagai fitur tambahan dan TF-IDF sebagai fitur pembobotan kata dengan model pembelajaran mesin *Support Vector Machine*.

2. Studi Terkait

Pendekatan leksikon merupakan pendekatan analisis sentimen yang melibatkan perhitungan kata atau frasa yang muncul pada sebuah kalimat atau teks[7]. Diperlukan kamus leksikal yang berisikan kata-kata positif dan negatif untuk menjadi acuan perhitungan kata atau frasa tersebut. Indonesia memiliki beberapa kamus leksikal yang disebarluaskan secara publik untuk kebutuhan penelitian. Dengan metode seperti *Sentiwordnet* terbentuk kamus leksikal yang terbagi menjadi corpus positif dan negatif yang tidak memiliki nilai polaritas dengan nama kamus Vania [8]. Penggunaan kamus leksikal yang tidak memiliki polaritas cukup terbatas dan membutuhkan perhitungan manual dalam memberikan nilai polaritas setiap kata, maka ahli linguistik Universitas Gadjah Mada melakukan publikasi data berupa kamus leksikal yang memiliki nilai polaritas dengan nama kamus Masdevid [5]. Indonesia memiliki beragam kata-kata sinonim yang memiliki arti berlawanan, sehingga terbentuk kamus leksikal yang memanfaatkan sinonim dari sebuah kata dalam pemberian nilai polaritas, sehingga menghasilkan kamus leksikal yang memiliki kata lebih banyak dengan nama kamus InSet[6]. Kamus leksikal yang sudah diciptakan dapat digunakan pada analisis sentimen dalam memberikan sentimen pada suatu kalimat.

Analisis sentimen merupakan cabang dari teks klasifikasi yang memiliki output berupa klasifikasi suatu topik atau pembahasan menjadi dua sentimen yaitu, positif dan negatif [9]. Hasil klasifikasi positif didapat dari kata-kata yang berbentuk rasa suka, gembira, dan kejutan dengan hasil nilai beban polaritas tiap kata adalah diatas nol. Sementara klasifikasi negatif didapat dari kata-kata yang memiliki nilai beban polaritas di bawah nol, seperti kata-kata yang membentuk sebuah opini kemarahan, kesedihan, dan rasa takut[10]. Analisis sentimen dapat dilakukan dengan cara leksikal atau *rule based* atau menggunakan secara *statistical* dengan bantuan pembelajaran mesin atau bisa menggabungkan kedua cara tersebut dimana *rule based* digunakan sebagai fitur pada sistem pembelajaran mesin yang akan dibuat.

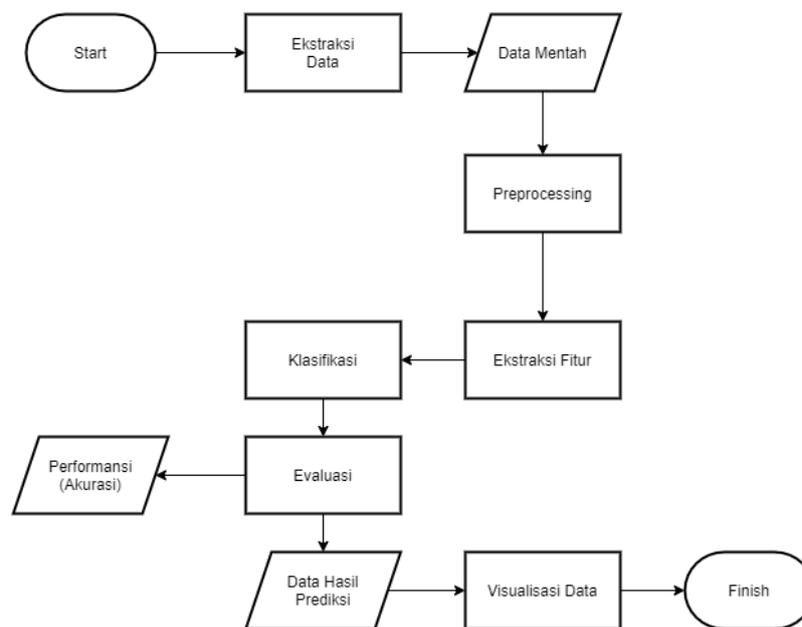
Penelitian dengan topik bahasan pengaduan publik kepada pemerintah dengan memanfaatkan kamus leksikal milik Vania dan menerapkan perhitungan seperti *sentiwordnet* mendapatkan akurasi sebesar 65.4% [3]. Dengan adanya nilai polaritas tersebut, peneliti lainnya dapat memanfaatkan nilai tersebut sebagai fitur tambahan sebagai data input pada klasifikasi *machine learning*. penelitian dengan topik pembahasan keluhan provider telepon seluler yang memanfaatkan metode leksikal dengan kamus leksikal yang diberikan nilai polaritas secara manual sebagai fitur dan *Support Vector Machine* sebagai model klasifikasi, mendapatkan akurasi sebesar 79% [4]. Penelitian dengan topik bahasan kebijakan pemerintah dalam menangani penyebaran

coronavirus dengan tidak menambahkan metode leksikal sebagai fitur tambahan dan menggunakan mesin klasifikasi *Support Vector Machine* mendapatkan akurasi sebesar 68.89% [11]. Penelitian dengan topik bahasan layanan ojek online yang memanfaatkan kamus leksikal Masdevit dan mesin klasifikasi *Support Vector Machine* mendapatkan akurasi sebesar 89% [12].

