

Penerapan Metode Naïve Bayes Classifier Pada Klasifikasi Sentimen Terhadap Anies Baswedan Sebagai Bakal Calon Presiden 2024

Mar`iy Romizzidi Amly*, Yusra, Muhammad Fikry

Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim, Pekanbaru, Indonesia

Email: ^{1,*}11950111714@students.uin-suska.ac.id, ²yusra@uin-suska.ac.id, ³muhammad.fikry@uin-suska.ac.id

Email Penulis Korespondensi: 11950111714@students.uin-suska.ac.id

Submitted: 28/05/2023; Accepted: 30/06/2023; Published: 30/06/2023

Abstrak—Anies Baswedan menjadi tokoh politik yang telah dinyatakan sebagai bakal calon presiden 2024. Opini masyarakat merupakan sumber informasi yang berharga untuk menganalisis sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024. Terbatasnya tenaga manusia, ketidakstabilan emosi, dan lamanya waktu yang dibutuhkan menjadi kesulitan dalam menganalisis sentimen terhadap data yang berjumlah besar secara manual. Machine learning dimanfaatkan untuk memberikan kemudahan dalam klasifikasi sentimen. Penelitian ini menerapkan metode Naïve Bayes Classifier dalam klasifikasi sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024. Penelitian ini bertujuan untuk mengetahui kinerja metode Naïve Bayes Classifier pada klasifikasi sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024. Dataset yang digunakan sebanyak 3.400 yang dilabelkan secara crowdsourcing menghasilkan 2.130 positif (62,65%) dan 1.270 negatif (37,35%). Pengujian dilakukan menggunakan metode validasi silang 10-fold cross-validation dan 5-fold cross-validation yang masing-masing terdiri dari dua skenario percobaan, yaitu menggunakan dataset yang tidak seimbang dan menggunakan dataset yang seimbang. Metode Naïve Bayes Classifier menghasilkan model terbaik pada pengujian 10-fold cross-validation dengan akurasi sebesar 89,76%, presisi sebesar 89,92%, recall sebesar 89,76%, dan f1-score sebesar 89,75% pada fold keenam dengan menentukan nilai threshold sebesar 13 pada percobaan dengan menggunakan dataset seimbang yang terdiri dari 1.270 positif dan 1.270 negatif dengan rata-rata tingkat akurasi sebesar 79,88%.

Kata Kunci: Klasifikasi; Sentimen; Naïve Bayes Classifier; K-Fold Cross-Validation; Bakal Calon Presiden

Abstract—Anies Baswedan is a political figure who has been declared as a 2024 presidential candidate. Public opinion is a valuable source of information to analyze sentiment towards Anies Baswedan as a 2024 presidential candidate. Limited human power, emotional instability, and the length of time required are difficulties in analyzing sentiment on large amounts of data manually. Machine learning is utilized to provide convenience in sentiment classification. This research applies the Naïve Bayes Classifier method in the classification of sentiment towards Anies Baswedan as a 2024 presidential candidate. This study aims to determine the performance of the Naïve Bayes Classifier method in the classification of sentiment towards Anies Baswedan as a 2024 presidential candidate. The dataset used was 3,400 which were labeled by crowdsourcing resulting in 2,130 positive (62.65%) and 1,270 negative (37.35%). Tests were conducted using the 10-fold cross-validation and 5-fold cross-validation methods, each consisting of two experimental scenarios, namely using an unbalanced dataset and using a balanced dataset. The Naïve Bayes Classifier method produces the best model in the 10-fold cross-validation test with an accuracy of 89.76%, precision of 89.92%, recall of 89.76%, and f1-score of 89.75% on the sixth fold by determining a threshold value of 13 in an experiment using a balanced dataset consisting of 1,270 positives and 1,270 negatives with an average accuracy rate of 79.88%.

Keywords: Classification; Sentiment; Naïve Bayes Classifier; K-Fold Cross-Validation; Presidential Candidate

1. PENDAHULUAN

Media sosial adalah alat untuk berbagi informasi dan mengungkapkan pendapat tentang berbagai topik dengan masyarakat. Media sosial memungkinkan komunikasi terbuka dengan latar belakang yang berbeda, karena dapat memiliki dampak besar pada perubahan negatif dan positif [1]. Pada Januari 2023, menunjukkan bahwa sebanyak 167 juta jiwa di Indonesia merupakan pengguna aktif media sosial atau 60,4% dari jumlah penduduk Indonesia [2]. Twitter berada di urutan ke-enam menjadi media sosial yang sering digunakan di Indonesia dalam periode Januari 2023 [3]. Hal ini mendorong semakin banyak pengguna untuk berbagi dan mengunggah produk dan layanan yang mereka gunakan, serta menyuarakan opini mereka tentang masalah agama dan politik [4]. Tokoh politik yang bakal maju menjadi bakal calon presiden 2024 merupakan perbincangan tentang masalah politik di Twitter. Twitter menjadi media yang paling banyak digunakan untuk menyuarakan opini terhadap topik tokoh politik yang bakal maju menjadi calon presiden 2024 [5]. Tokoh politik yang menjadi bakal calon presiden akan mempertimbangkan popularitas mereka berdasarkan opini masyarakat [6].

Anies Baswedan menjadi tokoh politik bakal calon presiden 2024 yang dideklarasikan oleh partai Nasional Demokrat pada tanggal 3 Oktober 2022. Pada deklarasi tersebut, masyarakat dapat menyuarakan pendapat mereka dengan mengunggah tweet atau cuitan pada media sosial Twitter tentang Anies Baswedan. Pada November 2022, Anies Baswedan menjadi nama tokoh politik yang paling banyak diperbincangkan di media sosial dengan 745.501 mentions [5]. Opini masyarakat merupakan sumber informasi yang berharga. Opini tersebut dapat dimanfaatkan untuk menganalisis sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024. Analisis sentimen dilakukan untuk menentukan apakah pendapat atau tanggapan pada suatu topik mengarah pada sentimen negatif atau positif [7].

