



KLASIFIKASI SENTIMEN MASYARAKAT TERHADAP EFISIENSI ANGGARAN PEMERINTAH MENGGUNAKAN METODE NAÏVE BAYES CLASSIFIER

M. Audi Alfaridzy¹, Elin Haerani², Jasril³, Lola Oktavia⁴

^{1,2,3,4} Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau

Email: 12050117689@students.uin-suska.ac.id¹, elin.haerani@uin-suska.ac.id², jasril@uin-suska.ac.id³, lola.oktavia@uin-suska.ac.id⁴

| Informasi Artikel | ABSTRACT |
|--|--|
| <p>Riwayat artikel : Disubmit : 15 Juni 2025 Direvisi : 20 Juni 2025 Diterima : 21 Juni 2025 Dipublikasi : 25 Juni 2025</p> | <p><i>The Indonesian government's 2025 budget efficiency policy responds to the need for fiscal strengthening and reallocation of funds to national priority programs. Through Presidential Instruction No. 1 of 2025, the government set a savings target of Rp306.7 trillion by cutting expenditures in ministries/agencies and transfers to local governments. Although the policy aims to support strategic programs such as Free Nutritious Meals (MBG), it has caused significant consequences, including over 50% budget cuts to vital institutions (e.g., BMKG), canceled infrastructure projects, and reductions in the public media workforce. These outcomes have triggered public debate over the balance between fiscal savings and potential risks to public services, investment, and equitable development. This study aims to classify public sentiment toward the efficiency policy using Instagram comments as data. The research process includes data collection, manual labeling, cleaning, case folding, tokenizing, normalization, negation handling, stopword removal, stemming, TF-IDF weighting, Naïve Bayes classification, and evaluation. A total of 1,408 comments from two Instagram accounts were analyzed using the Naïve Bayes Classifier, resulting in an accuracy of 90.74%, precision of 85.16%, recall of 98.51%, and an F1-score of 91.35%. Future research is expected to explore alternative classification methods to enhance sentiment analysis performance.</i></p> |
| <p>Keywords: Public sentiment; budget efficiency; social impact; Naïve Bayes Classifier; sentiment classification</p> | |
| <p>Kata Kunci: Sentimen masyarakat; Efisiensi anggaran; dampak sosial; Klasifikasi Naïve Bayes; klasifikasi sentimen.</p> | <p>ABSTRAK</p> <p>Kebijakan efisiensi anggaran pemerintah Indonesia tahun 2025 merupakan respons terhadap kebutuhan penguatan fiskal dan pengalokasian ulang anggaran untuk program prioritas nasional. Melalui Instruksi Presiden Nomor 1 Tahun 2025, pemerintah menetapkan penghematan sebesar Rp306,7 triliun dengan memotong belanja kementerian/lembaga dan transfer ke daerah. Meskipun ditujukan untuk mendukung program strategis seperti Makan Bergizi Gratis (MBG), kebijakan ini menimbulkan dampak signifikan, seperti pemangkasan anggaran lembaga penting (misalnya BMKG) lebih dari 50%, pembatalan proyek infrastruktur, serta pengurangan tenaga kerja di sektor media publik. Kondisi ini menimbulkan perdebatan di tengah masyarakat terkait kebutuhan penghematan dan potensi risikonya terhadap pelayanan publik, investasi, serta pemerataan pembangunan. Penelitian ini bertujuan mengklasifikasikan sentimen masyarakat terhadap kebijakan efisiensi anggaran berdasarkan komentar dari media sosial Instagram. Tahapan penelitian meliputi pengumpulan data, pelabelan manual, cleaning, case folding, tokenizing, normalisasi, negation handling, stopword removal, stemming, pembobotan TF-IDF, klasifikasi dengan Naïve Bayes, dan pengujian. Sebanyak 1.408 komentar dari dua akun Instagram diklasifikasikan menggunakan metode Naïve Bayes Classifier dengan hasil akurasi 90,74%, presisi 85,16%, recall 98,51%, dan F1-score 91,35%. Hasil penelitian ini membuktikan bahwa metode yang digunakan mampu mengklasifikasikan sentimen dengan tingkat akurasi yang memadai.</p> |





PENDAHULUAN

Efisiensi anggaran pemerintah merupakan indikator penting dalam menilai kualitas tata kelola keuangan negara. Secara umum, efisiensi anggaran merujuk pada kemampuan pemerintah dalam menggunakan sumber daya fiskal secara optimal untuk mencapai hasil atau output yang maksimal, dengan pemborosan seminimal mungkin (Astari et al., 2020). Dalam kasus ini, efisiensi bukan hanya berarti penghematan, tetapi juga mencakup bagaimana setiap pengeluaran anggaran menghasilkan manfaat yang sebanding atau lebih besar bagi masyarakat (Hertati, Hertati; Haerani, Elin; Syafria, 2023).