Pada penelitian Tugas Akhir ini sistem yang dibangun adalah sistem yang dapat melakukan klasifikasi pada kalimat dari *tweet* dari platform sosial media *Twitter* menggunakan kamus leksikal InSet sebagai fitur tambahan dan SVM sebagai model klasifikasi yang dibandingkan dengan kamus leksikal Masdevit sebagai fitur tambahan dan SVM sebagai model klasifikasi.

3. Sistem yang Dibangun

Tahap ini merupakan penjelasan dari sistem. Sistem yang dibangun merupakan sistem yang dapat melakukan klasifikasi terhadap kumpulan *tweet* yang sudah didapat, dimana tahap yang dilakukan adalah: (1) Ekstraksi Data, (2) *Preprocessing*, (3) Ekstraksi Fitur, (4) Klasifikasi Sentimen, (5) Evaluasi, dan (6) Visualisasi Data,



Gambar 1. Flowchart Sistem

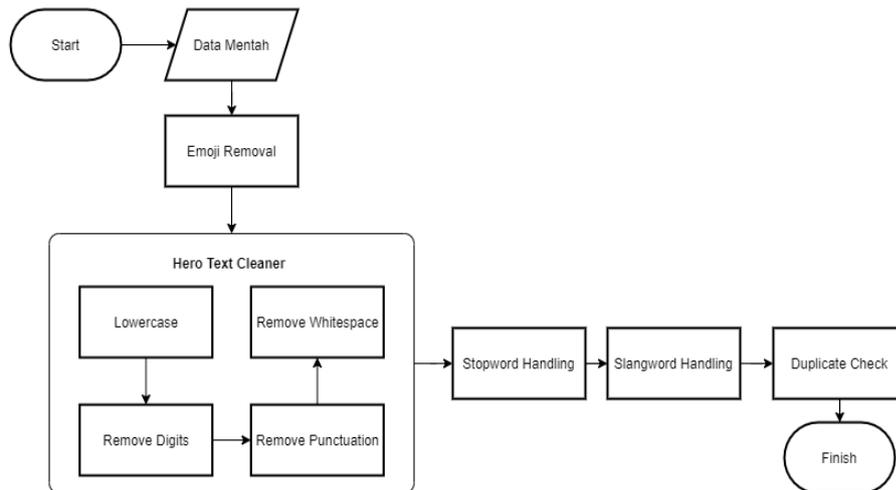
Berikut penjelasan rinci dari flowchart pada Gambar 1 yang merupakan proses inti dari penelitian tugas akhir ini:

1. Ekstraksi Data

Ekstraksi data atau pengumpulan data dilakukan dengan cara mengambil data dari *twitter* menggunakan *library python* yang bernama *Twint*. Pengumpulan data dilakukan dari bulan Februari 2021 - Mei 2021, dan mendapatkan data sebanyak 2104 *tweet*. Setelah itu dilakukan pelabelan secara manual oleh tiga orang mahasiswa dengan jurusan Sastra Indonesia, Universitas Negeri Jakarta dengan sistem *vote* atau memilih nilai terbanyak jika terjadi pelabelan sentimen yang sama. Jumlah *tweet* dengan label atau klasifikasi positif (dengan angka 1) sebanyak 1057 *tweet*, sementara untuk klasifikasi negatif (dengan angka 0) sebanyak (1047) *tweet*.

2. Preprocessing

Preprocessing adalah salah satu tahap untuk melakukan klasifikasi data pada penelitian analisis sentimen. Data yang sudah diambil dari platform *Twitter* merupakan data mentah yang harus dilakukan pembersihan. Menggunakan data mentah untuk melakukan klasifikasi akan menurunkan kualitas sistem yang dihasilkan. Data yang sudah bersih akan mempermudah dan meningkatkan performansi sistem. Tahap *preprocessing* pada penelitian ini memiliki beberapa tahap seperti yang digambarkan pada *flowchart preprocessing* pada Gambar 2:



Gambar 2. Flowchart Preprocessing Sistem

- **Emoji Removal**, *Emoji* atau *emoticon* merupakan icon untuk memberikan kesan emosi dari penulis *tweet*, namun pada penelitian kali ini, emoji tidak digunakan, karena pada *Twitter* sekarang emoji tidak lagi diartikan sebagai emosional dari penulis *tweet* tersebut.
 - **Hero Text Cleaner** merupakan *library python* yang dapat melakukan penanganan *preprocessing* umum secara otomatis[13], penggunaan *library* ini dapat memudahkan dan mempercepat proses *preprocessing* umum seperti berikut:
 - *Lowercase* merupakan tahap dihilangkannya huruf kapital seperti kapital pada awal kalimat atau kapital pada sebuah singkatan, contohnya “PPKM” menjadi “ppkm”
 - *Remove digits* merupakan tahap dihilangkannya seluruh angka pada sebuah teks, contohnya “*covid19*” menjadi “*covid*”.
 - *Remove punctuation* merupakan tahap dihilangkannya tanda baca pada sebuah teks, seperti koma, titik, tanda seru, *strip*, tanda kutip, dsb. Contohnya “*Covid-19*” menjadi “*Covid19*”
 - *Remove Whitespace* merupakan tahap dihilangkannya *space* atau jarak antar kata, jika terdapat jarak yang berlebih, contohnya “*covid bikin saya sakit*” menjadi “*covid bikin saya sakit*”
 - **Slang Word handling** merupakan kata-kata yang tidak baku atau singkatan seperti “tdk, kmn, aja” menjadi “tidak, kemana, saja”. Tahap ini dilakukan karena *tweets* umumnya tidak menggunakan kata baku, sehingga menghindari terjadinya kerancuan arti. Pada penelitian ini kumpulan kata yang didapat merupakan dari kamus *slang word indonesia*.
 - **Stopword Removal** merupakan tahap untuk menghilangkan kata yang sangat umum digunakan tetapi tidak memiliki makna sentimen sama sekali seperti “di, dari, kapan, yang, ke”, dsb
 - **Duplicate Check**. Pada tahap ini, data mentah sering ditemukan data yang duplikat, pada penelitian ini cara mengecek data duplikat adalah mencari data atau *tweet* yang memiliki penulisan yang sama, dimana acuan dari duplikat adalah *tweet* bukan dari *username*.
3. Ekstraksi Fitur
- Ekstraksi Fitur adalah pemilihan ciri pada sebuah dokumen atau data, yang dimana nilai dari ekstraksi fitur tersebut akan digunakan sebagai data input dalam sistem yang akan digunakan. Ekstraksi fitur pada teks analisis merupakan data berbentuk teks dan diubah menjadi data numerik dan menjadi fitur set dalam bentuk vektor atau *sparse matrix* yang dapat berguna bagi *classifier*[14][15]. Fitur set yang digunakan pada penelitian kali ini adalah TF-IDF Unigram dimana data pada satu kalimat dipecah menjadi satu-satuan kata seperti “*Budi makan nasi*” menjadi “*Budi*”, “*makan*”, “*nasi*”. Fitur tambahan atau fitur skor yang terdiri dari kumpulan nilai polaritas dengan metode leksikal berdasarkan kamus InSet dan Masdevid. Untuk melakukan klasifikasi pada sistem yang dibangun, dibutuhkan data input untuk klasifikasinya. Data input tersebut merupakan fitur-fitur yang akan dibentuk, pada penelitian ini fitur yang digunakan adalah TF-IDF sebagai pembobotan kata dan metode leksikal menggunakan kamus leksikal bahasa Indonesia sebagai fitur tambahan.

- TF-IDF

Analisis sentimen memiliki data mentah berbentuk teks, data teks ini tidak dapat dibaca langsung oleh komputer, sehingga diperlukan sebuah metode yang mengubah data yang berawal berbentuk teks menjadi sekumpulan angka yang dapat diproses oleh komputer atau sistem[16]. Salah satu metode yang digunakan adalah dengan memberi bobot pada teks dengan *Term Frequency Inverse Document Frequency (TF-IDF)*. Pada tahap TF-IDF akan dilakukan perhitungan bobot dari setiap kata pada *tweet*. Perhitungan TF-IDF dilakukan secara dua tahap yaitu TF (*Term Frequency*) yang menghitung berapa banyak *term* atau kata pada suatu dokumen muncul dan IDF (*Inverse Document Frequency*) perhitungan untuk melihat bagaimana istilah tersebut disebarakan secara luas dalam suatu dokumen. Contoh penerapan TF-IDF pada *tweet* yang sudah dilakukan *preprocessing* adalah sebagai berikut :

tw1: budi harap ppkm sukses
 tw2: budi orang sukses
 tw3: budi sakit

Untuk melakukan perhitungan TF atau menghitung istilah yang sering muncul dapat memecah kata tersebut menjadi satu kata, sehingga menghasilkan ‘budi’, ‘harap’, ‘ppkm’, ‘sukses’, ‘orang’, ‘sakit’. kemudian untuk melakukan perhitungan TF dapat dilakukan seperti pada Tabel 1:

Tabel 1. Hasil Perhitungan TF-IDF

Token Tweet	TF			IDF	TF-IDF		
	tw1	tw2	tw3		tw1	tw2	tw3
budi	1	1	1	1	1	1	1
harap	1	0	0	1,3013	1,3013	0	0
ppkm	1	0	0	1,3013	1,3013	0	0
sukses	1	1	0	1,1249	1,1249	1,1249	0
orang	0	1	0	1,3013	0	1,3013	0
sakit	0	0	1	1,3013	0	0	1,3013

Untuk melakukan perhitungan TF atau menghitung istilah yang sering muncul dapat memecah kata tersebut menjadi satu kata, sehingga menghasilkan ‘budi’, ‘harap’, ‘ppkm’, ‘sukses’, ‘orang’, ‘sakit’. kemudian untuk melakukan perhitungan TF , IDF dapat dihitung dengan menggunakan Persamaan (1):

$$IDF = \log \left(\frac{1 + D}{1 + df(t)} \right) + 1 \tag{1}$$

Dimana D merupakan banyaknya *tweet* atau tw dan df(t) merupakan nilai total dari term atau istilah pada masing-masing dokumen. Nilai dari TF-IDF ini disimpan dan selanjutnya akan digabungkan dengan nilai dari metode leksikal. Fitur yang didapat dari melakukan tahap TF-IDF diatas adalah enam fitur atau banyaknya kata atau term yang diterapkan pada proses TF-IDF tersebut.

