

Analisis Sentimen Terhadap Data Komentar Publik Mengenai Isu UU Pilkada 2024 Menggunakan Metode Naïve Bayes dan K-Nearest Neighbor

Sebastianus Adi Santoso Mola, Yulianto Triwahyuadi Polly, Yosefa Carela Atok*

Fakultas Sains dan Teknik, Ilmu Komputer, Universitas Nusa Cendana, Kupang, Indonesia
Email: ¹adimola@staf.undana.ac.id, ²yuliantopolly@staf.undana.ac.id, ^{3,*}byuncarela04@gmail.com
Email Penulis Korespondensi: byuncarela04@gmail.com

Abstrak—Undang-Undang Pemilihan Kepala Daerah (UU Pilkada) 2024 menjadi isu penting yang banyak diperbincangkan di Indonesia, terutama di platform media sosial X. Beragam komentar publik terkait isu ini mengandung sentimen positif, negatif, maupun netral, yang mencerminkan persepsi masyarakat. Penelitian ini bertujuan menganalisis sentimen komentar publik tentang UU Pilkada 2024 menggunakan dua metode pembelajaran mesin: Naïve Bayes dan K-Nearest Neighbor (K-NN). Dataset terdiri dari 3864 komentar yang dibagi menjadi tiga kelas sentimen: 1477 komentar negatif, 1385 komentar netral, dan 1002 komentar positif, yang telah melalui proses text preprocessing. Evaluasi dilakukan dengan k-fold cross validation ($k=10$). Hasil pengujian menunjukkan bahwa metode Naïve Bayes memiliki akurasi tertinggi 62,95%, sementara K-NN mencapai 56,73%. Presisi untuk sentimen negatif adalah 56,84%, yang berarti sekitar 43% dari komentar yang diprediksi negatif oleh model sebenarnya bukan negatif. Recall negatif 45,45% menunjukkan bahwa model hanya menangkap kurang dari separuh komentar negatif yang ada. Untuk sentimen netral, presisi 60,71% dan recall 66,23% mengindikasikan model cukup baik dalam mengenali komentar netral, meskipun masih ada kesalahan 39,29%. Sedangkan untuk sentimen positif, presisi 55,55% dan recall 57,63% menunjukkan adanya kesalahan dalam pengklasifikasian komentar positif. Secara keseluruhan, meskipun model dapat mengklasifikasikan sebagian data dengan benar, ada potensi peningkatan akurasi untuk kelas negatif dan positif.

Kata Kunci: Text Mining; Analisis Sentimen; UU Pilkada 2024; Naïve Bayes; K-Nearest Neighbor

Abstract—The 2024 Regional Head Election Law (UU Pilkada) has become an important issue widely discussed in Indonesia, especially on the social media platform X. Various public comments related to this issue contain positive, negative, and neutral sentiments, reflecting public perceptions. This study aims to analyze the sentiment of public comments on the 2024 UU Pilkada using two machine learning methods: Naïve Bayes and K-Nearest Neighbor (K-NN). The dataset consists of 3864 comments divided into three sentiment classes: 1477 negative comments, 1385 neutral comments, and 1002 positive comments, all of which have undergone text preprocessing. Evaluation was conducted using k-fold cross-validation ($k=10$). The test results show that the Naïve Bayes method achieves the highest accuracy of 63.47%, while K-NN reaches 56.73%. The precision for negative sentiment is 56.84%, meaning that about 43% of the comments predicted as negative by the model are actually not negative. The recall for negative sentiment is 45.45%, indicating that the model only captures less than half of the actual negative comments. For neutral sentiment, the precision of 60.71% and recall of 66.23% suggest that the model performs fairly well in recognizing neutral comments, although there is still a 39.29% error. For positive sentiment, the precision of 55.55% and recall of 57.63% indicate errors in classifying positive comments. Overall, while the model can correctly classify a portion of the data, there is potential to improve accuracy for both the negative and positive classes.

Keywords: Text Mining; Sentiment Analysis; 2024 Regional Head Election Law; Naïve Bayes; K-Nearest Neighbor

1. PENDAHULUAN

Dalam lanskap politik Indonesia yang semakin dinamis, Undang-Undang Pemilihan Kepala Daerah (UU Pilkada) 2024 telah memicu perdebatan sengit di kalangan masyarakat. Perubahan signifikan dalam regulasi pemilihan kepala daerah memunculkan berbagai reaksi, mulai dari dukungan hingga kritik yang tajam. Perdebatan utama meliputi batas usia calon, ambang batas pencalonan, proses yang dianggap tergesa-gesa, serta dugaan adanya permainan politik dalam penetapan regulasi tersebut. Polarisasi pun semakin meningkat, sehingga menjadi penting untuk memahami sentimen publik terkait perubahan ini.

