

Analisis Sentimen Masyarakat terhadap Kenaikan Harga Bahan Pokok Menggunakan Text Mining dan Pembobotan TF-IDF

Raheliya Br Ginting^{1,*}, David JM Sembiring¹, Sinek Mehuli Br Perangin-Angin², Meiliyani Br Ginting³

¹Fakultas Sains dan Teknologi, Prodi Teknik Informatika, Institut Teknologi dan Bisnis Indonesia, Medan, Indonesia

²Fakultas Sains dan Teknologi, Prodi Manajemen Informatika, Institut Teknologi dan Bisnis Indonesia, Medan, Indonesia

³Fakultas Sains dan Teknologi, Prodi Rekayasa Perangkat Lunak, Institut Teknologi dan Bisnis Indonesia, Medan, Indonesia

Email: ^{1,*}raheliyabrginting@gmail.com, ²davidjmsimbiring@gmail.com, ³sinekmehuli19@gmail.com,

⁴Meiliyani.ginting@gmail.com

(* : coressponding author)

Abstrak—Kenaikan harga bahan pokok merupakan permasalahan ekonomi yang dapat memengaruhi daya beli masyarakat dan memunculkan beragam tanggapan di media sosial. Opini masyarakat yang tersebar dalam jumlah besar pada media sosial sulit dianalisis secara manual sehingga diperlukan pendekatan pengolahan teks untuk mengidentifikasi kecenderungan sentimen. Penelitian ini bertujuan menganalisis sentimen masyarakat terhadap kenaikan harga bahan pokok berdasarkan komentar yang dipublikasikan pada Twitter menggunakan pendekatan text mining dan pembobotan Term Frequency–Inverse Document Frequency (TF-IDF). Data penelitian dikumpulkan melalui proses crawling menggunakan kata kunci yang berkaitan dengan kenaikan harga bahan pokok. Sebanyak 100 data dikumpulkan, kemudian 50 data dipilih untuk dianalisis. Tahapan pengolahan meliputi case folding, tokenizing, filtering, dan stemming. Selanjutnya, sejumlah kata yang diasumsikan merepresentasikan sentimen positif dan negatif ditentukan untuk menghitung frekuensi kemunculan kata (term frequency), frekuensi dokumen (document frequency), serta bobot TF-IDF. Hasil perhitungan yang dilaporkan menunjukkan bahwa sentimen positif memperoleh persentase sebesar 24,241%, sedangkan sentimen negatif sebesar 75,759%. Dominasi bobot kata yang dikategorikan negatif menunjukkan kecenderungan negatif pada data yang dianalisis. Penelitian ini diharapkan memberikan gambaran awal mengenai opini masyarakat terhadap kenaikan harga bahan pokok dan menjadi informasi pendukung bagi penelitian maupun evaluasi kebijakan terkait. Namun, hasil tersebut merepresentasikan sampel yang dianalisis dan belum dapat digeneralisasi untuk seluruh masyarakat. Selain itu, persentase tersebut merupakan hasil penghitungan berbasis kata kunci dan bobot TF-IDF, bukan ukuran akurasi model klasifikasi.

Kata Kunci: Analisis Sentimen; Harga Bahan Pokok; Text Mining; TF-IDF; Twitter

Abstract—Rising prices for basic commodities represent an economic issue that can affect public purchasing power and trigger various reactions on social media. Given the vast volume of public opinion shared on social media, manual analysis is difficult; therefore, a text-processing approach is required to identify sentiment trends. This study aims to analyze public sentiment regarding the rising prices of basic commodities based on comments posted on Twitter, utilizing a text-mining approach and Term Frequency–Inverse Document Frequency (TF-IDF) weighting. Data were collected through a crawling process using keywords related to the increase in basic commodity prices. A total of 100 entries were gathered, from which 50 were selected for analysis. The processing stages included case folding, tokenizing, filtering, and stemming. Subsequently, specific terms assumed to represent positive or negative sentiments were identified to calculate their term frequency, document frequency, and TF-IDF weights. The results indicate that positive sentiment accounts for 24.241%, while negative sentiment accounts for 75.759%. The prevalence of terms categorized as negative suggests a negative trend within the analyzed data. This study is intended to provide an initial overview of public opinion regarding the rising prices of basic commodities and to serve as supporting information for further research or policy evaluation. However, these findings represent only the analyzed sample and cannot be generalized to the entire population. Furthermore, these percentages are derived from keyword-based calculations and TF-IDF weighting, rather than representing the accuracy of a classification model.

Keywords: Sentiment Analysis; Basic Commodity Prices; Text Mining; TF-IDF; Twitter

1. PENDAHULUAN

Kenaikan harga bahan pokok merupakan salah satu permasalahan ekonomi yang berkaitan langsung dengan daya beli dan kesejahteraan masyarakat. Bahan pokok, seperti beras, minyak goreng, gula, telur, dan komoditas pangan lainnya, memiliki peran penting dalam memenuhi kebutuhan sehari-hari. Ketika harga komoditas tersebut meningkat, masyarakat berpotensi mengalami peningkatan pengeluaran rumah tangga, khususnya kelompok masyarakat yang memiliki keterbatasan pendapatan. Perubahan harga bahan pokok juga dapat memengaruhi pola konsumsi dan persepsi masyarakat terhadap kondisi perekonomian. Oleh karena itu, pemantauan terhadap perkembangan harga dan tanggapan masyarakat menjadi salah satu aspek yang dapat mendukung evaluasi kebijakan pangan[1], [2].

Perkembangan teknologi informasi telah mengubah cara masyarakat menyampaikan pendapat, keluhan, dan pengalaman mengenai permasalahan sosial maupun ekonomi. Media sosial Twitter, yang kini dikenal sebagai X, merupakan salah satu platform yang dapat digunakan masyarakat untuk menyampaikan opini secara terbuka. Opini tersebut dapat berupa keluhan mengenai harga komoditas, perbandingan harga antardaerah, pengalaman berbelanja, maupun tanggapan terhadap kebijakan pemerintah[3]. Kumpulan opini tersebut berpotensi menjadi sumber informasi untuk memahami persepsi masyarakat terhadap kenaikan harga bahan pokok. Meskipun demikian, banyaknya teks yang dihasilkan pengguna menyebabkan analisis secara manual membutuhkan waktu dan tenaga yang relatif besar. Selain itu, teks media sosial umumnya memiliki struktur tidak baku, menggunakan singkatan, mengandung kesalahan penulisan, serta memuat kata-kata yang maknanya bergantung pada konteks[4], [5].