- Metode Leksikal

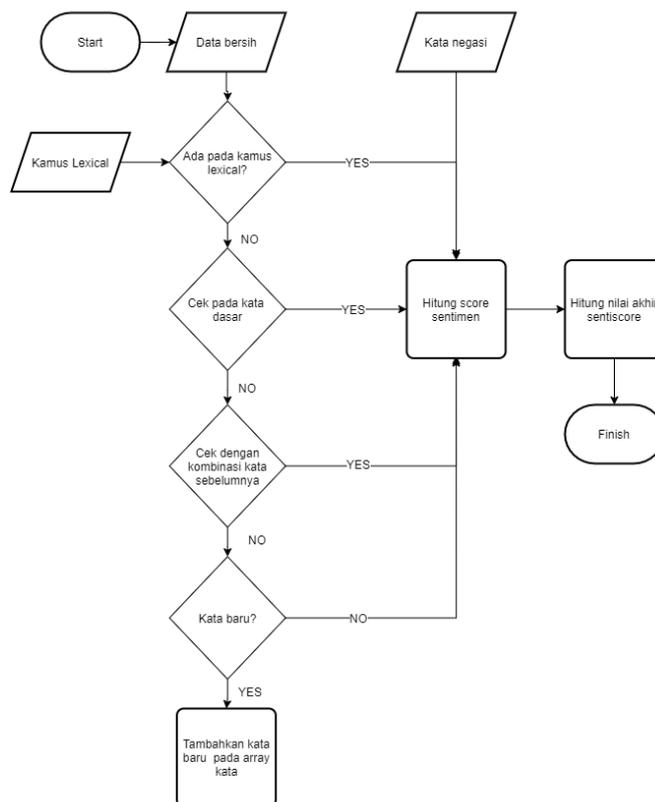
Metode leksikal merupakan salah satu metode yang digunakan untuk klasifikasi yang memiliki acuan dari nilai sentimen atau nilai polaritas dari teks, beberapa penelitian menggunakan metode leksikal untuk melakukan klasifikasi pada suatu teks, namun pada penelitian ini menggunakan metode leksikal akan digunakan sebagai fitur tambahan. Untuk menerapkan metode leksikal memerlukan kamus leksikal yang berisi kumpulan kata-kata atau kalimat yang sudah dipisah berdasarkan sentimennya(negatif atau positif). Kamus leksikal bahasa Indonesia pada penelitian ini menggunakan kamus *Indonesia Sentiment(InSet)* milik Koto Fajri dan Masdevid yang sudah memiliki nilai polaritas. Kedua kamus leksikal merupakan hasil dari menarik data *Twitter*, dimana Kamus leksikal Koto Fajri memberi nilai polaritas secara manual yang diperkuat dengan membandingkan kata sinonim pada suatu kata tersebut. Kamus leksikal Masdevid memberi nilai polaritas secara manual yang dikerjakan oleh kelompok ahli linguistik Universitas Gajah Mada. Kedua kamus leksikal memiliki dataset kata positif dan negatif, dimana memiliki nilai polaritas dari -5 (sangat negatif) dan +5 (sangat positif). Tabel 2 dan Tabel 3 merupakan contoh kata-kata serta nilai sentimen pada masing-masing kamus.

Tabel 2. Contoh Kamus InSet

Kata	Nilai sentimen (polarity)
hai	3
sesal	-4
sakit	-5
sukses	3
harap	3

Tabel 3. Contoh Kamus Masdevid

Kata	Nilai sentimen (polarity)
abadi	5
absen	-3
aman	4
anarki	-5
sakit	-4



Gambar 3 Flowchart Perhitungan Sentimen Score

Pada flowchart Gambar 3 perhitungan nilai sentimen diawali dengan hasil dari data preprocessing kemudian data tersebut dilakukan pengecekan pada setiap kalimat dan kata pada kamus leksikal, jika ada maka akan disimpan pada array dan kemudian akan dilakukan perhitungan score sentimen, lalu mempertimbangkan juga kata dasar pada kata yang digunakan. Perhitungan *score sentiment* dilakukan dengan cara menjumlahkan setiap nilai sentimen setiap kata pada satu kalimat, dan perhitungan nilai akhir skor menggunakan rumus pada Persamaan 2 dengan contoh penerapan pada Tabel 4 dan Tabel 5

$$\text{Nilai Polaritas} = \frac{Nlx}{Nw} \quad (2)$$

Dimana :

Nlx : Jumlah nilai polaritas

Nw : Jumlah kata yang memiliki nilai polaritas

Tabel 4. Hasil Perhitungan Nilai Polaritas InSet

	Token Tweet				Nilai Polaritas
	budi	harap	ppkm	sukses	
Polarity Kamus InSet	0	3	0	3	3

Tabel 5. Hasil Perhitungan Nilai Polaritas Masdevid

	Token Tweet				Nilai Polaritas
	budi	harap	ppkm	sukses	
Polarity Kamus Masdevid	0	0	0	4	4

Jadi, nilai polaritas dari *tweet* tw1 adalah tiga, dari polaritas tersebut akan digabungkan dengan TF-IDF untuk dijadikan data input klasifikasi. Fitur yang digunakan sebanyak tujuh fitur dimana enam fitur berasal dari TF-IDF dan satu fitur terdapat dari perhitungan nilai polaritas.

4. Klasifikasi

Pada penelitian ini, klasifikasi untuk menentukan *class* pada *tweet* menggunakan *classifier* berbasis pembelajaran mesin. *Support Vector Machine* yang merupakan salah satu metode yang digunakan untuk klasifikasi yang cukup efisien dalam masalah non-linear [12]. Dipilihnya *Support Vector Machine* dalam penelitian ini karena, SVM merupakan salah satu model pembelajaran mesin yang efisien dalam mengolah data teks yang besar. Cara kerja SVM adalah dengan menemukan *hyperplane* terbaik dengan cara memaksimalkan margin, dimana *hyperplane* adalah garis pemisah antara dua *class* dan margin adalah jarak antar *class*.

