

ANALISIS SENTIMEN MENGGUNAKAN NAIVE BAYES MULTINOMIAL TERHADAP ISU KAESANG PANGAREP DI MEDIA SOSIAL X

Hafizh Fuzan Syawwali¹, Rizky Pradana^{2*}

^{1,2} Teknik Infomatika, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia

Email: ¹2011500937@student.budiluhur.ac.id, ^{2*}rizky.pradana@budiluhur.ac.id

Abstrak- Di era digital, media sosial seperti Twitter (X) menjadi platform utama untuk menyampaikan pendapat dan berbagi informasi. Kaesang Pangarep, yang aktif dalam dunia bisnis, media, dan politik sejak September 2023, menarik perhatian publik dengan berbagai inisiatifnya. Penelitian ini bertujuan untuk menganalisis sentimen publik terhadap isu-isu yang terkait dengan Kaesang Pangarep pada tahun 2024 melalui platform Twitter. Dataset yang digunakan dalam penelitian ini berjumlah 443 tweet yang dikumpulkan menggunakan Tweet Harvest dan dilabeli secara manual ke dalam kategori positif, negatif, dan netral. Metode yang digunakan dalam penelitian ini adalah pembobotan TF-IDF untuk representasi teks, serta algoritma Naïve Bayes Multinomial untuk klasifikasi sentimen. Model kemudian dievaluasi dengan metrik akurasi, precision, recall, dan F1-score. Hasil menunjukkan bahwa model memiliki akurasi 71,91% untuk sentimen positif, 58,43% untuk sentimen negatif, dan 57,30% untuk sentimen netral. Precision untuk kategori positif mencapai 80,00%, sedangkan untuk kategori negatif dan netral masing-masing sebesar 47,06% dan 33,33%. Recall tertinggi diperoleh pada kategori negatif sebesar 70,59%, sedangkan recall untuk kategori positif dan netral masing-masing adalah 14,29% dan 40,74%. F1-score terbaik berada di kategori negatif dengan nilai 56,47%. Penelitian ini menunjukkan bahwa metode Naïve Bayes Multinomial mampu membedakan sentimen publik terhadap Kaesang Pangarep dengan tingkat keberhasilan yang moderat. Hasil ini dapat menjadi acuan untuk memahami persepsi masyarakat melalui analisis sentimen di media sosial, khususnya terhadap tokoh publik di Indonesia.

Kata Kunci: *Text mining, Analisis Sentimen, TF-IDF, Crawling, Naïve Bayes Multinomial*

SENTIMENT ANALYSIS USING MULTINOMIAL NAIVE BAYES ON THE ISSUE OF KAESANG PANGAREP ON SOCIAL MEDIA X

Abstract- *In the digital era, social media platforms like Twitter (X) have become key channels for expressing opinions and sharing information. Kaesang Pangarep, who has been active in the business, media, and political arenas since September 2023, has garnered public attention with his various initiatives. This research aims to analyze public sentiment regarding issues related to Kaesang Pangarep in 2024 through Twitter. The dataset used in this study consists of 443 tweets collected using Tweet Harvest and manually labeled into positive, negative, and neutral categories. The method applied in this research is TF-IDF weighting for text representation, along with the Naïve Bayes Multinomial algorithm for sentiment classification. The model was then evaluated using accuracy, precision, recall, and F1-score metrics. The results show that the model achieved 71.91% accuracy for positive sentiment, 58.43% for negative sentiment, and 57.30% for neutral sentiment. The precision for the positive category reached 80.00%, while for the negative and neutral categories, it was 47.06% and 33.33%, respectively. The highest recall was obtained for the negative category at 70.59%, while recall for the positive and neutral categories was 14.29% and 40.74%, respectively. The best F1-score was in the negative category, with a value of 56.47%. This study demonstrates that the Naïve Bayes Multinomial method can moderately distinguish public sentiment toward Kaesang Pangarep. These findings can serve as a reference for understanding public perception through sentiment analysis on social media, particularly regarding public figures in Indonesia..*

Keywords: *Text mining, Analysis Sentiment, TF-IDF, Crawling, Naïve Bayes Multinomial*

1. PENDAHULUAN

Di era digital saat ini, media sosial telah menjadi platform utama bagi masyarakat untuk menyampaikan pendapat dan berbagi informasi. Platform seperti Twitter (yang kini dikenal sebagai media sosial X) memungkinkan pengguna untuk berinteraksi dengan cepat dan mudah [1]. Namun, dalam menyampaikan pendapat dan informasi, bisa timbul sentimen yang mencerminkan pandangan seseorang secara positif, negatif, atau netral terhadap suatu hal [2].

