

Analisis Sentimen Twitter Atas Isu Hak Angket Menggunakan Pembobotan TF-IDF dan Algoritma SVM

Irqi Anbi Fahrezi¹, Rudiman², Nauval Azmi Verdikha³

^{1,2,3} Universitas Muhammadiyah Kalimantan Timur

2011102441036@umkt.ac.id¹, rudiman@umkt.ac.id², nav651@umkt.ac.id³

ABSTRACT

Social media has become an important platform for voicing public opinion. One of the most popular and frequently used social media is Twitter. Twitter is a popular social media in Indonesia for discussions on political issues. The topic that is being discussed is the "inquiry right" because of the alleged fraud that occurred in the 2024 elections. The alleged fraud in the 2024 elections raised issues related to the rolling of the right of inquiry aimed at finding out the oddity or fraud. Therefore, a method is needed to classify the opinion whether it is classified as a positive or negative sentiment. This research uses 1113 data obtained from Twitter social media by applying crawling techniques. The data goes through several preprocessing stages then feature extraction using Term Frequency-Inverse Document Frequency, split data, and Support Vector Machine algorithms. The test results using these stages obtained an accuracy of 75%, indicating that the applied method is effective in classifying public sentiment related to the inquiry right issue..

Keywords : Accuracy, Inquiry Rights, Support Vector Machine, TF-IDF, Twitter

ABSTRAK

Media sosial menjadi platform penting dalam menyuarakan opini publik. Salah satu media sosial yang sering digunakan dan paling populer adalah Twitter. Twitter menjadi media sosial yang populer di Indonesia digunakan untuk berdiskusi termasuk isu politik. Topik yang ramai diperbincangkan adalah "hak angket" karena adanya dugaan kecurangan yang terjadi pada pemilu tahun 2024. Adanya dugaan kecurangan yang terjadi pada pemilu tahun 2024 memunculkan isu terkait bergulirnya hak angket yang ditujukan untuk mengetahui adanya keganjilan atau kecurangan tersebut. Oleh karena itu diperlukan sebuah metode untuk mengklasifikasikan opini tersebut apakah tergolong sentimen positif atau negatif. Penelitian ini menggunakan sebanyak 1113 data yang telah yang didapatkan dari media sosial Twitter dengan menerapkan teknik crawling. Data melewati beberapa tahapan preprocessing kemudian ekstraksi fitur menggunakan Term Frequency-Invers Document Frequency, split data dan algoritma Support Vector Machine. Hasil pengujian menggunakan tahapan tersebut memperoleh hasil akurasi sebesar 75%, menunjukkan bahwa metode yang diterapkan efektif dalam mengklasifikasikan sentimen publik terkait isu hak angket.

Kata kunci : Akurasi, Hak Angket, Support Vector Machine, TF-IDF, Twitter.

PENDAHULUAN

Melihat polemik yang terjadi di dunia politik belakangan ini adanya indikasi terjadinya kecurangan pada pemilihan umum tahun 2024 sehingga memunculkan isu terkait bergulirnya hak angket oleh Dewan Perwakilan Rakyat (DPR) untuk menuntaskan adanya dugaan keganjilan dan kecurangan (Aryanti et al., 2024). Kekacauan ini terjadi sebab adanya dugaan ketidaknetralan ASN, politik uang dan lainnya yang mana hal ini sudah semestinya dengan bergulirnya hak hak angket dapat menjadi pemberantasan sistem pemilu dan pemerintahan (Supryadi, 2024). Hal ini didasari oleh salah satu hak yang dimiliki oleh DPR sebagaimana tercantum pada Undang-Undang Republik Indonesia Nomor

27 Tahun 2009 Pasal 77 ayat 3 tentang MPR, DPD, DPD, dan DPRD. Hal ini pun akhirnya mengundang berbagai macam respon yang diberikan oleh masyarakat.

Salah satu media dimana masyarakat dapat memberikan komentarnya terhadap suatu isu adalah Twitter. Twitter adalah media sosial yang digunakan untuk mengirimkan pesan singkat atau tweet (Krisdiyanto, 2021). Indonesia dengan jumlah pengguna Twitter yang berkisar 19,5 juta pengguna dengan menduduki peringkat ke-5 media sosial yang sering digunakan pada tahun 2020 (Amelia et al., 2022). Dengan banyaknya pengguna serta kebebasan yang diberikan dalam platform media sosial ini maka penting untuk melakukan analisis sentimen terhadap opini-opini atau pandangan masyarakat terhadap isu-isu tertentu yang diungkapkan di media sosial Twitter.

Analisis sentimen merupakan sebuah metode dalam melakukan ekstraksi data opini, mengolah dan memahami data yang memiliki basis tekstual secara otomatis untuk melihat sentimen yang tercantum pada sebuah pendapat (Hendra & Fitriyani, 2021). Metode analisis ini menerapkan teknik *Natural Language Processing* (NLP) untuk mengidentifikasi kata dan frasa yang menunjukkan emosi tertentu (Munawaroh et al., 2024). Untuk mengatasi pencarian dokumen yang relevan dan mengurangi kesalahan pengambilan, digunakan metode pembobotan *Term Frequency-Inverse Document Frequency* (TF-IDF) untuk pencarian keterkaitan antar beberapa dokumen. merupakan jenis pembobotan yang kerap kali digunakan dalam *information retrieval* (Yutika et al., 2021). TF-IDF merupakan sebuah metode menghitung atau membobotkan kata melalui teknik *tokenisasi, stopwords, stemming* dan frekuensi terhadap munculnya kata dalam sebuah dokumen yang menunjukkan tingkat kepentingan sebuah kata dalam sebuah dokumen (Rofiqi et al., 2019). Untuk melakukan analisis sentimen menggunakan teknik *Text Mining* diperlukan metode klasifikasi yang tepat. Salah satu model algoritma yang kerap kali digunakan dalam klasifikasi yaitu algoritma *Support Vector Machine* (SVM).