Menganalisis sentimen sulit dilakukan secara manual menggunakan tenaga manusia karena banyaknya jumlah opini. Hal ini disebabkan oleh keterbatasan tenaga manusia, ketidakstabilan emosi, dan membutuhkan waktu yang lama. Pendekatan yang dapat digunakan adalah menggunakan ilmu Natural Language Processing dan machine learning. Natural Language Processing adalah bidang ilmu yang berkaitan dengan pemahaman dan pengolahan bahasa manusia oleh komputer. Salah satu tugas Natural Language Processing yang dapat digunakan adalah klasifikasi sentimen. Klasifikasi sentimen pada bidang ilmu Natural Language Processing adalah membangun mesin yang dapat mengenali dan mengekstrak opini dalam teks [8]. Sedangkan machine learning berfokus pada pengembangan algoritma yang memungkinkan program komputer belajar dari pengalaman sebelumnya [9]. Machine learning dimanfaatkan untuk membantu manusia karena machine learning tidak melibatkan emosi namun didasarkan pada data yang telah diolah, kemudian data tersebut diekstraksi pengetahuannya untuk mendapatkan hasil yang tepat [10]. Metode Naive Bayes Classifier merupakan algoritma machine learning yang dapat digunakan dalam klasifikasi sentimen. Metode Naive Bayes Classifier mengklasifikasikan teks ke dalam kategori tertentu berdasarkan kata-kata yang terdapat dalam teks [11]. Kelebihan Naive Bayes Classifier yaitu sederhana, cepat dan menghasilkan akurasi yang tinggi [12].

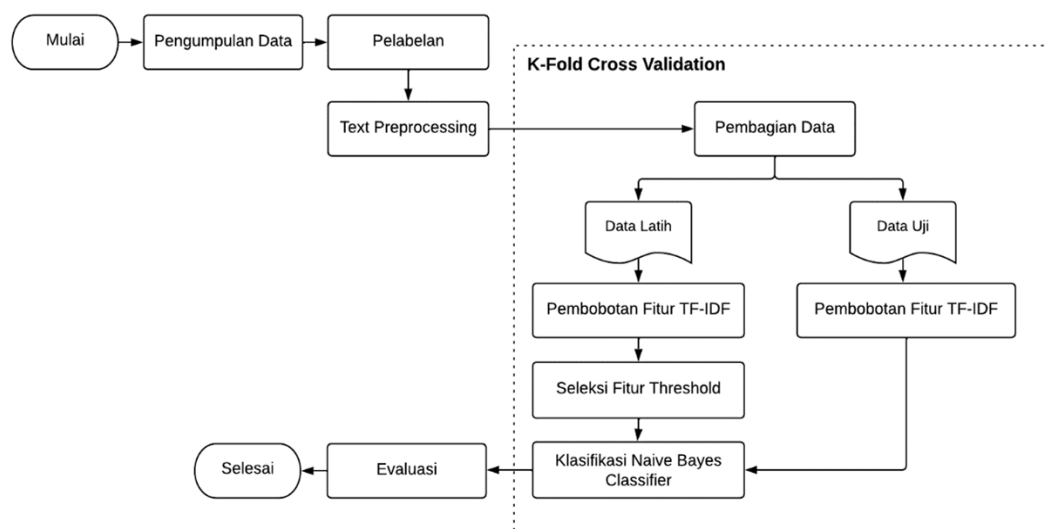
Penelitian terkait penerapan Naive Bayes Classifier terhadap tokoh politik dalam klasifikasi sentimen telah pernah dilakukan sebelumnya. Pada penelitian Soer dan Sutrisno (2022), Naive Bayes Classifier diterapkan pada analisis sentimen terhadap Ridwan Kamil sebagai Gubernur Jawa Barat yang memperoleh akurasi sebesar 84,38% [4]. Penelitian lainnya oleh Mahardhika dan Zuliarso (2018) yang melakukan analisis sentimen terhadap Joko Widodo menggunakan Naive Bayes Classifier menghasilkan akurasi sebesar 97% [13]. Pada penelitian Fatchan dan Sugeng (2021), melakukan analisis terhadap Tri Rismaharini sebagai Menteri Sosial dengan menerapkan Algoritma Naive Bayes memperoleh akurasi 90,33%, presisi sebesar 77,7% dan recall sebesar 99,9% [14]. Beberapa penelitian juga membandingkan metode Naive Bayes Classifier dengan metode lainnya dalam klasifikasi sentimen. Pada penelitian Widowati dan Sadikin (2020), membandingkan Naive Bayes Classifier dan Support Vector Machine menghasilkan akurasi Naive Bayes Classifier sebesar 91,48%, sedangkan Support Vector Machine sebesar 85,47% [15]. Pada penelitian Permana dan Noviyani (2022), membandingkan metode Naive Bayes Classifier dan metode K-Nearest Neighbor yang menghasilkan akurasi metode Naive Bayes Classifier sebesar 77,62% sedangkan metode K-Nearest Neighbor memperoleh akurasi sebesar 76,43% [16].

Berdasarkan pemaparan diatas, penelitian ini menerapkan metode Naive Bayes Classifier pada klasifikasi sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024. Perbedaan penelitian ini dengan penelitian terdahulu adalah data penelitian yang digunakan merupakan tweet terkait Anies Baswedan sebagai bakal calon presiden 2024. Penelitian ini bertujuan untuk mengetahui kinerja metode Naive Bayes Classifier pada klasifikasi sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024 dengan menggunakan dataset sebanyak 3.400 tweet yang dikategorikan menjadi positif dan negatif.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini merupakan jenis penelitian eksperimen yang melibatkan beberapa tahapan. Tahapan pada penelitian disajikan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Gambar 1 menyajikan tahapan penelitian yang disusun secara sistematis dan terstruktur dalam mencapai tujuan penelitian. Langkah awal yang dilakukan adalah mengumpulkan data terkait objek penelitian berupa tweet.

Selanjutnya, data dilakukan pelabelan menjadi dua kelas, yaitu positif dan negatif. Tahap selanjutnya dilakukan text preprocessing guna menghasilkan data yang lebih terstruktur. Langkah selanjutnya adalah melakukan k-fold cross-validation. Pada tahap k-fold cross-validation mencakup proses pembagian data menjadi data latih dan data uji, pembobotan fitur TF-IDF, seleksi fitur threshold, dan klasifikasi menggunakan metode Naïve Bayes Classifier. Tahap terakhir adalah mengevaluasi terhadap model yang dihasilkan, sehingga memperoleh kinerja dari metode Naïve Bayes Classifier dalam klasifikasi sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024.

2.2 Pengumpulan Data

Pengumpulan data adalah langkah pertama untuk melakukan analisis sentimen. Data dikumpulkan menggunakan teknik crawling dengan menggunakan bahasa pemrograman Python dan bantuan Twitter API. Dataset yang dikumpulkan merupakan tweet berbahasa Indonesia yang mengandung kata kunci yang berkaitan dengan Anies Baswedan sebagai bakal calon presiden 2024.