Media sosial, sebagai ruang publik digital yang paling aktif, telah menjadi arena utama bagi masyarakat untuk menyuarakan pendapat mereka. Berbagai platform seperti X (sebelumnya Twitter), Facebook, Instagram, dan TikTok menjadi wadah utama bagi jutaan pengguna untuk berbagi opini, informasi, serta ekspresi emosi terkait berbagai isu, termasuk UU Pilkada 2024. Tingginya volume percakapan mengenai topik ini di media sosial mencerminkan besarnya perhatian masyarakat terhadap kebijakan yang akan berdampak pada sistem demokrasi lokal. Oleh karena itu, dengan memanfaatkan potensi besar data yang dihasilkan oleh media sosial, penelitian ini bertujuan untuk mengukur sentimen publik terhadap UU Pilkada 2024.

Untuk menganalisis sentimen publik, penelitian ini menggunakan metode *Naïve Bayes* dan *K-Nearest Neighbor* (K-NN), yang telah terbukti efektif dalam mengklasifikasikan teks ke dalam kategori tertentu, seperti positif, negatif, atau [1]. *Naïve Bayes* dipilih karena kemampuannya yang baik dalam menangani data teks yang besar dan tidak terstruktur. Metode ini menggunakan pendekatan probabilistik yang sederhana namun kuat dalam mengidentifikasi kata-kata atau frasa yang memberikan petunjuk tentang emosi atau opini. Dengan mempertimbangkan frekuensi kemunculan kata dalam suatu teks, *Naïve Bayes* dapat dengan cepat mengklasifikasikan sentimen berdasarkan pola yang ditemukan dalam dataset pelatihan.

Sementara itu, K-NN dipilih karena merupakan algoritma berbasis instance yang mudah dipahami dan diimplementasikan. Algoritma ini bekerja dengan mengelompokkan data berdasarkan kedekatannya dengan data lainnya. Dalam analisis sentimen, K-NN sangat berguna karena dapat memanfaatkan kedekatan fitur antara kata-kata yang sering muncul dalam komentar atau opini yang serupa. Dengan demikian, metode ini dapat membantu dalam mengidentifikasi pola sentimen publik yang kompleks terhadap UU Pilkada 2024.

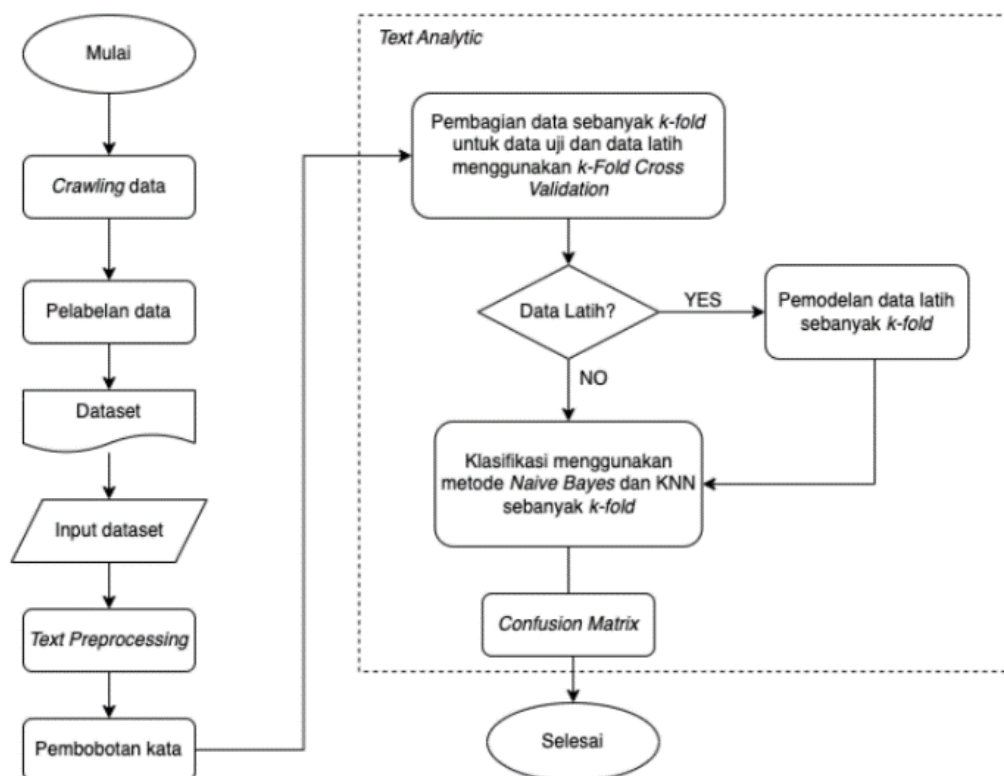
Untuk memperkuat pemilihan metode tersebut, beberapa penelitian sebelumnya telah dianalisis guna membandingkan performa keduanya. Penelitian [2] dan [3] menunjukkan bahwa metode klasifikasi K-Nearest Neighbor lebih unggul dibandingkan metode *Naive Bayes*, dengan akurasi tertinggi sebesar 89,44%, precision sebesar 65,45%, dan recall sebesar 22,25%. Sementara itu, penelitian lain seperti [4],[5],[6],[7],[8], dan [9] menemukan bahwa metode klasifikasi *Naive Bayes* lebih unggul dibandingkan dengan *K-Nearest Neighbor*, dengan hasil akurasi, 88,5%, precision sebesar 88,7%, dan sebesar 88,2%.. Hasil-hasil ini memperlihatkan bahwa performa kedua metode sangat bergantung pada karakteristik data yang digunakan dalam analisis sentimen.