SVM memiliki konsep utama dalam klasifikasi data, yaitu menentukan *hyperlane* optimal yang memaksimalkan jarak antara dua kelas yang sudah ada (Tineges et al., 2020). *Hyperlane* merupakan fungsi yang dapat digunakan untuk memisahkan antar kelas pada data (Pratiwi et al., 2021). Merujuk pada penelitian sebelumnya yang berjudul “Penerapan Algoritma SVM Untuk Analisis Sentimen Pada Data Twitter Komisi Pemberantasan Korupsi Republik Indonesia” Dengan mengadopsi algoritma SVM dan TF-IDF untuk melakukan analisis sentimen dari data hasil *crawling* Twitter terhadap opini publik terhadap KPK, dari pengujian didapatkan hasil akurasi sebesar 82% serta dihasilkan sentimen label negatif 77%, positif 8%, dan netral 25% (Darwis et al., 2020). Penelitian kedua pada analisis sentimen layanan indihome menggunakan SVM didapatkan hasil akurasi 87% (Tineges et al., 2020).

Berdasarkan penjelasan pada paragraf sebelumnya, penelitian ini memiliki urgensi penelitian yang terletak pada pentingnya menganalisis sentimen masyarakat yang ada di media sosial terkait isu hak angket dalam konteks pemilihan umum di Indonesia tahun 2024. Proses analisis sentimen dalam penelitian ini akan menerapkan pembobotan atau ekstraksi fitur *Term Frequency-Inverse Document Frequency* (TF-IDF) dan model klasifikasi *Support Vector Machine* (SVM). Hasil akhir yang didapatkan dari penerapan metode tersebut adalah akurasi yang digunakan melakukan evaluasi. Dengan adanya penelitian ini

juga diharapkan dapat berguna bagi lembaga legislatif dalam memahami sentimen terhadap penggunaan hak angket yang dimiliki dalam menjalankan tugas dan kewajiban.

METODE PENELITIAN

Terdapat beberapa tahapan penelitian yang dilakukan yang digambarkan pada gambar 1. Penelitian diawali dengan pengumpulan data, *labeling*, *preprocessing*, ekstraksi fitur, *split* data, *classification*, dan evaluasi. Keseluruhan tahapan dilakukan memanfaatkan bahasa pemrograman Python dan fungsi serta *library* yang dimilikinya seperti *library pandas*, *library NLTK*, *library sastrawi*, *library matplotlib*, *library scikit-learn*. Untuk menuliskan program digunakan *google colabatory* sebagai *text editor*.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Data

Metode yang digunakan untuk mengumpulkan data adalah metode *crawling* pada platform *Twitter* dengan menerapkan kata kunci “hak angket” dalam konteks pemilihan umum Indonesia tahun 2024. *Crawling* dilakukan dengan memanfaatkan *tools tweet-harvest* yang dikembangkan dengan Node.js. *Tweet harvest* adalah *tools* untuk pengambilan data di *Twitter* dengan memanfaatkan *auth_token* Twitter (Yuniarossy et al., 2024).

2.2 Labeling

Data yang telah diekstrak kemudian masuk kedalam tahap labeling. Tujuannya adalah memberikan label pada dataset berdasarkan keadaan emosi dan bahasa pengguna yang ada pada setiap tweet (Aldisa & Maulana, 2022). Pemberian label sentimen dilakukan dengan memberikan label positif ataupun negatif pada komentar berdasarkan acuan dasar kebahasaan. Oleh sebab itu pada penelitian ini labeling dilakukan oleh *expert* dalam di dalam bidangnya dengan memanfaatkan *website projects.co.id*, tempat transaksi antara pengguna jasa dan tenaga ahli.

2.3 Preprocesssing

Tahap *preprocessing* bertujuan untuk mengubah bentuk dokumen yang memiliki data tidak terstruktur menjadi terstruktur agar dapat diolah lebih lanjut (Ridwansyah, 2022). Dalam arti lain *preprocessing* berfungsi untuk mengurangi volume kosa kata dengan menghapus noise dan menyeragamkan bentuk kata pada data (Normawati & Prayogi, 2021). Tahap ini juga menggunakan *library sastrawi* untuk melakukan pemrosesan teks berbasis bahasa Indonesia. Adapun proses *preprocessing* yang diterapkan adalah *case folding, cleaning, tokenizing, stopword, stemming*, dan *delete duplicate* (Supriyadi & Sibaroni, 2023); (Fitriyah & Kartikasari, 2023).

2. 3.1 Case Folding

Data berbasis teks seringkali terjadi inkonsistensi dalam penggunaan huruf kapital. Dengan menerapkan fungsi ‘lower()’ yang dimiliki python seluruh kata didalam dokumen akan diubah menjadi huruf kecil (*lowercase*).