SVM hanya mencari satu *hyperplane* yang tepat di tengah-tengah antar dua *class*. Memaksimalkan margin dilakukan agar memiliki kemampuan generalisasi yang tinggi terhadap data yang baru[12]. Sebelum menghitung margin, terlebih dahulu menentukan kernel yang digunakan. Pada penelitian kali ini, Kernel yang digunakan adalah kernel linear, karena data yang digunakan dapat diklasifikasi secara binary atau linear (1 dan 0) [12]. Kernel linear dapat dirumuskan dengan persamaan pada Persamaan 3 :

$$K(x_i x_j) = x_i^T x_j \quad (3)$$

Support Vector Machine merupakan sebuah pembelajaran mesin yang fokus terhadap pembagian menggunakan *hyperplane* dengan maksimum margin, dimana titik terluar pada margin tersebut merupakan sebuah atau banyak data yang disebut dengan *support vector*. Pada pencarian nilai *support vector* dan mendapatkan *hyperplane* terbaik dapat dengan memaksimalkan atau meminimalkan nilai persamaan *Lagrange Multiplier* atau perkalian Lagrange yang ditulis pada Persamaan 4 :

$$\min L = \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i \cdot x_j - \sum_{i=1}^n a_i \quad (4)$$

Dengan syarat $a_i \geq 0$, $\sum_{i=1}^n a_i y_i = 0$.

Dimana $\{x_1, \dots, x_n\}$ merupakan data input pada sistem dan $y_i \in \{+1, -1\}$ merupakan label kelas pada data latih. Dengan mengacu pada syarat dimana yang disebut sebagai *support vector* adalah $a_i \geq 0$ maka $a_i = 0$ bukan merupakan *support vector*. Selanjutnya dapat mencari nilai bobot atau *weight*(w) dan nilai (b) dengan Persamaan 5 dan Persamaan 6:

$$w = \sum_{i=1}^m a_i y_i x_i \quad (5)$$

dan

$$b = y_i - (w^T \cdot x_i) \quad (6)$$

. Setelah mendapatkan seluruh nilai, kelas pada data uji dapat berdasarkan perhitungan dari Persamaan 7 :

$$f(x) = \sum_{i=1, x_i \in SV}^n a_i y_i K(x, x_i) + b \quad (7)$$

Dimana SV merupakan *support vector* dan data sebanyak l . Apabila hasil dari nilai $f(x)$ tersebut merupakan bilangan positif maka data point tersebut diklasifikasikan sebagai nilai dengan sentimen positif, jika hasil dari $f(x)$ adalah negatif maka data point tersebut memiliki sentimen negatif. Rasio data yang digunakan pada system ini adalah 8:2 untuk masing-masing data training dan data testing.

5. Evaluasi

Evaluasi dibutuhkan untuk mengetahui performansi dari sistem yang sudah dibangun. Metode evaluasi yang digunakan adalah *confusion matrix* yang merupakan metode evaluasi yang memiliki visualisasi data dalam bentuk matrik untuk melihat performansi dari dua kategori *class*. Tahap evaluasi merupakan tahap untuk mengukur performansi sistem yang dibuat, nilai akhir dari tahap evaluasi adalah akurasi, dimana akurasi digunakan sebagai acuan karena mengukur rasio data prediksi dengan jumlah seluruh data yang digunakan [17], dimana cukup mewakili dalam kasus analisis sentimen. Pengukuran evaluasi dilakukan dengan cara menghitung berdasarkan data testing yang berhasil ditebak oleh sistem. Tabel 6 merupakan cara menghitung akurasi pada sistem

Tabel 6. Perhitungan Akurasi

Komponen Confusion Matrix	Deskripsi	Hasil
TP	Jumlah <i>tweet</i> positif yang diprediksi benar oleh sistem	2
TN	Jumlah <i>tweet</i> negatif yang diprediksi benar oleh sistem	1

FP	Jumlah <i>tweet</i> negatif yang diprediksi sebagai <i>tweet</i> positif oleh sistem	1
FN	Jumlah <i>tweet</i> positif yang diprediksi sebagai <i>tweet</i> negatif oleh sistem	1
Akurasi	$\frac{TP + TN}{TN + TP + FP + FN}$	0.6

Dari Tabel 6 dapat kita ketahui bahwa akurasi model yang dibuat memiliki nilai sebesar 0.6 atau dalam persen adalah 60%.

6. Visualisasi Data

Visualisasi data adalah salah satu teknik untuk merepresentasikan data agar mudah dipahami oleh banyak orang. Pada penelitian ini, visualisasi data yang digunakan adalah *Word Cloud* dan *Pie Chart*. *Word Cloud* merepresentasikan jumlah banyaknya kata yang paling sering muncul pada dataset, dimana semakin besar kata tersebut ditulis, maka semakin sering kata tersebut muncul. *Pie Chart* merepresentasikan perbandingan jumlah *tweet* positif dan *tweet* negatif.

4. Eksperimen dan Evaluasi

Pada bab ini akan dijelaskan performansi dari sistem yang dibentuk, dimana setelah melakukan input, sistem dapat melakukan klasifikasi data menjadi dua *class* yaitu +1 sebagai sentimen positif dan -1 sebagai sentimen negatif dengan menggunakan *Support Vector Machine* sebagai *classifier*, sementara untuk data input merupakan TF-IDF dan metode leksikal digunakan sebagai fitur tambahan. Perbandingan dalam pengujian ini adalah model SVM yang hanya menggunakan TF-IDF sebagai data input.