Penelitian ini bertujuan untuk menganalisis sentimen data komentar publik terkait Undang-Undang Pemilihan Kepala Daerah (UU Pilkada) 2024 dengan menggunakan dua metode pembelajaran mesin, yaitu metode *Naive Bayes* dan metode *K-Nearest Neighbor* (K-NN). Selain itu penelitian ini juga bertujuan untuk mengidentifikasi isu-isu spesifik yang paling banyak diperdebatkan oleh masyarakat, seperti batas usia calon kepala daerah yang dinilai terlalu rendah atau tinggi, serta dugaan adanya kepentingan politik tertentu dalam penyusunan regulasi ini. Dengan memahami pola sentimen publik, pemangku kebijakan dapat memperoleh wawasan yang lebih baik mengenai dampak regulasi ini terhadap persepsi masyarakat.

Dengan demikian, penelitian ini tidak hanya memberikan wawasan akademis tetapi juga berkontribusi pada pemahaman yang lebih luas mengenai interaksi antara kebijakan publik dan opini masyarakat. Analisis sentimen berbasis media sosial dapat menjadi alat yang efektif untuk mengukur persepsi publik secara real-time dan membantu dalam proses pengambilan keputusan yang lebih berbasis data.

2. METODOLOGI PENELITIAN

Pada penelitian ini, metode yang digunakan adalah *Naive Bayes* dan *K-Nearest Neighbor*. Berikut merupakan *flowchart* penelitian yang ditampilkan pada Gambar 1.



Gambar 1. Flowchart Penelitian

2.1 Pengumpulan Data (Crawling data)

Crawling data adalah suatu proses untuk mengumpulkan opini pengguna dari berbagai website atau situs tertentu yang mengandung opini pengguna berdasarkan ruang lingkup yang diusulkan [10]. Data yang diambil pada penelitian ini bersumber dari data pengguna X.

2.2 Pelabelan Data

Pelabelan data adalah proses memberi kategori atau tag pada setiap entri dalam kumpulan data. Proses pelabelan data dilakukan oleh ahli bahasa dengan tujuan menghindari pendapat subjektif pada proses pelabelan.

2.3 Text Preprocessing

Text Preprocessing merupakan proses untuk mempersiapkan data mentah sebelum dilakukan proses lain. Pada umumnya, preprocessing data dilakukan dengan cara mengeleminasi data yang tidak sesuai atau mengubah data menjadi bentuk yang lebih mudah diproses oleh sistem [11].

2.4 Pembobotan Kata

Pembobotan kata adalah mekanisme untuk memberikan nilai berdasarkan frekuensi kemunculan suatu kata dalam dokumen teks. Salah satu metode pembobotan kata adalah TF-IDF (*Term Frequency-Inverse Document Frequency*), yang menggabungkan dua konsep, yaitu *Term Frequency* dan *Document Frequency* [12]. TF-IDF merupakan sebuah proses transformasi data teks ke dalam data numerik dengan tujuan melakukan pembobotan pada setiap kata. Pembobotan TF-IDF dilakukan dengan menggabungkan konsep TF (*term frequency*) dan IDF (*inverse document frequency*) [13]. Tahapan pertama dimulai dari perhitungan TF, dilanjutkan perhitungan IDF setelah itu baru dilakukan perhitungan TF-IDF.

$$TF_{(t,d)} = \frac{T}{D} \quad (1)$$

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

$$TF_IDF_{(t,d)} = TF_{t,d} \times IDF_t \quad (3)$$

Keterangan:

TF = *Term Frequency*

IDF = *Inverse Document Frequency*

d = Dokumen ke- d

t = Kata ke- t dari kata kunci

T = Jumlah frekuensi kemunculan kata pada dokumen d

D = Jumlah total keseluruhan kata pada dokumen d

N = Jumlah total dokumen

df_t = Jumlah dokumen yang mengandung kata t

2.5 Naïve Bayes Classifier

Naïve Bayes Classifier adalah sebuah metoda klasifikasi yang berdasar pada teorema *Bayes*. Metode pengklasifikasian ini menggunakan metode probabilitas dan statistik yang pertama kali dikemukakan oleh ilmuwan Inggris bernama Thomas Bayes, yaitu suatu metode untuk memprediksi peluang di masa depan berdasarkan pengalaman di masa sebelumnya, sehingga metode ini dikenal sebagai *Teorema Bayes*. Ciri utama dari *Naïve Bayes Classifier* ini adalah asumsi yang sangat kuat akan independensi dari masing-masing kondisi atau kejadian [14].

$$P(H|X) = \frac{P(X|H) \times P(H)}{P(X)} \quad (4)$$

Keterangan:

X : Data sample dengan klas (label) yang tidak diketahui

H : Hipotesa bahwa X adalah data dengan klas (label) C

$P(H|X)$: Peluang bahwa hipotesa benar (valid) untuk data sampel X yang diamati

$P(X|H)$: Peluang data sample X , bila diasumsikan bahwa hipotesa benar (valid).

