JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 15-20
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8137

Analisis Sentimen Kebijakan Efisiensi Anggaran 100 Hari Pemerintahan Menggunakan Logistic Regression

Saidi Ramadan Siregar

Teknik Informatika,Fakultas Ilmu Komputer & Teknologi Informasi, Medan,Indonesia
Email : saidiramadan@univ-bd.ac.id
Email korespondensi: saidiramadan@univ-bd.ac.id

Abstrak—Kebijakan efisiensi anggaran pada awal pemerintahan memicu beragam tanggapan dan menjadi objek potensial analisis sentimen berbasis teks. Penelitian ini menyusun dan memverifikasi alur klasifikasi sentimen dua kelas dengan metode Logistic Regression dan representasi Term Frequency–Inverse Document Frequency (TF-IDF). Tahapan mencakup pembersihan teks, penyeragaman huruf, pembentukan fitur unigram dan bigram, pemisahan data secara stratifikasi, pelatihan, evaluasi, serta interpretasi koefisien fitur. Karena data media sosial aktual tidak tersedia dalam berkas penelitian, verifikasi dilakukan terhadap 1.200 teks simulasi berlabel positif dan negatif, terdiri atas 960 data pelatihan dan 240 data pengujian. Hasil pengujian menghasilkan accuracy 92,92%, precision 91,87%, recall 94,17%, dan F1-score 93,00%. Evaluasi lima lipatan menghasilkan rata-rata accuracy 92,00% dengan simpangan baku 1,65 poin persentase. Koefisien model menunjukkan kontribusi fitur teks terhadap prediksi, meskipun beberapa kata umum juga memperoleh bobot tinggi. Temuan ini mendukung kelayakan teknis alur pemodelan pada data simulasi, bukan estimasi proporsi opini masyarakat. Validasi dengan data media sosial aktual, prosedur anotasi yang terukur, dan pengujian terhadap perubahan distribusi bahasa tetap diperlukan sebelum menarik kesimpulan substantif mengenai tanggapan publik terhadap kebijakan.

Kata Kunci: Analisis Sentimen; Efisiensi Anggaran; Logistic Regression; TF-IDF; Klasifikasi Teks

Abstract—The budget efficiency policy introduced during the early period of government attracted diverse public responses and provides a relevant topic for text-based sentiment analysis. This study develops and verifies a binary sentiment classification workflow using Logistic Regression and Term Frequency–Inverse Document Frequency (TF-IDF) features. The workflow includes text cleaning, case normalization, unigram and bigram vectorization, stratified data splitting, model training, evaluation, and coefficient interpretation. As actual social media records were not available in the source materials, the technical verification uses 1,200 simulated positive and negative texts, divided into 960 training and 240 testing instances. The test evaluation yielded 92.92% accuracy, 91.87% precision, 94.17% recall, and a 93.00% F1-score. Five-fold cross-validation produced an average accuracy of 92.00% with a standard deviation of 1.65 percentage points. The model coefficients identify textual features associated with its predictions, although some general-purpose words receive relatively high weights. These findings demonstrate the feasibility of the classification procedure in a controlled simulation. They do not quantify real public sentiment or establish the representativeness of social media users. Further research requires authentic, date-bounded social media data, transparent labeling protocols, independent evaluation, and robustness checks for informal language, negation, sarcasm, and dataset shifts before substantive policy-related conclusions can be made.

Keywords: Sentiment Analysis; Budget Efficiency; Logistic Regression; TF-IDF; Text Classification

1. PENDAHULUAN

Media sosial menyediakan ruang bagi pengguna untuk menanggapi kebijakan publik secara cepat. Kebijakan efisiensi anggaran pada awal pemerintahan tahun 2025 berkaitan dengan pengeluaran pemerintah, program pelayanan, dan pengelolaan kegiatan. Konten dalam platform digital dapat mengandung dukungan maupun kritik terhadap kebijakan tersebut. Namun, banyaknya komentar dan ragam gaya bahasa membuat kategorisasi manual sulit diterapkan secara konsisten pada skala besar. Pemrosesan bahasa alami dan pembelajaran mesin menawarkan pendekatan untuk mengubah teks menjadi fitur dan memprediksi label sentimen.