Salah satu pendekatan yang dapat digunakan untuk mengolah data teks tersebut adalah text mining. Pendekatan ini bertujuan mengekstraksi informasi dan pola yang bermakna dari kumpulan dokumen teks. Dalam analisis sentimen,

pengolahan teks dilakukan untuk mengidentifikasi kecenderungan opini yang terkandung dalam suatu pernyataan. Penelitian mengenai analisis sentimen pada media sosial telah menggunakan berbagai pendekatan, antara lain metode klasifikasi Naive Bayes pada data Twitter[6]. Penelitian terkait kebijakan kenaikan harga bahan bakar minyak juga menunjukkan relevansi penggunaan data media sosial untuk mengkaji tanggapan masyarakat terhadap perubahan harga. Penelitian-penelitian tersebut menjadi landasan untuk menempatkan analisis opini masyarakat mengenai kenaikan harga bahan pokok sebagai persoalan yang relevan untuk dikaji melalui pengolahan teks[7], [8].

Dalam pengolahan teks, tahap preprocessing diperlukan untuk mengurangi variasi penulisan dan mempersiapkan dokumen sebelum dilakukan analisis lebih lanjut. Tahapan yang dapat diterapkan meliputi case folding, yaitu mengubah huruf menjadi bentuk yang seragam; tokenizing, yaitu memisahkan teks menjadi unit kata; filtering, yaitu menghilangkan kata yang tidak relevan berdasarkan aturan yang ditetapkan; serta stemming, yaitu mengubah kata berimbuhan menjadi bentuk dasarnya[9]. Penerapan tahapan tersebut diharapkan menghasilkan representasi teks yang lebih terstruktur sehingga frekuensi kemunculan kata dapat dihitung secara konsisten. Namun, hasil preprocessing tetap perlu diperiksa karena penghapusan kata tertentu dapat mengubah makna pernyataan, terutama apabila kata tersebut menunjukkan negasi, seperti “tidak”, “bukan”, atau “belum”[10], [11].

Setelah teks diproses, pembobotan kata dapat dilakukan menggunakan Term Frequency–Inverse Document Frequency (TF-IDF). Metode ini menggabungkan frekuensi kemunculan suatu kata dalam dokumen dengan informasi mengenai penyebaran kata tersebut di seluruh koleksi dokumen. Secara umum, kata yang sering muncul dalam sebuah dokumen dapat memperoleh bobot TF yang tinggi, sedangkan komponen IDF memberikan bobot lebih besar pada kata yang relatif jarang ditemukan di antara dokumen. Dengan demikian, TF-IDF dapat membantu merepresentasikan kepentingan relatif suatu kata dalam kumpulan dokumen. Dalam konteks penelitian ini, pembobotan digunakan untuk menghitung bobot kata yang telah ditentukan sebagai indikator sentimen positif dan negatif[12], [13].

Meskipun demikian, TF-IDF tidak secara otomatis menentukan apakah sebuah kalimat memiliki sentimen positif atau negatif. Pembobotan tersebut menghasilkan nilai numerik untuk merepresentasikan kata, sedangkan penentuan kelas sentimen memerlukan aturan pelabelan, pendekatan berbasis leksikon, atau algoritma klasifikasi yang sesuai. Kata yang memiliki makna negatif dalam satu konteks juga belum tentu menunjukkan sentimen negatif dalam konteks lain. Sebagai contoh, kata “naik” dapat mengindikasikan kenaikan harga yang merugikan konsumen, tetapi dalam konteks tertentu dapat pula merujuk pada peningkatan pendapatan atau kualitas. Oleh sebab itu, interpretasi hasil pembobotan perlu memperhatikan konteks penggunaan kata dan aturan penentuan sentimen yang diterapkan[14], [15].

Berdasarkan penelitian terdahulu yang dicantumkan dalam naskah, pendekatan analisis sentimen telah digunakan pada beragam objek, termasuk opini terhadap pemerintah, kebijakan publik, dan permasalahan yang diperbincangkan di media sosial. Sementara itu, TF-IDF juga digunakan sebagai metode pembobotan dalam berbagai tugas pengolahan teks. Meskipun demikian, perbedaan objek, karakteristik data, proses prapengolahan, dan mekanisme penentuan kelas dapat memengaruhi hasil analisis. Penelitian ini secara khusus memusatkan perhatian pada opini mengenai kenaikan harga bahan pokok. Berdasarkan referensi yang tersedia dalam naskah awal, kesenjangan penelitian yang hendak ditangani adalah kebutuhan untuk menggambarkan kecenderungan sentimen pada sampel komentar terkait kenaikan harga bahan pokok melalui tahapan preprocessing dan pembobotan TF-IDF. Klaim bahwa pendekatan ini lebih baik daripada metode lain belum dapat dibuat karena penelitian ini tidak menyajikan eksperimen perbandingan secara langsung[16], [17], [18].


Penelitian ini menggunakan data yang dikumpulkan dari Twitter dengan kata kunci yang berkaitan dengan kenaikan harga bahan pokok. Data tersebut melalui tahapan preprocessing, kemudian kata-kata yang diasumsikan mewakili sentimen positif dan negatif dihitung menggunakan TF-IDF. Hasil pembobotan selanjutnya digunakan untuk menggambarkan perbandingan kecenderungan sentimen berdasarkan aturan yang diterapkan dalam penelitian. Ruang lingkup penelitian dibatasi pada sampel data yang dianalisis sehingga hasilnya tidak secara langsung mewakili seluruh opini masyarakat.

