

**ANALISIS SENTIMEN PENGGUNA INSTAGRAM TERHADAP KEBIJAKAN
NADIEM MAKARIM YANG MEMPERBOLEHKAN MAHASISWA LULUS TANPA
SKRIPSI MENGGUNAKAN METODE ANALISIS VADER DAN METODE
KLASIFIKASI NAÏVE BAYES**

***ANALYSIS OF INSTAGRAM USER SENTIMENTS TOWARDS NADIEM
MAKARIEM'S POLICY OF ALLOWING STUDENTS TO GRADUATE WITHOUT A
THESIS USING THE VADER ANALYSIS METHOD AND NAÏVE BAYES
CLASSIFICATION METHOD***

Kirk Ezra Rofran¹, Fergie Joanda Kaunang²

^{1,2}Universitas Advent Indonesia; Jl. Kolonel Masturi No. 288, Cihanjuang Rahayu, Kec. Parongpong,
Kabupaten Bandung Barat, Jawa Barat 40559, (022) Fakultas Teknologi Informasi, Universitas
Advent Indonesia

¹2081013@unai.edu, ²fergie.kaunang@unai.edu

ABSTRACT

Instagram, as a popular social media, has received a lot of attention from researchers to be used as a data collection platform for conducting sentiment analysis. In this research, a sentiment analysis was carried out on Instagram users regarding Nadiem Makarim's policy which allows students to graduate without a thesis. Researchers collected data in the form of comments from Instagram users' posts related to Nadiem Makarim's policies. The Valence Aware Dictionary for Sentiment Reasoning (VADER) analysis method and the Naïve Bayes classification method were used to analyze data taken from Instagram user uploads. VADER is used to assess the general sentiment in posts, while Naïve Bayes is used to classify sentiment into positive, negative, or neutral categories. The results of this research provide in-depth insight into how Instagram users respond to Nadiem Makarim's policies. In this study, the Naïve Bayes classification algorithm was applied to test data of 508 comments, which is 25% of the total data. The results show that using TF-IDF provides an accuracy of 71.29%. This shows that TF-IDF provides high accuracy in sentiment analysis, with the majority of people responding positively to the policy. Suggestions for further research are to carry out sentiment analysis using other algorithmic classification methods such as Support Vector Machine (SVM), Random Forest, or Neural Network to gain a more comprehensive understanding of the public's response to the policy. Further studies could also involve analyzing the long-term impact of this policy on education and society, as well as exploring aspects that have not been revealed in public comments. The diversity in the use of classification algorithms can provide deeper insight.

Keywords: *Sentiment Analysis, VADER, Nadiem Makarim's policy, Naïve Bayes, Instagram*

ABSTRAK

Instagram, sebagai media sosial yang populer, telah mendapat banyak perhatian dari para peneliti untuk digunakan sebagai wadah pengambilan data untuk melakukan analisis sentimen. Di dalam penelitian ini, dilakukan Analisis Sentimen terhadap pengguna Instagram terkait Kebijakan Nadiem Makarim yang memperbolehkan mahasiswa lulus tanpa skripsi. Peneliti mengumpulkan data yang berupa komentar dari unggahan pengguna Instagram yang berkaitan dengan kebijakan Nadiem Makarim. Metode analisis *Valence Aware Dictionary for sEntiment Reasoning* (VADER) dan metode klasifikasi Naïve Bayes digunakan untuk menganalisis data yang diambil dari unggahan pengguna Instagram. VADER digunakan untuk menilai sentimen umum dalam unggahan, sementara Naïve Bayes digunakan untuk mengklasifikasikan sentimen menjadi kategori positif, negatif, atau netral. Hasil penelitian ini memberikan wawasan mendalam tentang bagaimana pengguna Instagram merespon kebijakan Nadiem Makarim. Pada penelitian ini, algoritma klasifikasi Naïve Bayes diterapkan pada pengujian data sebanyak 508 komentar, yang merupakan 25% dari total data. Hasilnya menunjukkan bahwa penggunaan TF-IDF memberikan akurasi sebesar 71.29%. Hal ini menunjukkan bahwa TF-IDF memberikan akurasi yang tinggi dalam analisis sentimen, dengan sebagian besar masyarakat memberikan respon positif terhadap kebijakan tersebut. Saran untuk penelitian selanjutnya adalah melakukan analisis sentimen menggunakan metode klasifikasi algoritma lain seperti Support Vector Machine (SVM), Random Forest, atau Neural Network untuk mendapatkan pemahaman yang lebih komprehensif mengenai respons masyarakat terhadap kebijakan tersebut. Studi lebih lanjut juga dapat melibatkan analisis dampak

jangka panjang dari kebijakan ini terhadap dunia pendidikan dan masyarakat, serta eksplorasi aspek-aspek yang belum terungkap dalam komentar publik. Adanya keragaman dalam penggunaan algoritma klasifikasi dapat memberikan wawasan yang lebih mendalam.