Tingginya tekanan terhadap anggaran, baik karena keterbatasan penerimaan negara maupun meningkatnya kebutuhan belanja untuk pembangunan dan pelayanan publik, menuntut pemerintah untuk mengelola anggaran secara cerdas, transparan, dan berbasis pada kinerja. Konsep efisiensi anggaran tidak terlepas dari prinsip *value of money*, yang mencakup tiga aspek utama: ekonomi, efisiensi, dan efektivitas (Azhar et al., 2022). Ekonomi berarti pengadaan input dengan biaya terendah, efisiensi berarti pemanfaatan input untuk menghasilkan output secara optimal, dan efektivitas berkaitan dengan sejauh mana output tersebut mencapai tujuan yang telah ditetapkan (Nurtikasari et al., 2022).

Namun, pada praktiknya, penilaian terhadap efisiensi anggaran sering kali tidak hanya didasarkan pada indikator teknis atau administratif, melainkan juga dipengaruhi oleh persepsi publik (Arsi et al., 2021). Masyarakat sebagai pihak yang terdampak langsung oleh kebijakan fiskal pemerintah memiliki pandangan yang beragam terkait bagaimana anggaran digunakan—apakah belanja negara benar-benar memberikan manfaat nyata, atau justru dianggap boros, tidak tepat sasaran, bahkan berpotensi sarat dengan penyimpangan (Prabowo & Wiguna, 2021).

Di era digital dan keterbukaan informasi saat ini, opini publik mengenai pengelolaan anggaran pemerintah dapat dengan mudah ditemukan melalui media sosial, kolom komentar berita, forum daring, dan platform digital lainnya (Singgalen, 2022). Di sinilah muncul kebutuhan untuk melakukan pengelolaan informasi dan analisis sentimen masyarakat sebagai bagian dari upaya menilai persepsi terhadap efisiensi anggaran. Informasi ini sangat berharga, tidak hanya untuk tujuan evaluasi kebijakan, tetapi juga sebagai bahan untuk meningkatkan partisipasi dan kepercayaan publik terhadap institusi pemerintahan (Alfandi Safira & Hasan, 2023).

Melalui pendekatan teknologi, seperti klasifikasi sentimen berbasis pembelajaran mesin, pemerintah dan peneliti dapat mengolah data dalam skala besar untuk mengidentifikasi pola persepsi yang dominan dalam masyarakat (Doloksaribu & Yusran Timur Samuel, 2022). Salah satu metode yang efektif untuk melakukan hal ini adalah *Naïve Bayes Classifier* (NBC), yang dikenal luas dalam bidang pengolahan bahasa alami (*Natural Language Processing/NLP*) karena keakuratannya dalam menangani teks opini (Anjani et al., 2022).



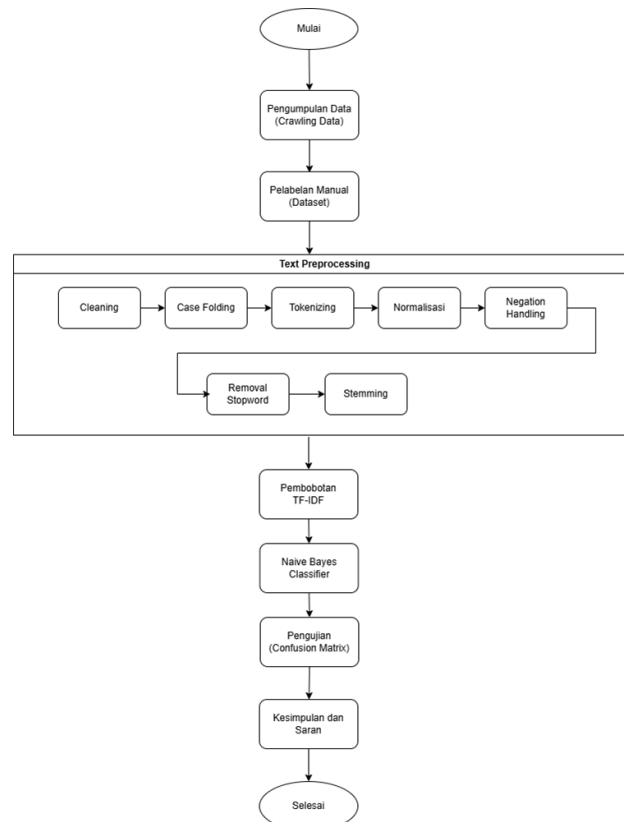


Penelitian ini bertujuan untuk mengembangkan dan menguji model klasifikasi sentimen masyarakat terhadap efisiensi anggaran pemerintah menggunakan metode *Naïve Bayes* (Zaenab Kurnia et al., 2024). Dengan memanfaatkan data opini masyarakat dari berbagai sumber digital, model ini diharapkan mampu menyajikan potret umum persepsi publik yang objektif dan dapat dijadikan sebagai salah satu dasar dalam perumusan kebijakan yang lebih responsif, adaptif, dan efisien (Amrin, 2024).