2.3 Pelabelan

Pelabelan data dilakukan dengan mengkategorikan menjadi dua kelas, yaitu positif dan negatif secara manual. Data dilabelkan menggunakan teknik crowdsourcing, yaitu melibatkan annotator lebih dari satu orang. Hal ini bertujuan untuk menghindari unsur subjektivitas pada label sentimen yang diberikan [17]. Metode majority voting digunakan untuk mengambil hasil akhir dari pelabelan. Konsep majority voting adalah mengambil label yang memperoleh suara terbanyak. Pelabelan dilakukan agar model dapat mengenali teks berdasarkan label yang diberikan. Dalam penelitian ini, dilakukan pengukuran tingkat kesepakatan antara annotator dalam proses pelabelan menggunakan metode yang dikenal sebagai Fleiss Kappa. Fleiss Kappa digunakan untuk mengukur keandalan antara annotator dalam memberikan label. Tingkat kesepakatan tersebut dihitung menggunakan persamaan (1).

$$\text{Kappa} = \frac{p_o - p_e}{1 - p_e} \tag{1}$$

Proporsi kesepakatan yang diamati pada annotator (p_o) dapat dihitung menggunakan persamaan (2) dan proporsi kesepakatan yang diharapkan (p_e) dapat dihitung menggunakan persamaan (3).

$$p_o = \frac{1}{n} \sum_{i=1}^n \frac{\sum_{j=1}^k x_{ij}^2 - m}{m^2 - m} \tag{2}$$

$$p_e = \sum_{j=1}^k q_j^2, \text{ dimana } p_j = \frac{1}{nm} \sum_{i=1}^n x_{ij} \tag{3}$$

Keterangan:

- p_o : Proporsi kesepakatan annotator yang diamati
- p_e : Proporsi kesepakatan yang diharapkan
- n : Jumlah data
- m : Jumlah annotator
- x_{ij} : Keputusan annotator data ke-i pada kelas j
- p_j : Probabilitas kesepakatan annotator pada kelas j


Tabel 1. Tingkat Kesepakatan

Kappa	Kategori
< 0	Poor Agreement
0.00 - 0.20	Slight Agreement
0.21 - 0.40	Fair Agreement
0.41 - 0.60	Moderate Agreement
0.61 - 0.80	Substantial Agreement
0.81 - 1.00	Almost Perfect Agreement

Tabel 1 memberikan tingkatan kesepakatan antara annotator yang diukur menggunakan nilai kappa yang diperoleh dari hasil perhitungan menggunakan persamaan (1). Nilai kappa dikategorikan menjadi enam tingkat kesepakatan. Semakin tinggi nilai kappa yang diperoleh, maka tingkat kesepakatan antara annotator akan semakin baik. Perhitungan tingkat kesepakatan ini memberikan gambaran mengenai sejauh mana tingkat konsistensi dan keandalan antara annotator dalam pelabelan data.

2.4 Text Preprocessing

Text preprocessing adalah tahap untuk mempersiapkan dataset dari teks mentah supaya siap untuk dianalisis teks sesuai dengan metode yang digunakan [11]. Teks yang berasal dari Twitter dapat mengandung noise, tanda baca, karakter khusus, kata-kata yang tidak relevan, dan berbagai variasi kata yang memberikan arti yang serupa.



Gambar 2. Tahapan Text Preprocessing

Gambar 2 menyajikan tahapan pada text preprocessing. Dalam penelitian ini, text preprocessing terdiri dari tujuh proses, yaitu cleaning, case folding, tokenizing, normalisasi, negation handling, stopwords, dan stemming. Penjelasan setiap proses pada tahapan text preprocessing sebagai berikut:

- a. Cleaning adalah proses membersihkan teks dari mentions (@username), Uniform Resource Locator (URL), hashtag (#), special character (!@#%&*()_+={}[]\|:~";',.< > ? /), emoji, angka, dan white space.
- b. Case folding adalah proses mengganti teks menjadi huruf kecil.
- c. Tokenizing, merupakan proses membagi teks menjadi unit-unit kecil yang disebut dengan token atau kata.
- d. Normalisasi merupakan suatu proses yang mengubah kata dalam sebuah teks menjadi bentuk baku dalam bahasa Indonesia. Pada proses ini, dilakukan pemeriksaan setiap token-token dalam teks. Jika ditemukan kata tidak baku, maka kata tersebut akan diganti menjadi bentuk baku dengan menggunakan kamus normalisasi yang telah dibuat oleh penulis yang disesuaikan dengan data yang digunakan.
- e. Negation handling adalah proses penanganan negasi atau penyangkalan dalam sebuah teks. Pada proses ini, dilakukan penggabungan antara kata negasi dan kata setelahnya menggunakan tanda garis bawah (underscore) sehingga menjadi satu kata baru. Selanjutnya, jika kata baru tersebut terdapat pada kamus negasi yang telah dibuat, kata tersebut diubah sesuai dengan kamus telah dibuat. Proses ini menggunakan kamus negasi yang berisi arti serupa pada kata yang telah digabung.
- f. Stopwords merupakan proses penghapusan kata umum yang tidak memberikan informasi penting. Pada proses ini menggunakan stoplist bahasa Indonesia pada library NLTK. Proses penghapusan ini dilakukan dengan memeriksa setiap kata dalam teks, jika kata tersebut merupakan stoplist, maka kata tersebut dihapus.
- g. Stemming adalah proses pengembalian kata yang berimbuhan menjadi bentuk dasar. Proses ini menggunakan algoritma Enhanced Contextual Stemmer (ECS).

2.5 Pembagian Data

Pembagian data dimaksudkan untuk membedakan dataset menjadi data latih dan data uji. Data latih berguna untuk melatih model dan data uji berguna untuk mengukur kinerja model yang dilatih. Penelitian ini menggunakan teknik k-fold cross-validation untuk pembagian data. Teknik k-fold cross-validation melibatkan pembagian data sebanyak k partisi yang setara, di mana 1 partisi digunakan menjadi data uji dan pastisi lainnya digunakan menjadi data latih. Proses pengujian dilakukan dalam k iterasi secara silang, di mana setiap partisi bergantian menjadi data latih dan data uji [18], [19].

2.6 Pembobotan Fitur TF-IDF

Pembobotan fitur dilakukan untuk mengubah fitur berupa kata menjadi data numerik. Pada langkah ini, setiap fitur yang diperoleh dari langkah text preprocessing diberi bobot dengan Term Frequency Inverse Document Frequency (TF-IDF), yang menghasilkan bobot berdasarkan keseringan kemunculan kata tertentu dalam dokumen [8]. Proses pembobotan fitur TF-IDF meliputi perhitungan nilai Term Frequency (TF) dan nilai Inverse Document Frequency (IDF) untuk setiap fitur disetiap dokumen [20]

2.7 Seleksi Fitur Threshold

Proses seleksi fitur memperoleh hasil klasifikasi yang lebih efisien. Langkah ini mengidentifikasi fitur-fitur yang relevan dan memprosesnya menggunakan model yang diperoleh pada proses pelatihan [20]. Seleksi fitur yang diterapkan menggunakan metode frequency-based dengan menentukan nilai ambang batas (threshold) pada Document Frequency (DF). Fitur yang jarang muncul pada dokumen lain cenderung tidak memberikan informasi yang relevan [21].

