

## ANALISIS SENTIMEN PUBLIK TERHADAP POLEMIK DANA APBD MENGENDAP PADA KOMENTAR VIDEO YOUTUBE MENGGUNAKAN METODE NAÏVE BAYES

Muhamad Rijal Al Jauhari<sup>1</sup>, Bambang Irawan<sup>2</sup>, Willy Prihartono<sup>3</sup>, Fatihanursari Dikananda<sup>4</sup>.

Program Studi Teknik Informatika<sup>1,2,4</sup>  
Program Studi Komputerisasi Akuntansi<sup>3</sup>

STMIK IKMI Cirebon  
<https://ikmi.ac.id/page/18/?lang=de>  
rijalaljauhari@gmail.com

(\*) Corresponding Author : rijalaljauhari@gmail.com  
Published : 30 Januari 2026

**Abstract**—The development of social media and video-sharing platforms such as YouTube has made the comment section a space for the public to express opinions on various public issues. One issue that has attracted public attention is the controversy related to idle regional budget (APBD) funds involving Purbaya Yudhi Sadewa as the Minister of Finance of Indonesia and Dedi Mulyadi as the Governor of West Java. The diverse comments appearing on YouTube videos discussing this issue reflect various public perspectives that can be analyzed using sentiment analysis techniques. This study aims to analyze public sentiment toward the controversy and evaluate the performance of the Naïve Bayes method in classifying sentiments in YouTube comments. Data collection was carried out through web scraping using YT-DLP from several YouTube videos discussing the related issue. The collected comment data then underwent preprocessing stages including case folding, tokenization, stopword removal, and stemming. Sentiment labeling was performed using a lexicon-based approach to classify comments into positive, negative, and neutral categories. Furthermore, the classification process was conducted using the Naïve Bayes algorithm and evaluated using accuracy, precision, recall, and F1-score metrics. This study also considers the condition of imbalanced data by applying a random under-sampling technique to balance the class distribution before the model training process. The results of the analysis show that out of a total of 9,337 comments analyzed, public sentiment toward the controversy of idle APBD funds is dominated by negative sentiment, indicating a high level of criticism or dissatisfaction from the public regarding the issue. Meanwhile, neutral and positive sentiments appear in smaller proportions. The classification model using the Naïve Bayes method achieved an accuracy of 67.07%, indicating that the model is able to classify most comments into the appropriate sentiment categories. These results indicate that the Naïve Bayes method is sufficiently effective for sentiment analysis on YouTube comment data, particularly in identifying public opinion tendencies regarding public policy issues.

**Keywords:** sentiment analysis, Naïve Bayes, YouTube comments, public opinion, regional budget (APBD)

**Abstrak**—Perkembangan media sosial dan platform berbagi video seperti YouTube menjadikan ruang komentar sebagai sarana masyarakat untuk menyampaikan opini terhadap berbagai isu publik. Salah satu isu yang menjadi perhatian publik adalah polemik terkait dana APBD mengendap yang melibatkan Purbaya Yudhi Sadewa selaku Menteri Keuangan Indonesia dan Dedi Mulyadi yang menjabat sebagai Gubernur Jawa Barat. Beragamnya komentar yang muncul pada video YouTube terkait isu tersebut mencerminkan berbagai pandangan masyarakat yang dapat dianalisis menggunakan teknik analisis sentimen. Penelitian ini bertujuan untuk menganalisis sentimen publik terhadap polemik tersebut serta mengevaluasi kinerja metode *Naïve Bayes* dalam mengklasifikasikan sentimen komentar YouTube. Pengumpulan data dilakukan melalui teknik *web scraping* menggunakan YT-DLP pada beberapa video YouTube yang membahas isu terkait. Data komentar yang diperoleh kemudian melalui tahap *preprocessing* yang meliputi *case folding*, *tokenization*, *stopword removal*, dan *stemming*. Pelabelan sentimen dilakukan menggunakan pendekatan *lexicon-based* untuk mengelompokkan komentar ke dalam kategori positif, negatif, dan netral. Selanjutnya, proses klasifikasi dilakukan menggunakan algoritma *Naïve Bayes* dan dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Penelitian ini juga mempertimbangkan kondisi *imbalanced data* dengan menerapkan teknik *random under-sampling* untuk menyeimbangkan distribusi kelas sebelum