Analisis sentimen tidak identik dengan pengukuran pendapat seluruh penduduk. Komentar media sosial dikirim oleh pengguna yang memilih sendiri untuk berpartisipasi, dipengaruhi algoritma platform, dan tidak mewakili sampel probabilitas penduduk. Penelitian yang memakai teks digital perlu membedakan kinerja model klasifikasi dari klaim distribusi opini publik. Dalam artikel ini pembatasan tersebut penting karena data empiris kebijakan efisiensi anggaran belum disediakan pada dokumen sumber.

Penelitian terdahulu menggunakan Naive Bayes dan Support Vector Machine untuk mengkaji respons terhadap figur politik dan pemilihan umum [1]–[7]. Penelitian tentang kebijakan publik dengan Logistic Regression juga telah dilakukan pada topik pemindahan ibu kota negara [8], sedangkan penelitian lain menggunakan Logistic Regression dan TF-IDF untuk opini dalam bahasa Indonesia [9], [10]. Temuan tersebut mendukung relevansi pendekatan klasifikasi linier pada teks bahasa Indonesia, tetapi kesimpulan performanya tidak dapat langsung dipindahkan ke isu efisiensi anggaran yang memiliki kosakata dan konteks berbeda.

Logistic Regression relevan sebagai metode dasar karena membentuk probabilitas kelas berdasarkan kombinasi linear fitur. Ketika dikombinasikan dengan TF-IDF, model dapat menangani representasi teks

Submitted: **28/09/2024**; Accepted: **25/11/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 15-20
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8137
berdimensi tinggi dan menyediakan koefisien yang membantu menjelaskan arah kontribusi fitur. Interpretabilitas ini tidak menjamin penjelasan semantik yang sempurna karena bobot dapat dipengaruhi frekuensi kata, korelasi fitur, atau konstruksi data pelatihan.

Celah penelitian yang dapat ditangani dalam dokumen ini bersifat metodologis: menyusun alur yang transparan dari pembersihan data sampai interpretasi klasifikasi dengan fokus kebijakan efisiensi anggaran. Berbeda dari kajian berbasis korpus riil, verifikasi pada artikel ini memakai data simulasi agar setiap tahapan model dapat ditelusuri. Kebaruan empiris mengenai persepsi masyarakat belum dapat diklaim tanpa pengumpulan komentar aktual yang relevan dengan periode 100 hari pemerintahan.

Tujuan penelitian adalah menguraikan prosedur TF-IDF dan Logistic Regression untuk sentimen positif–negatif, memverifikasi penghitungan metrik pada data uji, serta mengkaji batas interpretasi koefisien fitur. Artikel ini juga menyajikan batasan dan rancangan validasi lanjutan. Dengan demikian, kontribusi yang dibuktikan berupa verifikasi metode pada skenario terkontrol, bukan kesimpulan mengenai dukungan atau penolakan masyarakat terhadap kebijakan.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian mengikuti rangkaian identifikasi masalah, telaah literatur, penyiapan teks, pelabelan, preprocessing, pembentukan TF-IDF, pembagian data, pelatihan Logistic Regression, evaluasi, dan interpretasi. Alur ini disusun untuk menghindari kontaminasi data uji terhadap pembelajaran model. Pada implementasi riil, seluruh keputusan pembersihan, seleksi komentar, deduplikasi, dan anotasi harus terdokumentasi.