2.8 Klasifikasi Naïve Bayes Classifier

Metode Naïve Bayes Classifier merupakan metode klasifikasi yang menerapkan teorema bayes [12], [22], [23]. Naïve Bayes Classifier didasarkan pada konsep prediksi probabilitas dimasa mendatang berdasarkan pengalaman dimasa sebelumnya, yang diciptakan oleh ilmuwan Inggris Thomas Bayes [8]. Konsep Naïve Bayes Classifier yaitu mencari nilai probabilitas tertinggi dalam mengklasifikasi teks pada kelas yang paling tepat [20]. Naive Bayes Classifier melakukan pengklasifikasian dengan bentuk probabilistik dan statistik, dengan asumsi bahwa setiap atribut bersifat independen [24], [25]. Pada Naïve Bayes Classifier, terdapat beberapa langkah yang dilakukan. Langkah pertama adalah mempersiapkan vocabulary, yaitu daftar kata-kata yang terseleksi dari hasil seleksi fitur. Kedua, menghitung probabilitas prior untuk setiap kelas. Probabilitas prior adalah peluang kemunculan suatu kelas dalam data latih. Ketiga, menghitung probabilitas pada setiap kata terhadap masing-masing kelas menggunakan hasil pembobotan fitur TF-IDF. Hal ini dilakukan untuk menentukan peluang suatu

kata dalam suatu kelas. Keempat, melakukan perhitungan nilai probabilitas posterior pada data uji. Nilai probabilitas posterior tertinggi digunakan sebagai hasil klasifikasi dokumen.

2.9 Evaluasi

Evaluasi dilakukan bertujuan untuk mengevaluasi model yang dibangun. Hasil evaluasi memberikan hasil kinerja metode Naïve Bayes Classifier pada klasifikasi sentimen. Evaluasi dalam penelitian ini menggunakan confusion matrix. Confusion matrix adalah matriks yang memperoleh perbandingan antara hasil klasifikasi yang dihasilkan pada model dengan kelas sebenarnya [24].

Tabel 2. Confusion Matrix

Kelas	Prediksi	
	Positive	Negative
Aktual Positive	True Positive (TP)	False Negative (FN)
Aktual Negative	False Positive (FP)	True Negative (TN)

Tabel 2 memperlihatkan nilai hasil klasifikasi yang terdapat pada confusion matrix. Terdapat empat nilai hasil klasifikasi yang dapat diamati, yaitu True Positive (TP) yang merupakan jumlah data yang benar diprediksi sebagai kelas positif, True Negative (TN) yang merupakan jumlah data yang benar diprediksi sebagai kelas negatif, False Positive (FP) yang merupakan jumlah data yang salah diprediksi sebagai kelas positif, dan False Negative (FN) yang merupakan jumlah data yang salah diprediksi sebagai kelas negatif.

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Data dalam penelitian ini bersumber dari tweet berbahasa Indonesia menggunakan kata kunci yang merujuk pada Anies Baswedan sebagai bakal calon presiden 2024. Data berhasil dikumpulkan dari tanggal 21 Oktober 2022 hingga 23 November 2022, dengan total data sebanyak 5.355 tweet. Selanjutnya, data diseleksi secara manual untuk menyaring tweet yang tidak merepresentasikan opini. Data yang digunakan setelah proses seleksi data berjumlah sebanyak 3.400 tweet yang disajikan pada Gambar 3.

	Tanggal	Username	Content
0	2022-10-21 11:58:00	lyukTanjung	@yusuf_dumdum Saat Anies gantikan Ahok, Anies d...
1	2022-10-21 12:07:00	AsepMah57973790	@Fery49857895 @Miduk17 Gua di Jakarta merasa J...
2	2022-10-21 12:09:00	newlding30	Harusnya pendukung ani es jgn main klaim ni me...
3	2022-10-21 12:14:00	JohnElmer71	@HelmiFellis_ Sebutin aja namanya, su.. \nAnies...
4	2022-10-21 12:18:00	landy_bajidakka	@PutraErlangga95 cantik betul DKI.. \nsemoga k...
...
3395	2022-11-23 16:17:00	inilahdotcom	Relawan Amanat Indonesia atau Anies menegaskan...
3396	2022-11-23 16:22:00	san_jateng	Kelompok relawan itu resmi dibentuk pada 17 No...
3397	2022-11-23 16:39:00	aressoes57	Dalam kepemimpinan Anies Jakarta aman, nyaman &a...
3398	2022-11-23 16:39:00	MoeKhlis69	Hampir semua elemen Masyarakat mendukung Mas A...
3399	2022-11-23 16:42:00	djaywikarta	@tatakujiyati Kebayang kalau Anies presiden.

Gambar 3. Dataset Penelitian

3.2 Pelabelan

Pelabelan melibatkan 5 annotator yang menggunakan metode crowdsourcing untuk melakukan penilaian terhadap sentimen positif dan negatif. Proses pelabelan dilakukan dengan mengumpulkan penilaian dari masing-masing annotator. Hasil akhir dari pelabelan tersebut ditentukan berdasarkan penilaian terbanyak yang diberikan kepada setiap tweet.

Tabel 3. Contoh Pelabelan Data Menggunakan Crowdsourcing

No	Teks	Annotator					Label
		1	2	3	4	5	
1	@kurawa Memaafkan pak Anies dengan cara tidak memilih belio sebagai calon presiden	Negatif	Negatif	Negatif	Negatif	Negatif	Negatif
2	@Dennysiregar7 Pak Anies Baswedan Presiden RI 2024, inshaa Allah !	Positif	Positif	Positif	Positif	Positif	Positif

Tabel 3 memberikan contoh cara pelabelan yang dilakukan secara crowdsourcing. Pada contoh pertama, teks memperoleh penilaian negatif sebanyak 5 dan tidak ada penilaian positif. Dengan demikian, teks pertama

dilabel sebagai negatif. Hal yang sama terjadi pada contoh kedua, di mana teks memperoleh penilaian positif sebanyak 5 dan tidak ada penilaian negatif. Dengan demikian, teks kedua dilabel sebagai positif.