Tujuan penelitian ini adalah menganalisis kecenderungan sentimen masyarakat terhadap kenaikan harga bahan pokok berdasarkan komentar di Twitter dengan menggunakan text mining dan pembobotan TF-IDF. Secara khusus, penelitian ini bertujuan menjelaskan tahapan pengolahan teks, menghitung bobot kata yang digunakan sebagai indikator sentimen, serta menggambarkan perbandingan hasil sentimen positif dan negatif pada sampel penelitian. Kontribusi yang diharapkan adalah penyajian prosedur analisis yang dapat menjadi dasar bagi penelitian lanjutan mengenai opini masyarakat terhadap harga pangan. Hasil penelitian juga berpotensi memberikan gambaran awal bagi pemangku kebijakan, dengan tetap mempertimbangkan keterbatasan jumlah data, pemilihan kata kunci, dan mekanisme penentuan sentimen yang digunakan.

2. METODE PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilaksanakan melalui beberapa tahapan yang sistematis untuk menganalisis sentimen masyarakat terhadap kenaikan harga bahan pokok berdasarkan opini yang disampaikan melalui media sosial Twitter. Tahapan penelitian dimulai dari identifikasi masalah, pengumpulan data, seleksi data, preprocessing teks, pembobotan kata menggunakan Term Frequency–Inverse Document Frequency (TF-IDF), analisis sentimen, hingga interpretasi hasil dan penarikan kesimpulan. Setiap tahapan dilaksanakan secara berurutan agar data yang digunakan sesuai dengan tujuan penelitian dan dapat diolah secara sistematis. Secara keseluruhan, tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Pada gambar 1 dapat dilihat terhadap tahapan penelitian. Dari penelitian terdapat 7 tahapan penelitian yang dilalui.

2.2 Text Mining

Text mining adalah salah satu bidang khusus dalam data mining. Text mining dapat didefinisikan sebagai proses penggalian informasi di mana pengguna berinteraksi dengan sekumpulan dokumen menggunakan alat analisis yang merupakan komponen dalam data mining. Dalam konteks text mining, tujuannya adalah mencari pola-pola tertentu, mengasosiasikan satu bagian teks dengan yang lain berdasarkan aturan-aturan tertentu, dan menemukan kata-kata yang dapat mewakili informasi tertentu sehingga dapat dilakukan analisis tentang keterhubungan antara satu dokumen dengan dokumen lainnya dalam kumpulan dokumen yang sangat banyak[19], [20].

2.3 Term Frequency-Inverse Document Frequency (TF-IDF)

Term Frequency-Inverse Document Frequency (TF-IDF) adalah kombinasi dari TF dan IDF, yang menggabungkan informasi tentang seberapa sering suatu term muncul dalam sebuah dokumen dan seberapa umum atau jarang term tersebut muncul di seluruh koleksi dokumen. Term Frequency (TF) adalah semakin besar frekuensi kemunculan kata pada sebuah dokumen maka akan semakin besar nilai bobot untuk kata tersebut. Inverse Document Frequency (IDF) adalah semakin besar frekuensi kemunculan kata maka nilai bobot kata tersebut akan semakin kecil. Adapun rumus dari pembobotan kata TF-IDF adalah[21], [22], [23]:

$$W_{d,t} = tf_{d,t} \times idf_t = tf_{d,t} \times \log \frac{N}{df_t} \quad (1)$$

Keterangan dari persamaan tersebut adalah $W_{d,t}$ merupakan nilai pembobotan TF-IDF atau bobot dari term t yang dikategorikan ke dalam kelas c . Selanjutnya, $tf_{d,t}$ menunjukkan jumlah kemunculan kata (term) t dalam dokumen d . Simbol N menyatakan jumlah seluruh dokumen yang digunakan dalam proses analisis, sedangkan df_t menunjukkan jumlah dokumen yang mengandung kata (term) t . Keempat komponen tersebut digunakan dalam proses pembobotan TF-IDF untuk menentukan bobot kepentingan suatu kata berdasarkan frekuensi kemunculannya dalam dokumen dan distribusinya pada keseluruhan dokumen.

2.4 RapidMiner

RapidMiner adalah platform aplikasi perangkat lunak, aplikasi ini menyediakan lingkungan terpadu untuk berbagai kegiatan dalam bidang data ilmu pengetahuan, seperti pembelajaran mesin, penambangan teks, dan analisis prediktif. RapidMiner juga bisa mengimpor dan mempersiapkan data, membangun model pembelajaran mesin dan mendalaminya, melakukan analisis teks, serta melakukan analisis prediktif. RapidMiner menyediakan lingkungan terpadu yang memungkinkan pengguna untuk mengimpor data, mempersiapkan data, menarik data, untuk membangun model analisis dan menganalisis hasilnya[24], [25].

3. HASIL DAN PEMBAHASAN

Analisis sentimen adalah proses menganalisis dan mengidentifikasi opini, perasaan, atau sentimen yang terkandung dalam teks. Penelitian ini melakukan analisa sentimen naiknya bahan pokok yang berupa opini atau pendapat dari sebuah komentar yang masyarakat sampaikan pada media sosial Twitter mengenai pengaruh naiknya bahan pokok bagi masyarakat. Data sentimen masyarakat diperoleh dari hasil crawling pada media sosial Twitter, Sampel data yang di kumpulkan berjumlah 100 data dengan kata kunci “naiknya bahan pokok”. Jumlah 50 data yang telah di crawling dilakukan tahap pengolahan data yang akan digunakan sebagai data pengujian. Tahap pengolahan dilakukan untuk memilih data yang hanya bersifat komentar yang disampaikan oleh pengguna atau masyarakat, karena data yang di crawling biasanya berisikan data campur antara data postingan berita dan data komentar yang disampaikan oleh pengguna atau masyarakat pada sebuah postingan berita.

Data yang telah melewati tahap pengolahan akan dilakukan tahap penerapan algoritma text mining dan Term Frequency-Inverse Document Frequency (TF-IDF). Penerapan algoritma text mining dilakukan untuk mengolah 50 data melalui preprocessing text. Preprocessing text melewati beberapa tahapan seperti case folding, tokenizing, filtering dan stemming. Tahapan-tahapan yang telah dilewati pada preprocessing text ini dilakukan agar 50 data teks komentar tersebut menjadi data teks yang lebih terstruktur. Setelah penerapan algoritma text mining dilakukan, selanjutnya melakukan penerapan algoritma Term Frequency-Inverse Document Frequency (TF-IDF). Penerapan Term Frequency-Inverse Document Frequency (TF-IDF) menggabungkan dua perhitungan bobot, yaitu Term Frequency (TF) yang digunakan untuk menghitung frekuensi kemunculan kata kunci dalam sebuah dokumen dan Inverse Document Frequency (IDF) yang akan digunakan untuk menghitung frekuensi seluruh dokumen yang mengandung kata kunci. Proses yang dilakukan algoritma Term Frequency-Inverse Document Frequency (TF-IDF) dapat menentukan konotasi positif dan negatif, sehingga dapat diketahui jumlah hasil konotasi sentimen positif dan negatif dari naiknya bahan pokok.