Pemerintahan Indonesia terdiri dari berbagai institusi dan lembaga yang bekerja sama untuk menjalankan negara. Indonesia menganut sistem republik konstitusional dengan demokrasi presidensial. Namun, di media sosial X, berbagai opini mengenai Kaesang Pangarep sering kali menjadi bahan diskusi. Siapa sebenarnya

Kaesang Pangarep? Kaesang Pangarep adalah seorang pengusaha makanan, youtuber Indonesia, dan individu yang aktif dalam dunia politik sejak 23 September 2023. Dia adalah anak bungsu dari Presiden ke-7 Republik Indonesia, Joko Widodo. Penelitian ini didasarkan pada isu-isu terkait Kaesang Pangarep yang sering menjadi perbincangan netizen Indonesia, terutama isu-isu politik yang menjadi topik panas. Kaesang Pangarep menarik perhatian publik karena keterlibatannya dalam berbagai sektor. Sebagai pengusaha, ia berhasil mendirikan beberapa bisnis kuliner yang mendapat respons positif dari masyarakat. Sebagai youtuber, Kaesang memiliki jumlah pengikut yang cukup besar, menjadikannya figur publik yang berpengaruh. Namun, yang paling menarik adalah langkahnya di dunia politik yang mulai terlihat sejak September 2023. Keputusan Kaesang untuk masuk ke dunia politik menimbulkan berbagai reaksi, baik positif maupun negatif, dari berbagai kalangan. Diskusi tentang Kaesang di media sosial mencakup berbagai isu, mulai dari keberhasilannya sebagai pengusaha hingga langkah-langkah politik yang diambilnya. Banyak netizen yang mendukung langkah Kaesang dan melihatnya sebagai sosok muda yang dapat membawa perubahan positif. Namun, tidak sedikit pula yang mengkritik dan meragukan kapasitas serta motivasinya dalam dunia politik.

Penelitian sebelumnya telah menganalisis sentimen masyarakat mengenai program BPJS dengan menggunakan metode *Naive Bayes*, SVM, dan *Random Forest*. Studi tersebut memanfaatkan model-model ini, yang masing-masing menghasilkan tingkat akurasi yang cukup tinggi, yakni 99,6%, 97,6%, dan 98,5%. Dari 1053 data yang telah melalui tahap preprocessing, metode SVM terbukti paling unggul di antara metode lainnya dengan mengidentifikasi 339 *tweet* positif, 290 *tweet* netral, dan 211 *tweet* negative [3].

Gap penelitian antara studi sebelumnya dan penelitian yang diusulkan terlihat pada beberapa aspek penting. Pertama, metode yang digunakan: penelitian sebelumnya menggunakan berbagai model machine learning, termasuk SVM, *Random Forest*, dan *Naive Bayes*, sementara penelitian yang diusulkan fokus pada penggunaan satu model, yaitu *Naive Bayes Multinomial*, dengan TF-IDF sebagai representasi teks. Kedua, ukuran dataset: penelitian sebelumnya menggunakan dataset yang lebih besar, yaitu 1053 *tweet*, sedangkan penelitian ini menggunakan 443 *tweet*, yang dapat mempengaruhi hasil performa model. Ketiga, konteks analisis sentimen: sentimen yang dianalisis dalam penelitian ini mungkin memiliki karakteristik berbeda, yang menunjukkan tantangan baru dalam memahami persepsi publik. Gap ini menyoroti bahwa penelitian yang diusulkan menghadirkan pendekatan yang berbeda, yang dapat memperkaya pemahaman tentang analisis sentimen publik.

Penelitian ini bertujuan untuk mengetahui sentimen masyarakat Indonesia terhadap Kaesang Pangarep berdasarkan sentimen positif, negatif, dan netral di seluruh Indonesia dengan memanfaatkan platform media sosial X. Penelitian ini diharapkan dapat menghasilkan model analisis sentimen menggunakan metode *Naive Bayes Multinomial* yang dioptimalkan dengan teks berbahasa Indonesia. Data dikumpulkan melalui fitur *Application Programming Interface* (API) di Twitter dengan menggunakan bahasa Python dan *Tweet Harvest* sebagai media *crawling*. Data diekstraksi menggunakan kata kunci yang terkait dengan Kaesang Pangarep, kemudian melalui tahap *preprocessing*, dan difokuskan pada pengenalan tipe konten dari berbagai informasi *tweet* dengan menggunakan algoritma *Naive Bayes Multinomial*. Dengan memahami opini publik, kita dapat lebih baik menilai dampak dari keterlibatan Kaesang dalam politik dan bisnis, serta bagaimana pandangan masyarakat terhadap generasi muda yang masuk ke dunia politik. Model ini dirancang untuk menangkap sentimen publik terhadap tokoh politik Indonesia dengan mempertimbangkan konteks sosial dan bahasa yang spesifik. Selain itu, penelitian ini juga memberikan perspektif baru tentang peran generasi muda dalam politik dan dampaknya terhadap pandangan masyarakat luas. Penelitian ini diharapkan dapat memperkaya