proses pelatihan model. Hasil analisis menunjukkan bahwa dari total 9.337 komentar yang dianalisis, sentimen publik terhadap polemik dana APBD mengendap didominasi oleh sentimen negatif, yang menunjukkan tingginya kritik atau ketidakpuasan masyarakat terhadap isu tersebut. Sementara itu, sentimen netral dan positif muncul dalam jumlah yang lebih sedikit. Model klasifikasi menggunakan metode naïve bayes menghasilkan tingkat akurasi sebesar 67,07%, yang menunjukkan bahwa model mampu mengklasifikasikan sebagian besar komentar ke dalam kategori sentimen yang sesuai. Hasil ini menunjukkan bahwa metode naïve bayes cukup efektif digunakan untuk analisis sentimen pada data komentar youtube, khususnya dalam mengidentifikasi kecenderungan opini publik terhadap isu kebijakan publik.

**Kata Kunci :** analisis sentimen, Naïve Bayes, komentar YouTube, opini publik, APBD

## INTRODUCTION

YouTube telah menjadi salah satu platform digital paling berpengaruh dalam pembentukan opini publik, terutama dalam isu-isu politik dan pemerintahan. Komentar pengguna di YouTube mencerminkan spektrum opini masyarakat yang luas dan sering kali menunjukkan pola polarisasi, misinformasi, dan bias ideologis. Dalam konteks ini, analisis sentimen terhadap komentar YouTube menjadi alat penting untuk memahami persepsi publik terhadap isu-isu kebijakan maupun tokoh politik.

[1] meneliti lebih dari 3,5 juta komentar berbahasa Inggris pada kanal berita dan kesehatan di YouTube selama pandemi COVID-19. Mereka menemukan bahwa misinformasi meningkat sekitar 0,4% per bulan dan bahwa komentar palsu mendapatkan lebih banyak *likes* serta *replies*. Studi tersebut juga menyoroti peran polarisasi afektif dalam penyebaran misinformasi, menggarisbawahi fungsi YouTube sebagai ruang wacana publik terkait isu pemerintahan dan kesehatan.

Dalam konteks politik internasional, [2] menganalisis 650 komentar pada video yang menampilkan Presiden Volodymyr Zelensky dan menemukan tingkat polarisasi yang tinggi, ditandai oleh komentar pro-/anti-Ukraina atau Rusia serta banyak ujaran kebencian. Temuan ini menunjukkan bahwa kolom komentar YouTube berfungsi sebagai arena bagi ekspresi opini publik mengenai isu politik.

[3] meneliti manajemen konten oleh *think tanks* Spanyol di YouTube dan menemukan bahwa lebih dari separuh video memiliki kurang dari sepuluh komentar atau bahkan menonaktifkan fitur komentar, yang menimbulkan pertanyaan mengenai representativitas opini publik di ruang komentar daring tersebut.

[4] melakukan studi besar dengan menganalisis 134 juta komentar lintas ideologi di YouTube. Mereka menemukan pola komunikasi yang asimetris: kelompok

konservatif cenderung berinteraksi dengan liberal, namun sebaliknya jarang terjadi. Hal ini memperlihatkan keterbatasan jangkauan percakapan lintas pandangan politik di YouTube.

[5] menggabungkan analisis sentimen dan analisis jaringan sosial untuk meneliti homogenitas opini pada isu hak seksual, jilbab, dan perubahan iklim. Mereka menemukan adanya homogenitas ideologis yang moderat, tetapi juga koneksi lintas ideologi yang signifikan, menunjukkan bahwa YouTube tetap menjadi ruang bagi interaksi sosial-politik yang dinamis.

Berdasarkan berbagai penelitian tersebut, dapat disimpulkan bahwa YouTube memiliki peran penting sebagai arena digital bagi opini publik terhadap isu pemerintahan dan politik. Namun, karakteristik interaksi pengguna seperti polarisasi, misinformasi, dan ketimpangan komunikasi antarideologi menunjukkan bahwa analisis sentimen diperlukan untuk memahami persepsi publik secara lebih sistematis dan berbasis data. Dalam konteks Indonesia, isu polemik dana APBD antara Purbaya dan Dedi Mulyadi menjadi relevan untuk diteliti melalui pendekatan serupa, guna menilai bagaimana masyarakat bereaksi dan membentuk opini melalui komentar di YouTube.