3.1 Text Mining

Setelah data diolah pada algoritma text mining, maka diperoleh hasil data dari penerapan preprocessing text. Hasil data yang telah melewati penerapan algoritma text mining dapat dilihat pada tabel berikut:

Tabel 1. Hasil Preprocessing Text

No	Komentar	Case Folding	Tokenizing	Filtering	Stemming
1	Penyaluran bantuan tsb sebagai wujud kepedulian pemerintah utk mengurangi beban masyarakat dlm memenuhi kebutuhan beras di tengah naiknya harga sembako. Kenaikan harga bahan pokok tentu saja berdampak bagi warga yg kurang mampu. Bupati Kampung ini sangat memahami hal tsb https://t.co/bmRomuBjaN	penyaluran bantuan tsb sebagai wujud kepedulian pemerintah utk mengurangi beban masyarakat dlm memenuhi kebutuhan beras di tengah naiknya harga sembako. kenaikan harga bahan pokok tentu saja berdampak bagi warga yg kurang mampu. bupati kampung ini sangat memahami hal tsb https://t.co/bmromubjan	[penyaluran] [bantuan] [tersebut] [sebagai] [wujud] [kepedulian] [pemerintah] [utk] [mengurangi] [beban] [masyarakat] [dlm] [memenuhi] [kebutuhan] [beras] [di] [tengah] [naiknya] [harga] [sembako] [kenaikan] [harga] [bahan] [pokok] [tentu] [saja] [berdampak] [bagi] [warga] [yg] [kurang] [mampu] [bupati] [kampung] [ini] [sangat] [memahami] [hal] [tersebut]	[penyaluran] [bantuan] [wujud] [peduli] [perintah] [kurang] [beban] [masyarakat] [penuh] [butuh] [beras] [harga] [sembako] [kenaikan] [harga] [bahan] [pokok] [berdampak] [warga] [bupati] [kampong] [memahami]	[salur] [bantu] [wujud] [peduli] [perintah] [kurang] [beban] [masyarakat] [penuh] [butuh] [beras] [harga] [sembako] [naik] [harga] [bahan] [pokok] [dampak] [warga] [paham]

Setelah data diolah pada algoritma text mining, maka diperoleh hasil keseluruhan dari 50 data dari penerapan preprocessing text. Hasil keseluruhan 50 data yang telah melewati penerapan algoritma text mining dapat menggunakan algoritma Term Frequency-Inverse Document Frequency (TF-IDF).

3.2 Algoritma Term Frequency-Inverse Document Frequency (TF-IDF)

Penerapan algoritma Term Frequency-Inverse Document Frequency (TF-IDF) memerlukan kata kunci dari hasil penerapan text mining yang akan digunakan dalam pembobotan Term Frequency-Inverse Document Frequency (TF-IDF). Kata kunci yang dipakai untuk pembobotan dengan cara memilih beberapa kata kunci yang dianggap berkonotasi positif

dan negatif. Kata kunci yang berkonotasi positif dan negatif yang akan digunakan dalam pembobotan Term Frequency-Inverse Document Frequency (TF-IDF) dapat dilihat pada tabel 2 berikut:

Tabel 2. Kata Kunci Konotasi Positif dan Negatif

No	Konotasi Positif	Konotasi Negatif
1	turun	mahal
2	murah	susah
3	bagus	sedih
4	peduli	beban
5	salut	kurang
6	terjangkau	rugi
7	mantap	naik
8		rendah

Berdasarkan dari hasil kata kunci konotasi positif dan negatif yang telah ditentukan, maka dapat dilakukan pembobotan Term Frequency (TF). Pembobotan Term Frequency (TF) dengan menggunakan Microsoft Excel yang bertujuan untuk mencari frekuensi kemunculan kata kunci dalam sebuah dokumen. yang digunakan dalam pembobotan Term Frequency (TF) dapat di lihat pada tabel 3 berikut:

Tabel 3. Hasil Pembobotan Term Frequency (TF)

		Konotasi positif									
No	Kata kunci	D1	D2	D3	D4	D5	D6	D7	...	D49	D50
1	turun	0	0	0	0	0	0	0	...	0	0
2	murah	0	0	0	0	0	0	0	...	1	0
3	bagus	0	0	0	0	0	0	0	...	0	0
4	peduli	1	0	0	0	0	0	0	...	0	0
5	salut	0	0	0	0	0	0	0	...	0	0
6	terjangkau	0	0	0	0	0	0	0	...	0	0
7	mantap	0	0	1	0	0	0	0	...	0	0

		Konotasi negatif									
No	Kata kunci	D1	D2	D3	D4	D5	D6	D7	...	D49	D50
8	mahal	0	0	0	0	0	0	0	...	0	0
9	susah	0	0	0	0	0	0	0	...	0	2
10	sedih	0	0	0	0	0	0	0	...	0	1
11	beban	1	0	0	0	0	0	0	...	0	0
12	kurang	1	0	0	0	0	0	0	...	0	0
13	rugi	0	0	0	0	0	0	0	...	1	0
14	naik	1	1	1	1	1	1	1	...	0	0
15	rendah	0	1	0	0	1	0	0	...	0	0

Setelah diperoleh hasil dari analisis Term Frequency (TF), maka langkah selanjutnya adalah melakukan analisis Inverse Document Frequency (IDF). Analisa Inverse Document Frequency (IDF) bertujuan untuk menghitung frekuensi seluruh dokumen yang mengandung kata kunci, yang digunakan untuk memperoleh hasil dalam pembobotan Inverse Document Frequency (IDF) dapat di lihat pada tabel 4 berikut:

Tabel 4. Hasil Pembobotan Inverse Document Frequency (IDF)

		Konotasi Positif			
No	Kata Kunci	DF	N	$\log\left(\frac{N}{df_t}\right) + 1$	
1	turun	4	50	2,097	
2	murah	4	50	2,097	
3	bagus	1	50	2,699	
4	peduli	1	50	2,699	
5	salut	1	50	2,699	
6	terjangkau	1	50	2,699	
7	mantap	1	50	2,699	

		Konotasi Negatif			
No	Kata Kunci	DF	N	$\log\left(\frac{N}{df_t}\right) + 1$	
8	mahal	3	50	2,222	
9	susah	2	50	2,398	
10	sedih	1	50	2,699	

11	beban	1	50	2,699
12	kurang	6	50	1,921
13	rugi	7	50	1,854
14	naik	35	50	1,155
15	rendah	3	50	2,222

Konotasi Positif

No	Kata Kunci	DF	N	$\log\left(\frac{N}{df}\right) + 1$
1	bagus	4	50	2,097
2	mudah	2	50	2,398
3	murah	2	50	2,398
4	akurat	1	50	2,699
5	puas	1	50	2,699
6	percaya	1	50	2,699
7	jamin	1	50	2,699
8	selektif	1	50	2,699

Setelah diperoleh hasil dari pembobotan Inverse Document Frequency (IDF) menggunakan Microsoft Excel maka langkah selanjutnya adalah melakukan pembobotan Term Frequency-Document Frequency (TF-IDF). Pembobotan Term Frequency- Inverse Document Frequency (TF-IDF) bertujuan untuk menghitung frekuensi kata kunci konotasi positif dan negatif. Hasil dari Microsoft Excel dalam pembobotan Term Frequency- Inverse Document Frequency (TF-IDF) dapat dilihat pada tabel 5 berikut:

Tabel 5. Hasil Pembobotan Term Frequency- Inverse Document Frequency (TF-IDF)

		Konotasi Positif								
No	Kata Kunci	D1	D2	D3	D4	D5	...	D49	D50	
1	turun	0	0	0	0	0	...	0	0	
2	murah	0	0	0	0	0	...	2,097	0	
3	bagus	0	0	0	0	0	...	0	0	
4	peduli	2,699	0	0	0	0	...	0	0	
5	salut	0	0	0	0	0	...	0	0	
6	terjangkau	0	0	0	0	0	...	0	0	
7	mantap	0	0	2,699	0	0	...	0	0	

		Konotasi Negatif								
No	Kata Kunci	D1	D2	D3	D4	D5	...	D49	D50	
8	mahal	0	0	0	0	0	...	0	0	
9	susah	0	0	0	0	0	...	0	4,796	
10	sedih	0	0	0	0	0	...	0	2,699	
11	beban	2,699	0	0	0	0	...	0	0	
12	kurang	1,921	0	0	0	0	...	0	0	
13	rugi	0	0	0	0	0	...	1,8854	0	
14	naik	1,155	1,155	1,155	1,155	2,310	...	0	0	
15	rendah	0	2,22	0	0	2,222	...	0	0	

Berdasarkan penjelasan di atas dari hasil pembobotan Term Frequency- Inverse Document Frequency (TF-IDF) dapat disimpulkan hasil pembobotan Term Frequency- Inverse Document Frequency (TF-IDF) yang menggunakan Microsoft Exce dari setiap kata kunci konotasi positif dan negatif. Hasil pembobotan konotasi positif dan negatif dapat dilihat pada tabel 6 berikut:

Tabel 6. Hasil Pembobotan Konotasi Positif dan Negatif

No	Konotasi positif	Bobot konotasi positif	Konotasi negatif	Bobot konotasi negatif
1	turun	10,485	mahal	6,666
2	murah	8,388	susah	7,194
3	bagus	2,699	sedih	2,699
4	peduli	2,699	beban	2,699
5	salut	2,699	kurang	11,525
6	terjangkau	2,699	rugi	12,977
7	mantap	2,699	naik	48,506
8			rendah	8,887
Hasil konotasi positif dan negatif				
positif			negatif	
32,367			101,153	

Berdasarkan hasil konotasi positif dan konotasi negatif yang diperoleh pada hasil analisis algoritma Term Frequency- Inverse Document Frequency (TF-IDF), menggunakan Microsoft Excel dapat diperoleh total hasil bobot dari setiap kata kunci konotasi positif sebesar 32,367 dan setiap kata kunci konotasi negatif sebesar 101,153. Namun untuk mengetahui keseluruhan total hasil sentimen positif dan negatif mengenai naiknya bahan pokok bagi masyarakat dapat dilakukan perhitungan menggunakan rumus berikut:

$$\begin{aligned}\text{Sentimen Positif} &= \frac{100}{\text{Sentimen Positif} + \text{Sentimen Negatif}} \times \text{Sentimen Positif} \\ &= \frac{100}{32,367 + 101,153} \times 32,367 = 24,241\%\end{aligned}$$

$$\begin{aligned}\text{Sentimen Negatif} &= \frac{100}{\text{Sentimen Negatif} + \text{Sentimen Positif}} \times \text{Sentimen Negatif} \\ &= \frac{100}{101,153 + 32,367} \times 101,153 = 75,759\%\end{aligned}$$

Tabel 7. Hasil Sentimen

Sentimen	Hasil Sentimen
Positif	24,241%
Negatif	75,759%
Total Hasil Sentimen	100%

3.3 Pembahasan

Hasil penelitian menunjukkan bahwa bobot indikator sentimen negatif sebesar 101,153 lebih tinggi dibandingkan dengan bobot indikator sentimen positif sebesar 32,367. Berdasarkan persentase yang dilaporkan, sentimen negatif mencapai 75,759%, sedangkan sentimen positif sebesar 24,241%. Temuan tersebut menunjukkan bahwa pada 50 data komentar yang dianalisis, kata-kata yang ditetapkan sebagai indikator negatif memiliki bobot lebih dominan dibandingkan dengan kata-kata yang ditetapkan sebagai indikator positif. Hasil ini memberikan gambaran awal mengenai kecenderungan opini masyarakat terhadap kenaikan harga bahan pokok pada sampel penelitian. Namun, hasil tersebut perlu dipahami sebagai perbandingan bobot berdasarkan kata kunci yang telah ditentukan, bukan sebagai ukuran langsung terhadap keseluruhan sentimen masyarakat atau akurasi suatu model klasifikasi.