$P(H)$: Peluang dari hipotesa H

$P(X)$: Peluang data sample yang diamati

2.6 K-Nearest Neighbor (K-NN) Classifier

K-Nearest Neighbor (K-NN) termasuk kelompok *instance-based learning*. Algoritma ini juga merupakan salah satu teknik *lazy learning*. K-NN dilakukan dengan mencari kelompok K objek dalam data latih yang paling dekat (mirip) dengan objek pada data baru atau data uji [15]. Perhitungan jarak untuk menentukan tingkat kesamaan data menggunakan *cosine similarity*.

Cosine Similarity adalah ukuran kesamaan antara dua buah vektor dalam sebuah ruang dimensi yang didapat dari nilai cosinus sudut dari perkalian dua buah vektor yang dibandingkan karena cosinus dari adalah 1 dan kurang dari 1 untuk nilai sudut yang lain, maka nilai *similarity* dari dua buah vektor dikatakan mirip ketika nilai dari *Cosine similarity* adalah 1. *Cosine similarity* digunakan dalam ruang positif, dimana hasilnya dibatasi antara nilai 0 dan 1. Kalau nilainya 0 maka dokumen tersebut dikatakan mirip jika hasilnya 1 maka nilai tersebut dikatakan tidak mirip [16].

$$\cosSim(d_j, q_k) = \frac{\sum_{i=1}^n (td_{ij} \times tq_{ik})}{\sqrt{\sum_{j=1}^m td_{ij}^2 \times \sum_{k=1}^m tq_{ik}^2}} \quad (5)$$

Keterangan:

$\cosSim(d_j, q_k)$: tingkat kesamaan dokumen dengan *query* tertentu

td_{ij} : *term* ke-i dalam vektor untuk dokumen ke-j

tq_{ik} : *term* ke-i dalam vektor untuk dokumen ke-k

n : jumlah *term* yang unik dalam dataset

2.7 k-fold Cross Validation

k-Fold Cross Validation (*k-fold CV*) adalah suatu metode yang digunakan untuk mengetahui rata-rata keberhasilan dari suatu sistem dengan cara melakukan redundansi dengan mengacak atribut masukan sehingga sistem tersebut teruji untuk beberapa atribut input yang acak. *k-fold CV* diawali dengan membagi data sejumlah *n-fold* yang diinginkan [17]. Langkah- langkahnya sebagai berikut:

- Bagi data menjadi k subset dengan ukuran yang sama
- Pilih satu subset sebagai data validasi dan sisanya sebagai data latih.
- Latih model menggunakan data latih dan evaluasi performanya menggunakan data validasi.
- Ulangi langkah 2 dan 3 k kali, setiap kali memilih subset yang berbeda sebagai data validasi.
- Hitung metrik evaluasi (misalnya akurasi, presisi, dan recall) untuk setiap iterasi k.
- Hitung rata-rata metrik evaluasi dari k iterasi sebagai estimasi performa model.

2.8 Evaluasi

Penelitian ini menggunakan *confusion matrix* sebagai metode evaluasi. *Confusion Matrix* merupakan metode evaluasi yang dapat digunakan untuk menghitung kinerja atau tingkat kebenaran dari proses klasifikasi. *Confusion Matrix* adalah tabel dengan 4 kombinasi berbeda dari nilai prediksi dan nilai actual [18]. Dalam penelitian ini, ada 3 rumus yang digunakan yaitu *Precision*, *Recall*, dan *Accuracy*, berikut rumusnya [19].

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (6)$$

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (7)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (8)$$

2.9 Visualisasi Data

Hasil klasifikasi dapat dipresentasikan ke dalam bentuk *pie chart* untuk memudahkan melihat hasil dari proses klasifikasi serta *wordcloud* untuk membuat gambaran kata dengan menyajikan visualisasi data teks yang menarik dan informatif. Frekuensi kata dalam keseluruhan data akan menentukan ukuran relatif kata, semakin tinggi frekuensi kata maka semakin besar ukuran kata dalam *wordcloud*, begitupun sebaliknya [20].