2. 3.2 Cleaning

Cleaning merupakan fungsi guna menghilangkan noise dari kata-kata yang tidak dibutuhkan dalam proses klasifikasi. Kata-kata yang merupakan karakter pada teks yang tidak penting dan tidak mempengaruhi sentimen seperti *hashtag, url, mention, simbol* ataupun karakter non-alfanumerik.

2. 3.3 Tokenizing

Tokenizing adalah proses pemisahan teks panjang dapat berupa kalimat, paragraf ataupun dokumen menjadi potongan-potongan yang disebut juga dengan token (kata). Contohnya pada kalimat “python memiliki banyak library” setelah ditokenisasi menjadi “python, memiliki, banyak, library”.

2.3.4. Stopword

Stopword atau *stopword removal* adalah proses mengambil kata-kata penting dalam dataset. Kata-kata yang bersifat umum, konjungsi, dan tidak memiliki makna akan dihapus, untuk menjalankan tahap ini digunakan *library sastrawi* untuk pemrosesan data teks berbasis bahasa indonesia.

2. 3.5 Stemming

Stemming adalah tahapan yang bertujuan untuk menghapus awalan, akhiran, ataupun gabungan dari keduanya dan merubahnya menjadi kata dasar atau root word. Tahap ini memanfaatkan ‘StemmerFactory’ dari *library sastrawi*.

2. 3.6 Delete Duplicate

Penerapan *delete duplicate* dapat mencegah adanya data berulang yang memiliki makna yang sama. Dengan menjaga kebersihan data dapat menghemat sumber daya dan menghemat waktu pemrosesan.

2.4 Ekstraksi Fitur

Proses selanjutnya, dilakukan pembobotan kata menggunakan *Term Frequency – Inverse Document Frequency* (TF-IDF) adalah proses mentransformasi data yang memiliki basis tekstual menjadi data numerik untuk memberi bobot pada setiap kata atau fitur dengan mengabungkan perhitungan frekuensi kemunculan sebuah kata dan *inverse* frekuensi dokumen yang mengandung kata tersebut (Mahendra., 2019; Septian et al., 2019).

Tujuan TF-IDF adalah melakukan identifikasi kata penting yang ada didalam dokumen atau kata kunci dalam sebuah dokumen atau kumpulan dokumen (Wati et al., 2023).

Nilai *Term Frequency* (TF) merupakan teknik dalam mencari bobot dari dokumen dengan mencari banyaknya kemunculan *term* pada dokumen. Semakin sering sebuah *term* muncul maka akan mempengaruhi nilai pembobotan (Mahendra., 2019). Untuk menghitung *term frequency* suatu dokumen dapat dihitung dengan persamaan (1) sebagai berikut (Ananda & Suryono, 2024):

$$tf_{t,d} = \frac{\text{Jumlah kemunculan term } t \text{ dalam dokumen } d}{\text{Total jumlah term dalam dokumen}} \quad (1)$$

TF memberikan nilai frekuensinya dari kemunculan suatu term dalam sebuah dokumen. Sedangkan *Inverse Document Frequency* adalah metode untuk menghitung penyebaran term pada keseluruhan dokumen (Mahendra., 2019). IDF dapat dihitung menggunakan persamaan (2) (Yutika et al., 2021):

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

Dimana N adalah total jumlah dokumen dalam kumpulan dokumen tersebut. Setelah didapatkan nilai TF dan IDF maka langkah selanjutnya adalah menghitung nilai TF-IDF dengan mengalikan kedua nilai TF dan nilai IDF. Dari kedua persamaan diatas maka nilai TF-IDF dapat dihitung menggunakan persamaan (3) (Yutika et al., 2021):

$$tfidf_{t,d} = tf_{t,d} * idf_t \quad (3)$$

2.5 Split Data

Merupakan metode yang dapat diterapkan untuk membagi dataset dan merupakan salah satu dari banyak aspek dapat menyebabkan pengaruh dari kinerja optimal suatu model dapat bekerja pada algoritma *machine learning* (Oktafiani et al., 2023). Data latih berfungsi untuk *mentraining* algoritma, sedangkan data uji berfungsi untuk memeriksa kinerja algoritma (Putri et al., 2023). Rasio pembagian data yang diterapkan pada penelitian ini yaitu sebesar 80% data akan digunakan sebagai data latih dan 20% sebagai data uji. Rasio ini mengacu pada penelitian sebelumnya dengan rasio 80:20 digunakan dapat menghasilkan performa yang baik dalam model klasifikasi sentimen dengan akurasi sebesar 87% (Pratiwi et al., 2021). Tahap *split data* memanfaatkan *library* ‘train_test_split’ dari *library sklearn*.

2.6 Classification

SVM adalah metode klasifikasi yang memungkinkan data dipisahkan kedalam kelas yang berbeda dengan mencari *hyperplane* optimal yang memaksimalkan jarak antar kelas-kelas tersebut (Ananda & Suryono, 2024). Tujuannya adalah untuk menemukan batasan keputusan optimal yang memisahkan data sebaik mungkin. Penerapan SVM memiliki tujuan untuk menemukan *hyperlane* optimal melalui cara memaksimalkan jarak antar kelas. *Hyperplane* adalah fungsi yang dapat digunakan untuk memisahkan beberapa kelas (Pratiwi et al., 2021). SVM sangat efektif dalam memproses data yang kompleks dan cocok untuk ruang fitur yang luas. Pada dasarnya, SVM merupakan suatu *linear classifier*, namun SVM dapat dikembangkan menjadi *nonlinear classifier* (Ade Dwi Dayani et al., 2024). Berikut adalah persamaan (4) merupakan rumus kernel linear pada SVM (Rahayu et al., 2022):