Kata Kunci: Analisis Sentimen, VADER, kebijakan Nadiem Makarim, Naïve Bayes, Instagram

PENDAHULUAN

Kebijakan pemerintah di dalam Peraturan Menteri Pendidikan, Kebudayaan, Riset, dan Teknologi Republik Indonesia Nomor 53 Tahun 2023 tentang Penjaminan Mutu Pendidikan Tinggi yang ditetapkan pada tanggal 16 Agustus 2023, menyebutkan bahwa tugas akhir yang menjadi syarat kelulusan seorang mahasiswa tidak harus berbentuk skripsi lagi, tetapi bisa dalam bentuk lain seperti prototipe, proyek, atau bentuk tugas akhir lainnya yang sejenis baik secara individu maupun berkelompok. Kebijakan ini menuai banyak respon dan opini dari berbagai kalangan masyarakat. Sebagian orang mendukung kebijakan ini karena dinilai dapat mengurangi beban mahasiswa dan meningkatkan relevansi pendidikan tinggi dengan kebutuhan dunia kerja, namun sebagian orang lainnya menolak kebijakan ini karena dapat dinilai dapat menurunkan kualitas lulusan perguruan tinggi.

Kebanyakan masyarakat saat ini menuangkan isi pikiran, opini mereka di platform-platform media sosial, salah satunya *Instagram*. Platform media sosial telah menjadi saluran populer untuk opini publik. Di antara platform-platform ini, *Instagram* menonjol karena tingkat keterlibatan pengguna yang tinggi, berbagai jenis konten, dan basis pengguna yang sebagian besar muda. Dengan lebih dari 1 miliar pengguna aktif bulanan, *Instagram* menyediakan dataset yang kaya dan beragam untuk analisis sentimen [1]. Pengguna mengungkapkan pendapat mereka melalui berbagai bentuk konten seperti, unggahan, komentar *hashtag*, video, dan *Instagram TV* (IGTV), yang memungkinkan sentimen yang lebih komprehensif.

Analisis sentimen adalah bidang studi yang melibatkan analisis dan

klasifikasi opini, emosi, dan sentimen orang yang diungkapkan dalam teks [2]. Hal ini bertujuan untuk mengetahui polaritas sentimen apakah positif, negatif, atau netral. Analisis sentimen dapat diterapkan ke berbagai topik, termasuk media sosial, ulasan pelanggan, wacana politik, dan lainnya. Analisis sentimen telah mendapatkan perhatian yang signifikan dalam beberapa tahun terakhir karena potensi penerapannya dalam memahami opini publik, meningkatkan *decision-making*, dan meningkatkan kepuasan pelanggan [3]. Di dalam penelitian ini, akan dilakukan analisis sentimen pada topik kebijakan Nadiem Makarim mengenai syarat kelulusan berdasarkan komentar *Instagram*. Metode yang akan digunakan adalah VADER (*Valence Aware Dictionary for sEntiment Reasoning*) dan *Naïve Bayes*.

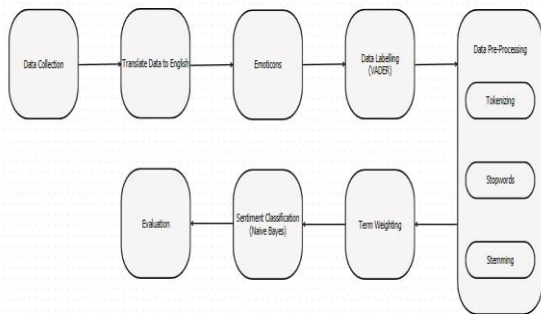
Penelitian terdahulu tentang Analisis Sentimen Akun Twitter Apex Legends Menggunakan VADER yang dilakukan oleh [4] mendapatkan hasil akurasi 65,2%. Sentimen positif yang didapatkan sebesar 18%, negatif sebesar 4,8%, dan netral sebesar 77,2%. Sebagian besar dari hasil analisis sentimen tersebut adalah respon netral. Analisis Sentimen Aplikasi Live.on Digital Provider Menggunakan Metode *Naïve Bayes Classifier* oleh [5], dari 1000 data yang digunakan, akurasi yang diperoleh sebesar 87%. Pada penelitian oleh [6] tentang Analisis Sentimen Twitter menggunakan VADER, *TextBlob* digunakan juga untuk meningkatkan akurasi, dan efisiensi didapatkan sekitar 85%-90%. VADER dan *Naïve Bayes* mempunyai keunggulan dan kelemahannya masing-masing.

Adapun tujuan dilakukannya penelitian ini adalah untuk memberikan wawasan tentang bagaimana pengguna *Instagram* merespon kebijakan Nadiem

Makarim mengenai kelulusan tanpa skripsi. Menerapkan pendekatan VADER untuk pelabelan dan algoritma Naïve Bayes untuk klasifikasi. Peneliti juga akan menggunakan metode *Crowdsourcing* untuk melakukan pelabelan, dan akan membandingkan masing-masing hasil dari metode VADER dengan *Crowdsourcing*.