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengujian

a. Pengumpulan Data

Pada tahap ini, dataset yang digunakan berasal dari Aplikasi X yang dikumpulkan menggunakan teknik *crawling* data. Total data yang dikumpulkan mencapai 3.864 dataset dalam rentang waktu 21 Agustus 2024 sampai 24 September 2024. Dataset terbagi menjadi 1477 data negatif, 1002 data positif, dan 1385 data netral.

b. Text Preprocessing

Proses selanjutnya setelah tahap pengumpulan data yaitu *Text Prerocessing*. Pada tahap ini, dataset yang ada menlewati 5 tahapan yaitu *cleaning*, *case folding*, normalisasi, *tokenizing*, dan *stemming*.

Tabel 1. Hasil *Text Preprocessing*

Sebelum <i>Text Preprocessing</i>	Setelah <i>Text Preprocessing</i>
Aksi kawal putusan MK terjadi di banyak kota besar di Indonesia yang sebagian besar dilakukan oleh mahasiswa https://t.co/YRpcLryxGg	aksi kawal putus mk jadi di banyak kota besar di indonesia yang bagi besar lakukan oleh mahasiswa
Kubu Prabowo tak ingin terkena imbas unjuk rasa kawal putusan MK itu terhadap pemerintahan barunya kelak.	kubu prabowo tidak ingin kena imbas unjuk rasa kawal putus mk itu terhadap perintah baru kelak

c. Hasil Klasifikasi Metode *Naïve Bayes* dan K-NN

Total data yang digunakan dalam proses analisis adalah sebanyak 3864 data dengan jumlah kelas negatif 1477 data, kelas netral 1385 data dan kelas positif 1002 data. Kemudian dilakukan pembagian data dan pengujian menggunakan

k-fold cross validation, dengan melakukan pengujian nilai $k=10$. Pembagian data nilai $k=10$ dapat dilihat pada tabel 4.1.

Tabel 2. Pembagian data nilai $k=10$

fold	Data Latih				Data Uji			
	Negatif	Netral	Positif	Total	Negatif	Netral	Positif	Total
Fold 1	1312	1260	905	3477	165	125	97	387
Fold 2	1324	1249	904	3477	153	136	98	387
Fold 3	1337	1241	899	3477	140	144	103	387
Fold 4	1324	1249	904	3477	153	136	98	387
Fold 5	1325	1246	907	3478	152	139	95	386
Fold 6	1345	1234	899	3478	132	151	103	386
Fold 7	1324	1258	896	3478	153	127	106	386
Fold 8	1343	1243	892	3478	134	142	110	386
Fold 9	1326	1254	898	3478	151	131	104	386
Fold 10	1333	1231	914	3478	144	154	88	386

Hasil pembagian data tersebut digunakan untuk klasifikasi metode *Naïve Bayes* dan K-NN, sebagai berikut:

1. Klasifikasi Metode *Naïve Bayes*

Pada pengujian metode *Naïve Bayes* menggunakan *k-fold cross validation* dengan menerapkan nilai $k=10$, menghasilkan *confusion matrix* yang memberikan gambaran tentang kinerja metode *naïve bayes* dalam klasifikasi data. *Confusion matrix* tersebut kemudian digunakan untuk menunjukkan akurasi, presisi dan *recall* yang dapat dilihat dalam tabel 3.

Tabel 3. Hasil Pengujian Metode *Naïve Bayes*

Akurasi	Presisi			Recall		
	Negatif	Netral	Positif	Negatif	Netral	Positif
62,95%	54,93%	59,86%	54,16%	61,80%	59,09%	44,31%

Berdasarkan hasil evaluasi, model menghasilkan akurasi sebesar 62,95%, yang berarti sekitar 62,95% komentar berhasil diklasifikasikan dengan benar, sementara sisanya sebesar 37,05% salah klasifikasi. Presisi untuk sentimen negatif mencapai 54,93%, yang menunjukkan bahwa dari seluruh komentar yang diprediksi negatif, sekitar 45,07% di antaranya sebenarnya bukan komentar negatif. Untuk sentimen netral, presisi sebesar 59,86% mengindikasikan bahwa sekitar 40,14% prediksi netral tidak tepat. Sementara itu, presisi sentimen positif sebesar 54,16% menunjukkan bahwa sekitar 45,84% komentar yang diprediksi positif ternyata bukan komentar positif. Dari sisi *recall*, sentimen negatif memiliki nilai sebesar 61,80%, yang berarti sekitar 38,20% komentar negatif yang sebenarnya tidak berhasil terdeteksi oleh model. *Recall* untuk sentimen netral sebesar 59,09% menunjukkan bahwa sekitar 40,91% komentar netral luput dari klasifikasi yang tepat. Sedangkan *recall* sentimen positif tercatat paling rendah, yaitu sebesar 44,31%, menunjukkan bahwa lebih dari separuh komentar positif, tepatnya 55,69%, tidak berhasil dikenali dengan benar. Secara keseluruhan, meskipun model memiliki akurasi moderat dan performa relatif seimbang antar kelas, masih terdapat peluang besar untuk meningkatkan ketepatan klasifikasi terutama pada komentar positif.