Gambar 1. Alur penelitian berdasarkan laporan sumber

2.2 Sumber Data dan Batasan Eksperimen

Sumber laporan menyatakan bahwa data komentar aktual dari media sosial tidak disertakan. Oleh karena itu, eksperimen memakai 1.200 teks simulasi yang dibentuk dari pola opini positif dan negatif, dengan variasi redaksi serta noise label 8%. Jumlah akhir setiap kelas adalah 598 positif dan 602 negatif. Data dibagi secara

Submitted: **28/09/2024**; Accepted: **25/11/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 15-20
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8137
stratified ke 960 baris pelatihan dan 240 baris pengujian. Simulasi ini memungkinkan verifikasi prosedur namun dapat membuat pola klasifikasi lebih sederhana dibanding teks organik.

2.3 Prapemrosesan dan Representasi Fitur
Cleaning menghapus elemen teknis seperti URL, nama pengguna, tanda baca dan simbol yang tidak diperlukan; case folding mengubah huruf menjadi kecil. Teks selanjutnya dipetakan ke unigram dan bigram dengan TF-IDF. Vocabulary dan statistik IDF perlu dipelajari hanya dari bagian training, kemudian digunakan untuk mentransformasikan data testing. Dengan demikian, informasi dari data pengujian tidak bocor ke tahap pembentukan fitur. Pada validasi silang, preprocessing yang mempelajari parameter juga harus diulang di dalam setiap fold.

2.4 Pemodelan Logistic Regression
Model linier memetakan vektor fitur x menjadi skor $z = \beta_0 + \Sigma\beta_i x_i$, kemudian probabilitas kelas positif dihitung melalui $p = 1/(1 + \exp(-z))$. Ambang klasifikasi yang digunakan adalah 0,5. Tanda koefisien memberikan arah asosiasi fitur terhadap kelas positif berdasarkan parameter model. Karena kelas ditentukan secara supervisi, kebenaran label dan kesesuaian definisi sentimen merupakan prasyarat penting untuk pemanfaatan model.

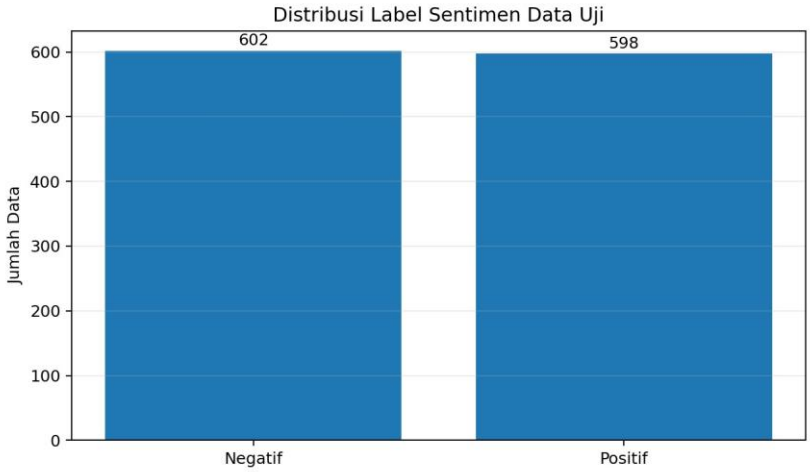
2.5 Pengujian dan Metrik
Evaluasi meliputi confusion matrix, accuracy, precision, recall, F1-score, serta 5-fold stratified cross-validation. Dalam pengujian ini kelas positif menjadi kelas target. Accuracy = (TP+TN)/(TP+TN+FP+FN), precision = TP/(TP+FP), recall = TP/(TP+FN), dan F1 = 2×precision×recall/(precision+recall). Kinerja model pada data simulasi harus dibedakan dari validasi pada data baru yang benar-benar dikumpulkan dari platform media sosial.

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi Data Simulasi
Setelah proses pembentukan dataset dan variasi label, diperoleh 598 teks positif dan 602 teks negatif. Komposisi yang hampir seimbang menyederhanakan evaluasi kelas, tetapi tidak menggambarkan proporsi sentimen nyata. Pembagian stratified dimaksudkan untuk menjaga keseimbangan label pada data pelatihan dan pengujian.