Jika dibandingkan dengan penelitian Ardiyanto dan Sela yang menganalisis sentimen opini mahasiswa terhadap aplikasi Portal Mahasiswa UTY menggunakan metode Naive Bayes Classifier, terdapat persamaan dalam pemanfaatan data berbentuk teks untuk mengidentifikasi kecenderungan opini. Perbedaannya terletak pada objek penelitian dan pendekatan analisis yang digunakan. Penelitian terdahulu berfokus pada opini mahasiswa terhadap aplikasi dengan menggunakan algoritma klasifikasi, sedangkan penelitian ini berfokus pada opini masyarakat mengenai kenaikan harga bahan pokok melalui tahapan text mining dan pembobotan Term Frequency-Inverse Document Frequency (TF-IDF). Dengan demikian, penelitian ini menempatkan TF-IDF sebagai pendekatan untuk menghitung bobot kepentingan kata yang telah ditetapkan sebagai indikator sentimen, sementara penelitian Naive Bayes menggunakan pendekatan klasifikasi untuk menentukan kelas opini berdasarkan model yang dibangun. Kedua pendekatan tersebut memiliki tujuan umum yang serupa, tetapi mekanisme penentuan sentimen dan bentuk hasil yang diperoleh berbeda.

Perbandingan berikutnya dapat dilakukan dengan penelitian Aprilia dan Isnain yang membahas analisis sentimen terhadap media sosial Twitter dalam konteks kampanye antikorupsi di Indonesia menggunakan Naive Bayes. Kedua penelitian memanfaatkan media sosial sebagai sumber data untuk mempelajari tanggapan masyarakat terhadap suatu persoalan. Meskipun demikian, perbedaan konteks pembahasan menyebabkan karakteristik kata dan ekspresi opini yang dianalisis juga berpotensi berbeda. Penelitian Aprilia dan Isnain berfokus pada isu antikorupsi, sedangkan penelitian ini membahas persoalan ekonomi yang berkaitan dengan harga kebutuhan sehari-hari. Dari sisi metodologi, penelitian ini menggunakan kata-kata indikator positif dan negatif yang ditentukan terlebih dahulu, kemudian menghitung frekuensi kemunculan serta bobot TF-IDF. Sementara itu, penelitian terdahulu menggunakan Naive Bayes sebagai metode klasifikasi. Perbandingan ini memperlihatkan bahwa analisis sentimen dapat diterapkan pada beragam isu publik, tetapi interpretasi hasilnya harus mempertimbangkan objek penelitian, karakteristik data, serta metode yang digunakan.

Penelitian Azzahra dan Mailoa mengenai analisis sentimen terhadap RSUD Salatiga menggunakan Support Vector Machine (SVM) dan TF-IDF memiliki keterkaitan metodologis yang lebih dekat dengan penelitian ini, khususnya dalam penggunaan TF-IDF untuk merepresentasikan teks secara numerik. Persamaan tersebut terletak pada pemanfaatan bobot kata sebagai bagian dari proses analisis teks. Akan tetapi, terdapat perbedaan mendasar dalam penggunaan metode. Pada penelitian Azzahra dan Mailoa, TF-IDF digunakan bersama SVM, yaitu algoritma klasifikasi, sedangkan dalam penelitian ini pembobotan TF-IDF digunakan untuk menghitung bobot kata-kata yang telah diasumsikan mewakili sentimen positif dan negatif. Oleh karena itu, TF-IDF dalam penelitian ini tidak dapat dipandang sebagai algoritma klasifikasi yang secara otomatis menentukan sentimen suatu komentar. Perbedaan tersebut penting karena hasil penelitian berbasis pembobotan kata tidak dapat dibandingkan secara langsung dengan hasil klasifikasi berbasis SVM tanpa menyamakan dataset, prosedur pelabelan, dan kriteria evaluasi.

Selanjutnya, penelitian Ramadhani dan Suryono yang membandingkan algoritma Naive Bayes dan Logistic Regression untuk analisis sentimen Metaverse menunjukkan adanya pendekatan penelitian yang menekankan evaluasi metode klasifikasi. Penelitian ini berbeda karena tidak melakukan perbandingan kinerja antaralgoritma, melainkan menggambarkan kecenderungan sentimen melalui pembobotan kata berdasarkan TF-IDF. Dengan demikian, kontribusi penelitian ini bukan untuk membuktikan bahwa TF-IDF lebih unggul daripada Naive Bayes, Logistic Regression, SVM, atau metode lainnya, melainkan menerapkan tahapan pengolahan teks dan pembobotan kata pada topik kenaikan harga bahan pokok. Perbandingan tersebut juga menunjukkan peluang pengembangan penelitian berikutnya, yaitu menggunakan bobot TF-IDF sebagai representasi fitur dan mengintegrasikannya dengan algoritma klasifikasi agar hasil analisis dapat dievaluasi menggunakan metrik seperti akurasi, presisi, recall, dan F1-score.

Dari sisi pengolahan data, penelitian ini menerapkan case folding, tokenizing, filtering, dan stemming sebelum menghitung bobot TF-IDF. Tahapan tersebut sejalan dengan kebutuhan prapengolahan teks dalam penelitian analisis sentimen, termasuk penelitian Azzahra dan Mailoa yang menggunakan TF-IDF dalam analisis teks. Prapengolahan bertujuan menyeragamkan bentuk kata dan mengurangi unsur teks yang tidak diperlukan sehingga proses perhitungan menjadi lebih terstruktur. Akan tetapi, efektivitas prapengolahan sangat dipengaruhi oleh aturan yang digunakan. Pada topik kenaikan harga bahan pokok, kata seperti “naik” dan “kurang” dapat memiliki arti yang berbeda bergantung pada konteks kalimat. Selain itu, kata negasi seperti “tidak” dan “bukan” dapat mengubah makna sentimen apabila dihilangkan pada tahap filtering. Oleh sebab itu, penentuan kata indikator dan pemeriksaan hasil prapengolahan menjadi aspek penting dalam menafsirkan bobot yang dihasilkan.