2. Klasifikasi Metode K-NN

Pada pengujian metode *k-nearest neighbor* menggunakan *k-fold cross validation* dengan menerapkan nilai $k=10$. Hasil pengujian tersebut kemudian menghasilkan *confusion matrix* yang kemudian digunakan untuk menunjukkan akurasi, presisi dan *recall* yang dapat dilihat dalam tabel 4.

Tabel 4. Hasil Pengujian Metode *K-Nearest Neighbor*


Akurasi	Presisi			Recall		
	Negatif	Netral	Positif	Negatif	Netral	Positif
56,73%	54,93%	59,86%	54,16%	61,80%	59,09%	44,31%

Berdasarkan hasil evaluasi, model menghasilkan akurasi sebesar 56,73%, yang berarti hanya sekitar 56,73% dari total komentar yang berhasil diklasifikasikan dengan benar, sementara sekitar 43,27% lainnya salah klasifikasi. Presisi untuk sentimen negatif sebesar 54,93% menunjukkan bahwa dari seluruh komentar yang diprediksi negatif, sekitar 45,07% di antaranya sebenarnya bukan komentar negatif. Untuk sentimen netral, presisi sebesar 59,86% berarti bahwa sekitar 40,14% dari prediksi netral tidak tepat. Sementara itu, presisi sentimen positif sebesar 54,16% menunjukkan bahwa sekitar 45,84% komentar yang diprediksi positif ternyata bukan komentar positif. Dari sisi *recall*, sentimen negatif memiliki nilai 61,80%, yang berarti sekitar 38,20% komentar negatif yang sebenarnya tidak berhasil terdeteksi. *Recall* untuk sentimen netral sebesar 59,09% menunjukkan bahwa sekitar 40,91% komentar netral luput dari klasifikasi yang benar. Sedangkan *recall* untuk sentimen positif tercatat paling rendah, yaitu sebesar 44,31%, yang mengindikasikan bahwa lebih dari separuh komentar positif, tepatnya 55,69%, tidak berhasil dikenali dengan benar. Secara keseluruhan, performa model masih tergolong rendah, terutama dalam

mengenali komentar positif, sehingga terdapat ruang yang cukup besar untuk meningkatkan kinerja model, baik dari sisi presisi maupun *recall*.

3.2 Pembahasan

Hasil analisis penelitian terhadap isu UU Pilkada 2024 dapat dilihat pada gambar 2.



Gambar 2. Pie Chart Metode *Naïve Bayes* dan K-NN

Total data sentimen terhadap isu UU Pilkada 2024 sebanyak 3864 data yang terdiri atas 1477 data negatif (38.2%), 1385 data netral (35.8%), dan 1002 data positif (25.9%), hal ini menunjukkan bahwa metode *Naïve Bayes* mengklasifikasikan 51.3% data sebagai sentimen negatif, 32.1% sebagai netral, dan hanya 16.6% sebagai positif. Ini berarti *Naïve Bayes* cenderung lebih sensitif terhadap sentimen negatif, memberikan proporsi yang jauh lebih besar untuk sentimen ini dibandingkan distribusi sebenarnya. Sebaliknya, sentimen positif dan netral diestimasi lebih rendah dari distribusi aktual, yang menunjukkan bahwa metode ini memiliki kelemahan dalam mengenali sentimen-sentimen tersebut secara akurat. Sementara itu, metode K-NN memberikan distribusi sentimen yang lebih mendekati data aktual. Hasil K-NN menunjukkan bahwa 37.8% data diklasifikasikan sebagai negatif, 43.5% sebagai netral, dan 18.7% sebagai positif. Meskipun sentimen positif masih sedikit lebih rendah dari data aktual, metode ini lebih akurat dalam mencerminkan proporsi sentimen negatif dan netral. Secara keseluruhan, metode K-NN tampak lebih seimbang dalam distribusi sentimen dibandingkan *Naïve Bayes*. Dari kedua metode tersebut, K-NN lebih mendekati distribusi sentimen aktual dan cocok digunakan jika tujuan analisis adalah mendapatkan hasil yang lebih seimbang. Di sisi lain, *Naïve Bayes* cenderung terlalu fokus pada sentimen negatif, sehingga kurang cocok jika diperlukan representasi yang lebih merata dari semua jenis sentimen.