Dalam konteks Indonesia, dinamika opini publik di media sosial memiliki implikasi langsung terhadap persepsi masyarakat terhadap kebijakan pemerintah. Platform seperti YouTube menjadi ruang diskusi yang aktif dalam menanggapi isu-isu politik dan kebijakan publik. Oleh karena itu, penelitian ini menjadi penting sebagai upaya untuk menyediakan pendekatan analitis dalam memantau dan memahami kecenderungan sentimen publik secara digital, sehingga dapat mendukung transparansi kebijakan serta evaluasi respons masyarakat terhadap kebijakan pemerintah.

## MATERIALS AND METHODS

Tahapan penelitian ini mengikuti alur kerja analisis sentimen berbasis *machine learning*, yang disusun secara sistematis seperti pada Gambar 1 berikut:



Gambar 1. Alur Penelitian

Dataset penelitian diperoleh dari komentar publik pada video YouTube yang membahas polemik dana APBD mengendap antara Purbaya dan Dedi Mulyadi. Pengambilan data dilakukan menggunakan perangkat lunak yt-dlp untuk mengekstraksi komentar beserta metadata seperti ID komentar, ID video, tanggal unggah komentar, jumlah likes, serta isi teks komentar. Video yang dipilih harus memenuhi beberapa kriteria, yaitu relevan dengan topik pemerintahan daerah atau APBD, memiliki minimal 500 komentar publik, serta komentar dapat diakses secara terbuka. Untuk menjaga kualitas data, komentar yang bersifat spam atau tidak relevan dihapus pada tahap awal pengolahan data dengan tetap memperhatikan etika penelitian dan penggunaan data publik.

Setelah proses pengumpulan data, dilakukan tahap preprocessing untuk mengubah teks mentah menjadi data yang bersih dan siap dianalisis. Tahapan preprocessing meliputi case folding untuk mengubah seluruh teks menjadi huruf kecil, cleaning untuk menghapus tanda baca, URL, emoji, angka, dan simbol non-alfabet, stop-word removal untuk menghilangkan kata umum yang tidak memiliki kontribusi terhadap makna sentimen, normalization untuk mengubah kata tidak baku menjadi bentuk formal, serta stemming menggunakan library Sastrawi untuk mengembalikan kata ke bentuk dasar. Tahapan ini bertujuan meningkatkan kualitas representasi teks sehingga model klasifikasi dapat bekerja lebih optimal.

Setelah preprocessing, dilakukan pelabelan sentimen terhadap komentar yang telah dibersihkan. Pelabelan dilakukan secara otomatis menggunakan pendekatan berbasis leksikon, di mana setiap komentar diberikan skor sentimen berdasarkan kamus kata yang memiliki nilai polaritas tertentu. Skor total diperoleh dari penjumlahan nilai polaritas setiap kata dalam komentar. Berdasarkan nilai tersebut, komentar diklasifikasikan ke dalam tiga kategori sentimen, yaitu positif apabila skor lebih dari nol, negatif apabila skor kurang dari nol, dan netral apabila skor sama dengan nol. Pendekatan ini memungkinkan proses pelabelan data dalam jumlah besar secara efisien, meskipun memiliki keterbatasan dalam memahami konteks kalimat, ironi, atau sarkasme.

Selanjutnya, dilakukan ekstraksi fitur menggunakan metode Term Frequency–Inverse Document Frequency (TF–IDF) untuk mengubah teks menjadi representasi numerik. Metode ini memberikan bobot pada setiap kata berdasarkan frekuensi kemunculannya dalam suatu dokumen dan tingkat kelangkaannya di seluruh dokumen. Proses ini menghasilkan matriks dua dimensi yang merepresentasikan setiap komentar sebagai vektor numerik, yang kemudian digunakan sebagai input pada algoritma klasifikasi.

Model klasifikasi yang digunakan dalam penelitian ini adalah Multinomial Naïve Bayes, karena metode ini efektif untuk data teks berdimensi tinggi dan berbasis frekuensi kata. Proses klasifikasi meliputi pembentukan matriks TF–IDF, pelatihan model menggunakan data berlabel sentimen, serta proses prediksi menggunakan probabilitas posterior dengan penerapan Laplace smoothing untuk menghindari probabilitas nol. Dataset kemudian dibagi menjadi data pelatihan dan data pengujian menggunakan skema train–test split 80:20.