METODE PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini terbagi menjadi enam tahap, dimulai dari pengumpulan data, pelabelan manual dataset, *text preprocessing*, pembobotan kata, klasifikasi *Naïve Bayes Classifier*, hingga pengujian. Gambar 1 menjabarkan alur tahapan penelitian.



Gambar 1. Tahap Penelitian

1.1.1 Pengumpulan Data

Dengan menggunakan *command exporter* dari *website* easycoment.ai, data penelitian ini dikumpulkan dari dua akun instagram, @trenasiacom dan @greenpeaceid. Komentar-komentar ini





berasal dari postingan yang membahas Efisiensi Anggaran Pemerintah dengan rentang waktu dari tanggal 11 hingga 12 Februari 2025. Baik saat mengumpulkan data maupun saat menyimpannya, data disimpan dalam format *file* CSV. Data yang dihimpun masih dalam bentuk mentah (*raw*) dan belum diberi label.

1.1.2 Pelabelan Manual Dataset

Semua data yang dikumpulkan perlu diberi label secara manual. Komentar diklasifikasikan sebagai positif atau negatif berdasarkan isinya. Label positif diberikan untuk komentar yang mendukung kebijakan, seperti apresiasi, masukan konstruktif, atau respons positif lainnya. Sementara itu, label negatif diberikan untuk komentar yang menolak, mengkritik secara tidak konstruktif, atau berpotensi memicu perpecahan, seperti provokasi dan SARA. Pelabelan divalidasi oleh Guru SMA bahasa Indonesia yang memiliki 5 tahun pengalaman secara manual meninjau setiap komentar dan menetapkan label yang sesuai.

1.1.3 Text Preprocessing

Text preprocessing adalah tahap awal dalam *text mining* yang bertujuan untuk mengolah data mentah menjadi data terstruktur dan siap dianalisis. Proses ini mencakup pembersihan data dari karakter yang tidak diperlukan, penerjemahan kata asing, serta konversi kalimat tidak terstruktur menjadi kata dasar (Budianita et al., 2022). Dengan *preprocessing*, data mentah seperti dari Instagram dapat diubah menjadi format yang layak dan efektif untuk menemukan pola, tren, serta pengetahuan yang berguna dalam proses analisis selanjutnya.

1. *Cleaning* adalah tahap awal untuk menghapus elemen tidak relevan dalam teks seperti mention, link, emoticon, angka, dan simbol. Proses ini bertujuan agar data lebih bersih dan siap dianalisis. *Cleaning* tidak menggunakan kamus, melainkan *regex* dan fungsi *string*.
2. *Case folding* mengubah semua huruf dalam teks menjadi huruf kecil agar konsisten, sehingga “Pemerintah” dan “pemerintah” dianggap sama. Tahap ini tidak menggunakan kamus, hanya menggunakan fungsi *.lower()*.
3. *Tokenizing* memecah teks menjadi token atau kata per kata berdasarkan spasi atau tanda baca. Proses ini penting untuk membentuk fitur analisis teks. Tokenisasi tidak memerlukan kamus khusus, cukup metode seperti *.split()* atau *nlk*.
4. Normalisasi mengubah kata tidak baku atau informal menjadi bentuk baku, seperti “gk” menjadi “tidak”. Proses ini menggunakan kamus normalisasi, seperti kamus-normalisasi.csv, berisi daftar kata tidak baku dan padanannya.





5. *Negation handling* mendeteksi kata negasi seperti “tidak” atau “bukan” agar makna kalimat tidak keliru. Untuk ini digunakan kamus negasi berisi daftar kata negasi seperti pada kamus-negasi.csv..
6. *Stopword removal* menghapus kata umum seperti “dan”, “yang”, atau “di” yang tidak berkontribusi pada makna penting. Proses ini menggunakan kamus stopwords, seperti stopwordsbahasa.csv.
7. *Stemming* mengubah kata berimbuhan ke bentuk dasar, seperti “bermain” menjadi “main”. Proses ini menggunakan *PySastrawi*, pustaka stemming bahasa Indonesia yang memiliki kamus internatiul dan aturan morfologi.