4.KESIMPULAN

Penelitian ini bertujuan untuk menganalisis sentimen komentar publik terhadap Undang-Undang Pemilihan Kepala Daerah (UU Pilkada) 2024 menggunakan dua metode pembelajaran mesin, yaitu *Naïve Bayes* dan K-Nearest Neighbor (K-NN). Berdasarkan hasil klasifikasi, ditemukan bahwa metode *Naïve Bayes* cenderung menghasilkan distribusi sentimen yang tidak seimbang, dengan proporsi sentimen negatif yang jauh lebih tinggi dibandingkan distribusi aktual, yakni sebesar 51,3% data diklasifikasikan sebagai negatif, 32,1% sebagai netral, dan hanya 16,6% sebagai positif. Hal ini menunjukkan bahwa *Naïve Bayes* lebih sensitif terhadap sentimen negatif, namun memiliki kelemahan dalam mengenali sentimen netral dan positif secara akurat. Sebaliknya, metode K-NN menunjukkan hasil distribusi yang lebih mendekati kondisi sebenarnya, dengan 37,8% data diklasifikasikan sebagai negatif, 43,5% sebagai netral, dan 18,7% sebagai positif. Meskipun distribusi sentimen positif masih sedikit lebih rendah dibandingkan data aktual, metode K-NN secara keseluruhan lebih akurat dalam mencerminkan proporsi sentimen negatif dan netral. Dengan demikian, K-NN dinilai lebih seimbang dalam mendistribusikan klasifikasi sentimen dan lebih cocok digunakan untuk analisis yang mengutamakan representasi sentimen yang proporsional. Secara umum, dapat disimpulkan bahwa untuk penelitian yang bertujuan menggambarkan distribusi sentimen masyarakat secara lebih adil, metode K-NN lebih direkomendasikan. Sedangkan metode *Naïve Bayes* lebih sesuai diterapkan pada konteks yang memerlukan sensitivitas tinggi terhadap deteksi sentimen negatif, meskipun dengan risiko bias terhadap kelas tersebut. Ke depan, kombinasi metode atau pengoptimalan parameter dapat menjadi strategi untuk meningkatkan performa klasifikasi pada semua kelas sentimen secara lebih merata. Adapun saran yang dapat diberikan untuk penelitian selanjutnya yaitu dapat memperbanyak daftar kata dalam kamus normalisasi yang digunakan karena dalam penelitian ini masih banyak kata yang tidak ternormalisasi karena adanya kesalahan penulisan maupun singkatan-singkatan

REFERENCES

- [1] T. Winarti, H. Indriyawati, V. Vydia, and F. W. Christanto, "Performance comparison between naive bayes and k- nearest neighbor algorithm for the classification of Indonesian language articles," *IAES Int. J. Artif. Intell. IJ-AI*, vol. 10, no. 2, p. 452, Jun. 2021, doi: 10.11591/ijai.v10.i2.pp452-457.