METODE

Gambar 1 menunjukkan tahapan untuk melakukan analisis sentimen pengguna Instagram terhadap kebijakan Nadiem Makarim yang memperbolehkan mahasiswa lulus tanpa skripsi. Tahapan dimulai dari *data collection*, *translate data to english*, *emoticons*, *data labelling (VADER)*, *data pre-processing*, *term weighting*, *sentiment classification (Naïve Bayes)*, dan *evaluation*.



Gambar 1. Workflow

Data Collection

Dalam penelitian ini, data yang digunakan diambil dari komentar unggahan akun @AHQUOTE, akun Instagram yang mengunggah foto atau video tentang budaya atau berita di Indonesia. Dari unggahan @AHQUOTE tersebut, peneliti mengambil komentar dengan total sebanyak 2154 data, namun setelah melakukan *filtering*, data tersisa menjadi 2031 data. Unggahan tersebut diunggah pada tanggal 30 Agustus 2023, dan peneliti mengambil data tersebut pada tanggal 3 Oktober 2023. Peneliti menggunakan tool IGCommentsExport yang merupakan sebuah extension Google Chrome.

Translate Data to English

Data yang telah dikumpulkan di terjemahkan ke bahasa Inggris, penerjemahan diperlukan karena bahasa utama yang digunakan dalam kamus lexicon VADER adalah bahasa Inggris [7]. Peneliti menggunakan *Python* pada *Google Colaboratory* untuk menerjemahkan seluruh data.

```

[79] print("Before translation:")
      print(sentence)

Before translation:
Skripsi gak seseram dan menyusahkan yang kalian pikirkan hehe

[80] translation = translator.translate(sentence, dest='en')

[81] print("\nAfter translation:")
      print(translation.text)

After translation:
Thesis is not as scary and as hard as you can think hehe
  
```

Gambar 2. Penerjemahan Data ke Inggris

Emoticons

Emoticon adalah ikon bergambar yang umumnya menampilkan emosi atau sentimen. Emoticon sering digunakan dalam komunikasi digital untuk menambahkan dimensi emosi dan niat di balik teks. Dalam konteks analisis sentimen, emoticon dapat memberikan petunjuk penting tentang sentimen pengguna. Misalnya, emoticon tersenyum (:-)) biasanya menunjukkan sentimen positif, sedangkan emoticon cemberut (:-() menunjukkan sentimen negatif. Oleh karena itu, adanya emoticon didalam kalimat dapat memainkan peran penting dalam meningkatkan akurasi analisis sentimen. Peneliti akan mengubah emoticon yang ada didalam data menjadi teks dengan cara manual.

Tabel 1. Emoticon ke teks

@farrahblvaa: 😊	:relieved face:
@rrizkiramadhani: Thesis paper is only for fried food wrap 😊	Thesis paper is only for fried food wrap:face with tears of joy:

Data Labelling

Setelah seluruh data telah diterjemahkan, sekarang masuk kedalam

tahap *labelling*. Algoritma VADER (*Valence Aware Dictionary sEntiment Reasoner*) digunakan untuk melakukan *data labelling*. Peneliti juga melakukan pelabelan secara *crowdsourcing*. *Crowdsourcing* adalah pendekatan dimana penilaian atau interpretasi terhadap sentimen dalam data dilakukan secara manual. Tujuan penggunaan sistem *crowdsourcing* adalah untuk melakukan perbandingan antara hasil pelabelan VADER dan *crowdsourcing*. Label yang akan diberikan adalah Positif, Negatif, dan Netral. Peneliti menggunakan *Google Colaboratory* sebagai *environment* untuk melakukan *data labelling*, karena banyak *library Python* populer yang biasa digunakan untuk *data science* dan *machine learning*, dan salah satu *library* tersebut adalah VADER. Terdapat 556 data positif, 245 data negatif, dan 1230 data netral dari pelabelan menggunakan VADER. Berikut adalah contoh yang sudah diberi label dengan menggunakan VADER dan *Crowdsourcing*.

Tabel 2. VADER

Comment Text	Sentiment
chaotic	Negatif
Thesis is not as scary and as hard as you can think hehe	Positif
The thesis is still valid	Netral

Tabel 3. Crowdsourcing

Comment Text	Sentiment
WTF?	Negatif
wow	Netral
Time to be unemployed	Negatif

Data Preprocessing

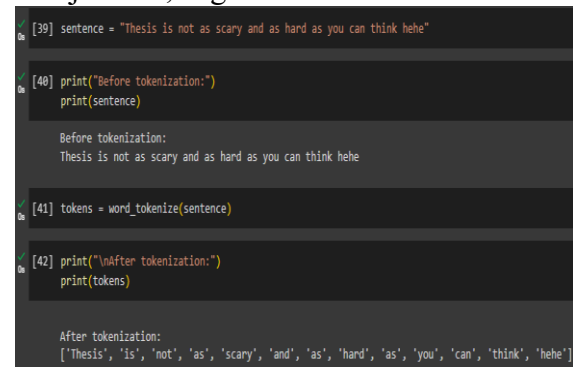
Data preprocessing merupakan tahap yang sangat penting karena tahap ini menentukan kualitas hasil analisis sentimen. Hukum ketiga *data mining* menyatakan bahwa, *data preprocessing* lebih dari separuh proses *data mining* [8]. *Data preprocessing* membuat data menjadi

lebih mudah untuk di analisa dan digunakan. Berikut tahap-tahap yang dilakukan untuk *data preprocessing*:

1. Tokenizing

Kata-kata dalam kalimat dipisahkan oleh sebuah *special character* yaitu *space* atau spasi. Setiap kata disebut dengan *token*. Dan proses mendiskritisasikan kata-kata dalam suatu dokumen disebut *tokenizing*.

Contoh *tokenizing* adalah “I agree”, menjadi “I”, “agree”.



```
[39] sentence = "Thesis is not as scary and as hard as you can think hehe"

[40] print("Before tokenization:")
print(sentence)

Before tokenization:
Thesis is not as scary and as hard as you can think hehe

[41] tokens = word_tokenize(sentence)

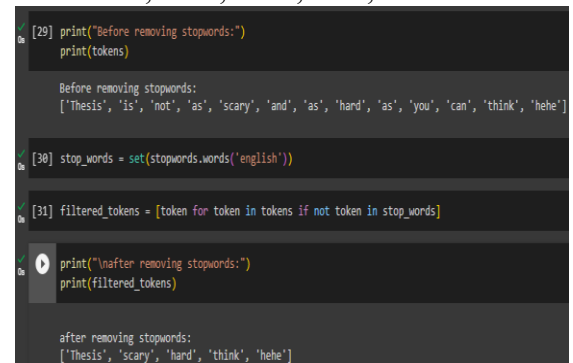
[42] print("\nAfter tokenization:")
print(tokens)

After tokenization:
['Thesis', 'is', 'not', 'as', 'scary', 'and', 'as', 'hard', 'as', 'you', 'can', 'think', 'hehe']
```

Gambar 3. Sebelum Dan Setelah Melakukan Tokenizing

2. Stopwords

Proses *Stopwords* merupakan penghapusan kata-kata biasa yang tidak terlalu berpengaruh dalam proses klasifikasi positif atau negatif, seperti kata-kata “the”, “an”, “on”, “or”, dan lain-lain.



```
[29] print("Before removing stopwords:")
print(tokens)

Before removing stopwords:
['Thesis', 'is', 'not', 'as', 'scary', 'and', 'as', 'hard', 'as', 'you', 'can', 'think', 'hehe']

[30] stop_words = set(stopwords.words('english'))

[31] filtered_tokens = [token for token in tokens if token not in stop_words]

[32] print("\nAfter removing stopwords:")
print(filtered_tokens)

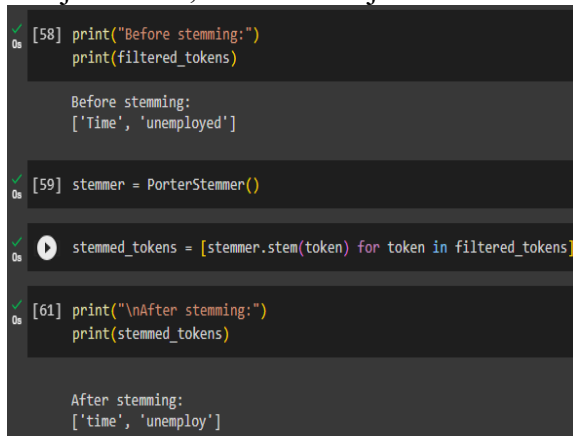
After removing stopwords:
['Thesis', 'scary', 'hard', 'think', 'hehe']
```

Gambar 4. Sebelum Dan Setelah Melakukan Stopwords

3. Stemming

Stemming merupakan proses mencari kata dasar dari suatu kata. Dengan menemukan kata dasar dari suatu kata, proses analisis menjadi lebih mudah, lebih konsisten. Algoritma *stemming* yang biasa

digunakan untuk *data mining* dalam bahasa Inggris adalah algoritma *Porter Stemmer*. Contoh *stemming* adalah “Agreed” menjadi “Agree”, “Lying” menjadi “Lie”, “Faces” menjadi “Face”.



```
[58] print("Before stemming:")
     print(filtered_tokens)

Before stemming:
['Time', 'unemployed']

[59] stemmer = PorterStemmer()

[60] stemmed_tokens = [stemmer.stem(token) for token in filtered_tokens]

[61] print("\nAfter stemming:")
     print(stemmed_tokens)

After stemming:
['time', 'unemploy']
```