Tabel 1. Distribusi label pada data simulasi

Kelas	Jumlah	Persentase
Positif	598	49,83%
Negatif	602	50,17%
Jumlah	1.200	100%



Gambar 2. Distribusi kelas pada data simulasi

3.2 Hasil Preprocessing dan Pembentukan Fitur
Tahap pembersihan menghilangkan variasi karakter yang tidak informatif dan menghasilkan teks yang lebih seragam. Sebagai contoh, opini mengenai pengurangan pemborosan dinyatakan sebagai pola positif, sedangkan kekhawatiran terhadap pendidikan atau pelayanan dinyatakan sebagai pola negatif pada skenario pembentukan data. Setelah pembersihan, fitur unigram dan bigram memungkinkan model mengenali kata tunggal dan

Submitted: **28/09/2024**; Accepted: **25/11/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 15-20
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8137

kombinasi dua kata. Karena korpus bersifat sintetis, beberapa frasa kemungkinan terlalu berkaitan langsung dengan label yang ditentukan sebelumnya.

Tabel 2. Ilustrasi pola teks dalam data simulasi

Contoh teks simulasi	Kategori rancangan
Penghematan biaya seremonial merupakan langkah yang masuk akal	Positif
Kebijakan dapat memperbaiki disiplin fiskal	Positif
Pemotongan berisiko memperburuk pelaksanaan kegiatan	Negatif
Pemotongan berdampak pada layanan pendidikan	Negatif

3.3 Confusion Matrix dan Perhitungan Evaluasi

Pengujian 240 baris menghasilkan TN=110, FP=10, FN=7, dan TP=113. Dengan demikian sebanyak 223 prediksi benar dan 17 prediksi keliru. Struktur kesalahan menunjukkan jumlah false positive lebih tinggi daripada false negative, tetapi selisih kecil ini belum cukup untuk menyimpulkan kecenderungan model pada data media sosial nyata.

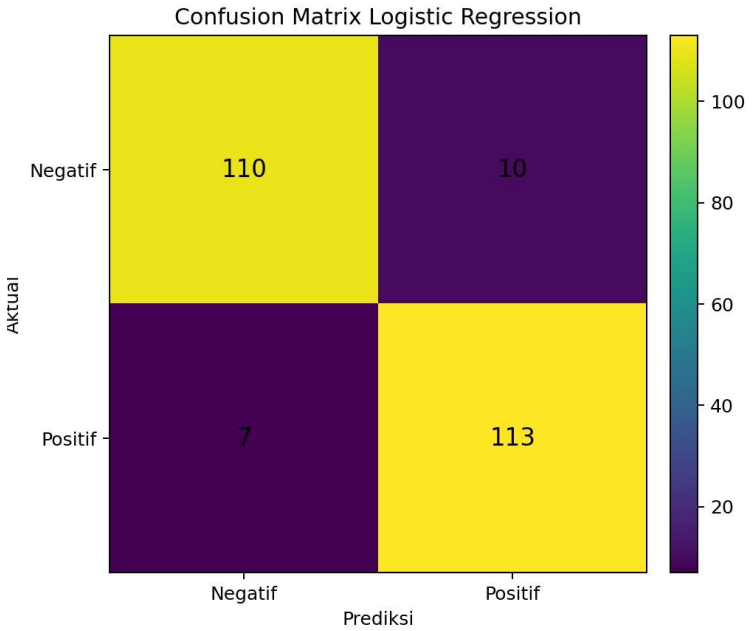
Tabel 3. Confusion matrix pada data testing simulasi

Aktual / Prediksi	Negatif	Positif
Negatif	110 (TN)	10 (FP)
Positif	7 (FN)	113 (TP)

Tabel 4. Ringkasan hasil evaluasi simulasi

Metrik	Nilai
Accuracy	0,9292 (92,92%)
Precision	0,9187 (91,87%)
Recall	0,9417 (94,17%)
F1-score	0,9300 (93,00%)
5-fold CV accuracy	0,9200 ± 0,0165
5-fold CV F1	0,9199 ± 0,0163