$$k(x_i, x) = x^t x \quad (4)$$

Secara default dari penerapan ‘*scikit-learn*’ untuk memodelkan klasifikasi menggunakan kernel *Radial Basis Function* (RBF), tetapi dengan menambahkan parameter (*kernel='linear'*) pada program maka kernel linear dapat digunakan dalam proses klasifikasi. Kernel linear menghitung produk titik (*dot product*) dari dua vektor input di ruang asli tanpa mentransformasikannya ke ruang fitur yang lebih tinggi (Rabbani et al., 2023). Berikut adalah persamaan (5) merupakan persamaan *support vector machine* (Oktavia et al., 2023):

$$f(x) = \sum_{i=1}^{\infty} a_i y_i K(x, x^i) + b \quad (5)$$

Keterangan:

a_i = alfa ke-i

y_i = kelas data latih ke-i

Σ = jumlah data

$K(x, x')$ = fungsi kernel yang digunakan, dengan

x = data uji

x_i = data latih ke-i

b = bias

Hasil permodelan dapat dituangkan dalam bentuk tabel *confusion matrix*. *Confusion matrix* adalah tabel yang menunjukkan Jumlah data hasil pengujian klasifikasi yang benar dan jumlah data pengujian yang salah (Normawati & Prayogi, 2021). Berikut adalah tabel 1 merupakan *confusion matrix*:

Tabel 1. Confusion Matrix

		Prediksi	
		Negative	Positive
Aktual	Negative	TN (<i>True Negative</i>)	FP (<i>False Positive</i>)
	Positive	FN (<i>False Negative</i>)	TP (<i>True Positive</i>)

Keterangan:

- True Positive (TP)*, adalah nilai dari kelas positif yang diprediksi dengan benar.
- True Negative (TN)*, adalah nilai dari kelas negatif yang diprediksi dengan benar.
- False Positive (FP)*, adalah nilai dari kelas negatif yang diprediksi sebagai label positif.
- False Negative (FN)*, adalah nilai dari kelas positif yang diprediksi sebagai label negatif.

2.6 Evaluasi

Pada penelitian ini penilaian kinerja algoritma hanya menentukan nilai akurasi untuk mengevaluasi kinerja yang diberikan dari algoritma. Akurasi merupakan nilai rasio data *tweet* yang benar terdeteksi di dalam data pengujian. Dalam arti lain akurasi adalah ukuran yang menunjukkan seberapa dekat hasil atau nilai prediksi yang diberikan sistem dengan nilai hasil prediksi manusia (Azhari et al., 2021). berikut persamaan rumus untuk menghitung nilai akurasi:

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

HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Pengambilan data dilakukan dengan rentang waktu pencarian 14 November 2023 - 10 Mei 2024 agar data yang diambil merupakan data yang relevan dalam masa pemilu Indonesia tahun 2024. Dari proses pengambilan data tersebut didapatkan total data mentah sebanyak 1113 data, kemudian data disimpan dalam format file "hakangket.csv" yang akan digunakan pada proses selanjutnya. Hasil *crawling* terdiri dari 15 kolom namun untuk mempermudah proses analisis data pada tahapan selanjutnya, maka hanya kolom *full_text* saja yang digunakan. Berikut adalah gambar 2 menampilkan data yang berhasil dikumpulkan.

conversation_id_str	created_at	Favorite_count	full_text	id_str	image_url	in_reply_to_screen_name	lang	location	quote_count	reply_count	retweet_count	tweet_url	user_id_str	username
1798319876692383237	Fri Jun 07 12:12:27 +0000 2024	0	@MichelAdam7... Sudah wkt nya Hak Angket dip..._	1799081797220499872	Nah	MicheleAdam7...	In	NaN	0	0	0	https://x.com/AchmadSucihami2/status/1799081797220499872	AchmadSucihami2	
179816432422049993	Fri Jun 07 10:39:41 +0000 2024	0	Hak Angket - Kalau misalnya ga punya sama perjal..._	1799028440017349986	Nah	prasastutian	In	Maasshort	0	1	0	https://x.com/prasastutian/status/1799028440017349986	prasastutian	
1798842099144870562	Fri Jun 07 08:21:18 +0000 2024	1	@Ika_hm71 Yang ngotot UU Tapera disahkan siapa..._	179903811649983269	Nah	Ika_hm71	In	NaN	0	0	0	https://x.com/Dppahan4/status/179903811649983269	Dppahan4	
1789577857833173216	Fri Jun 07 07:18:59 +0000 2024	1	@gociticcom AH MHDSBN LBIKUTNYA HAK ANGKET MANA..._	1799078877839173216	Nah	deltocom	In	NaN	0	0	0	https://x.com/ayut6531/status/1799078877839173216	ayut6531	
1798647487333586444	Fri Jun 07 06:58:20 +0000 2024	0	@jokasirazo PDF-P pak usah bantuin drakor pasok..._	179907123502811818	Nah	gekoraz	In	Indonesia	0	0	0	https://x.com/jokasirazono/status/179907123502811818	jokasirazono	
...	In	NaN	0	0	0	
1793327344092383237	Thu May 23 11:55:38 +0000 2024	0	@Miqut77 Aaah... kalau yakar mabul belum ngl..._	17936117455772304166	Nah	Miqut77	In	NaN	0	0	0	https://x.com/akierooo/status/17936117455772304166	akierooo	
1792392415124914444	Thu May 23 11:33:34 +0000 2024	0	@maaid_idu Mengenalkan kasus UU ket artingan..._	1793616190230452082	Nah	maaid_idu	In	NaN	0	0	0	https://x.com/BunaJannah/status/1793616190230452082	BunaJannah	
179344864992017199	Thu May 23 11:09:58 +0000 2024	0	@IkaWibuber @PrabowoHaryati @bernasih_m33350 @..._	179360222070801068	Nah	Kakanhuber	In	NaN	0	0	0	https://x.com/BunaJannah/status/179360222070801068	BunaJannah	
179367676468111783	Thu May 23 09:30:34 +0000 2024	2	SAVE NRR apakah jokowi TIDAK HADIR SAAT OPA..._	179367676468111783	Nah	NaN	In	NaN	0	0	0	https://x.com/EN88321139/status/179367676468111783	EN88321139	
1793492288119783739	Thu May 23 09:18:34 +0000 2024	0	@PDU_Perlengkaran DEB HAK ANGKET SUD PADAM..._	179367144077267957	Nah	PDU_Perlengkaran	In	NaN	0	0	0	https://x.com/ahadet952613/status/179367144077267957	ahadet952613	