1.1.4 Pembobotan TF/IDF

Metode pembobotan TF-IDF dapat digunakan untuk menentukan seberapa sering setiap token muncul dalam sebuah dokumen. *Inverse Document Frequency* (IDF) mengukur seberapa jarang sebuah kata muncul di seluruh kumpulan dokumen, sedangkan *Term Frequency* (TF) menentukan seberapa sering sebuah kata muncul dalam sebuah dokumen (Tamara Rosyida et al., 2023). Paket *Tfidf Vectorizer* digunakan dalam penelitian ini untuk mengubah data teks menjadi vektor. Untuk mengubah teks tak terstruktur menjadi representasi numerik yang dapat diproses oleh algoritma pembelajaran mesin, prosedur ini diperlukan. Setiap kata dalam teks dievaluasi menurut bobotnya menggunakan algoritma TF-IDF, yang diimplementasikan oleh modul *Scikit-learn TfidfVectorizer* (Nugraha, 2021).

$$TF = \frac{\text{jumlah kemunculan term dalam dokumen}}{\text{total jumlah kata dalam dokumen}} \quad (1)$$

$$IDF = \log \left(\frac{\text{Jumlah dokumen dalam korpus}}{\text{jumlah dokumen yang mengandung term}} \right) \quad (2)$$

$$w_{ij} = tf_{ij} \times \log \left(\frac{n}{D_{fi}} \right)^{nt} \quad (3)$$

Keterangan :

$w_{i,j}$: bobot term i terhadap dokumen j

$tf_{i,j}$: jumlah kemunculan term i dalam dokumen

j N : total jumlah dokumen

D_{fi} : jumlah dokumen yang terdapat term i

1.1.5 Klasifikasi *Naïve Bayes Classifier*

Pengklasifikasi probabilistik yang sederhana, Pengklasifikasi *Naïve Bayes* menentukan probabilitas dengan memeriksa frekuensi dan kombinasi nilai dalam kumpulan data (Ratih Puspitasari et al., 2023).





Untuk meningkatkan akurasi klasifikasi dan memperkirakan kemungkinan setiap kategori berdasarkan karakteristik dokumen yang diuji, metode ini yang disebut *Teorema Bayes* dilatih menggunakan data pelatihan (Asmara et al., 2020). Rumus untuk metode klasifikasi Pengklasifikasi *Naïve Bayes* ditunjukkan dalam persamaan (4).

$$P(c|x) = \frac{P(c|x) P(c)}{P(x)} \quad (4)$$

Keterangan:

$P(c|x)$: *Posterior probability* (probabilitas kelas c setelah melihat fitur x)

$P(x|c)$: *Likelihood* (probabilitas mendapatkan fitur x jika diketahui kelasnya c)

$P(c)$: *Prior probability* (probabilitas awal kelas c)

$P(x)$: *Prior probability* dari fitur x secara umum

1.1.6 Pengujian

Sebelum pengujian dilakukan, data dibagi menjadi data latih (*training*) dan data uji (*testing*). Setelah model klasifikasi dibangun menggunakan *Naïve Bayes Classifier*, hasil utama yang diperoleh adalah model terlatih yang dapat digunakan untuk melakukan prediksi pada data baru (Prasetyo, 2025). Model ini kemudian diuji pada data uji untuk mendapatkan nilai *accuracy*, *precision*, *recall*, dan *f1-score* (Annisa & Ulama, 2023). Evaluasi performa klasifikasi ini dilakukan dengan menggunakan *confusion matrix*, yang ditampilkan pada Tabel 1 (Raffi et al., 2023).

Tabel 1. Pengujian dengan Confusion Matrix

| | Actual Positive | Actual Negative |
|---------------------------|------------------------|------------------------|
| Predicted Positive | TP (True Positive) | FP (False Positive) |
| Predicted Negative | FN (False Negative) | TN (True Negative) |

Jenis pembagian data dengan tingkat akurasi terbaik akan ditentukan oleh hasil pengujian. Rumus berikut dapat digunakan untuk menentukan skor F1, *recall*, akurasi, dan presisi.





$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

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

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

$$F1 - Score = \frac{(2 \times Recall \times Precision)}{Recall + Precision} \quad (8)$$

HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Proses pengumpulan data mencakup peninjauan metode serta kategori yang digunakan dalam klasifikasi. Komentar yang diperoleh kemudian dikategorikan sebagai positif atau negatif. Dalam penelitian ini, sebanyak 1.408 komentar berbahasa Indonesia dikumpulkan dari postingan Instagram trenasiacom dan greenpeaceid menggunakan alat Easycomment.ai. Data yang dihimpun masih dalam bentuk mentah (*raw*) dan belum diberi label.

3.2 Pelabelan Manual Dataset

Seluruh data dianotasi secara manual dengan klasifikasi sentimen positif atau negatif berdasarkan isi komentar. Label positif diberikan pada komentar yang mendukung kebijakan, seperti apresiasi, saran konstruktif, atau tanggapan yang bernuansa positif. Sementara itu, label negatif diterapkan pada komentar yang menolak kebijakan, mengandung kritik tidak membangun, atau berpotensi menimbulkan konflik, seperti provokasi dan unsur SARA. Proses anotasi ini divalidasi oleh seorang Guru SMA bahasa Indonesia yang memiliki pengalaman profesional lebih dari lima tahun dalam melakukan peninjauan dan pelabelan konten secara manual.