- [2] A. T. Dewi Septiani, A. P. Kuncoro, P. Subarkah, and R. Riyanto, "Perbandingan Kinerja Metode Naïve Bayes Classifier dan K-Nearest Neighbor pada Analisis Sentimen Ulasan Mobile Banking Jenius," *J. Krisnadana*, vol. 3, no. 2, pp. 67–77, Jan. 2024, doi: 10.58982/krisnadana.v3i2.516.
- [3] F. M. D. Maharani, A. L. Hananto, S. S. Hilabi, F. N. Apriani, A. Hananto, and B. Huda, "Perbandingan Metode Klasifikasi Sentimen Analisis Penggunaan E-Wallet Menggunakan Algoritma Naïve Bayes dan K-Nearest Neighbor," *METIK J.*, vol. 6, no. 2, Art. no. 2, Dec. 2022, doi: 10.47002/metik.v6i2.372.
- [4] R. T. S. A. Putri, D. E. Ratnawati, and D. W. Brata, "Perbandingan Naive Bayes dan K-Nearest Neighbor untuk Analisis Sentimen Aplikasi Gapura UB Berdasarkan Ulasan Pengguna pada Playstore," *J. Pengemb. Teknol. Inf. Dan Ilmu Komput.*, vol. 7, no. 1, pp. 229–236, Feb. 2023.
- [5] D. Era, S. Andryana, and A. Rubhasy, "Perbandingan Algoritma Naïve Bayes Dan K-Nearest Neighbor pada Analisis Sentimen Pembukaan Pariwisata Di Masa Pandemi Covid 19," *J-SAKTI J. Sains Komput. Dan Inform.*, vol. 7, no. 1, Art. no. 1, Mar. 2023, doi: 10.30645/j-sakti.v7i1.590.
- [6] H. Taufiqurrahman, F. T. Anggraeny, and M. M. A. Haromainy, "PERBANDINGAN ALGORITMA NAÏVE BAYES DAN K-NEAREST NEIGHBOR PADA ANALISIS SENTIMEN ULASAN APLIKASI MYPERTAMINA," *JATI J. Mhs. Tek. Inform.*, vol. 7, no. 6, Art. no. 6, 2023, doi: 10.36040/jati.v7i6.7801.
- [7] S. Alfari and Kusnawi, "Komparasi Metode KNN dan Naive Bayes Terhadap Analisis Sentimen Pengguna Aplikasi Shopee," *Indones. J. Comput. Sci.*, vol. 12, no. 5, Oct. 2023, doi: 10.33022/ijcs.v12i5.3304.
- [8] - Azhar, - Siti Ummi Masruroh, - Luh Kesuma Wardhani, and - Okfalisa, "Perbandingan kinerja algoritma Naïve Bayes dan K-NN Pendekatan Lexicon pada Analisis Sentimen di Media Twitter (Peer Review)." Accessed: Apr. 09, 2025. [Online]. Available: <https://repository.uin-suska.ac.id/26321/>
- [9] Z. P. Putra and A. Nugroho, "Pebandingan Performa Naïve Bayes dan KNN pada Klasifikasi Teks Sentimen Jasa Ekspedisi," *JOINTECS J. Inf. Technol. Comput. Sci.*, vol. 6, no. 3, p. 145, Sep. 2021, doi: 10.31328/jointecs.v6i3.2635.
- [10] Solimun, A. A. R. Fernandes, Nurjannah, E. G. Erwinda, R. Hardianti, and L. H. Y. Arini, *Metodologi Penelitian: Variabel Mining berbasis Big Data dalam Pemodelan Sistem untuk mengungkap Research Novelty*. Universitas Brawijaya Press, 2023.
- [11] D. D. A. Yani, H. S. Pratiwi, and H. Muhardi, "Implementasi Web Scraping untuk Pengambilan Data pada Situs Marketplace," *J. Sist. Dan Teknol. Inf. JUSTIN*, vol. 7, no. 4, p. 257, Oct. 2019, doi: 10.26418/justin.v7i4.30930.
- [12] D. R. Wahyuni, "ANALISIS SENTIMEN MASYARAKAT TERHADAP POLITIK DINASTI DI INDONESIA MENGGUNAKAN METODE K-NEAREST NEIGHBOR.pdf." Repository UIN Suska, 2025. [Online]. Available: <https://repository.uin-suska.ac.id/>
- [13] S. Kaparang, D. R. Kaparang, and V. P. Rantung, "Analisis Sentimen New Normal Pada Masa Covid-19 Menggunakan Algoritma Naive Bayes Classifier," *JOINTER J. Inform. Eng.*, vol. 2, no. 01, Art. no. 01, Jun. 2021, doi: 10.53682/jointer.v2i01.33.
- [14] M. S. Mustafa, M. R. Ramadhan, and A. P. Thenata, "Implementasi Data Mining untuk Evaluasi Kinerja Akademik Mahasiswa Menggunakan Algoritma Naive Bayes Classifier," *Creat. Inf. Technol. J.*, vol. 4, no. 2, Art. no. 2, Jan. 2018, doi: 10.24076/citec.2017v4i2.106.
- [15] H. Azis, P. Purnawansyah, F. Fattah, and I. P. Putri, "Performa Klasifikasi K-NN dan Cross Validation pada Data Pasien Pengidap Penyakit Jantung," *Ilk. J. Ilm.*, vol. 12, no. 2, Art. no. 2, Aug. 2020, doi: 10.33096/ilkom.v12i2.507.81-86.
- [16] N. Vendyansyah and Y. A. Pranoto, "Perancangan Dan Pembuatan Aplikasi Untuk Mendeteksi Kemiripan Jawaban Menggunakan Cosine Similarity," *J. Tek.*, vol. 13, no. 1, Art. no. 1, Mar. 2021, doi: 10.30736/jt.v13i1.536.
- [17] M. R. Fahlevvi, "ANALISIS SENTIMEN TERHADAP ULASAN APLIKASI PEJABAT PENGELOLA INFORMASI DAN DOKUMENTASI KEMENTERIAN DALAM NEGERI REPUBLIK INDONESIA DI GOOGLE PLAYSTORE MENGGUNAKAN METODE SUPPORT VECTOR MACHINE," *J. Teknol. Dan Komun. Pemerintah.*, vol. 4, no. 1, pp. 1–13, Jun. 2022, doi: 10.33701/jtkp.v4i1.2701.
- [18] M. F. A. Halik, "Analisis Sentimen Masyarakat Indonesia Terhadap Kebijakan Pemerintah Dalam Menangani Pandemi Covid-19 Menggunakan Klasifikasi Random Forest pada Media Sosial Twitter," Thesis, Universitas Hasanuddin, 2023. Accessed: Jun. 14, 2024. [Online]. Available: <https://repository.unhas.ac.id/id/eprint/29102/>
- [19] S. Adi Santoso Mola, S.T., M.Kom, N. Dessy Rumlaklak, S. Kom., M.Kom, and D. Putri Novita Polly, S.Kom, *Analisis Sentimen dengan Metode Random Forest*. Kaizen Media Publishing, 2024.
- [20] D. Musfiroh, U. Khaira, P. E. P. Utomo, and T. Suratno, "Analisis Sentimen terhadap Perkuliahan Daring di Indonesia dari Twitter Dataset Menggunakan InSet Lexicon: Sentiment Analysis of Online Lectures in Indonesia from Twitter Dataset Using InSet Lexicon," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 1, no. 1, Art. no. 1, Mar. 2021, doi: 10.57152/malcom.v1i1.20.