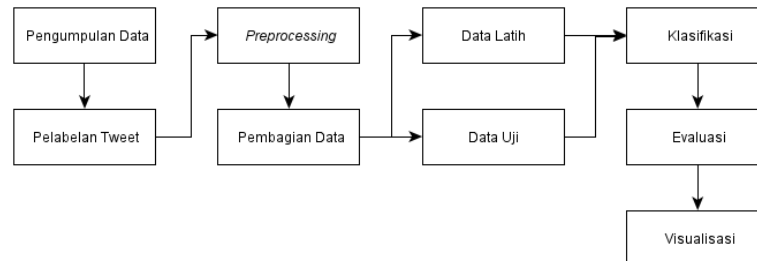
2. METODE PENELITIAN

2.1 Data Penelitian

Data dalam penelitian atau dikenal sebagai dataset ini berasal dari media sosial X. Data yang digunakan adalah *tweet* yang dikumpulkan dari tahun 2024. Data diambil dengan menggunakan metode *crawling* data. *Crawling* adalah proses otomatis pengumpulan dan pengindeksan data dari berbagai sumber seperti situs web, basis data, atau dokumen. Proses ini melibatkan penggunaan perangkat lunak atau aplikasi khusus yang dikenal sebagai *crawler* atau *web crawler* untuk mengakses sumber data dan mengekstrak informasi yang relevan [4]. *Crawling* tersebut diperoleh menggunakan *Tweet Harvest*. Kata kunci yang digunakan untuk mengumpulkan dataset berfokus pada Kaesang Pangarep, dengan total data sebanyak 437 data.

2.2 Penerapan Metode

Dalam penelitian ini, metode Naïve Bayes Multinomial digunakan untuk membangun sistem analisis sentiment. Adapun tahapan yang digunakan untuk melakukan dan mencapai tujuan dari penelitian secara keseluruhan. Berikut merupakan gambar yang menerangkan tahapan-tahapan yang dilakukan.



Gambar 1. Tahapan Metode

Pada gambar diatas menunjukkan tahapan-tahapan yang dilakukan dalam penelitian ini. Tahapan pertama adalah pengumpulan data tweet yang digunakan sebagai dataset, proses pengumpulan pengambilan data ini merupakan proses crawling data. Setelah data berhasil dikumpulkan data diberikan label secara manual ke dalam 3 kategori, yaitu positif, negatif, dan netral. Proses pelabelan ini dipandu oleh Bu Saskia Lydiani, S.Pd., M.Si dari Universitas Budi Luhur Jakarta, beliau merupakan seorang dosen psikologi yang dapat membantu untuk pelabelan dari sudut pandang seorang psikologi.

Setelah pelabelan selesai, tahapan selanjutnya adalah preprocessing, tahapan ini merupakan tahapan dimana data dibersihkan dengan mengurangi dimensi kata.

a) *Cleansing*

Cleansing adalah Pembersihan teks adalah proses menghilangkan karakter selain huruf a sampai z atau karakter non-huruf, seperti angka 8266, garis miring (/), dan sebagainya, sehingga hanya karakter huruf yang tersisa[5].

b) *Case Folding*

Case folding adalah salah satu bentuk prapemrosesan teks yang paling sederhana dan efektif. Tujuan dari *case folding* adalah untuk mengubah semua huruf besar dalam teks menjadi huruf kecil.

c) *Tokenization*

Tokenization atau tokenisasi proses memecah teks yang sebelumnya berbentuk kalimat menjadi unit-unit kata atau token. Dengan tokenisasi, kita dapat menghitung frekuensi distribusi setiap token. Frekuensi distribusi token menunjukkan jumlah kemunculan masing-masing token dalam teks atau dokumen. Dengan mengetahui frekuensinya, kita dapat menentukan seberapa sering setiap token muncul dalam teks.

d) *Replace Slangword*

Slangword adalah kata-kata yang tidak mengikuti aturan ejaan bahasa Indonesia yang baku (EYD). Kata-kata ini sering kali berupa singkatan, istilah gaul atau modern, serta kesalahan dalam penulisan ejaan. Slangwords sering ditemukan dalam komunikasi sehari-hari, terutama di media sosial dan percakapan informal.

e) *Removes Stopword*

Stopword removal adalah proses menghapus kata-kata yang kurang penting atau tidak memiliki makna signifikan dalam analisis teks. Kata-kata ini sering kali tidak berkontribusi banyak terhadap pemahaman isi teks dan hanya menyimpang dari kosakata yang bermakna. Contoh *stopwords* dalam bahasa Indonesia meliputi kata-kata seperti "dan," "yang," "di," "ke," dan "dari."

f) *Stemming*

Stemming adalah proses yang bertujuan untuk mengubah kata-kata menjadi bentuk dasarnya (lemma) dengan menghapus imbuhan seperti awalan, akhiran, dan infleksi lainnya. Tujuan utama stemming adalah untuk mengurangi variasi dari berbagai bentuk kata menjadi satu bentuk dasar yang sama.

Setelah melakukan pengumpulan dan *preprocessing* data, pengujian dilakukan dengan membagi data menjadi 80% untuk data latih dan 20% untuk data uji. Pembagian data ini disesuaikan dengan dokumen [6].