3.3 Text Preprocessing

Modul Python seperti NLTK dan Pysastrawi digunakan untuk menangani dan mengatur data teks menggunakan praproses teks sebelum metode pembelajaran mesin digunakan untuk kategorisasi. Langkah-langkah dan hasil dari prosedur praproses teks ditunjukkan pada Tabel 2.





Tabel 2. Tabel Text Preprocessing

| Proses | Hasil |
|--------------------------|---|
| Data Mentah | Yang saya gak habis pikir jelas2 jejak rekam dengan pelanggaran HAM tapi masih dipilih rakyat.....dimanakah hati mereka yang memilihnyasehingga pelanggar HAM bisa menjadi presiden atas negara ini....maaf ya kak curhat ajah |
| Cleaning | Yang saya gak habis pikir jelas jejak rekam dengan pelanggaran HAM tapi masih dipilih rakyat dimanakah hati mereka yang memilihnya sehingga pelanggar HAM bisa menjadi presiden atas negara ini maaf ya kak curhat ajah |
| Case Folding | yang saya ga habies pikir jelas jejak rekam dgn pelanggaran ham tapi masih dipilih rakyat dimanakah hati mereka yang memilihnya sehingga pelanggar ham bisa menjadi presiden atas negara ini maaf ya kak curhat ajah |
| Tokenizing | ['yang', 'saya', 'ga', 'habis', 'pikir', 'jelas', 'jejak', 'rekam', 'dgn', 'pelanggaran', 'ham', 'tapi', 'masih', 'dipilih', 'rakyat', 'dimanakah', 'hati', 'mereka', 'yang', 'memilihnya', 'sehingga', 'pelanggar', 'ham', 'bisa', 'menjadi', 'presiden', 'atas', 'negara', 'ini', 'maaf', 'ya', 'kak', 'curhat', 'ajah'] |
| Normalisasi | ['yang', 'saya', 'enggak', 'habis', 'pikir', 'jelas', 'jejak', 'rekam', 'dengan', 'pelanggaran', 'ham', 'tapi', 'masih', 'dipilih', 'rakyat', 'dimanakah', 'hati', 'mereka', 'yang', 'memilihnya', 'sehingga', 'pelanggar', 'ham', 'bisa', 'menjadi', 'presiden', 'atas', 'negara', 'ini', 'maaf', 'ya', 'kak', 'curhat', 'saja'] |
| Negation Handling | ['yang', 'saya', 'enggak', 'habis', 'pikir', 'jelas', 'jejak', 'rekam', 'dengan', 'pelanggaran', 'ham', 'tapi', 'masih', 'dipilih', 'rakyat', 'dimanakah', 'hati', 'mereka', 'yang', 'memilihnya', 'sehingga', 'pelanggar', 'ham', 'bisa', 'menjadi', 'presiden', 'atas', 'negara', 'ini', 'maaf', 'ya', 'kak', 'curhat', 'saja'] |
| Stopword Removal | ['habis', 'pikir', 'jejak', 'rekam', 'pelanggaran', 'ham', 'dipilih', 'rakyat', 'dimanakah', 'hati', 'memilihnya', 'pelanggar', 'ham', 'presiden', 'negara', 'maaf', 'kak', 'curhat'] |





| | |
|-----------------|---|
| Stemming | ['habis', 'pikir', 'jejak', 'rekam', 'langgar', 'ham', 'pilih', 'rakyat', 'mana', 'hati', 'pilih', 'langgar', 'ham', 'presiden', 'negara', 'maaf', 'kak', 'curhat'] |
|-----------------|---|

| ID | Text | Sentimen | stemming |
|------|---|----------|---|
| 0 | Buat bayar Hutang | Negatif | [bayar, hutang] |
| 1 | Jangan menyesal kalian yang inginkan dia naik,... | Negatif | [sesal, biar, petinggi, gemoy] |
| 2 | mau jadi apa indonesia | Negatif | [indonesia] |
| 3 | Selamat menikmati, smga negara ini semakin Han... | Negatif | [selamat, nikmat, moga, negara, hancur, leeburr] |
| 4 | Indonesia gelap | Negatif | [indonesia, gelap] |
| ... | ... | ... | ... |
| 1403 | pak negara kita makin hancur kena efisiensi | Negatif | [negara, hancur, efisiensi] |
| 1404 | Demi makan gratis | Negatif | [makan, gratis] |
| 1405 | Yang kudu dipotong adalah tunjangan atau gaji ... | Negatif | [kudu, potong, tunjang, gaji, jabat, bikin, ma...] |
| 1406 | Kapan negara kita yang ini bisa maju seperti ... | Negatif | [negara, yangg, maju, negara, tetangga, seba, ...] |
| 1407 | Hapus saja makan siangnya alihkan saja ke daer... | Negatif | [hapus, makan, siang, alih, daerah, idt, biar, ...] |

1408 rows x 3 columns

Gambar 3. Hasil Text Preprocessing Seluruh Dataset

Setelah dataset dikumpulkan dan dilabeli secara manual, seluruh tahapan *text preprocessing* diselesaikan terlebih dahulu, dengan *stemming* sebagai langkah terakhir. Gambar 3 menampilkan hasil text preprocessing pada seluruh dataset yang diproses menggunakan Google Colab.