Berdasarkan perbandingan tersebut, posisi penelitian ini terletak pada penerapan text mining dan pembobotan TF-IDF untuk menggambarkan kecenderungan opini masyarakat mengenai kenaikan harga bahan pokok. Penelitian terdahulu yang dirujuk dalam naskah telah membahas analisis sentimen pada beragam objek, baik menggunakan algoritma klasifikasi maupun mengombinasikan TF-IDF dengan metode klasifikasi. Penelitian ini memiliki perbedaan pada fokus permasalahan, jumlah sampel yang dianalisis, serta mekanisme penentuan sentimen berdasarkan kata indikator. Meskipun hasil yang dilaporkan memperlihatkan dominasi bobot negatif, penelitian ini masih memiliki keterbatasan berupa jumlah data yang relatif kecil, yaitu 50 komentar terpilih dari 100 data hasil pengumpulan, serta penggunaan kata indikator yang ditentukan sebelumnya. Dengan kondisi tersebut, hasil penelitian belum dapat digeneralisasi untuk menggambarkan seluruh opini masyarakat.

Secara keseluruhan, penelitian ini memberikan gambaran awal tentang kecenderungan opini negatif terhadap kenaikan harga bahan pokok berdasarkan sampel komentar yang dianalisis. Berbeda dari penelitian terdahulu yang menggunakan algoritma klasifikasi atau membandingkan kinerja beberapa metode, penelitian ini menekankan penghitungan bobot kata melalui TF-IDF sebagai dasar perbandingan indikator sentimen. Untuk meningkatkan kekuatan hasil dan memungkinkan perbandingan yang lebih objektif dengan penelitian sebelumnya, penelitian selanjutnya disarankan menggunakan jumlah data yang lebih besar, melakukan pelabelan sentimen berdasarkan anotasi yang jelas, serta menguji hasil menggunakan data berlabel sebagai acuan. Penggunaan TF-IDF yang dikombinasikan dengan Naive Bayes atau SVM juga dapat dipertimbangkan agar kinerja klasifikasi dapat diukur secara kuantitatif. Dengan pengembangan tersebut, analisis tidak hanya menghasilkan gambaran bobot kata, tetapi juga memungkinkan evaluasi yang lebih terukur mengenai kemampuan metode dalam mengidentifikasi sentimen masyarakat.

4. KESIMPULAN

Penelitian ini membahas analisis sentimen masyarakat terhadap kenaikan harga bahan pokok berdasarkan komentar yang dikumpulkan dari media sosial Twitter dengan menggunakan pendekatan text mining dan pembobotan Term Frequency–Inverse Document Frequency (TF-IDF). Proses penelitian meliputi pengumpulan 100 data melalui crawling, pemilihan 50 data untuk dianalisis, serta pengolahan teks melalui tahapan case folding, tokenizing, filtering, dan stemming. Selanjutnya, kata-kata yang ditetapkan sebagai indikator sentimen positif dan negatif dihitung berdasarkan frekuensi kemunculan dan bobot TF-IDF. Berdasarkan hasil yang dilaporkan dalam naskah, total bobot indikator positif sebesar 32,367 dan total bobot indikator negatif sebesar 101,153, dengan persentase yang dilaporkan masing-masing sebesar 24,241% dan 75,759%. Hasil tersebut menunjukkan bahwa bobot indikator negatif lebih dominan dibandingkan bobot indikator positif pada sampel yang dianalisis. Temuan ini memberikan gambaran awal mengenai kecenderungan opini negatif dalam komentar yang berkaitan dengan kenaikan harga bahan pokok. Meskipun demikian, hasil penelitian perlu ditafsirkan secara hati-hati karena TF-IDF merupakan metode pembobotan kata dan bukan pengukur akurasi klasifikasi secara langsung. Selain itu, jumlah sampel yang terbatas, pemilihan kata indikator, serta kemungkinan perbedaan makna kata berdasarkan konteks membatasi generalisasi hasil. Oleh karena itu, penelitian selanjutnya disarankan menggunakan jumlah data yang lebih besar, memperjelas prosedur pelabelan sentimen, memvalidasi hasil menggunakan label acuan, serta membandingkan pendekatan berbasis leksikon dengan algoritma klasifikasi seperti Naive Bayes atau Support Vector Machine. Langkah tersebut diharapkan menghasilkan analisis yang lebih terukur, dapat direplikasi, dan memberikan gambaran yang lebih representatif mengenai tanggapan masyarakat terhadap perubahan harga bahan pokok.

REFERENCES

- [1] A. Ardiyanto and E. I. Sela, “Analisis Sentimen Opini Mahasiswa terhadap Aplikasi Portal Mahasiswa UTY Menggunakan Metode Naïve Bayes Classifier,” *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 1, pp. 525–540, 2024, doi:

- 10.35870/jimik.v5i1.508.
- [2] N. W. A. S. Aprilia and A. R. Isnain, "Analisis Sentimen Terhadap Media Sosial Twitter dengan Kasus Kampanye Anti-Korupsi di Indonesia Menggunakan Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 695–703, 2024, doi: 10.30865/mib.v8i2.7582.
- [3] S. A. Lestari and Sugiyono, "Analisis Sentimen Pada Media Sosial X (Twitter) Terhadap Tumor Jinak Payudara Menggunakan Metode Naive Bayes," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 3336–3348, 2024, doi: 10.35870/jimik.v5i3.1015.
- [4] A. N. Aida, P. Arsi, R. P. Aji, and Tarwoto, "Analisis Sentimen Pengguna Aplikasi Instagram Pada Situs Google Play Menggunakan Metode Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 704–713, 2024, doi: 10.30865/mib.v8i2.7388.
- [5] B. Ramadhani and R. R. Suryono, "Komparasi Algoritma Naive Bayes dan Logistic Regression Untuk Analisis Sentimen Metaverse," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 714–725, 2024, doi: 10.30865/mib.v8i2.7458.
- [6] T. Hidayat, M. J. Siddiq, S. Jayasri, A. Suhendi, and R. Rizky, "Analisis Sentimen Opini Masyarakat Terhadap Pilkada 2024 di Media Sosial Twitter Menggunakan Algoritma Naive Bayes," *J. Inform. dan Tek. Elektro Terap.*, vol. 13, no. 2, pp. 609–622, 2025, doi: 10.23960/jitet.v13i2.6280.
- [7] V. D. Yunanda and N. Hendrastuty, "Perbandingan Kernel Polynomial dan RBF Pada Algoritma SVM Untuk Analisis Sentimen Skincare di Indonesia," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 726–735, 2024, doi: 10.30865/mib.v8i2.7425.
- [8] D. Ananda and R. R. Suryono, "Analisis Sentimen Publik Terhadap Pengungsi Rohingya di Indonesia dengan Metode Support Vector Machine dan Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 748–757, 2024, doi: 10.30865/mib.v8i2.7517.
- [9] W. L. Azzahra and E. Mailoa, "Analisis Sentimen terhadap RSUD Salatiga Menggunakan SVM dan TF-IDF," *J. Indones. Manaj. Inform. dan Komun.*, vol. 6, no. 1, pp. 478–489, 2025, doi: 10.35870/jimik.v6i1.1208.
- [10] Z. C. Dwinnie and R. Novita, "Penerapan Machine Learning Pada Analisis Sentimen Twitter Sebelum dan Sesudah Debat Calon Presiden dan Wakil Presiden Tahun 2024," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 758–767, 2024, doi: 10.30865/mib.v8i2.7504.
- [11] S. Wulandari and F. N. Hasan, "Analisis Sentimen Masyarakat Indonesia Terhadap Pengalaman Belanja Thrifting Pada Media Sosial Twitter Menggunakan Algoritma Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 768–776, 2024, doi: 10.30865/mib.v8i2.7520.
- [12] I. Oktavia and A. R. Isnain, "Analisis Sentimen Opini Terhadap Tools Artificial Intelligence (AI) Berdasarkan Twitter Menggunakan Algoritma Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 777–787, 2024, doi: 10.30865/mib.v8i2.7524.
- [13] E. Andrian and A. R. Isnain, "Analisis Sentimen Masyarakat Terhadap Tiktok Shop di Twitter Menggunakan Metode Naive Bayes Classifier," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 788–796, 2024, doi: 10.30865/mib.v8i2.7530.
- [14] I. Verawati and S. N. Jaelani, "Analisis Sentimen Pengguna Twitter Terhadap Bus Listrik Menggunakan Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 832–842, 2024, doi: 10.30865/mib.v8i2.7030.
- [15] D. A. Nugroho and F. N. Hasan, "Analisis Sentimen Kegiatan Pembersihan Sampah Pada Media Sosial X Menggunakan SVM dan Naive Bayes," *J. Media Inform. Budidarma*, vol. 8, no. 2, pp. 843–853, 2024, doi: 10.30865/mib.v8i2.7562.
- [16] A. Hendrawan and E. I. Sela, "Analisis Sentimen Komentar Youtube Tentang Resesi Global 2023 Menggunakan LSTM," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 1, pp. 587–593, 2024, doi: 10.35870/jimik.v5i1.526.
- [17] I. M. A. Azis and T. Wahyudi, "Analisa Sentimen Rencana Pemindahan Ibu Kota Nusantara dari Jakarta ke Kalimantan Timur Menggunakan Algoritma Naive Bayes," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2668–2679, 2024, doi: 10.35870/jimik.v5i3.969.
- [18] R. H. Nufus and U. Surapati, "Analisis Sentimen Persepsi Masyarakat Terhadap Timnas Indonesia U-23 dalam AFC-23 Asian Cup 2024 Pada Media Sosial X Menggunakan Metode Naive Bayes Classifier," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2647–2657, 2024, doi: 10.35870/jimik.v5i3.964.
- [19] M. R. Julianto, Y. Akbar, and T. Wahyudi, "Analisis Sentimen Respon Publik Terhadap Program Internet Gratis di Platform X Melalui Pendekatan Algoritma Naive Bayes," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2940–2950, 2024, doi: 10.35870/jimik.v5i3.981.
- [20] I. Amelia, Sugiyono, F. M. Sarimole, and Tundo, "Analisis Sentimen Tanggapan Pengguna Media Sosial X Terhadap Program Beasiswa KIP-Kuliah dengan Menggunakan Algoritma Support Vector Machine (SVM)," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 2994–3003, 2024, doi: 10.35870/jimik.v5i3.990.
- [21] A. A. Lailany and S. Lestari, "Analisis Sentimen Publik Terhadap Penurunan Jumlah Pernikahan di Indonesia menggunakan Algoritma K-Nearest Neighbors (KNN)," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 3043–3053, 2024, doi: 10.35870/jimik.v5i3.1000.
- [22] P. D. Aprilia and S. Lestari, "Analisa Sentimen Drama Korea Melalui Media Sosial X dengan Menggunakan Algoritma Naive Bayes," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 3248–3261, 2024, doi: 10.35870/jimik.v5i3.997.
- [23] D. R. P. Jaya and S. Lestari, "Analisis Sentimen Naturalisasi Tim Nasional Indonesia U-23 di Era Shin Tae-yong Menggunakan Algoritma Naive Bayes dan K-Nearest Neighbors," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 3262–3277, 2024, doi: 10.35870/jimik.v5i3.1024.
- [24] Y. Akbar, A. N. H. Regita, Sugiyono, and T. Wahyudi, "Analisa Sentimen Pada Media Sosial 'X' Pencarian Keyword ChatGPT Menggunakan Algoritma K-Nearest Neighbors (KNN)," *J. Indones. Manaj. Inform. dan Komun.*, vol. 5, no. 3, pp. 3291–3305, 2024, doi: 10.35870/jimik.v5i3.1016.
- [25] D. Nugraha and F. Said, "Implementasi Algoritma C4.5 dan Naive Bayes untuk Analisis Sentimen Publik terhadap Platform Live

Streaming Dukov di Indonesia,” J. Indones. Manaj. Inform. dan Komun., vol. 5, no. 3, pp. 3326–3335, 2024, doi: 10.35870/jimik.v5i3.1011.