Setelah data diberikan melalui tahapan ekstraksi fitur menggunakan *Term Frequency-Inverse Document Frequency*. TF-IDF adalah teknik yang digunakan untuk memberikan bobot yang lebih besar pada kata-kata yang sering muncul di korpus tetapi hanya terdapat di sedikit dokumen. Penggunaan TF-IDF bertujuan untuk memperkuat fitur frekuensi teks, sehingga memperlancar proses klasifikasi. Hasil dari proses TF-IDF adalah model bobot untuk setiap kata berdasarkan kata-kata yang digunakan dalam data latih. [7]

Rumus Perhitungan TF-IDF:

$$TF(d, t) = \frac{f(d, t)}{n(d)} \quad (1)$$

$$IDF(t) = \log\left(\frac{n}{df(t)}\right) \quad (2)$$

$$TF - IDF(d, t) = TF(d, t) \times IDF(t) \quad (3)$$

Keterangan:

d = dokumen.

t = term (kata) yang sedang dievaluasi.

$f(d, t)$ = frekuensi kemunculan term t dalam dokumen d .

$n(d)$ = jumlah total term dalam dokumen d .

N = jumlah total dokumen dalam koleksi.

$df(t)$ = jumlah dokumen di dalam koleksi yang mengandung term

Tahapan berikutnya adalah penerapan *Naïve Bayes Multinomial* untuk menyelesaikan masalah dalam klasifikasi dokumen [8]. Algoritma *Naïve Bayes Multinomial* merupakan metode pembelajaran probabilistik yang didasarkan pada teorema Bayes dan diaplikasikan dalam Pemrosesan Bahasa Alami (NLP). Model ini mempertimbangkan dua aspek: apakah kata tersebut ada dalam dokumen atau tidak, dan frekuensi kemunculannya [9]. Adapun rumus sebagai berikut:

Naïve Bayes Multinomial
$$P(c|d) = P(c) \times \prod_{i=1}^{Nc} P(t_i|c) \quad (4)$$

Probabilitas prior

$$P(c) = \frac{Nc}{N} \quad (5)$$

Likelihood/probabilitas kemunculan kata

$$P(t_i|c) = \frac{W_{ct} + 1}{\sum_t W_{ct} + V} \quad (6)$$

Keterangan:

$P(c|d)$ = Probabilitas suatu dokumen termasuk dalam kelas c .

$P(c)$ = Probabilitas prior dari kelas c .

t_i = Kata dokumen d ke- i .

$P(t_i|c)$ = Probabilitas kata ke- i dengan diketahui kelas c .

Nc = Jumlah kelas c pada seluruh dokumen.

N = Jumlah seluruh dokumen.

W_{ct} = Nilai pembobotan TF-IDF atau W dari term t pada kategori c .

$\sum_t W_{ct}$ = Jumlah total W dari keseluruhan term pada kategori c .

V = Jumlah total term atau fitur yang berbeda dalam keseluruhan kumpulan data (vocabulary size)

Pengujian penelitian ini menggunakan *confusion matrix 3x3*. *Confusion matrix* merupakan tabel yang digunakan untuk menilai performa dari suatu model klasifikasi. Tabel ini memperbandingkan prediksi yang dibuat oleh model dengan nilai aktual dalam data pengujian [10]. Kinerja *confusion matrix* dapat diukur menggunakan nilai *True Negative (TN)*, *False Positive (FP)*, *True Positive (TP)*, dan *False Negative (FN)*. Tabel (1) menunjukkan tabel *Confusion Matrix 3x3*.

Tabel 1. *Confusion Matrix*

Prediksi	Aktual		
	Positive	Negative	Neutral
Positive	K1 (True)	K2 (False)	K3 (False)
Negative	K1 (False)	K2 (True)	K3 (False)
Neutral	K1 (False)	K2 (False)	K3 (True)

Dengan memanfaatkan *confusion matrix*, dapat diestimasikan nilai *accuracy*, *precision*, *recall*, dan *F1-Score*. *Accuracy* merupakan proporsi dari sampel yang terklasifikasi secara tepat dibandingkan dengan total sampel yang diamati. Nilai *accuracy* dapat dihitung dengan menggunakan rumus berikut.

$$Accuracy = \frac{\sum_{i=1}^n TP_{kelas-i}}{\sum_{i=1}^n TP_{kelas-i} + \sum_{i=1}^n FP_{kelas-i}} \quad (7)$$

Precision adalah rasio antara jumlah sampel positif yang diklasifikasikan dengan benar terhadap total prediksi sampel positif. Untuk menghitung nilai *precision*, rumus berikut dapat digunakan:

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

Recall adalah rasio antara jumlah sampel positif yang berhasil diklasifikasikan dengan benar terhadap total jumlah sampel positif. Untuk menghitung nilai *recall*, rumus berikut dapat digunakan:

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

F1-Score adalah metrik yang menggabungkan *precision* dan *recall* menjadi satu nilai tunggal. Untuk menghitung *F1-Score*, dapat digunakan rumus berikut:

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (10)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data dan Pelabelan