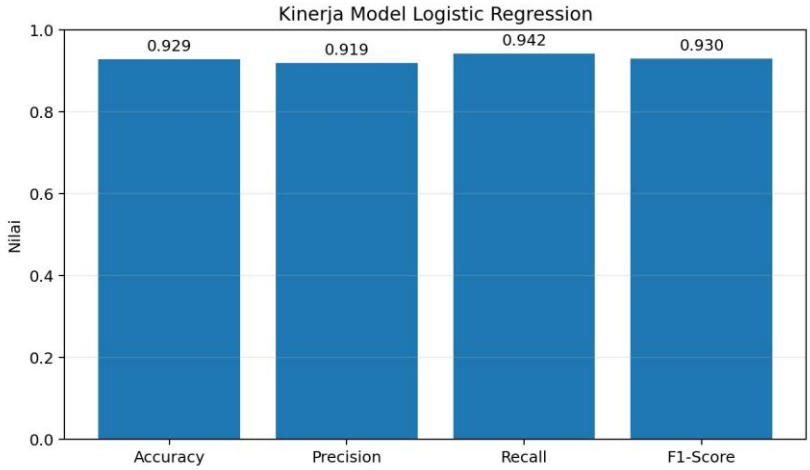
Nilai accuracy dihitung sebagai (110+113)/240 = 0,92917. Precision kelas positif adalah 113/(113+10)=0,91870, sedangkan recall 113/(113+7)=0,94167. Nilai F1 sekitar 0,930, konsisten dengan ringkasan laporan. Cross-validation dilaporkan sebagai pemeriksaan tambahan, tetapi konfigurasi ulangan, random seed, dan parameter pemodelan yang terperinci belum tersedia dalam dokumen sumber untuk replikasi penuh.



Gambar 3. Confusion matrix hasil pengujian

Submitted: **28/09/2024**; Accepted: **25/11/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 15-20
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8137



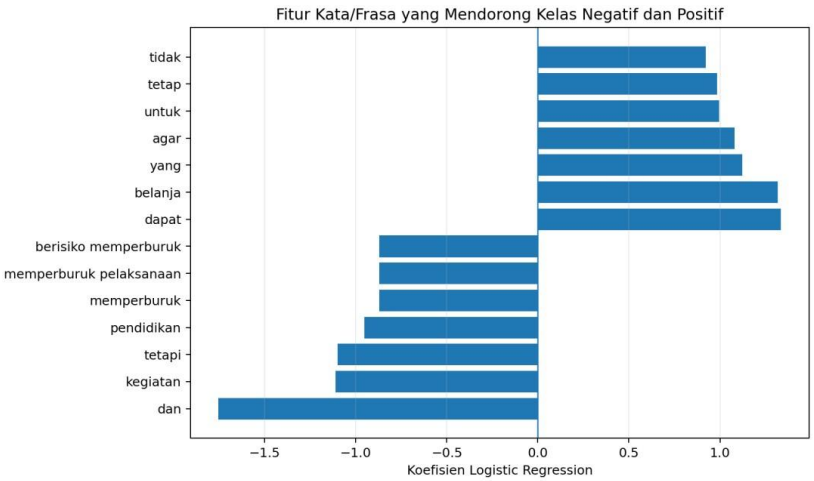
Gambar 4. Perbandingan metrik pada data pengujian

3.4 Interpretasi Koefisien

Fitur positif	Koefisien	Fitur negatif	Koefisien
dapat	1,335	dan	−1,753
belanja	1,318	kegiatan	−1,111
agar	1,080	pendidikan	−0,953
diprioritaskan untuk	0,795	memperburuk	−0,870

Tabel 5. Cuplikan fitur dengan bobot koefisien dari laporan

Fitur seperti “belanja” dan “pendidikan” mungkin mempunyai kaitan topikal dengan pembahasan kebijakan. Namun munculnya kata umum “dapat”, “agar”, dan “dan” di antara koefisien terbesar memperlihatkan bahwa bobot model tidak otomatis sama dengan kata penentu sentimen yang dapat ditafsirkan secara substantif. Diperlukan analisis kesalahan, pemeriksaan stopword, dan peninjauan n-gram berbasis konteks untuk menghindari interpretasi keliru.