Gambar 2. Data hasil Crawling


3.2 Labeling

Sebanyak 1113 data diberi label sentimen positif dan negatif oleh *expert* yang hasilnya ditampilkan pada tabel 2 dibawah ini.

Tabel 2. Dataset Terlabeli

	Full_text	Label
1	@democrazymedia Njirr katanya hak angket? Manaaaaaa ?? Penipu lu	Negatif
...
1113	@gorunbiraz3 @jokowi @prabowo @gibran_tweet @AgusYudhoyono @bengkeldodo @cocolatetwo @KangayamLombok Padahal tinggal lakuin hak angket	Positif

Hasil pemberian label dapat divisualisasikan dalam bentuk grafik lingkaran untuk menampilkan persentase kelas. Gambar 3 dibawah ini menunjukan bahwa dalam dataset terdapat 64,3% data tergolong kelas negatif dan 35,7% data adalah kelas positif, apabila dinyatakan dalam angka yaitu 397 merupakan kelas positif dan 716 adalah kelas negatif. Artinya banyak pengguna *Twitter* yang condong memberikan respon negatif dalam mengomentari isu hak angket yang ramai diperbincangkan.



Gambar 3. Persentase Kelas Positif dan Negatif

3.3 Preprocessing

Data yang belum diolah dapat ditampilkan dalam bentuk *wordcloud* untuk melihat pola kata yang sering muncul. Gambar 4 adalah *wordcloud* sebelum dataset melalui proses *preprocessing*.



Gambar 4. Wordcloud Sebelum Preprocessing

Dari gambar diatas menunjukkan kata-kata yang paling sering muncul dalam dataset yang berkaitan dengan topik Hak Angket seperti “https”, “dan”, “yg”, “PDIP”, “co”, “itu”, “Puan Maharani”, “Jokowi” dan kata-kata lainnya juga muncul dalam *wordcloud* menunjukkan bahwa didalam dataset terdapat kata-kata bersifat umum, tidak baku, bahkan *url* yang tidak memiliki pengaruh apapun. Kata-kata ini perlu dihilangkan agar tidak menjadi *noise* dan mempengaruhi hasil akhir yang didapatkan. Keberadaan kata yang tidak memiliki makna ini menunjukkan bahwa pentingnya tahapan *preprocessing* untuk membuat dataset yang digunakan menjadi lebih terstruktur.

Sebanyak 1113 data mentah yang telah diberi label positif dan negatif diproses melewati tahap *case folding*, *cleaning*, *tokenizing*, *stopword*, *stemming*, dan *delete duplicate* untuk menciptakan data yang terstruktur. Hasil dari tahapan *preprocessing* ditampilkan dalam bentuk *wordcloud* gambar 5.



Gambar 5. Wordcloud Sebelum Preprocessing

Setelah dilakukannya *preprocessing* menyisakan 939 data bersih yang akan digunakan dalam tahapan selanjutnya. Data-data ini dapat divisualisasikan dalam bentuk

wordcloud untuk melihat kata-kata apa saja yang sering muncul pada dataset baik sebelum ataupun sesudah proses *preprocessing*. Gambar *wordcloud* diatas memberikan informasi adanya perbedaan pola pada kata-kata yang sering muncul dalam dataset selain itu perubahan juga lainnya terdapat pada berubahnya setiap kata yang memiliki awalan. Namun secara keseluruhan proses *preprocessing* masih memiliki kekurangan. Kekurangan tersebut terdapat pada tahap *stopword*, dimana masih terdapat kata-kata yang tidak memiliki arti belum terhapus secara menyeluruh contohnya adalah kata “yg”, “gak”, “ya”, “nya”, “sdh”, “ga”, dan sebagainya. Hal ini dikarenakan dari *library sastrawi* yang digunakan untuk memproses data teks berbasis bahasa Indonesia tidak sepenuhnya mencakup kata-kata istilah, bahasa gaul, atau singkatan yang digunakan oleh masyarakat dalam memberikan opininya. Permasalahan ini dapat menyebabkan pengaruh pada hasil dari pembobotan TF-IDF serta penerapannya pada algoritma SVM.