4.1 Hasil Pengujian

Hasil perbandingan dari performansi *Support Vector Machine* yang menggunakan dua fitur yaitu, TF-IDF dan Metode Leksikal dengan kamus milik Koto Fajri dan Masdevid dan *Support Vector Machine* yang hanya menggunakan satu fitur TF-IDF. Pada perbandingan terhadap ketiga sistem tersebut data yang digunakan sebanyak 2.104 dengan 1.057 data dengan label positif dan 1.047 data dengan label negatif. pembagian data training-testing masing-masing sebesar 80% dan 20%. Fitur yang digunakan sebanyak 5.988 pada TF-IDF tanpa kamus leksikal dan 5.989 pada fitur yang memiliki kamus leksikal, dengan parameter C sebesar satu serta menggunakan kernel linear. Pada Tabel 7 merupakan perbandingan performansi pada sistem.

Tabel 7. Hasil Performansi Sistem

Fitur SVM	Akurasi(%)
TF-IDF	82%
TF-IDF + Kamus Masdevid	82%
TF-IDF + Kamus InSet	83%

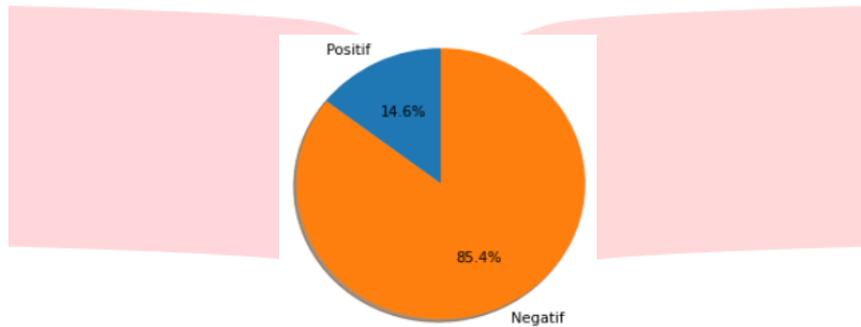
Pada Tabel 7 dijelaskan bahwa *Support Vector Machine* dengan dua fitur yaitu TF-IDF dan Metode Leksikal memiliki performansi lebih baik, dimana leksikal dengan kamus InSet memiliki performansi terbaik menghasilkan. Akurasi yang didapat oleh sistem dengan menggunakan fitur tambahan Kamus InSet adalah sebesar 83%. Dengan melakukan perbandingan akurasi tersebut, SVM dengan fitur TF-IDF dan Kamus InSet dipilih menjadi model yang digunakan pada data baru. Gambar 4 dan 5 merupakan visualisasi data dari data hasil prediksi menggunakan sistem atau model yang sudah dipilih. Gambar 6 merupakan hasil perbandingan sentimen masyarakat.



Gambar 4. Wordcloud Tweet Positif



Gambar 5. Wordcloud Tweet Negatif



Gambar 6. Perbandingan Klasifikasi Tweet

Setelah mendapatkan model yang akan digunakan, selanjutnya menerapkan model tersebut pada data baru dimana data baru diambil pada tanggal 1 Juli hingga 20 Juli sebanyak 19.843 tweets dengan kata kunci “PPKM”. Hasil klasifikasi pada data baru tersebut menunjukkan dominasi pengguna *Twitter* memiliki sentimen negatif pada kebijakan PPKM yang dilaksanakan oleh pemerintah (Gambar 6). Pada Gambar 4 merupakan kumpulan kata yang paling banyak diucapkan pada tweets dengan sentimen positif dan Gambar 5 merupakan kumpulan kata yang paling banyak diucapkan pada tweets dengan sentimen negatif.

4.2 Analisis Hasil Pengujian

Sistem yang dibangun merupakan sistem klasifikasi menggunakan *machine learning Support Vector Machine classifier* yang menggunakan dua fitur yaitu TF-IDF dengan Metode Leksikal. Dengan komponen data , pembagian data train, data test yang sama (8:2), dan parameter C sama dengan satu , menggabungkan dua fitur tersebut dapat meningkatkan akurasi sebesar 1% atau menjadi 83% untuk kamus leksikal InSet dibanding yang hanya menggunakan satu fitur TF-IDF yang menghasilkan akurasi sebesar 82%. Meningkatnya akurasi dikarenakan jumlah variasi kata yang dimiliki oleh masing-masing kamus sangat berbeda, dengan melakukan perhitungan sentimen yang sama. Kamus InSet memiliki variasi kata-kata yang lebih banyak dibandingkan dengan Masdevid.. Pada Tabel 8 merupakan perbandingan jumlah kata pada kedua kamus:

Tabel 8. Perbandingan Jumlah Kata antara kamus InSet dan Masdevid

Kamus Leksikal	Jumlah Kata	
	Positif	Negatif
Kamus InSet	3.609	6.609
Kamus Masdevid	517	1.212

Kamus yang dimiliki InSet memiliki jumlah kata yang lebih banyak dibandingkan dengan kamus Masdevid, Variasi kata-kata yang dimiliki kamus InSet cukup berpengaruh jika memiliki data latih yang lebih besar dan memiliki kata-kata yang lebih bervariasi. Banyaknya kata yang didapat dari kamus InSet dikarenakan penggunaan sinonim dari sebuah kata. Pada Tabel 9 merupakan contoh perbedaan nilai polaritas pada sinonim dari kata “*meninggal*” pada kamus InSet.