Pelabelan dengan crowdsourcing menghasilkan 2.130 tweet bersentimen positif (62,65%) dan 1.270 tweet bersentimen negatif (37,35%). Selanjutnya, dilakukan perhitungan fleiss kappa untuk mengukur tingkat kesepakatan antara kelima annotator dalam melakukan pelabelan menggunakan persamaan (1). Perhitungan menggunakan bantuan Microsoft Excel untuk mempermudah proses perhitungan. Hasil perhitungan fleiss kappa menunjukkan nilai sebesar 0,68. Nilai kappa tersebut termasuk dalam kategori tingkat substantial agreement, yang berarti kesepakatan yang kuat antara kelima annotator dalam pelabelan dataset.

3.3 Text Preprocessing

Dataset yang berhasil dikumpulkan dari Twitter belum terstruktur dengan baik dan perlu dilakukan text preprocessing terlebih dahulu. Hasil dari setiap proses pada text preprocessing ditunjukkan pada Tabel 4.

Tabel 4. Text Preprocessing

Proses	Sebelum	Sesudah
Cleaning	@kurawa Memaafkan pak Anies dengan cara tidak memilih belio sebagai calon presiden	Memaafkan pak Anies dengan cara tidak memilih belio sebagai calon presiden
Case Folding	Memaafkan pak Anies dengan cara tidak memilih belio sebagai calon presiden	memaafkan pak anies dengan cara tidak memilih belio sebagai calon presiden
Tokenizing	memaafkan pak anies dengan cara tidak memilih belio sebagai calon presiden	['memaafkan', 'pak', 'anies', 'dengan', 'cara', 'tidak', 'memilih', 'belio', 'sebagai', 'calon', 'presiden']
Normalisasi	['memaafkan', 'pak', 'anies', 'dengan', 'cara', 'tidak', 'memilih', 'belio', 'sebagai', 'calon', 'presiden']	['memaafkan', 'bapak', 'anies', 'dengan', 'cara', 'tidak', 'memilih', 'beliau', 'sebagai', 'calon', 'presiden']
Negation Handling	['memaafkan', 'bapak', 'anies', 'dengan', 'cara', 'tidak', 'memilih', 'beliau', 'sebagai', 'calon', 'presiden']	['memaafkan', 'bapak', 'anies', 'dengan', 'cara', 'menolak', 'beliau', 'sebagai', 'calon', 'presiden']
Stopwords	['memaafkan', 'bapak', 'anies', 'dengan', 'cara', 'menolak', 'beliau', 'sebagai', 'calon', 'presiden']	['memaafkan', 'anies', 'menolak', 'beliau', 'calon', 'presiden']
Stemming	['memaafkan', 'anies', 'menolak', 'beliau', 'calon', 'presiden']	['maaf', 'anies', 'tolak', 'beliau', 'calon', 'presiden']

Tabel 4 merupakan contoh hasil dari ketujuh proses pada text preprocessing. Pada proses cleaning dilakukan penghapusan @kurawa yang merupakan mention. Proses case folding mengubah teks menjadi huruf kecil. Proses tokenizing memotong kalimat pada setiap kata menjadi token. Pada proses normalisasi mengubah kata “pak” menjadi “bapak” dan kata “belio” menjadi “beliau”. Proses negation handling melakukan penggabungan kata “tidak” yang merupakan kata negasi dengan kata selanjutnya yaitu “memilih” dan mengubahnya menjadi arti serupa yaitu “menolak”. Proses stopwords menghapus kata terdapat pada stoplist NLTK, yaitu “bapak”, “dengan”, “cara”, dan “sebagai”. Proses stemming mengubah kata “memaafkan” menjadi “maaf” dan kata “menolak” menjadi “tolak”. Data yang telah dilakukan text preprocessing digunakan untuk dilakukan klasifikasi dengan menggunakan Naïve Bayes Classifier.

3.4 Klasifikasi Naïve Bayes Classifier

Klasifikasi sentimen menggunakan Naive Bayes Classifier (NBC) dilakukan dalam beberapa eksperimen. Eksperimen mencakup mekanisme pengujian, jenis dataset, dan penggunaan seleksi fitur. Pengujian dilakukan dengan menggunakan dua mekanisme, yaitu 10-fold cross-validation dan 5-fold cross-validation. Setiap mekanisme pengujian, dilakukan dalam dua percobaan dengan jenis dataset yang berbeda. Percobaan pertama menggunakan dataset yang tidak seimbang dan percobaan kedua menggunakan dataset yang seimbang. Setiap mekanisme pengujian juga dilakukan percobaan terhadap penggunaan seleksi fitur. Seleksi fitur menggunakan beberapa nilai threshold pada Document Frequency (DF) dalam rentang 1 sampai 50 hingga ditemukan nilai threshold yang tepat.

Tabel 5. Jumlah Data Latih dan Data Uji

Pengujian	Jenis Dataset	Jumlah Kelas		Data Latih		Data Uji	
		Positif	Negatif	Positif	Negatif	Positif	Negatif
10-Fold Cross-Validation	Tidak Seimbang	2130	1270	1917	1143	213	127
	Seimbang	1270	1270	1143	1143	127	127
5-Fold Cross-Validation	Tidak Seimbang	2130	1270	1704	1016	426	254
	Seimbang	1270	1270	1016	1016	254	254

Tabel 5 menunjukkan jumlah data latih dan data uji yang digunakan dalam setiap mekanisme pengujian. Pada 10-fold cross-validation, dataset dibagi sebanyak 10 bagian dengan rasio 90% data latih dan 10% data uji dalam setiap iterasinya. Proses ini diulang 10 kali dengan pengujian menggunakan data uji yang berbeda setiap kali. Pada 5-fold cross-validation, dataset dibagi sebanyak 5 bagian dengan rasio 80% data latih dan 20% data uji dalam setiap iterasinya. Proses ini diulang 5 kali dengan pengujian menggunakan data uji yang berbeda setiap kali.

a. Percobaan Menggunakan Dataset Tidak Seimbang

Pada percobaan pertama, dataset yang digunakan merupakan dataset asli dari hasil pelabelan yang terdapat ketidakseimbangan jumlah data antara kedua kelas. Hal ini terlihat pada Tabel 5, bahwa kelas positif memiliki jumlah yang lebih banyak daripada kelas negatif. Hasil percobaan menggunakan dataset yang tidak seimbang diperlihatkan pada Tabel 6 dan 7.