Untuk menilai performa model, dilakukan evaluasi menggunakan beberapa metrik, yaitu accuracy, precision, recall, dan F1-score. Selain itu, diterapkan k-fold cross-validation (k=5) untuk memastikan stabilitas model dan mengurangi risiko overfitting. Pendekatan evaluasi ini digunakan untuk memastikan bahwa model mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.

Penelitian ini didukung oleh beberapa alat dan bahan penelitian yang terdiri dari perangkat keras dan perangkat lunak. Perangkat keras yang digunakan berupa komputer dengan spesifikasi minimal prosesor Ryzen 5, RAM 8 GB, penyimpanan SSD 256 GB, dan sistem operasi Windows 10. Sementara itu, perangkat lunak yang digunakan meliputi Python sebagai bahasa pemrograman utama, Jupyter Notebook atau Google Colab sebagai lingkungan eksperimen, serta beberapa library seperti pandas, numpy, scikit-learn, nltk, dan Sastrawi untuk pengolahan data dan pemodelan machine learning. Selain itu, matplotlib dan seaborn digunakan untuk visualisasi hasil analisis. Seluruh perangkat lunak yang digunakan bersifat open-source sehingga mendukung proses penelitian yang transparan dan dapat direplikasi.

## RESULTS AND DISCUSSION

Pada tahap ini dilakukan proses pemodelan menggunakan algoritma Multinomial Naive Bayes (MNB) serta evaluasi kinerjanya dalam melakukan klasifikasi sentimen pada komentar YouTube. Proses pemodelan dilakukan setelah seluruh data melalui tahapan preprocessing dan ekstraksi fitur TF-IDF, sehingga model menerima input berupa representasi vektor n-gram.

Berikut adalah kode utama yang digunakan sebagai implementasi tahap pemodelan baseline:

```

from sklearn.model_selection import train_test_split
from sklearn.naive_bayes import MultinomialNB
from sklearn.metrics import classification_report, accuracy_score, confusion_matrix
import matplotlib.pyplot as plt
import seaborn as sns
import pandas as pd

print("\n--- [TAHAP 5.1] Memulai Pemodelan MNB Awal (Alpha default=1.0) ---")

# Ambil data dari tahap sebelumnya (X_global, Y_global diasumsikan ada)
try:
    X = X_global
    Y = Y_global
except NameError:
    print("FATAL ERROR: Harap jalankan TAHAP 4.1 terlebih dahulu.")
    raise

# 1. Pembagian Data
X_train, X_test, Y_train, Y_test = train_test_split(
    X,
    Y,
    test_size=0.2,
    random_state=42,
    stratify=Y
)

# **PERBAIKAN KRISTAL:** Simpan SEMUA data split secara global untuk TAHAP 5.2
global X_train_global, Y_train_global, X_test_global, Y_test_global
X_train_global = X_train
Y_train_global = Y_train
X_test_global = X_test
Y_test_global = Y_test

# 2. Inisiasi dan Pelatihan Model
mnb_initial = MultinomialNB(alpha=1.0)
mnb_initial.fit(X_train, Y_train)
Y_pred_initial = mnb_initial.predict(X_test)

# 3. Evaluasi Model
accuracy_initial = accuracy_score(Y_test, Y_pred_initial)
report_initial = classification_report(Y_test, Y_pred_initial)

print("\n--- [OUTPUT LAPORAN] Hasil Evaluasi MNB Awal ---")
print(f"Akurasi Keseluruhan: {accuracy_initial * 100:.2f}%")

```

Gambar 2 pemodelan *Naive Bayes*

Kode dimulai dengan pemanggilan beberapa pustaka inti yang dibutuhkan, seperti *train\_test\_split* untuk pembagian dataset, *MultinomialNB* untuk pemodelan Naive Bayes, serta metrik evaluasi seperti *accuracy\_score* dan *classification\_report*. Library *matplotlib* dan *seaborn* juga disiapkan untuk kebutuhan visualisasi apabila diperlukan di tahap lanjutan.

Langkah pertama dalam kode adalah pengambilan data fitur dan label dari variabel global yang dihasilkan pada tahap sebelumnya, yakni *X\_global* dan *Y\_global*. Kedua variabel ini memuat representasi data komentar dalam bentuk matriks TF-IDF serta label sentimen hasil pelabelan *lexicon*. Struktur ini memastikan bahwa model menerima input data yang sudah bersih, terstandarisasi, dan siap digunakan dalam proses pembelajaran.