Tabel 9. Contoh Kata Sinonim dan Nilai Polaritasnya

Kata	Nilai Polaritas Kata
Meninggal	-4
Mampus	-5
Tewas	-5
Koit	-5
Modar	-5

Dengan adanya perbandingan dengan sinonim pada suatu kata, kamus InSet lebih unggul dalam mendapatkan nilai polaritas yang lebih baik, karena pengguna media sosial Indonesia didominasi oleh anak remaja usia 18 hingga 25 tahun (Tahun 2020)[18]. Anak remaja cenderung memilih kata-kata yang non-formal pada saat melakukan interaksi sosial media [19]. InSet mengambil data dari *Twitter* pada tahun 2017, sehingga mencakup kata-kata yang sering digunakan pada *Twitter*. Model yang digunakan pada data uji yang baru adalah model dengan menggunakan kamus InSet, karena memiliki akurasi yang terbaik.

Data baru yang digunakan merupakan data dari *Twitter* menggunakan keyword “PPKM” yang diambil dari tanggal 1 Juli hingga 20 Juli, mendapatkan data sebanyak 19.843 *tweet*. Hasil menggunakan data baru didapatkan sebanyak 85.4% dari data tersebut memiliki sentimen negatif dan 14.6% memiliki sentimen positif terhadap kebijakan PPKM pemerintah. Pada Tabel 10 dengan acuan *wordcloud* data negatif (Gambar 5), menarik beberapa kata kunci untuk melihat *tweets*. Dari *tweets* tersebut dapat memahami maksud lebih dalam pada kata kunci tersebut.

Tabel 10. Contoh *Tweets* dari Keyword “makan”, “perpanjang” dan “rakyat”

Username	Tweet
@hikmat****If	ppkm ga kasih bansos : rakyat kecil harus keluar rumah biar cari makan karena ga ada bantuan dari pemerintah. ppkm dikasih bansos : wah jumlah 39t mah bakal dikorup lagi ini mah.
@iiy****	gaji gua ga seberapa bulan ini. abis cuman buat bayar kontrakan, makan. krn ppkm gaji dipotong. terus gimana gua mau nabung buat kuliah sm sekolah adek gua nanti. cari kerjaan baru enggak dapet. cpek tau gak gua harus begini terus. cmn gua yang nyari duit disini.
Username	Tweet
@syj***	ppkm . bukan mengurangi dampak covid tp menambah angka kematian akibat kelaparan. yang punya gaji tetap tetep bs makan enak dsb. nah yg gajinya harian . kerja serabutan. makan apa ?
@sul****t	pak, disamping kita harus cari uang buat makan, tapi ada juga harus bayar tagihan listrik air dll, dari mana itu semua pak kalo selama ini isinya ppkm terus
@aris****us	perpanjang ppkm, sama saja membunuh rakyat yg sudah sekarat ,berpikir efek domino. dari kebijakan ini ,turun dan dengarkan tangisan rakyatmu
@deata****	ppkm harus dievaluasi! banyak rakyat yg sdg kesulitan mencari nafkah

Pada beberapa *tweets* pada Tabel 10, masyarakat memiliki opini atau pendapat bahwa pemberlakuan PPKM yang terus berlanjut atau diperpanjang merupakan hambatan bagi beberapa masyarakat yang harus mencari nafkah untuk memenuhi kebutuhan sehari-hari. Dari kata kunci “makan”, banyak masyarakat yang mengeluh terkait sulitnya mendapatkan makanan.

5. Kesimpulan

Penambahan fitur metode leksikal dapat mempengaruhi performansi sistem dalam melakukan klasifikasi data, pengaruh tersebut meningkatkan akurasi pada sistem sebesar 1%. Akurasi bertambah dikarenakan kamus leksikal InSet melakukan pengambilan data pada *twitter* diambil pada tahun 2017, sehingga variasi kata pada kamus InSet lebih banyak, serta kamus InSet mempertimbangkan kata sinonim sebagai pembanding nilai polaritas. Kamus InSet memiliki akurasi sebesar 83%, sehingga kamus InSet yang dipilih menjadi kamus leksikal yang digunakan sebagai fitur tambahan.

Sistem dengan akurasi tertinggi dipilih menjadi sistem yang melakukan prediksi dengan data baru yang diambil pada bulan Juli 2021 dengan topik kebijakan pemerintah terkait PPKM (per Juli 2021). Respons lebih condong ke arah sentimen negatif, dimana banyak opini dari masyarakat yang mengatakan “diperpanjang”, sehingga diperpanjangnya kebijakan tersebut tidak dianggap baik oleh sebagian besar masyarakat, selain *diperpanjang* keluhan-keluhan masyarakat banyak ditemui pada kata *makan* dan *rakyat* yang memiliki maksud dengan selalu diperpanjangnya kebijakan tersebut membuat kegiatan warga terbatas dan mengurangi pendapatan sehingga sulit untuk membeli makan. Penggunaan visualisasi data dengan menggunakan *wordcloud* belum efektif dalam memberikan representasi banyaknya kata-kata yang sering muncul, karena terdapat kata-kata yang kurang relevan dengan masing-masing sentimen, tetapi dari visualisasi *wordcloud* dapat melihat dominasi kata-kata yang diucapkan dengan skala yang besar dan mudah dipahami.