3.4 Ekstraksi Fitur


Setiap kata dalam dataset diproses dan dikonversi menjadi nilai vektor numerik. Hasil dari penerapan fungsi TF-IDF menggunakan persamaan rumus 3. output yang diberikan pada baris pertama menghasilkan (0, 2636) menunjukkan bahwa kata dalam dokumen indeks ke-0 dan indeks *term* dalam *vocabulary* ke-2636 memiliki nilai TF-IDF 0,4142567525057198. Untuk output (938, 151) yaitu kata dalam dokumen indeks ke-938 dan indeks *term* ke-151 dalam *vocabulary* memiliki nilai TF-IDF 0,11694591337534087. Proses TF-IDF menghasilkan hasil akhir jumlah baris data sebanyak 939 baris dengan jumlah 2846 *term*. Hasil perhitungan TF-IDF ditampilkan pada gambar 6.

TF-IDF Vocabulary Size: 2846 stemmed words (Indeks dokumen, Indeks Vocabulary) Nilai TF-IDF	
(0, 2636)	0.4142567525057198
(0, 1802)	0.5690749930139379
(0, 1485)	0.5690749930139379
(0, 1432)	0.4087676538015373
(0, 854)	0.08257928762885247
(0, 151)	0.0824036575914
(1, 2269)	0.41203315089023
(1, 2204)	0.43679355410911896
(1, 2200)	0.43679355410911896
(1, 2085)	0.43679355410911896
(1, 2084)	0.2656016759152822
(1, 2065)	0.29618235425927586
(1, 877)	0.3026163699991302
(1, 854)	0.06338383873384698
(1, 151)	0.06324983367206515
(2, 2734)	0.24778353561026176
(2, 2690)	0.23373749441987526
(2, 2526)	0.2972634991490242
(2, 2500)	0.44754333919301686
(2, 2414)	0.22377166959650843
(2, 2331)	0.23373749441987526
(2, 2161)	0.21604157531691023
(2, 2000)	0.17798366811187039
(2, 1618)	0.11515250600275552
(2, 921)	0.1997598035827551
:	:
(935, 854)	0.06445018789121043
(935, 772)	0.3328844538418887
(935, 489)	0.444142027279415
(935, 218)	0.4011017226690048
(935, 151)	0.06431311491276544
(935, 129)	0.4189650630627091
(936, 1944)	0.37981042210341653
(936, 1517)	0.53181716427325
(936, 854)	0.11381033640741206
(936, 659)	0.404278842561801
(936, 151)	0.11356828402091597
(936, 148)	0.6193732828753261
(937, 1944)	0.23711954576897687
(937, 1839)	0.37946860029539026
(937, 1062)	0.48964335662390107
(937, 854)	0.07105296143082653
(937, 727)	0.2472454811414237
(937, 311)	0.48964335662390107
(937, 151)	0.07090184564095328
(937, 95)	0.4421936717817633
(937, 78)	0.2313774031323151
(938, 2631)	0.5659840532013405
(938, 1350)	0.8076205781514263
(938, 854)	0.11719516463124831
(938, 151)	0.11694591337534087
Jumlah Baris: 939	
Jumlah terms: 2846	

Gambar 6. Hasil TF-IDF

3.5 Split Data


Penelitian ini melakukan *split* data dengan porsi dari data latih dan data uji yaitu 80:20 dengan 80% data latih dan 20% data uji dengan mengambil data hasil dari pembobotan TF-IDF. Gambar 7 menampilkan hasil pembagian data dengan output dari proses *split* data, dari 939 data 751 data adalah data latih dan 188 data merupakan data uji.



Gambar 7. Hasil Split Data

3.6 Klasifikasi

Pada tahap klasifikasi 188 data diuji menggunakan model *Support Vector Machine* menghasilkan prediksi yang dapat disajikan dalam bentuk confusion matrix. Gambar 8 menampilkan *confusion matrix*.



Gambar 8. Confusion Matrix

Berdasarkan gambar dapat diketahui bahwa dari penerapan model algoritma didapatkan *confusion matrix* yaitu *True Positive* 21 (21 data yang diklasifikasikan kelas positif dan benar kelas positif), *True Negative* 120 (120 data yang diklasifikasikan kelas negatif dan benar kelas negatif), *False Positive* 7 (7 data yang sebenarnya kelas negatif, tetapi salah diklasifikasikan sebagai kelas positif), *False Negative* (FN) 40 (40 data yang sebenarnya adalah kelas positif, tetapi salah diklasifikasikan sebagai kelas negatif).

3.7 Evaluasi

Berdasarkan *confusion matrix* yang dihasilkan, maka dapat dihitung nilai akurasi dari hasil permodelan dengan menggunakan persamaan rumus 6 yang dapat dijabarkan dalam bentuk perhitungan sebagai berikut.

$$\text{Accuracy} = \frac{21+120}{21+7+40+120} = \frac{141}{188} = 0,75 \quad (7)$$

Dari penerapan persamaan rumus diatas dapat dijelaskan secara rinci dari perhitungan yang ada. Nilai penjumlahan 21 (TP) + 120 (TN) adalah 141 merupakan jumlah prediksi benar kemudian dibagi dengan total keseluruhan prediksi 21(TP) + 7 (FP) + 40 (FN) + 120 (TN) adalah 188. Jumlah data tersebut kemudian dibagi sehingga didapatkan nilai akhir yaitu 0,75. Menunjukkan bahwa model yang digunakan mampu melakukan prediksi yang benar sebesar 75% dari keseluruhan data yang diuji.