Penelitian ini mengumpulkan data menggunakan Tweet Harvest. Pada tahap pengambilan data, kata kunci yang terkait dengan Kaesang Pangarep digunakan untuk proses *scraping*. Data yang terambil dari *scraping* disimpan dalam format Excel. Dalam penelitian ini, pelabelan dilakukan dengan membagi *tweet* ke dalam tiga kategori: positif (1), negatif(2), dan netral(0). Proses pelabelan dilakukan secara manual dengan menganalisis makna dari setiap *tweet*. Untuk menganalisis data *tweet*, pendekatan yang digunakan adalah pendekatan makna linguistik dengan menggunakan konsep konseptual. Konsep konseptual ini mengacu pada makna kata atau kalimat berdasarkan arti gramatikal tanpa mempertimbangkan konteksnya. Proses pelabelan ini dipandu oleh Bu Saskia Lydiani, S.Pd., M.Si dari Universitas Budi Luhur Jakarta, beliau merupakan seorang dosen psikologi yang dapat membantu untuk pelabelan dari sudut pandang seorang psikologi. Tabel (2) menunjukkan dataset yang telah berhasil diperoleh.

Tabel 2. Hasil Dataset

No	Username	Text
1	EDYUs99	@Piyusaja2 Aduuhh kok anis pasangan sama kaesang mana kewarasan pks
2	EndangNasr	@Mdy_Asmara1701 Kalo pk anis maju berpasangan dg kaesang sy pilih yg lain aja.
3	jarudin59	@abnewsco Duet Kaesang dan Anis Berpeluang menang utk DKJ
4	virdazz28	@CNNIndonesia Projo ini ogah dkung knp ada isu kaesang anis wkwkbbissa aja nih politik

3.2 Preprocessing

Pada tahap ini data mentah yang telah diperoleh kemudian diubah secara signifikan menjadi data yang telah melalui proses pembersihan data untuk pengolahan oleh sistem. Informasi lebih lanjut mengenai tahapan-tahapan *preprocessing* dapat ditemukan untuk memahami detail proses. Berikut adalah *preprocessing* yang telah dilakukan. Tabel (3) menunjukkan tahapan *preprocessing* yang telah dilakukan.

Tabel 3. Preprocessing

Tahapan	Text	Preprocessing
Cleansing + Case Folding	Aduuhh kok anis pasangan sama kaesang mana kewarasan pks	aduhh kok anis pasangan sama kaesang mana kewarasan pks
Tokenization	Aduuhh kok anis pasangan sama kaesang mana kewarasan pks	["aduhh", "kok", "anis", "pasangan", "dengan", "kaesang", "mana", "kewarasan", "pks"]
Replace Slangwords	Aduuhh kok anis pasangan sama kaesang mana kewarasan pks	["aduh", "kok", "anis", "pasangan", "dengan", "kaesang", "mana", "kewarasan", "pks"]
Remove Stopwords	Aduuhh kok anis pasangan sama kaesang mana kewarasan pks	["aduh", "kok", "anis", "pasangan", "kaesang", "mana", "kewarasan", "pks"]
Stemming	Aduuhh kok anis pasangan sama kaesang mana kewarasan pks	["aduh", "kok", "anis", "pasang", "kaesang", "mana", "waras", "pks"]
Final Text	Aduuhh kok anis pasangan sama kaesang mana kewarasan pks	aduh kok anis pasang kaesang mana waras pks

3.3 Pembagian Data

Proses ini adalah proses dimana data dibagi menjadi dua bagian, yaitu: data latih dan uji. Proporsi pembagian data secara umum adalah 80% untuk data latih dan 20% untuk data uji. Pembagian dilakukan secara acak agar terhindar dari bias. Tahapan ini penting untuk memastikan bahwa model yang dibangun tidak terpengaruh oleh ketidakseimbangan data dan dapat diuji secara valid dengan data yang belum pernah dilihat oleh model sebelumnya. Pembagian data ini mengikuti jurnal yang dibuat [6].

3.4 TF-IDF

Setelah melakukan split data, selanjutnya dilakukan tahapan pembobotan kata dengan menggunakan TF-IDF. Tahapan ini meliputi perhitungan TF (*Term Frequency*), perhitungan IDF (*Inverse Document Frequency*), dan kemudian menggabungkan keduanya sehingga menjadi nilai TF-IDF. Tabel (4) menampilkan data latih.

Tabel 4. Data Latih

Dokumen	Tweet
DOC 1	tetap percaya kaesang
DOC 2	tetap kaesang baik
DOC 3	najis anis pasang kaesang
DOC 4	ngarep kaesang pangarep
DOC 5	pilih heru anis atau kaesang golput udah
DOC 6	jadi damping anis apa kaesang

Perhitungan TF-IDF (*Term Frequency – Inverse Document Frequency*) Pada perhitungan ini, hasil TF dari setiap dokumen dikalikan dengan IDF masing-masing kata, sehingga hasil TF-IDF dapat dilihat dalam tabel. Tabel (5) menunjukkan perhitungan TF-IDF.