Gambar 5. Sebelum Dan Setelah Melakukan Stemming

VADER

VADER (*Valence Aware Dictionary for sEntiment Reasoning*) adalah salah satu *tool* analisis sentimen *rule and lexicon based* yang secara spesifik disesuaikan dengan sentimen yang ditemukan di media sosial. VADER menggunakan kamus *lexicon* berbahasa Inggris. VADER mengidentifikasi apakah suatu teks memiliki sentimen positif, negatif, atau netral berdasarkan kata-kata yang digunakan, serta memperhitungkan intensitas sentimen. VADER menggunakan kamus leksikon yang memiliki skor sentimen untuk kata-kata tertentu, dan dengan demikian, dapat mengenali bahasa figuratif, *slang*, serta intensitas emosi dalam teks. VADER juga menggunakan aturan tata bahasa untuk menentukan sentimen teks. Setelah menghitung skor sentimen untuk setiap kata, VADER kemudian menggabungkan skor-skor tersebut untuk menentukan keseluruhan teks. Sentimen keseluruhan teks dapat diklasifikasikan sebagai positif, negatif, atau netral [9].

Data yang telah dikumpulkan mengenai kebijakan Nadiem Makarim tidak menyertakan atribut yang melabeli komentar sebagai positif atau negatif. Sebagai solusi, VADER digunakan untuk

mendapatkan atribut yang memberi label komentar sebagai positif, negatif, dan netral. Dalam VADER, setiap istilah yang mengandung sentimen positif atau negatif diberi bobot. Berbeda dengan metode *polarity-based* yang mengklasifikasikan kalimat sebagai positif, negatif, atau netral dengan nilai 1, -1, dan 0 masing-masing, metode *valence/intensity based* mempertimbangkan nilai intensitas yang terkait dengan kata-kata untuk berkisar dari -1 hingga 1.

Contohnya, kata “baik” dan “luar biasa” akan memiliki polaritas yang sama yaitu 1 dalam pendekatan *polarity-based*, sedangkan dalam pendekatan *valence-based*, “luar biasa” dianggap lebih positif daripada “baik” sehingga intensitas untuk “luar biasa” akan lebih dari nilai intensitas “baik”.

Klasifikasi NAÏVE BAYES

Naïve Bayes merupakan salah satu algoritma yang paling populer dan paling banyak digunakan. Naïve Bayes adalah salah satu algoritma *supervised machine learning* yang menggunakan teorema Bayes untuk mengklasifikasikan teks sebagai positif, negatif, atau netral [10]. Algoritma ini bekerja dengan mengasumsikan bahwa setiap fitur teks adalah independen satu sama lain, dan kemudian menggunakan teorema Bayes untuk menghitung probabilitas suatu teks termasuk dalam kelas sentimen tertentu. Keuntungan menggunakan Naïve Bayes salah satunya adalah hanya diperlukan dataset yang kecil untuk *training data* [11]. Kinerja pengklasifikasi Naïve Bayes dihitung menggunakan *confusion matrix*. *Confusion Matrix* memberikan jumlah komentar positif dan negatif yang diprediksi dengan benar dan salah oleh pengklasifikasi. Berikut proses perhitungan yang digunakan:

$$P(y|x) = \frac{P(y|x) \times P(y)}{P(x)}$$

$P(y|x)$ = Probabilitas label y diberikan teks x

$P(x|y)$ = Probabilitas label x muncul dalam label y

$P(y)$ = Probabilitas prior dari kategori y

$P(x)$ = Probabilitas prior dari teks y

Term Weighting

Term weighting adalah proses yang menentukan seberapa penting suatu kata dalam suatu dokumen. Bobot ini dihitung dengan berbagai formula yang mempertimbangkan frekuensi masing-masing term dalam dokumen dan dalam koleksi dokumen, serta panjang dokumen dan panjang rata-rata atau maksimum dari setiap dokumen dalam koleksi. Tahapan term weighting biasanya melibatkan teknik seperti TF-IDF (Term Frequency-Inverse Document Frequency). Teknik ini bekerja dengan menentukan frekuensi relatif suatu kata kemudian dibandingkan dengan proporsi kata tersebut pada seluruh dokumen. Nilai TF dan IDF dapat diperoleh dengan rumus berikut:

$$TF = \frac{n_k}{n}$$

$$IDF = \log\left(\frac{n}{n_k}\right)$$

Setelah nilai TF dan IDF telah diperoleh, TF-IDF dapat diperoleh dengan rumus berikut:

$$TF - IDF = \frac{n_k}{n \times \log \frac{n}{n_k}}$$

n = jumlah dokumen

n_k = jumlah dokumen yang mengandung kata tersebut (k)