KESIMPULAN DAN SARAN

Berdasarkan penelitian yang telah berhasil dilakukan maka dapat disimpulkan penelitian ini menggunakan data yang diambil dari media sosial *Twitter* mengenai topik Hak Angket menggunakan teknik *crawling*. Didapatkan 1113 kemudian diberikan label sentimen yang menghasilkan 397 positif dan 716 negatif. Data kemudian diproses pada tahap *preprocessing*, tahap ini menghasilkan data bersih siap olah sebanyak 939 data. Selanjutnya data dibobotkan menggunakan TF-IDF untuk dibobotkan dengan merubah data menjadi nilai vektor numerik, yang menghasilkan 939 baris dan 2846 kata unik.

Selanjutnya dengan mengimplementasikan metode *Support Vector Machine* dengan distribusi data latih 80% dan data uji 20% didapatkan akurasi sebesar 75%. Dengan hasil *confusion matrix* *true positif* 21, *true negatif* 120, *false positif* 7, dan *false negatif* 40. Namun pada penelitian ini terdapat kekurangan yaitu tidak optimalnya hasil yang diberikan pada tahap *preprocessing* sebab masih adanya kata-kata yang tidak memiliki makna belum terhapus secara menyeluruh pada tahap *stopword*. Hal ini dapat menyebabkan kata-kata yang tidak penting mendapatkan bobot yang tidak seharusnya dalam model TF-IDF, sehingga mengaburkan kata-kata yang benar-benar penting. Selain itu hasil *stopword* yang tidak optimal ini juga dapat menyebabkan dimensionalitas fitur, sehingga membuat model lebih kompleks dan adanya potensi *overfitting* pada algoritma.

DAFTAR PUSTAKA

- Ade Dwi Dayani, Yuhandri, & Widi Nurcahyo, G. (2024). Analisis Sentimen Terhadap Opini Publik pada Sosial Media Twitter Menggunakan Metode Support Vector Machine. *Jurnal KomtekInfo*, 11, 1–10. <https://doi.org/10.35134/komtekinfo.v11i1.439>
- Aldisa, R. T., & Maulana, P. (2022). Analisis Sentimen Opini Masyarakat Terhadap Vaksinasi Booster COVID-19 Dengan Perbandingan Metode Naive Bayes, Decision Tree dan SVM. *Building of Informatics, Technology and Science (BITS)*, 4(1), 106–109. <https://doi.org/10.47065/bits.v4i1.1581>
- Amelia, R., Darmansah, D., Prastiwi, N. S., & Purbaya, M. E. (2022). Implementasi Algoritma Naive Bayes Terhadap Analisis Sentimen Opini Masyarakat Indonesia Mengenai Drama Korea Pada Twitter. *JURIKOM (Jurnal Riset Komputer)*, 9(2), 338. <https://doi.org/10.30865/jurikom.v9i2.3895>
- Ananda, D., & Suryono, R. R. (2024). *Analisis Sentimen Publik Terhadap Pengungsi Rohingya di Indonesia dengan Metode Support Vector Machine dan Naïve Bayes*. 8(April), 748–757. <https://doi.org/10.30865/mib.v8i2.7517>
- Aryanti, D., Aeni, Q., Razi, F., & Qalban, A. A. (2024). Framing Pemberitaan Wacana Hak Angket Dpr Pasca Pemilu Di Media Online. *Jurnal Mutakallimin : Jurnal Ilmu Komunikasi*, 7(1), 49–57. <https://doi.org/10.31602/jm.v7i1.14537>
- Azhari, M., Situmorang, Z., & Rosnelly, R. (2021). Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes. *Jurnal Media Informatika Budidarma*, 5(2), 640. <https://doi.org/10.30865/mib.v5i2.2937>
- Darwis, D., Pratiwi, E. S., & Pasaribu, A. F. O. (2020). Penerapan Algoritma Svm Untuk Analisis Sentimen Pada Data Twitter Komisi Pemberantasan Korupsi Republik Indonesia. *Edutic - Scientific Journal of Informatics Education*, 7(1), 1–11. <https://doi.org/10.21107/edutic.v7i1.8779>
- Fitriyah, Z., & Kartikasari, M. D. (2023). Text Classification of Twitter Opinion Related To Permendikbud 30/2021 Using Bidirectional Lstm. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 17(2), 1113–1122. <https://doi.org/10.30598/barekengvol17iss2pp1113-1122>
- Hendra, A., & Fitriyani, F. (2021). Analisis Sentimen Review Halodoc Menggunakan Naïve Bayes Classifier. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 6(2), 78–89. <https://doi.org/10.14421/jiska.2021.6.2.78-89>