Tabel 5. Perhitungan TF-IDF

	TF DOC1	TF DOC2	TF DOC3	TF DOC4	TF DOC5	TF DOC6
Tetap	0.158	0.158	0	0	0	0
Percaya	0.259	0	0	0	0	0
Kaesang	0	0	0	0	0	0
Baik	0	0.259	0	0	0	0

Najis	0	0	0.194	0	0	0
Anis	0	0	0.075	0	0.042	0.06
Pasang	0	0	0.194	0	0	0
Ngarep	0	0	0	0.259	0	0
Pangarep	0	0	0	0.259	0	0
Pilih	0	0	0	0	0.11	0
Heru	0	0	0	0	0.11	0
Atau	0	0	0	0	0.11	0
Golput	0	0	0	0	0.11	0
Udah	0	0	0	0	0.11	0
Jadi	0	0	0	0	0	0.155
Damping	0	0	0	0	0	0.155
Apa	0	0	0	0	0	0.155

Setelah menghitung nilai TF-IDF selanjutnya adalah menghitung nilai W untuk setiap kata. Tabel (6) menunjukkan perhitungan W.

Tabel 6. Perhitungan W

	Positif	Negatif	Netral
Tetap	0.316	0	0
Percaya	0.259	0	0
Kaesang	0	0	0
Baik	0.259	0	0
Najis	0	0.194	0
Anis	0	0.075	0.102
Pasang	0	0.194	0
Ngarep	0	0.259	0
Pangarep	0	0.259	0
Pilih	0	0	0.11
Heru	0	0	0.11
Atau	0	0	0.11
Golput	0	0	0.11
Udah	0	0	0.11
Jadi	0	0	0.155
Damping	0	0	0.155
Apa	0	0	0.155
Jumlah	0.834	0.981	1.117

3.5 Naïve Bayes Multinomial

Tahapan proses klasifikasi menggunakan algoritma *Naïve Bayes Multinomial* dimulai dengan menghitung probabilitas untuk setiap label atau kelas. Dalam contoh data latih yang diberikan sebelumnya, terdapat 6 contoh data latih dengan distribusi label yang seimbang: dua data dengan label positif, dua data dengan label negatif, dan dua data lagi dengan label netral. Proses ini melibatkan analisis setiap fitur dalam data untuk menentukan seberapa besar kemungkinan suatu data baru termasuk dalam salah satu dari tiga kategori tersebut.

$$P(\text{Positif}) = \frac{\text{Jumlah Dokumen Positif}}{\text{Total Dokumen}}$$

$$P(\text{Positif}) = \frac{2}{6} = 0.333$$

$$P(\text{Negatif}) = \frac{\text{Jumlah Dokumen Negatif}}{\text{Total Dokumen}}$$

$$P(\text{Negatif}) = \frac{2}{6} = 0.333$$

$$P(\text{Netral}) = \frac{\text{Jumlah Dokumen Netral}}{\text{Total Dokumen}}$$

$$P(\text{Netral}) = \frac{2}{6} = 0.333$$

Proses pengujian data menggunakan 1 buah sampel data uji yang digambarkan pada tabel (7) berikut:

Tabel 7. Data Uji

No.	Text	Label Aktual
1.	Kaesang dorong jadi walikota	Netral

Setelah menghitung probabilitas untuk setiap label, berikutnya adalah menghitung nilai likelihood untuk setiap kelas berdasarkan TF-IDF dari data latih menggunakan persamaan yang telah ditentukan. Tabel (8) menunjukkan total dari TF-IDF.

Tabel 8. Total TF-IDF

Nilai TF-IDF	Hasil Nilai TF-IDF
Positif	Hasil TF-IDF = sum (TF-IDF) positif = 0.834
Negatif	Hasil TF-IDF = sum (TF-IDF) negatif = 0.981
Netral	Hasil TF-IDF = sum (TF-IDF) netral = 1.117

Selanjutnya, menghitung probabilitas pada setiap kata dalam data uji terhadap kelas. Tabel (9) menunjukkan perhitungan probabilitas likelihood dan posterior untuk kelas positif.

Tabel 9. Probabilitas *Likelihood* dan *Posterior* dari Kelas Positif

Term	Probabilitas <i>Likelihood</i>	Probabilitas <i>Posterior</i>
Kaesang	$\frac{=(0+1)/(0.834+17)}{0.056072} = 1/17.834 =$	
Dorong	$\frac{=(0+1)/(0.834+17)}{0.056072} = 1/17.834 =$	$0.333 \times 0.056072 \times 0.056072 \times$
Jadi	$\frac{=(0+1)/(0.834+17)}{0.056072} = 1/17.834 =$	$0.056072 \times 0.056072 =$
Walikota	$\frac{=(0+1)/(0.834+17)}{0.056072} = 1/17.834 =$	0.00000328 (3.28 x 10⁻⁶)

Setelah kelas menghitung kelas positif dilanjutkan untuk menghitung kelas negatif. Tabel (10) menunjukkan perhitungan probabilitas likelihood dan posterior untuk kelas negatif.