Evaluation

Setelah melewati tahap-tahap sebelumnya, sekarang masuk ke dalam tahap evaluasi dengan menggunakan *confusion matrix*. *Confusion Matrix* adalah salah satu alat yang digunakan untuk mengukur kinerja suatu metode klasifikasi. Kinerja suatu model akan diketahui jika dilakukan evaluasi data pada matriks. Dari pengolahan nilai-nilai yang ada pada kolom matriks (*True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN)) maka dapat

diketahui *accuracy*, *precision*, *recall*, dan *F-measure*. Meskipun ada kelas “netral”, dalam analisis sentimen rumus-rumus untuk metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F-measure* tersebut tetap sama. Karena metrik-metrik tersebut pada dasarnya mengukur hubungan antara prediksi model dan label sebenarnya, dan konsep tersebut tidak berubah dengan penambahan kelas.

a. Accuracy

Accuracy diartikan sebagai total presentase perasaan atau sentimen yang terdeteksi dengan benar. Perhitungan *accuracy* ditentukan dengan membagi total data dan data uji dengan jumlah data sentimen yang tepat.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

b. Precision

Precision merupakan metrik keakuratan yang mengindikasikan sejauh mana perbedaan nilai setiap kali suatu tindakan diulang. *Precision* didapatkan dari membagi *True Positive* dengan total dari *True Positive* dan *False Positive*.

$$precision = \frac{TP}{TP + FP} \times 100\%$$

c. Recall

Recall adalah nilai persentase suatu model memprediksi data ke bukan kelas aktualnya. Perhitungan *recall* dilakukan dengan cara mengalikan data *True Positive* dan *False Negative*. Nilai data *False Negative* ditentukan dengan menghitung semua nilai selain baris *True Positive* untuk setiap kelas.

$$recall = \frac{TP}{TP + FN} \times 100\%$$


d. F-measure

F-measure atau *F1 score* merupakan metrik yang menggabungkan *precision* dan *recall* menjadi satu angka Tunggal.

$$F - measure = \frac{2 \times precision \times recall}{precision + recall} \times 100\%$$


HASIL DAN PEMBAHASAN

Analisis dilakukan pada 2031 dataset dengan melakukan pembagian label menggunakan VADER dan *crowdsourcing*. Dan hasil dari labelling data menggunakan VADER bisa dilihat pada gambar 7.




Gambar 6. Hasil Labelling Data Menggunakan VADER

Pada gambar 6, terdapat *chart* yang menunjukkan hasil labelling menggunakan VADER, dan menunjukkan bahwa terdapat 556 sentimen positif (27.4%), 245 sentimen negatif (12.1%), dan 1230 sentimen netral (60.6%)



Gambar 7. Hasil Labelling Data Menggunakan Crowdsourcing

Pada gambar 7, metode crowdsourcing mendapatkan hasil sentimen positif sebanyak 650 (32%), negatif sebanyak 465 (22.9%), dan netral sebanyak 916 (45.1%). Perbandingan hasil dari metode VADER dan crowdsourcing bisa dilihat di gambar 8.



Gambar 8. Perbandingan Hasil VADER Dan Crowdsourcing

Hasil pelabelan dari metode VADER dan *Crowdsourcing* telah didapatkan. Hasil metode VADER didominasi oleh label netral yang sebesar 60.6%, sedangkan metode *crowdsourcing* mendapatkan hasil label netral sebesar 45.1%. Label positif dan negatif mengalami peningkatan jumlah dalam penggunaan metode *crowdsourcing*, dimana hasil label positif dan negatif metode VADER lebih rendah daripada metode *crowdsourcing*.

Langkah selanjutnya adalah *preprocessing* data yang terdiri dari tokenizing, stopwords, stemming. Berikut adalah hasil dari tahap preprocessing data. Di mana terdapat 2 kolom utama, yaitu "Comment Text" yang berisi data asli dari Instagram dan "clean_comment" yang berisi data yang telah diproses. Langkah selanjutnya adalah tokenizing, hal ini dilakukan untuk memisahkan kata-kata dari setiap kalimat. Hasil dari proses tokenisasi dapat dilihat dalam Gambar 10.

	Comment Text	clean_comment
0	Sieun Desen	sieun desen
1	Thises paper is only for fried food wrap.	thesis paper is only for fried food wrap
2	Not obliged to make a thesis, keep changing to...	not obliged to make a thesis keep changing to ...
3	OK	ok
4	👍	
...
2026	Aamin is the most in this open	aamin is the most in this open
2027	What is thesis too?	what is thesis too
2028	I should have always sir so that I didn't bother	i should have always sir so that i didn't bother
2029	Who use the service of the thesis jockey when ...	who use the service of the thesis jockey when ...
2030	👍	

Gambar 9. Data Yang Akan Di Preprocessing

	Comment Text	clean_comment	tokenizing
0	Sieun Desen	sieun desen	[sieun, desen]
1	Thises paper is only for fried food wrap.	thesis paper is only for fried food wrap	[thesis, paper, is, only, for, fried, food, wrap]
2	Not obliged to make a thesis, keep changing to...	not obliged to make a thesis keep changing to ...	[not, obliged, to, make, a, thesis, keep, chan...
3	OK	ok	[ok]
4	👍		[]
...
2026	Aamin is the most in this open	aamin is the most in this open	[aamin, is, the, most, in, this, open]
2027	What is thesis too?	what is thesis too	[what, is, thesis, too]
2028	I should have always sir so that I didn't bother	i should have always sir so that i didn't bother	[i, should, have, always, sir, so, that, i, di...
2029	Who use the service of the thesis jockey when ...	who use the service of the thesis jockey when ...	[who, use, the, service, of, the, thesis, jock...
2030	👍		[]

Gambar 10. Tokenizing

Setelah langkah tersebut yaitu adalah *stopwords*. Hasil dari proses *stopwords* dapat dilihat pada gambar 11.