Tabel 6. Hasil 10-Fold Cross-Validation Pada Dataset Tidak Seimbang

Fold	Tanpa Threshold			Threshold = 15		
	Akurasi (%)	F1-Score (%)		Akurasi (%)	F1-Score (%)	
		Positif	Negatif		Positif	Negatif
1	73,82	81,72	53,89	80,88	85,52	71,86
2	77,94	81,14	63,77	82,35	86,49	74,58
3	77,65	84,1	62,38	79,71	84,49	70,64
4	78,24	84,84	61,46	80	85,09	69,64
5	80,59	85,9	68,87	85,59	88,94	79,32
6	77,65	84,03	62,75	80,29	85,08	71
7	79,41	85,48	64,65	79,12	84,53	67,87
8	77,94	84,01	64,45	80	84,68	71,19
9	75,88	82,48	61,32	80	84,19	72,8
10	77,06	83,4	62,86	77,94	83,22	67,81
Rata-rata	77,62	83,71	62,64	80,59	85,22	71,67

Pada Tabel 6, hasil pengujian dengan 10-fold cross-validation pada percobaan menggunakan dataset yang tidak seimbang menghasilkan akurasi tertinggi pada fold kelima dengan menggunakan nilai threshold sebesar 15, yang menghasilkan tingkat akurasi sebesar 85,59% dan rata-rata tingkat akurasi sebesar 80,59%.

Tabel 7. Hasil 5-Fold Cross-Validation Pada Dataset Tidak Seimbang

Fold	Tanpa Threshold			Threshold = 7		
	Akurasi (%)	F1-Score (%)		Akurasi (%)	F1-Score (%)	
		Positif	Negatif		Positif	Negatif
1	76,62	83,42	60,35	80,44	85,17	71,27
2	77,65	84,36	60,82	82,65	87	73,89
3	78,68	84,72	64,72	80,44	85,07	71,64
4	77,94	84,28	63,05	79,41	84,41	69,7
5	76,62	83,03	62,41	79,41	84,16	70,59
Rata-rata	77,5	83,96	62,27	80,47	85,16	71,42

Tabel 7 menunjukkan bahwa pengujian menggunakan 5-fold cross-validation pada dataset yang tidak seimbang menghasilkan akurasi tertinggi pada fold kedua dengan menggunakan nilai threshold sebesar 7 yang mencapai 82,65% dan rata-rata tingkat akurasi sebesar 80,47%.

Berdasarkan Tabel 6 dan 7, percobaan menggunakan dataset yang tidak seimbang menunjukkan tingkat akurasi yang cukup tinggi pada model yang dihasilkan. Namun, ditemukan bahwa f1-score pada kelas negatif jauh lebih rendah dibandingkan dengan f1-score pada kelas positif. Hal ini mengindikasikan bahwa model kurang mampu dalam mengklasifikasikan pada kelas minoritas. Meskipun ketika menggunakan nilai threshold pada seleksi fitur berhasil mengalami peningkatan kinerja model, namun hal tersebut tidak sepenuhnya mengatasi permasalahan dalam pengklasifikasian pada kelas minoritas.

b. Percobaan Menggunakan Dataset Seimbang

Percobaan kedua dilakukan menggunakan dataset yang seimbang. Dataset dilakukan penyeimbangan data dengan cara mengurangi jumlah data pada kelas mayoritas secara acak sehingga setara dengan jumlah data pada kelas minoritas. Hasil percobaan menggunakan dataset yang seimbang diperlihatkan pada Tabel 8 dan 9.

Tabel 8. Hasil 10-Fold Cross-Validation Pada Dataset Seimbang

Fold	Tanpa Threshold			Threshold = 13		
	Akurasi (%)	F1-Score (%)		Akurasi (%)	F1-Score (%)	
		Positif	Negatif		Positif	Negatif
1	75,2	73,42	76,75	74,41	72,57	76,01
2	75,98	74,69	77,15	81,1	79,83	82,22

Fold	Tanpa Threshold			Threshold = 13		
	Akurasi (%)	F1-Score (%)		Akurasi (%)	F1-Score (%)	
		Positif	Negatif		Positif	Negatif
3	81,89	80,83	82,84	82,68	81,97	83,33
4	77,95	76,86	78,95	78,74	78,23	79,23
5	76,77	76,31	77,22	75,59	75,2	75,97
6	86,22	85,6	86,79	89,76	89,43	90,08
7	77,17	76,03	78,2	77,56	77,47	77,65
8	77,17	75,83	78,36	77,95	76,86	78,95
9	80,31	79,84	80,77	82,68	82,26	83,08
10	77,56	76,73	78,33	78,35	78,26	78,43
Rata-rata	78,62	77,61	79,54	79,88	79,21	80,5

Tabel 8 menunjukkan hasil pengujian 10-fold cross-validation pada dataset yang seimbang. Dalam pengujian ini, ditemukan bahwa akurasi tertinggi dicapai pada fold keenam dengan menggunakan nilai threshold sebesar 13, yang mencapai 89,76% dan rata-rata tingkat akurasi sebesar 79,88%.

Tabel 9. Hasil 5-Fold Cross-Validation Pada Dataset Seimbang

Fold	Tanpa Threshold			Threshold = 8		
	Akurasi (%)	F1-Score (%)		Akurasi (%)	F1-Score (%)	
		Positif	Negatif		Positif	Negatif
1	74,21	72,88	75,42	77,95	76,47	79,26
2	78,15	76,92	79,25	81,5	80,97	81,99
3	82,09	81,47	82,67	83,86	83,67	84,05
4	75,59	74,49	76,6	76,77	76,02	77,48
5	79,33	78,96	79,69	79,72	79,36	80,08
Rata-rata	77,87	76,94	78,73	79,96	79,3	80,57

Pada Tabel 9, hasil pengujian menggunakan 5-fold cross-validation pada dataset yang seimbang menunjukkan bahwa akurasi tertinggi berhasil dicapai pada fold ketiga menggunakan nilai threshold sebesar 8, yang mencapai 83,86% dan rata-rata akurasi sebesar 79,96%.

Berdasarkan Tabel 8 dan 9, percobaan menggunakan dataset yang seimbang menghasilkan model yang lebih baik. Hal ini terlihat dari perbedaan yang tidak signifikan antara f1-score pada kedua kelas, yang menunjukkan bahwa model mampu mengklasifikasikan kedua kelas yang sama baik. Menetapkan nilai threshold pada seleksi fitur juga berhasil mengalami peningkatan kinerja model.

3.5 Evaluasi


Berdasarkan beberapa eksperimen yang dilakukan, diperoleh delapan model yang menghasilkan akurasi tertinggi pada kombinasi eksperimen yang berbeda. Hasil kinerja kedelapan model secara keseluruhan dalam berbagai eksperimen diperlihatkan pada Tabel 10.