Gambar 5. Ilustrasi koefisien fitur pada data simulasi

3.5 Pembahasan Kritis dan Perbandingan Literatur

Hasil teknis menunjukkan kesesuaian Logistic Regression dengan representasi TF-IDF pada korpus simulasi. Kajian Findawati et al. [3] telah memasukkan Logistic Regression dalam klasifikasi sentimen politik. Penelitian lain pada komentar bahasa Indonesia juga mendukung kegunaan kombinasi fitur TF-IDF dan model klasifikasi linier [8]–[10]. Namun perbandingan angka kinerja antarkajian tidak dapat diperlakukan sebagai eksperimen head-to-head karena sumber data, cara pelabelan, distribusi kelas, dan tata cara pembagian data berbeda.

Kesimpulan tentang opini masyarakat tidak dapat ditarik dari dataset buatan. Simulasi dimulai dengan kalimat bercorak positif dan negatif, sehingga model berpotensi mempelajari penanda yang sengaja dibangun dalam data.

Submitted: **28/09/2024**; Accepted: **25/11/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 15-20
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8137

Performa tinggi dengan demikian dapat mencerminkan kemudahan pola sintetis, bukan kemampuan menangani ujaran spontan yang mengandung bahasa tidak baku, komentar sarkastik, ambiguitas atau konteks politik.

Keterbatasan kedua adalah validitas label. Pada data aktual, persetujuan terhadap efisiensi tertentu dapat muncul bersama kritik terhadap dampak kebijakan pada sektor lain. Model dua kelas dapat menyederhanakan opini campuran. Karena itu perlu pedoman anotasi, minimal dua anotator, pelaporan kesepakatan, pemeriksaan ambiguitas, dan bila perlu penambahan kelas netral atau campuran sesuai pertanyaan penelitian.

Keterbatasan ketiga berkaitan dengan evaluasi. Pelaporan kinerja sebaiknya dilengkapi baseline mayoritas dan model pembanding, seperti Naive Bayes atau SVM, pada partisi yang identik. Pengujian lintas waktu dan lintas sumber juga dapat menilai perubahan kosakata. Pengumpulan data harus menerapkan ketentuan platform, penghilangan identitas pribadi, dokumentasi rentang tanggal, serta transparansi kriteria inklusi dan eksklusi.

Dari sisi praktik, model dapat berfungsi sebagai alat bantu triase atau ringkasan awal dalam penelitian komunikasi kebijakan. Hasil model tidak boleh digunakan untuk menyatakan tingkat dukungan penduduk tanpa desain sampling yang benar. Dengan batasan tersebut, artikel ini merupakan demonstrasi alur pemodelan yang dapat dikembangkan menjadi studi empiris setelah pengadaan dataset sebenarnya.

4. KESIMPULAN

Penelitian ini menyusun proses analisis sentimen dua kelas tentang kebijakan efisiensi anggaran pada periode awal pemerintahan menggunakan TF-IDF dan Logistic Regression. Tahapan meliputi pembersihan teks, ekstraksi unigram dan bigram, pembagian data stratifikasi, pelatihan model, evaluasi confusion matrix, dan interpretasi koefisien. Pada 1.200 teks simulasi, hasil uji mencapai accuracy 92,92%, precision 91,87%, recall 94,17%, dan F1-score 93,00%, dengan rata-rata accuracy lima lipatan 92,00%. Perhitungan tersebut menunjukkan bahwa alur komputasi dapat dijalankan dan dievaluasi secara kuantitatif pada data terkontrol. Akan tetapi, tidak ada data hasil pengambilan komentar media sosial aktual dalam berkas penelitian, sehingga angka-angka tersebut tidak membuktikan kemampuan model pada opini masyarakat sesungguhnya. Koefisien juga menunjukkan adanya fitur umum yang mendapat bobot besar, sehingga interpretasi konten perlu dilakukan dengan hati-hati. Validasi lanjutan memerlukan dokumentasi korpus dan periode 100 hari yang jelas, pelabelan independen dan reliabel, pembandingan baseline, uji kesalahan pada bahasa tidak baku, serta evaluasi pada data yang belum pernah dilihat model. Hanya setelah langkah-langkah itu dilakukan, peneliti dapat membuat kesimpulan empiris yang terbatas dan proporsional mengenai komentar pengguna media sosial terhadap kebijakan efisiensi anggaran.