	Comment Text	clean_comment	tokenizing	stopwords
0	Sieun Desen	sieun desen	[sieun, desen]	sieun desen
1	Thises paper is only for fried food wrap.	thesis paper is only for fried food wrap	[thesis, paper, is, only, for, fried, food, wrap]	thesis paper fried food wrap
2	Not obliged to make a thesis, keep changing to...	not obliged to make a thesis keep changing to ...	[not, obliged, to, make, a, thesis, keep, chan...	obliged make thesis keep changing must project...
3	OK	ok	[ok]	ok
4	👍		[]	
...
2026	Aamin is the most in this open	aamin is the most in this open	[aamin, is, the, most, in, this, open]	aamin open
2027	What is thesis too?	what is thesis too	[what, is, thesis, too]	thesis
2028	I should have always sir so that I didn't bother	i should have always sir so that i didn't bother	[i, should, have, always, sir, so, that, i, di...	always sir bother
2029	Who use the service of the thesis jockey when ...	who use the service of the thesis jockey when ...	[who, use, the, service, of, the, thesis, jock...	use service thesis jockey when
2030	👍		[]	

Gambar 11. Stopwords

Setelah langkah stopwords selesai. Langkah selanjutnya adalah proses stemming.


	Comment Text	clean_comment	tokenizing	stopwords	stemming
0	Sieun Desen	sieun desen	[sieun, desen]	sieun desen	sieun des
1	Thises paper is only for fried food wrap.	thesis paper is only for fried food wrap	[thesis, paper, is, only, for, fried, food, wrap]	thesis paper fried food wrap	thes pag fr food wrap
2	Not obliged to make a thesis, keep changing to...	not obliged to make a thesis keep changing to ...	[not, obliged, to, make, a, thesis, keep, chan...	obliged make thesis keep changing must project level g...	oblig make thes keep chang must project level g...
3	OK	ok	[ok]	ok	ok
4	👍		[]		
...
2026	Aamin is the most in this open	aamin is the most in this open	[aamin, is, the, most, in, this, open]	aamin open	aamin op
2027	What is thesis too?	what is thesis too	[what, is, thesis, too]	thesis	thes
2028	I should have always sir so that I didn't bother	i should have always sir so that i didn't bother	[i, should, have, always, sir, so, that, i, di...	always sir bother	alway sir both
2029	Who use the service of the thesis jockey when ...	who use the service of the thesis jockey when ...	[who, use, the, service, of, the, thesis, jock...	use service thesis jockey when	us serv thes jockey whe
2030	👍		[]		

Gambar 12. Stemming

Peneliti melakukan analisis sentimen menggunakan Jupyter Notebook dan membagi dataset menjadi dua bagian, yaitu data training dengan 75% dari total data (1523 komentar) dan data testing dengan 25% dari total data (508 komentar). Setelah melakukan pembagian data, peneliti menjalankan algoritma klasifikasi Naïve Bayes dengan menggunakan library *sklearn*. Komentar yang berlabel netral dihilangkan sehingga membuat klasifikasi biner untuk memprediksi sentimen sebagai positif atau negatif [12]. Confusion matrix merupakan salah satu cara yang dapat digunakan untuk mengukur kinerja dalam memecahkan masalah klasifikasi tabel.

Pada gambar 13, hasil perhitungan menggunakan TF-IDF menghasilkan True Positif: 61, False Positif: 0, True Negatif: 11, False Negatif: 29.

Confusion Matrix Naive Bayes dengan TF-IDF Vectorizer



Gambar 13. Confusion Matrix Menggunakan TF-IDF

Tahap terakhir adalah perhitungan untuk mendapatkan nilai akurasi. Perhitungan dilakukan dengan menghitung *precision* untuk mengukur seberapa akurat model dalam mengidentifikasi data yang relevan, *recall* untuk mengukur seberapa baik model dalam menemukan semua data yang sebenarnya relevan, *f1-score* merupakan rata-rata harmonis dari *precision* dan *recall*, *F1-score* akan tinggi jika kedua *precision* dan *recall* tinggi, yang menunjukkan model memiliki keseimbangan yang baik antara akurasi dan kemampuan untuk menemukan data yang relevan. Nilai akurasi menggunakan TF-IDF sebesar 71,29%, hal ini dapat dilihat dari Gambar 14.