Tabel 10. Probabilitas *Likelihood* dan *Posterior* dari Kelas Negatif

Term	Probabilitas <i>Likelihood</i>	Probabilitas <i>Posterior</i>
Kaesang	$\frac{=(0+1)/(0.981+17)}{0.055614} = 1/17.981 =$	
Dorong	$\frac{=(0+1)/(0.981+17)}{0.055614} = 1/17.981 =$	$0.333 \times 0.055614 \times 0.055614 \times$
Jadi	$\frac{=(0+1)/(0.981+17)}{0.055614} = 1/17.981 =$	$0.055614 \times 0.055614 =$
Walikota	$\frac{=(0+1)/(0.981+17)}{0.055614} = 1/17.981 =$	0.00000321 (3.21 x 10⁻⁶)

Dan setelah menghitung kelas positif dan negatif, perhitungan ini ditutup dengan menghitung kelas terakhir yaitu, netral. Tabel (11) menunjukkan perhitungan probabilitas likelihood dan posterior untuk kelas netral.

Tabel 11. Probabilitas *Likelihood* dan *Posterior* dari Kelas Netral

Term	Probabilitas <i>Likelihood</i>	Probabilitas <i>Posterior</i>
Kaesang	$\frac{=(0+1)/(1.117+17)}{0.055196} = 1/18.117 =$	$0.333 \times 0.055196 \times 0.055196 \times$
Dorong	$\frac{=(0+1)/(1.117+17)}{0.055196} = 1/18.117 =$	$0.063752 \times 0.055196 =$
		0.00000357 (3.57 x 10⁻⁶)

$$\begin{aligned} \text{Jadi} &= (0.155+1)/(1.117+17) = 1.155/18.117 \\ &= \mathbf{0.063752} \\ \text{Walikota} &= (0+1)/(1.117+17) = 1/18.117 = \\ &= \mathbf{0.055196} \end{aligned}$$

3.6 Pengujian

Pengujian sistem merupakan tahap krusial dalam mengevaluasi kinerja suatu aplikasi. Tujuan utamanya adalah untuk menilai efektivitas aplikasi dalam mendeteksi dan mengidentifikasi konten yang mengandung sentimen masyarakat Indonesia. Dalam penelitian ini, digunakan 354 data sebagai data latih dan 89 data sebagai data uji. Model dilatih dengan data latih dan kemudian diuji dengan data uji. Di bawah ini adalah tabel yang menunjukkan hasil *confusion matrix* untuk evaluasi kinerja aplikasi dalam mendeteksi dan mengidentifikasi konten yang mengandung sentimen masyarakat. Tabel (12) menunjukkan nilai confusion matrix 3x3.

Tabel 12. Pengujian Confusion Matrix

Prediksi	Aktual		
	Positive	Negative	Neutral
Positive	24	0	10
Negative	12	4	12
Neutral	15	1	11

Evaluasi kinerja sistem klasifikasi sentimen menunjukkan bahwa dari 89 sampel data uji, sistem mengidentifikasi sampel kelas 0: 24 (TP), 28 (TN), 27 (FP), dan 10 (FN), untuk kelas 1 yaitu: 4 (TP), 60 (TN), 1 (FP), dan 24 (FN), dan untuk kelas 2 yaitu: 11 (TP), 40 (TN), 22 (FP), dan 16 (FN). Hasil ini menunjukkan perlunya perbaikan dalam mengurangi kesalahan klasifikasi untuk meningkatkan akurasi dan keandalan sistem. Tabel (13) menunjukkan nilai dari hasil pengujian.

Tabel 13. Hasil Pengujian

	Positif	Negatif	Netral
Accuracy	71.91%	58.43%	57.30%
Precision	80.00%	47.06%	33.33%
Recall	14.29%	70.59%	40.74%
F1-Score	24.24%	56.47%	36.67%

Pengujian menggunakan algoritma *Naïve Bayes Multinomial* menunjukkan kemampuan sistem dalam mengidentifikasi sentimen masyarakat yang terbagi menjadi tiga kategori: Positif, Negatif, dan Netral. Model mencapai *accuracy* 71.91% untuk kategori Positif, 58.43% untuk Negatif, dan 57.30% untuk Netral. *Precision* masing-masing kategori adalah 80.00% (Positif), 47.06% (Negatif), dan 33.33% (Netral). *Recall* model mencapai 14.29% (Positif), 70.59% (Negatif), dan 40.74% (Netral). *F1-Score* tercatat 24.24% (Positif), 56.47% (Negatif), dan 36.67% (Netral). Secara keseluruhan, model menunjukkan kinerja terbaik dalam mendeteksi kategori Negatif, namun perlu peningkatan dalam mengidentifikasi kategori Positif, terutama pada nilai recall yang rendah.