- Krisdiyanto, T. (2021). Analisis Sentimen Opini Masyarakat Indonesia Terhadap Kebijakan PPKM pada Media Sosial Twitter Menggunakan Naïve Bayes Clasifiers. *Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer Dan Teknologi Informasi*, 7(1), 32. <https://doi.org/10.24014/coreit.v7i1.12945>
- Mahendra. (2019). Penerapan Cosine Similarity dan Pembobotan TF-IDF untuk Mnendeteksi Kemiripan Dokumen. *Seminar Hasil Pengabdian Masyarakat 2019*, 2(1), 49–54.
- Munawaroh, A., Ridhoi, R., & Rudiman, R. (2024). Sentiment Analysis Dengan Naïve Bayes Berbasis Orange Terhadap Resiko Pembangunan Ikn. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(1), 587–592. <https://doi.org/10.36040/jati.v8i1.8454>
- Normawati, D., & Prayogi, S. A. (2021). Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 5(2), 697–711.
- Oktafiani, R., Hermawan, A., & Avianto, D. (2023). Pengaruh Komposisi Split data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma Machine Learning. *Jurnal Sains Dan Informatika*, 9(April), 19–28. <https://doi.org/10.34128/jsi.v9i1.622>
- Oktavia, D., Ramadahan, Y. R., & Minarto. (2023). Analisis Sentimen Terhadap Penerapan Sistem E-Tilang Pada Media Sosial Twitter Menggunakan Algoritma Support Vector Machine (SVM). *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 4(1), 407–417. <https://doi.org/10.30865/klik.v4i1.1040>
- Pratiwi, R. W., H, S. F., Dairoh, D., Af'idah, D. I., A, Q. R., & F, A. G. (2021). Analisis Sentimen Pada Review Skincare Female Daily Menggunakan Metode Support Vector Machine (SVM). *Journal of Informatics, Information System, Software Engineering and Applications (INISTA)*, 4(1), 40–46. <https://doi.org/10.20895/inista.v4i1.387>
- Putri, A., Hardiana, C. S., Novfuja, E., Siregar, F. T. P., Rahmaddeni, R., Fatma, Y., & Wahyuni, R. (2023). Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 3(1), 20–26. <https://doi.org/10.57152/malcom.v3i1.610>
- Rabbani, S., Safitri, D., Rahmadhani, N., Sani, A. A. F., & Anam, M. K. (2023). Perbandingan Evaluasi Kernel SVM untuk Klasifikasi Sentimen dalam Analisis Kenaikan Harga BBM. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 3(2), 153–160. <https://doi.org/10.57152/malcom.v3i2.897>
- Rahayu, A. S., Fauzi, A., & Rahmat, R. (2022). Komparasi Algoritma Naïve Bayes Dan Support Vector Machine (SVM) Pada Analisis Sentimen Spotify. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 4(2), 349. <https://doi.org/10.30865/json.v4i2.5398>
- Ridwansyah, T. (2022). Implementasi Text Mining Terhadap Analisis Sentimen Masyarakat Dunia Di Twitter Terhadap Kota Medan Menggunakan K-Fold Cross Validation Dan Naïve Bayes Classifier. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 2(5), 178–185. <https://doi.org/10.30865/klik.v2i5.362>
- Rofiqi, M. A., Fauzan, A. C., Agustin, A. P., & Saputra, A. A. (2019). Implementasi Term-Frequency Inverse Document Frequency (TF-IDF) Untuk Mencari Relevansi Dokumen Berdasarkan Query. *ILKOMNIKA: Journal of Computer Science and Applied*

- Informatics*, 1(2), 58–64. <https://doi.org/10.28926/ilkomnika.v1i2.18>
- Septian, J. A., Fachrudin, T. M., & Nugroho, A. (2019). Analisis Sentimen Pengguna Twitter Terhadap Polemik Persepakbolaan Indonesia Menggunakan Pembobotan TF-IDF dan K-Nearest Neighbor. *Journal of Intelligent System and Computation*, 1(1), 43–49. <https://doi.org/10.52985/insyst.v1i1.36>
- Supriyadi, P. F., & Sibaroni, Y. (2023). Xiaomi Smartphone Sentiment Analysis on Twitter Social Media Using IndoBERT. *Jurnal Riset Komputer*, 10(1), 2407–389. <https://doi.org/10.30865/jurikom.v10i1.5540>
- Supryadi, A. (2024). Urgensi Hak Angket Dewan Perwakilan Rakyat Republik Indonesia Guna Menyelidiki Dugaan Kecurangan Pemilu. *Ganec Swara*, 18(1), 491. <https://doi.org/10.35327/gara.v18i1.785>
- Tineges, R., Triayudi, A., & Sholihat, I. D. (2020). Analisis Sentimen Terhadap Layanan Indihome Berdasarkan Twitter Dengan Metode Klasifikasi Support Vector Machine (SVM). *Jurnal Media Informatika Budidarma*, 4(3), 650. <https://doi.org/10.30865/mib.v4i3.2181>
- Wati, R., Ernawati, S., & Rachmi, H. (2023). Pembobotan TF-IDF Menggunakan Naïve Bayes pada Sentimen Masyarakat Mengenai Isu Kenaikan BIPIH. *Jurnal Manajemen Informatika (JAMIKA)*, 13(1), 84–93. <https://doi.org/10.34010/jamika.v13i1.9424>
- Yuniarrossy, B. A., Hindrayani, K. M., & Damaliana, A. T. (2024). Analisis Sentimen Terhadap Isu Feminisme Di Twitter Menggunakan Model Convolutional Neural Network (Cnn). *Jurnal Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika Dan Statistika*, 5(1), 477–491. <https://doi.org/10.46306/lb.v5i1.585>
- Yutika, C. H., Adiwijaya, A., & Faraby, S. Al. (2021). Analisis Sentimen Berbasis Aspek pada Review Female Daily Menggunakan TF-IDF dan Naïve Bayes. *Jurnal Media Informatika Budidarma*, 5(2), 422. <https://doi.org/10.30865/mib.v5i2.2845>