	precision	recall	f1-score	support
negative	1.00	0.28	0.43	40
positive	0.68	1.00	0.81	61
accuracy			0.71	101
macro avg	0.84	0.64	0.62	101
weighted avg	0.81	0.71	0.66	101

Accuracy: 0.7128712871287128

Gambar 14. Hasil Akurasi TF-IDF

SIMPULAN

Berdasarkan dari penelitian ini, dari total 2031 data komen instagram mengenai kebijakan Nadiem Makarim yang memperbolehkan mahasiswa lulus tanpa skripsi pada tanggal 30 Agustus 2023, didapati bahwa hasil pelabelan dengan menggunakan VADER yaitu 556 (27.4%) komentar positif, 245 (12.1%) komentar negatif, dan 1230 (60.6%) komentar netral, yang berarti masyarakat lebih dominan menanggapi kebijakan ini dengan tanggapan yang netral, diikuti oleh tanggapan positif dan negatif. Pelabelan data *crowdsourcing* juga digunakan, dan pelabelan *crowdsourcing* mendapatkan hasil positif sebanyak 650 (32%), negatif sebanyak 465 (22.9%), dan netral sebanyak 916 (45.1%).

Melalui klasifikasi dari algoritma Naïve Bayes dengan data testing yang diambil 508 (25%) dari total 2031 data

komentar didapatkan hasil bahwa, perhitungan menggunakan TF-IDF Naïve Bayes mendapatkan akurasi sebesar 71,29%. Didapatkan hasil bahwa perhitungan menggunakan TF-IDF memiliki akurasi yang tinggi dalam analisis sentimen ini dan positifnya masyarakat memberikan respon baik dalam kebijakan yang telah dikeluarkan.

Saran untuk peneliti selanjutnya, bisa melakukan analisis sentimen terhadap kebijakan ini dengan menggunakan klasifikasi algoritma yang berbeda seperti Support Vector Machine (SVM), Random Forest, ataupun Neural Network

DAFTAR PUSTAKA

- [1] I. Mansoor, "Instagram Revenue and Usage Statistics (2022) - Business of Apps," Business of Apps. [Online]. Available: <https://www.businessofapps.com/data/instagram-statistics/>
- [2] W. Medhat, A. Hassan, and H. Korashy, "Sentiment analysis algorithms and applications: A survey," *Ain Shams Eng. J.*, vol. 5, no. 4, pp. 1093–1113, Dec. 2014, doi: 10.1016/J.ASEJ.2014.04.011.
- [3] K. Afifah, I. N. Yulita, and I. Sarathan, "Sentiment Analysis on Telemedicine App Reviews using XGBoost Classifier," pp. 22–27, 2021, doi: 10.1109/icaibda53487.2021.9689735.
- [4] D. Abimanyu, E. Budianita, and E. P. Cynthia, "Analisis Sentimen Akun Twitter Apex Legends Menggunakan VADER," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 3, pp. 423–431, Jun. 2022, doi: 10.32672/JNKTI.V5I3.4382.
- [5] C. Idli Mulia Asriguna, T. Hendro Pudjiantoro, P. Nurul Sabrina, and A. Id Hadiana, "Sentiment Analysis of Live.on Digital Provider Application Using Naive Bayes Classifier Method," 2022.
- [6] V. Kumar Chauhan and A. Bansal,

- “Twitter Sentiment Analysis Using Vader,” *Int. J. Adv. Res.*, 2018, Accessed: Nov. 15, 2023. [Online]. Available: www.IJARIIIT.com
- [7] Y. Findawati, U. Indahyanti, Y. Rahmawati, and R. Puspitasari, “Sentiment Analysis of Potential Presidential Candidates 2024: A Twitter-Based Study,” *Acad. Open*, vol. 8, no. 1, Aug. 2023, doi: 10.21070/acopen.8.2023.7138.
- [8] T. Khabaza, “9 Laws of Data Mining,” 2022, [Online]. Available: http://khabaza.codimension.net/index_files/9laws.htm
- [9] C. J. Hutto and E. Gilbert, “VADER: A Parsimonious Rule-Based Model for Sentiment Analysis of Social Media Text,” *Proc. Int. AAAI Conf. Web Soc. Media*, vol. 8, no. 1, pp. 216–225, May 2014, doi: 10.1609/ICWSM.V8I1.14550.
- [10] I. Rish, “An empirical study of the naive Bayes classifier,” 2001.
- [11] J. Singh, G. Singh, and R. Singh, “Optimization of sentiment analysis using machine learning classifiers,” *Human-centric Comput. Inf. Sci.*, 2017, doi: 10.1186/s13673-017-0116-3.
- [12] C. V. D, “Hybrid approach: naive bayes and sentiment VADER for analyzing sentiment of mobile unboxing video comments,” *Int. J. Electr. Comput. Eng.*, vol. 9, no. 5, pp. 4452–4459, Oct. 2019, doi: 10.11591/ijece.v9i5.pp4452-4459.