REFERENCES

[1] T. Rosyida, H. P. Putro, and H. Wahyono, “Analisis Sentimen Terhadap Pilpres 2024 Berdasarkan Opini Dari Twitter Menggunakan Naive Bayes Dan SVM,” Teknokris, vol. 26, no. 1, pp. 23–32, 2023. doi: 10.61488/teknokris.v26i1.245.

[2] F. Salsabila and U. Budiyanto, “Implementasi Naive Bayes Classifier Terkait Pencalonan Ganjar Pranowo Sebagai Calon Presiden 2024 Di Twitter,” Seminar Nasional Mahasiswa Fakultas Teknologi Informasi, vol. 2, pp. 1–10, 2023.

[3] Y. Findawati et al., “Sentiment Analysis of Potential Presidential Candidates 2024: A Twitter-Based Study,” Academia Open, vol. 8, no. 1, 2023. doi: 10.21070/acopen.8.2023.7138.

[4] A. P. Nardilasari et al., “Analisis Sentimen Calon Presiden 2024 Menggunakan Algoritma SVM Pada Media Sosial Twitter,” JOINTECS, vol. 8, no. 1, 2023. doi: 10.31328/jointecs.v8i1.4265.

[5] N. S. P. Juana et al., “Analisis Sentimen Tanggapan Masyarakat Terhadap Calon Presiden 2024 Ridwan Kamil Menggunakan Metode Naive Bayes Classifier,” Jurnal Sistem Komputer dan Informatika, vol. 4, no. 4, 2023. doi: 10.30865/json.v4i4.6168.

[6] K. Arifin, S. Iskandar, and A. Idrus, “Klasifikasi Emosi Pengguna Twitter Terhadap Bakal Calon Presiden Pada Pemilu 2024 Menggunakan Algoritma Naive Bayes,” vol. 23, pp. 37–45, 2024.

[7] M. R. Amly, Y. Yusra, and M. Fikry, “Penerapan Metode Naive Bayes Classifier Pada Klasifikasi Sentimen Terhadap Anies Baswedan Sebagai Bakal Calon Presiden 2024,” Jurnal Sistem Komputer dan Informatika, vol. 4, no. 4, 2023. doi: 10.30865/json.v4i4.6214.

[8] W. Maharani and A. Z. Latifa, “Analyzing Public Sentiment on the Relocation of Indonesia’s Capital to Kalimantan as the Ibu Kota Nusantara Using Logistic Regression,” JUTIF, 2025. doi: 10.52436/1.jutif.2025.6.2.4230.

[9] V. B. Lestari and C. A. Hutagalung, “Evaluation of TF-IDF Extraction Techniques in Sentiment Analysis of Indonesian-Language Marketplaces Using SVM, Logistic Regression, and Naive Bayes,” J-KOMA, vol. 8, no. 1, pp. 36–44, 2025. doi: 10.21009/j-koma.v8i1.05.

[10] H. S. Mulyono and U. Saprudin, “Efektivitas Logistic Regression dalam Analisis Sentimen Berbahasa Indonesia pada Komentar YouTube tentang Isu Ketenagakerjaan,” JIMIK, vol. 6, no. 3, 2025. doi: 10.63447/jimik.v6i3.1481.

Submitted: **28/09/2024**; Accepted: **25/11/2024**; Published: **28/01/2025**