Proses *text preprocessing* menghasilkan data teks yang dikelompokkan berdasarkan frekuensi kata. Kata-kata dengan frekuensi tertinggi divisualisasikan dalam bentuk *wordcloud* positif dan negatif untuk memahami topik dan sentimen utama dalam data teks.



Gambar 4. WordCloud Komentar Positif dan Negatif





3.4 Pembobotan TF/IDF


| | aapa | abah | abai | abdi | abk | abu | acak | acara | ada | adek | ... | yeyyy | ykpo | yoe | yudisial | yuk | zalim | zaman | zebra | zuma | Sentimen | | | |
|------|------|------|------|------|-----|-----|------|-------|-----|------|-----|-------|------|-----|----------|-----|-------|-------|-------|------|----------|---------|---------|-----|
| 0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | | |
| 1 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 2 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 3 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 4 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 1403 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 1404 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 1405 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 1406 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |
| 1407 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | Negatif | |

Gambar 5. Data Frame Pembobotan TF-IDF

TfidfVectorizer, pustaka Python yang dikembangkan oleh Scikit-learn, digunakan untuk melakukan proses ini. Gambar 5 menampilkan hasil pembobotan TF-IDF untuk setiap kata dalam teks. Kata-kata dengan bobot TF-IDF tertinggi dianggap paling penting dalam data teks.

3.5 Klasifikasi Naïve Bayes Classifier

Menggunakan strategi berbagi data yang berbeda, tiga pengujian klasifikasi dilakukan menggunakan Naïve Bayes Classifier. Akurasi maksimum sebesar 90,74% diperoleh pada percobaan pertama, yang menggunakan 90% data untuk pelatihan dan 10% untuk pengujian.



Gambar 6. Klasifikasi Pada Setiap Percobaan






3.6 Pengujian

Untuk menilai efektivitas algoritma yang digunakan, 1.408 titik data dipisahkan menjadi set pelatihan dan pengujian. Tiga skenario berbeda digunakan untuk pembagian data: 90% data pelatihan dan 10% data pengujian digunakan dalam skema pertama, 80% data pelatihan dan 20% data pengujian digunakan dalam skema kedua, dan 70% data pelatihan dan 30% data pengujian digunakan dalam skema ketiga. *Confusion Matrix* yang membandingkan keluaran prediksi algoritma dengan label asli dalam set data, digunakan untuk menilai kinerja algoritma. Gambar 7, 8, dan 9 menampilkan temuan evaluasi.

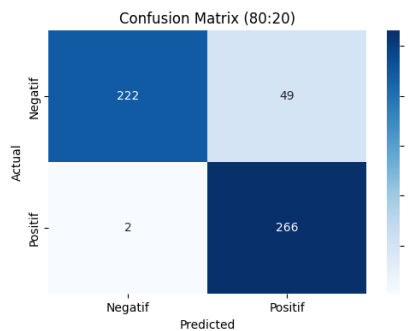
Tabel 3. Menunjukkan *true* dan *false* pada *confusion matrix*

| | |
|---------------------|---------------------|
| True Negative (TN) | False Positive (FP) |
| False Negative (FN) | True Positive (TP) |

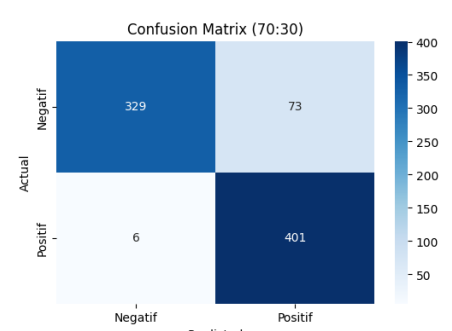
Tabel 3 menampilkan hasil pengujian untuk setiap skema pembagian data, yang diperoleh dari item dalam *confusion matrix* (Gambar 7, 8, dan 9). Rumus yang dijelaskan sebelumnya digunakan untuk melakukan perhitungan ini.