Tabel 10. Perbandingan Hasil Eksperimen

Pengujian	Jenis Dataset	Seleksi Fitur	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
10-Fold Cross-Validation	Tidak Seimbang	Tidak	80,59	82,35	75,92	77,38
	Tidak Seimbang	Threshold = 15	85,59	85,55	83,25	84,13
	Seimbang	Tidak	86,22	86,49	86,22	86,19
	Seimbang	Threshold = 13	89,76	89,92	89,76	89,75
5-Fold Cross-Validation	Tidak Seimbang	Tidak	78,68	80,79	73,36	74,72
	Tidak Seimbang	Threshold = 7	82,65	83,15	79,24	80,45
	Seimbang	Tidak	82,09	82,23	82,09	82,07
	Seimbang	Threshold = 8	83,86	83,88	83,86	83,86

Pada Tabel 10, ditemukan bahwa pengujian 10-fold cross-validation menghasilkan model yang lebih baik dibandingkan dengan pengujian 5-fold cross-validation pada semua eksperimen. Temuan ini sejalan dengan penelitian Dinar, dkk (2023) dan Harpizon, dkk (2022), bahwa dengan menggunakan jumlah data latih yang lebih besar dapat menghasilkan model yang lebih baik. Selain itu, menetapkan nilai threshold pada Document Frequency (DF) yang tepat dalam seleksi fitur dapat membantu dalam meningkatkan kinerja model. Selanjutnya, penggunaan dataset yang seimbang juga terbukti dalam mengatasi masalah pengklasifikasian yang kurang baik ketika menggunakan dataset yang tidak seimbang. Hal ini terlihat pada tingkat akurasi, presisi, recall, dan f1-score yang sama baiknya ketika menggunakan dataset yang seimbang. Dari delapan kombinasi eksperimen, diperoleh model

terbaik pada pengujian 10-fold cross-validation dengan menggunakan dataset seimbang dan nilai threshold sebesar 13 yang mencapai tingkat akurasi sebesar 89,76%, presisi 89,92%, recall 89,76%, dan f1-score 89,75%.



Gambar 4. Confusion Matrix Model Terbaik

Gambar 4 menyajikan evaluasi dari model terbaik dalam confusion matrix. Confusion matrix menggambarkan hasil pengklasifikasian pada model terbaik. Matriks menunjukkan model mengklasifikasikan positif sebanyak 119 dan negatif sebanyak 135, dengan True Positive (TP) sebanyak 110, False Positive (FP) sebanyak 9, True Negative (TN) sebanyak 118, dan False Negative (FN) sebanyak 17.

3.6 Word Cloud

Word cloud memberikan visualisasi kata-kata yang paling sering muncul. Kata-kata yang muncul lebih sering menghasilkan ukuran yang lebih besar, sedangkan kata-kata yang jarang muncul akan ditampilkan dengan ukuran yang lebih kecil.



Gambar 5. Word Cloud Sentimen Positif

Gambar 5 menampilkan word cloud dari visualisasi kata yang sering muncul pada sentimen positif. Pada word cloud ditemukan kata-kata seperti “dukung”, “allah”, “moga”, “pilih”, “amin”, “insyaallah”, “cerdas”, dan kata-kata lainnya yang sering digunakan dalam memberikan sentimen positif. Kata-kata ini menunjukkan dukungan dan harapan positif terhadap Anies Baswedan sebagai bakal calon presiden 2024.



Gambar 6. Word Cloud Sentimen Negatif

Gambar 6 menampilkan word cloud dari visualisasi kata yang sering muncul pada sentimen negatif. Word cloud ini mencakup kata-kata seperti “bodoh”, “tolak”, “yaman”, “mustahil”, “gagal”, “mimpi”, “kadrun”, dan kata-kata lainnya yang sering digunakan dalam memberikan sentimen negatif. Kata-kata ini menunjukkan adanya perasaan negatif seperti kecewa, penolakan, dan ketidaksukaan terhadap Anies Baswedan sebagai bakal calon presiden 2024.

4. KESIMPULAN

Berdasarkan hasil penelitian, menunjukkan bahwa metode Naïve Bayes Classifier berhasil diterapkan pada klasifikasi sentimen terhadap Anies Baswedan sebagai bakal calon presiden 2024. Metode Naïve Bayes Classifier menghasilkan model terbaik pada pengujian 10-fold cross-validation dengan akurasi sebesar 89,76%, presisi sebesar 89,92%, recall sebesar 89,76%, dan f1-score sebesar 89,75% pada fold keenam dengan menentukan nilai threshold sebesar 13 pada percobaan dengan menggunakan dataset seimbang yang terdiri dari 1.270 positif dan 1.270 negatif dengan rata-rata tingkat akurasi sebesar 79,88%. Hasil eksperimen menunjukkan bahwa penggunaan data latih yang lebih besar menghasilkan model yang lebih baik. Selain itu, menggunakan dataset dengan proporsi yang seimbang pada setiap kelas dapat mengatasi model yang kurang optimal dalam mengklasifikasi pada kelas minoritas. Selanjutnya, menentukan nilai threshold yang tepat pada Document Frequency (DF) dalam seleksi fitur dapat meningkatkan nilai tingkat akurasi, presisi, recall, dan f1-score sehingga dapat mengoptimalkan kinerja model machine learning. Penelitian selanjutnya disarankan untuk menggunakan metode K-Nearest Neighbor, Modified K-Nearest Neighbor, Random Forest, dan metode lainnya guna melihat variasi perbandingan antara kinerja metode.