4. KESIMPULAN

Penelitian ini mengevaluasi efektivitas metode *Naïve Bayes Multinomial* dengan pembobotan TF-IDF dalam menganalisis sentimen publik terhadap Kaesang Pangarep di platform Twitter. Hasil penelitian menunjukkan bahwa model ini memiliki *accuracy* moderat dalam mengklasifikasikan sentimen menjadi positif, negatif, dan netral. *Accuracy* tertinggi dicapai pada sentimen positif (71,91%), diikuti oleh sentimen negatif (58,43%) dan netral (57,30%). *Precision* tertinggi dicapai pada kategori positif (80,00%), sementara *precision* untuk kategori negatif dan netral masing-masing sebesar 47,06% dan 33,33%. *Recall* tertinggi diperoleh untuk kategori negatif (70,59%), sedangkan *recall* untuk kategori positif dan netral masing-masing adalah 14,29% dan 40,74%. F1-score terbaik terdapat pada kategori negatif dengan nilai 56,47%.

Hasil penelitian ini mengindikasikan bahwa model *Naïve Bayes Multinomial* cukup efektif dalam mengidentifikasi sentimen publik secara umum, namun masih menghadapi tantangan dalam mengklasifikasikan

sentimen secara lebih spesifik, terutama pada sentimen positif dan netral. Penelitian ini memberikan wawasan yang berguna dalam memahami persepsi masyarakat terhadap Kaesang Pangarep dan menyoroti perlunya penyempurnaan model untuk meningkatkan akurasi dan kemampuan deteksi sentimen dalam konteks media sosial, terutama dalam menangani bahasa informal dan variasi linguistik di Twitter.

DAFTAR PUSTAKA

- [1] T. Safitri, Y. Umaidah, and I. Maulana, “Analisis Sentimen Pengguna Twitter Terhadap BTS Menggunakan Algoritma Support Vector Machine,” 2023. [Online]. Available: <http://jurnal.polibatam.ac.id/index.php/JAIC>
- [2] Rahmania Mustaqilillah, Okky Widyaningtyas, and Tri Wantoro, “Efektivitas Penggunaan Twitter Sebagai Sarana Peningkatan Berpikir Kritis Mahasiswa Ilmu Komunikasi,” *MUKASI: Jurnal Ilmu Komunikasi*, vol. 2, no. 1, pp. 18–28, Feb. 2023, doi: 10.54259/mukasi.v2i1.1346.
- [3] Z. Ardika and A. D. Wowor, “Analisis Sentimen Masyarakat Terhadap Program Badan Penyelenggara Jaminan Sosial (BPJS) Menggunakan Data Twitter,” *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 1, pp. 90–99, 2024, doi: 10.29100/jupi.v9i1.4272.
- [4] Y. MZ, J. E. Bororing, and N. Fuadiah, “Penerapan Metode K-Nearest Neighbor Dan Decision Tree Untuk Analisis Sentimen (Studi Kasus Mario Dandi),” *IJITECH: Indonesia Journal of Information Technology*, vol. 1, no. 1, pp. 2-6, 2023.
- [5] M. A. Java, et al, “Analisis Sentimen Ulasan Pengguna Aplikasi Threads pada Google Play Store Menggunakan Multinomial Naive Bayes dan Support Vector Machine,” *Jurnal TICOM: Technology of Information and Communication*, vol. 12, no. 2, pp. 75-80, 2024.
- [6] K. Cindy Astuti, A. Firmansyah, A. Riyadi, and U. Pelita Bangsa Bekasi, “Implementasi Text Mining untuk Analisis Sentimen Masyarakat terhadap Ulasan Aplikasi Digital Korlantas Polri pada Google Play Store,” *Remik: Riset dan E-Jurnal Manajemen Informatika Komputer*, vol. 8, no. 1, pp. 383-394, 2024
- [7] R. Adrian, Musaddam, M. Ikhsan, and M. R. Pahlevi. B, “Detection of Hoax News Using TF-IDF Vectorizer and Multinomial Naïve Bayes and Passive Aggressive,” *Media Journal of General Computer Science*, vol. 1, no. 2, pp. 54–61, 2024, doi: 10.62205/mjgcs.v1i2.24.
- [8] V. P. Devi, “Otomatisasi Review Produk Pada Aplikasi Lazada Dengan Metode Naïve Bayes,” 2024.
- [9] M. I. Fariz, D. Arifianto, and Y. D. Rahayu, “Optimasi Metode Multinomial Naïve Bayes Dengan Menggunakan Metode Levenshtein Distance Pada Ulasan Aplikasi KAI Access,” *JASIE: Jurnal Aplikasi Sistem Informasi dan Elektronika*, vol 5, no. 1, pp. 19-27, 2023.
- [10] D. Ananda and R. R. Suryono, “Analisis Sentimen Publik Terhadap Pengungsi Rohingya di Indonesia dengan Metode Support Vector Machine dan Naïve Bayes,” *Jurnal Media Informatika Budidarma*, vol. 8, no. 2, pp. 748-757, 2024, doi: 10.30865/mib.v8i2.7517.