Gambar 1. *Confusion Matrix* Pada Pembagian Data 90%:10%



Gambar 8. *Confusion Matrix* Pada Pembagian Data 80%:20%



Gambar 9. *Confusion Matrix* Pada Pembagian Data 70%:30%

| Split Data | Accuracy | Precision | Recall | F1-Score |
|------------|----------|-----------|--------|----------|
| 90%:10% | 90.74% | 85.16% | 98.51% | 91.35% |
| 80%:20% | 90.54% | 84.44% | 99.25% | 91.25% |
| 70%:30% | 90.23% | 84.60% | 98.53% | 91.03% |





Algoritma ini bekerja paling baik ketika skenario pemisahan data uji adalah 90%:10%. Akurasi, presisi, recall, dan F1-score masing-masing adalah 90,74%, 85,16%, 98,51%, dan 91,35%. Hasil ini menunjukkan bahwa algoritma yang digunakan memiliki performa yang sangat baik dalam mengklasifikasikan data, terutama dengan recall yang tinggi, yang mengindikasikan kemampuannya dalam mengenali kelas positif secara konsisten (Akbar et al., 2024).

KESIMPULAN

Penelitian ini menganalisis 1.408 komentar di media sosial Instagram terkait efisiensi anggaran pemerintah, yang terdiri dari 61 komentar positif dan 1.347 komentar negatif. Data dikumpulkan dari dua akun berita dan telah diberi label secara manual oleh seorang Guru SMA bahasa Indonesia. Pengujian dilakukan menggunakan metode *Naïve Bayes Classifier* dengan skema pembagian data 90% untuk pelatihan dan 10% untuk pengujian. Hasil pengujian menunjukkan bahwa model ini mampu mencapai akurasi sebesar 90,74%, presisi 81,16%, *recall* 98,51%, dan *F1-score* 91,35%. Hasil ini menunjukkan bahwa metode *Naïve Bayes Classifier* memiliki tingkat keakuratan yang tinggi dalam mengklasifikasikan sentimen masyarakat terhadap efisiensi anggaran pemerintah. Ke depan, diharapkan pengujian dapat dilakukan menggunakan berbagai metode lain seperti K-Nearest Neighbor, Support Vector Machine, dan Linear Regression agar dapat membandingkan nilai akurasi, presisi, recall, dan F1-score pada masing-masing metode. Penelitian ini juga diharapkan dapat menjadi dasar bagi mahasiswa atau peneliti selanjutnya untuk mengembangkan dan menyempurnakan analisis sentimen pada isu-isu kebijakan publik serupa.

DAFTAR RUJUKAN

- Alfandi Safira, & Hasan, F. N. (2023). Analisis Sentimen Masyarakat Terhadap Paylater Menggunakan Metode Naive Bayes Classifier. *ZONAsi: Jurnal Sistem Informasi*, 5(1), 59–70. <https://doi.org/10.31849/zn.v5i1.12856>
- Akbar, L. A., Haerani, E., Syafria, F., Nazir, A., & Budianita, E. (2024). Klasifikasi Sentimen Presepsi Masyarakat di Instagram Terhadap Paslon Pilpres 2024 Menggunakan Naïve Bayes Classifier (NBC). *Jurnal Komtika (Komputasi Dan Informatika)*, 8(1), 102–112.
- Amrin, R. N. (2024). *Sentimen Warganet terhadap Postingan Akun Instagram @kementerian.atrbpn sebagai Evaluasi dalam Membangun Citra Kementerian ATR/BPN*. Kementerian Agraria dan Tata Ruang/Badan Pertanahan Nasional Sekolah Tinggi Pertanahan Nasional Yogyakarta.