REFERENCES

- [1] A. Mustofa and R. Novita, “Klasifikasi Sentimen Masyarakat terhadap Pemberlakuan Pembatasan Kegiatan Masyarakat Menggunakan Text Mining pada Twitter,” *Jurnal Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 1, pp. 200–208, 2022, doi: 10.47065/bits.v4i1.1628.
- [2] S. Widi, “Pengguna Media Sosial di Indonesia Sebanyak 167 Juta pada 2023,” *Data Indonesia*, 2023. <https://dataindonesia.id/digital/detail/pengguna-media-sosial-di-indonesia-sebanyak-167-juta-pada-2023> (accessed Feb. 10, 2023).
- [3] S. Kemp, “Digital 2023: Indonesia,” *Data Reportal*, 2023. <https://datareportal.com/reports/digital-2023-indonesia> (accessed Feb. 10, 2023).
- [4] D. Soer and S. Sutrisno, “Analisis Sentimen terhadap Pemerintahan Ridwan Kamil Sebagai Gubernur Jawa Barat Menggunakan Algoritma Naïve Bayes,” in *Prosiding Seminar Nasional Sains dan Teknologi (SAINTEK)*, 2022, pp. 77–82.
- [5] A. Rahman, “Popularitas Tokoh Politik di Indonesia,” *Drone Emprit*, 2022. <https://pers.droneemprit.id/popularitas-tokoh-politik-di-indonesia-3/> (accessed Feb. 10, 2023).
- [6] S. N. J. Fitriyyah, N. Safriadi, and E. E. Pratama, “Analisis Sentimen Calon Presiden Indonesia 2019 dari Media Sosial Twitter Menggunakan Metode Naive Bayes,” *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 5, no. 3, pp. 279–285, 2019, doi: 10.26418/jp.v5i3.34368.
- [7] T. Yulianita, T. W. Utami, and M. Al Haris, “Analisis Sentimen dalam Penanganan Covid-19 di Indonesia Menggunakan Naive Bayes Classifier,” in *Prosiding Seminar Nasional Venue Artikulasi-Riset, Inovasi, Resonansi-Teori, dan Aplikasi Statistika (VARIANSI)*, 2020, pp. 235–243.
- [8] E. A. Lisangan, A. Gormantara, and R. Y. Carolus, “Implementasi Naive Bayes pada Analisis Sentimen Opini Masyarakat di Twitter terhadap Kondisi New Normal di Indonesia,” *Konvergensi Teknologi dan Sistem Informasi (KONSTELASI)*, vol. 2, no. 1, pp. 23–32, 2022, doi: 10.24002/konstelasi.v2i1.5609.
- [9] O. Purbo, *Text Mining Analisis Medsos, Kekuatan Brand & Intelejen di Internet*. Yogyakarta: Andi, 2019.
- [10] I. Saputra and D. Kristiyanti, *Machine Learning Untuk Pemula*. Bandung: Informatika, 2022.
- [11] N. M. A. J. Astari, D. Divayana, and G. Indrawan, “Analisis Sentimen Dokumen Twitter Mengenai Dampak Virus Corona Menggunakan Metode Naive Bayes Classifier,” *Jurnal Sistem dan Informatika (JSI)*, vol. 15, no. 1, pp. 27–29, 2020, doi: 10.30864/jsi.v15i1.332.
- [12] H. Harpizon, R. Kurniawan, I. Iskandar, R. Salambue, E. Budianita, and F. Syafria, “Analisis Sentimen Komentar di YouTube tentang Ceramah Ustadz Abdul Somad Menggunakan Algoritma Naïve Bayes,” *Jurnal Nasional Komputasi dan Teknologi Informasi*, vol. 5, no. 1, pp. 131–140, 2022, doi: 10.32672/jnkti.v5i1.4008.
- [13] Y. S. Mahardhika and E. Zuliarso, “Analisis Sentimen terhadap Pemerintahan Joko Widodo pada Media Sosial Twitter Menggunakan Algoritma Naive Bayes Classifier,” in *Prosiding Seminar Nasional Teknologi Informasi & Aplikasi Komputer (SINTAK)*, 2018, pp. 409–413.
- [14] M. Fatchan and H. Sugeng, “Analisa Terpilihnya Tri Rismaharini sebagai Menteri Sosial dengan Pendekatan Algorithma Naïve Bayes,” *Journal of Practical Computer Science*, vol. 1, no. 2, pp. 50–57, 2021, doi: 10.37366/jpcs.v1i2.942.
- [15] T. Widowati and M. Sadikin, “Analisis Sentimen Twitter terhadap Tokoh Publik dengan Algoritma Naive Bayes dan Support Vector Machine,” *Simetris: Jurnal Teknik Mesin, Elektro dan Ilmu Komputer*, vol. 11, no. 2, pp. 626–636, 2020, doi: 10.24176/simet.v11i2.4568.
- [16] Y. A. Permana and H. Noviyani, “Komparasi Algoritma Naïve Bayes dan K-Nearest Neighbor dalam Melihat Analisis Sentimen terhadap Vaksinasi Covid-19,” in *Prosiding Sains dan Teknologi (SAINTEK)*, 2022, pp. 128–134.

- [17] D. F. Zhafira, B. Rahayudi, and I. Indriati, “Analisis Sentimen Kebijakan Kampus Merdeka Menggunakan Naive Bayes dan Pembobotan TF-IDF Berdasarkan Komentar pada Youtube,” *Jurnal Sistem Informasi, Teknologi Informasi, dan Edukasi Sistem Informasi*, vol. 2, no. 1, pp. 55–63, 2021, doi: 10.25126/justsi.v2i1.24.
- [18] A. Erfina and R. A. Lestari, “Sentiment Analysis of Electric Vehicles using the Naïve Bayes Algorithm,” *Jurnal Sistem Informasi (SISTEMASI)*, vol. 12, no. 1, pp. 178–185, 2023, doi: 10.32520/stmsi.v12i1.2417.
- [19] F. Ratnawati, “Implementasi Algoritma Naive Bayes terhadap Analisis Sentimen Opini Film pada Twitter,” *INOVTEK Polbeng - Seri Informatika*, vol. 3, no. 1, pp. 50–59, 2018, doi: 10.35314/isi.v3i1.335.
- [20] N. Marga, A. Isnain, and D. Alita, “Sentimen Analisis tentang Kebijakan Pemerintah terhadap Kasus Corona Menggunakan Metode Naive Bayes,” *Jurnal Informatika dan Rekayasa Perangkat Lunak (JATIKA)*, vol. 2, no. 4, pp. 453–463, 2021, doi: 10.33365/jatika.v2i4.1602.
- [21] M. M. Khoirudin, W. Wiranto, and W. Winamo, “News Opinion Mining around Universitas Sebelas Maret Using Naive Bayes Algorithm,” *Jurnal Teknologi dan Informasi (ITSMART)*, vol. 7, no. 1, pp. 44–50, 2018, doi: 10.20961/itsmart.v7i1.21134.
- [22] D. Aryanti, “Analisis Sentimen Ibukota Negara Baru Menggunakan Metode Naïve Bayes Classifier,” *Journal of Information System Research (JOSH)*, vol. 3, no. 4, pp. 524–531, 2022, doi: 10.47065/josh.v3i4.1944.
- [23] A. Dinar, A. Irawan, and Y. Umaidah, “Analisis Sentimen pada Pengguna Twitter terhadap Program Kampus Merdeka Menggunakan Naive Bayes,” *Jurnal Mahasiswa Teknik Informatika (JATI)*, vol. 7, no. 1, pp. 755–760, 2023, doi: 10.36040/jati.v7i1.6552.
- [24] M. I. Fikri, T. S. Sabrila, and Y. Azhar, “Perbandingan Metode Naïve Bayes dan Support Vector Machine pada Analisis Sentimen Twitter,” *SMATIKA Jurnal*, vol. 10, no. 02, pp. 71–76, 2020, doi: 10.32664/smatika.v10i02.455.
- [25] T. Mutiara, Y. Alkhalifi, N. Mayangky, and W. Gata, “Analisis Sentimen Opini Publik Mengenai Larangan Mudik pada Twitter Menggunakan Naïve Bayes,” *Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer dan Teknologi Informasi*, vol. 6, no. 2, pp. 85–88, 2020, doi: 10.24014/coreit.v6i2.9727.