REFERENSI

- [1] Adam, "Demografi Pengguna Twitter di Indonesia Paling Banyak Pria daripada Perempuan," *www.itworks.id*, 2019. <https://www.itworks.id/19408/demografi-pengguna-twitter-di-indonesia-paling-banyak-pria-daripada-perempuan.html> (accessed Nov. 15, 2020).
- [2] Ihsannudin, "Sederet Kebijakan Kontroversial Jokowi Selama Pandemi Covid-19," *www.kompas.com*, 2020. <https://nasional.kompas.com/read/2020/10/06/05332291/ini-sederet-kebijakan-kontroversial-jokowi-selama-pandemi-covid-19?page=all> (accessed Oct. 20, 2020).
- [3] M. Lailiyah, "Sentiment Analysis Menggunakan Rule Based Method Pada Data Pengaduan Publik Berbasis Lexical Resources," 2017, [Online]. Available: <http://repository.its.ac.id/42409/>.
- [4] M. Rofiqoh, U., Perdana, R., & Fauzi, "Analisis Sentimen Tingkat Kepuasan Pengguna Penyedia Layanan Telekomunikasi Seluler Indonesia Pada Twitter Dengan Metode Support Vector Machine dan Lexicon Based Features | Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 12, pp. 1725–1732, 2017, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/628>.
- [5] D. H. Wahid and A. SN, "Peringkasan Sentimen Esktraktif di Twitter Menggunakan Hybrid TF-IDF dan Cosine Similarity," *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 10, no. 2, p. 207, 2016, doi: 10.22146/ijccs.16625.
- [6] F. Koto and G. Y. Rahmaningtyas, "Inset lexicon: Evaluation of a word list for Indonesian sentiment analysis in microblogs," *Proc. 2017 Int. Conf. Asian Lang. Process. IALP 2017*, vol. 2018-Janua, no. December, pp. 391–394, 2018, doi: 10.1109/IALP.2017.8300625.
- [7] A. Jurek, M. D. Mulvenna, and Y. Bi, "Improved lexicon-based sentiment analysis for social media analytics," *Secur. Inform.*, vol. 4, no. 1, 2015, doi: 10.1186/s13388-015-0024-x.
- [8] C. Vania, M. Ibrahim, and M. Adriani, "Sentiment Lexicon Generation for an Under-Resourced Language," *Int. J. Comput. ...*, vol. 5, no. 1, pp. 59–72, 2014.
- [9] B. Liu, "Sentiment analysis and subjectivity," *Handb. Nat. Lang. Process. Second Ed.*, pp. 627–666, 2010.
- [10] A. R. Atmadja and A. Purwarianti, "Comparison on the rule based method and statistical based method on emotion classification for Indonesian Twitter text," *2015 Int. Conf. Inf. Technol. Syst. Innov. ICITSI 2015 - Proc.*, 2016, doi: 10.1109/ICITSI.2015.7437692.
- [11] I. Wahyudi, S. Bahri, and P. Handayani, "Aplikasi Pembelajaran Pengenalan Budaya Indonesia," vol. V, no. 1, pp. 135–138, 2019, doi: 10.31294/jtk.v4i2.
- [12] R. Mahendrajaya, G. A. Buntoro, and M. B. Setyawan, "Analisis Sentimen Pengguna Gopay Menggunakan Metode Lexicon Based Dan Support Vector Machine," *Komputek*, vol. 3, no. 2, p. 52, 2019, doi: 10.24269/jkt.v3i2.270.
- [13] MIT, "Texthero." texthero.org (accessed May 15, 2021).
- [14] R. N. Waykole and A. D. Thakare, "a Review of Feature Extraction Methods for Text Classification," *Int. J. Adv. Eng. Res. Dev.*, vol. 5, no. 04, pp. 351–354, 2018.
- [15] P. M. Prihatini, "Implementasi Ekstraksi Fitur Pada Pengolahan Dokumen Berbahasa Indonesia," *J. Matrix*, vol. 6, no. 3, pp. 174–178, 2016.
- [16] F. Rahutomo, P. Y. Saputra, and M. A. Fidyawan, "Implementasi Twitter Sentiment Analysis Untuk Review Film Menggunakan Algoritma Support Vector Machine," *J. Inform. Polinema*, vol. 4, no. 2, p. 93, 2018, doi: 10.33795/jip.v4i2.152.
- [17] B. Shamantha Rai, S. M. Shetty, and P. Rai, "Sentiment analysis using Machine learning classifiers: Evaluation of performance," *2019 IEEE 4th Int. Conf. Comput. Commun. Syst. ICCCS 2019*, pp. 21–25, 2019, doi: 10.1109/CCOMS.2019.8821650.
- [18] C. M. Annur, "Berapa Usia Mayoritas Pengguna Media Sosial di Indonesia?," 2020. <https://databoks.katadata.co.id/datapublish/2020/11/23/berapa-usia-mayoritas-pengguna-media-sosial-di-indonesia> (accessed Sep. 14, 2021).
- [19] H. Muliawati, "Variasi Bahasa Gaul pada Mahasiswa Unswagati Prodi Pendidikan Bahasa dan Sastra Indonesia Tahun 2016," *Deiksis J. Pendidik. Bhs. dan Sastra Indones.*, vol. 4, no. 2, p. 42, 2017, doi: 10.33603/deiksis.v4i2.618.