- Anjani, A., Chamid, A., & Murti, A. (2022). Analisis Sentimen Kaum LGBT pada Media Sosial Twitter Menggunakan Algoritma Naïve Bayes. *JTINFO: Jurnal Teknik Informatika*, 1(2), 1–8. <https://journal.unisnu.ac.id/JTINFO/article/view/259>
- Annisa, Z., & Ulama, B. S. S. (2023). Analisis Sentimen Data Ulasan Pengguna Aplikasi “PeduliLindungi” pada Google Play Store Menggunakan Metode Naïve Bayes Classifier Model Multinomial. *Jurnal Sains Dan Seni ITS*, 11(6). <https://doi.org/10.12962/j23373520.v11i6.94064>
- Arsi, P., Kusuma, B. A., & Nurhakim, A. (2021). Analisis Sentimen Pindah Ibu Kota Berbasis Naïve Bayes Classifier. *Jurnal Informatika Upgris*, 7(1), 1–6. <https://doi.org/10.26877/jiu.v7i1.7636>
- Asmara, R., Ardiansyah, M. F., & Anshori, M. (2020). Analisa Sentiment Masyarakat terhadap Pemilu 2019 berdasarkan Opini di Twitter menggunakan Metode Naive Bayes Classifier. *INOVTEK Polbeng - Seri Informatika*, 5(2), 193. <https://doi.org/10.35314/isi.v5i2.1095>
- Astari, N. M. A. J., Dewa Gede Hendra Divayana, & Gede Indrawan. (2020). Analisis Sentimen Dokumen Twitter Mengenai Dampak Virus Corona Menggunakan Metode Naive Bayes Classifier. *Jurnal Sistem Dan Informatika (JSI)*, 15(1), 27–29. <https://doi.org/10.30864/jsi.v15i1.332>
- Azhar, R., Surahman, A., & Juliane, C. (2022). Analisis Sentimen Terhadap Cryptocurrency Berbasis Python TextBlob Menggunakan Algoritma Naïve Bayes. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 6(1), 267–281.
- Budianita, E., Cynthia, E. P., Pranata, A., & Abimanyu, D. (2022). Pendekatan berbasis Machine Learning dan Leksikal Pada Analisis Sentimen. *Seminar Nasional Teknologi Informasi, Komunikasi Dan Industri (SNTIKI)*, 99–104. <https://ejournal.uin-suska.ac.id/index.php/SNTIKI/article/view/19137>
- Doloksaribu, H. P., & Yusran Timur Samuel. (2022). Komparasi Algoritma Data Mining Untuk Analisis Sentimen Aplikasi Pedulilindungi. *Jurnal Teknologi Informasi: Jurnal Keilmuan Dan Aplikasi Bidang Teknik Informatika*, 16(1), 1–11. <https://doi.org/10.47111/jti.v16i1.3747>
- Hertati, Hertati; Haerani, Elin; Syafria, F. N. (2023). KLIK: Kajian Ilmiah Informatika dan Komputer Analisis Sentimen Masyarakat Terhadap Kenaikan Biaya Haji Tahun 2023 Menggunakan Metode Naïve Bayes Classifier. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 4(3), 1578–1584. <https://doi.org/10.30865/klik.v4i3.1457>
- Nugraha, K. A. (2021). Analisis Sentimen Berbasis Emoticon pada Komentar Instagram Bahasa Indonesia Menggunakan Naïve Bayes. *Jurnal Teknik Informatika Dan Sistem Informasi*, 7(3), 715–721. <https://doi.org/10.28932/jutisi.v7i3.4094>





- Nurtikasari, Y., Syariful Alam, & Teguh Iman Hermanto. (2022). Analisis Sentimen Opini Masyarakat Terhadap Film Pada Platform Twitter Menggunakan Algoritma Naive Bayes. *INSOLOGI: Jurnal Sains Dan Teknologi*, 1(4), 411–423. <https://doi.org/10.55123/insologi.v1i4.770>
- Prabowo, W. A., & Wiguna, C. (2021). Sistem Informasi UMKM Bengkel Berbasis Web Menggunakan Metode SCRUM. *Jurnal Media Informatika Budidarma*, 5(1), 149. <https://doi.org/10.30865/mib.v5i1.2604>
- Prasetyo, A. (2025). *Implementasi Naive Bayes Classifier untuk Analisis Sentimen Ulasan Aplikasi Indodax pada Google Play Store*. UIN Sultan Syarif Kasim Riau.
- Raffi, M., Suharso, A., & Maulana, I. (2023). Analisis Sentimen Ulasan Aplikasi Binar Pada Google Play Store Menggunakan Algoritma Naive Bayes Sentiment Analysis of Binar Application Reviews on Google Play Store Using Naive Bayes Algorithm. *Journal of Information Technology and Computer Science (INTECOMS)*, 6(1), 1–7.
- Ratih Puspitasari, Findawati, Y., & Rosid, M. A. (2023). Sentiment Analysis of Post-Covid-19 Inflation Based on Twitter Using the K-Nearest Neighbor and Support Vector Machine Classification Methods. *Jurnal Teknik Informatika (Jutif)*, 4(4), 669–679. <https://doi.org/10.52436/1.jutif.2023.4.4.801>
- Singgalen, Y. A. (2022). Analisis Sentimen Wisatawan Melalui Data Ulasan Candi Borobudur di Tripadvisor Menggunakan Algoritma Naive Bayes Classifier. *Building of Informatics, Technology and Science (BITS)*, 4(3). <https://doi.org/10.47065/bits.v4i3.2486>
- Tamara Rosyida, Putro, H. P., & Herry Wahyono. (2023). Analisis Sentimen Terhadap Pilpres 2024 Berdasarkan Opini Dari Twitter Menggunakan Naive Bayes Dan Svm. *Teknokris*, 26(1), 23–32. <https://doi.org/10.61488/teknokris.v26i1.245>
- Zaenab Kurnia, Amalina Maryam Zakiiyyah, Nur Qodariyah Fitriyah, & Agus Milu Susetyo. (2024). Analisis Sentimen Masyarakat Berdasarkan Komentar Kerja Sama Tiktok Shop dan Tokopedia di Instagram Menggunakan Metode Naive Bayes Classifier. *Jurnal Penelitian Teknologi Informasi Dan Sains*, 2(2), 115–125. <https://doi.org/10.54066/jptis.v2i2.1978>