Selanjutnya dilakukan pembagian data menjadi *data latih* dan *data uji* menggunakan fungsi *train\_test\_split*. Pembagian dilakukan dengan rasio 80% data digunakan untuk pelatihan dan 20% sisanya untuk pengujian. Fungsi *stratify=Y* digunakan untuk menjaga distribusi kelas agar tetap seimbang pada kedua subset data. Hal ini penting mengingat analisis sentimen sering kali memiliki distribusi kelas yang tidak merata. Selain itu, nilai *random\_state=42* digunakan agar proses pembagian bersifat deterministik, sehingga hasil penelitian dapat direplikasi dengan konsisten.

Setelah pembagian data selesai, seluruh variabel pembagian disimpan kembali dalam bentuk variabel global baru (*X\_train\_global*, *Y\_train\_global*, *X\_test\_global*, *Y\_test\_global*). Penyimpanan ini sangat penting karena pembagian dataset yang sama digunakan kembali pada tahap tuning model pada bagian berikutnya (Tahap 5.2), sehingga konsistensi eksperimen tetap terjaga.

Model baseline MNB kemudian diinisialisasi menggunakan parameter  $\alpha = 1.0$ , yaitu nilai default dari teknik *Laplace smoothing* yang berfungsi untuk mencegah masalah probabilitas nol ketika suatu kata tidak muncul pada salah satu kelas sentimen. Model kemudian dilatih melalui fungsi *.fit(X\_train, Y\_train)*, yang memungkinkan Naive Bayes mempelajari pola distribusi kata berdasarkan karakteristik fitur TF-IDF.

Setelah proses pelatihan selesai, model digunakan untuk memprediksi sentimen komentar pada data uji melalui fungsi *.predict(X\_test)*. Hasil prediksi ini kemudian dibandingkan dengan label sebenarnya untuk mendapatkan nilai evaluasi.

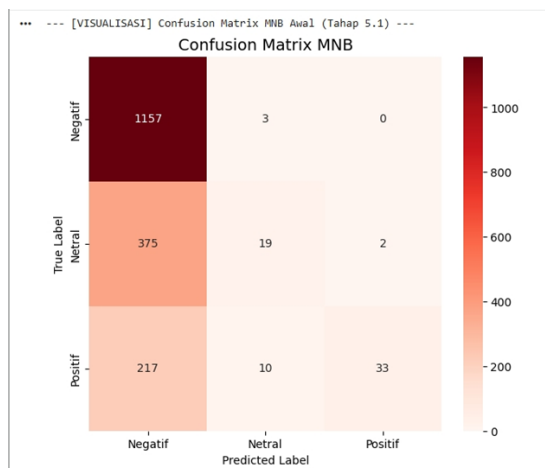
Evaluasi model dilakukan dengan menghitung akurasi sebagai ukuran proporsi prediksi yang benar dibandingkan total data. Selain akurasi, kode juga menghasilkan *classification report* yang meliputi metrik *precision*, *recall*, dan *F1-score* untuk masing-masing kelas (positif, negatif, dan netral). Penggunaan *classification report* memberikan gambaran yang lebih komprehensif mengenai performa model, terutama pada konteks data dengan distribusi kelas tidak merata.

Secara keseluruhan, kode tahapan ini menghasilkan gambaran performa awal algoritma *Multinomial Naive Bayes* sebelum dilakukan teknik penyempurnaan model seperti Random Under-Sampling atau tuning hyperparameter. Hasil baseline ini menjadi dasar pembandingan untuk

menilai apakah peningkatan performa terjadi pada tahap pemodelan berikutnya.

Tahap visualisasi dilaksanakan menggunakan *heatmap* dari pustaka *seaborn*. Matriks ditampilkan dengan anotasi angka (*annot=True*) untuk memperlihatkan nilai frekuensi secara langsung pada masing-masing sel. Skema warna *Reds* digunakan agar berbeda dari visualisasi model final pada tahap selanjutnya. Selain itu, label sumbu X dan Y diberikan untuk menunjukkan hubungan antara *true label* dan *predicted label*, sedangkan judul grafik membantu memberikan konteks terhadap visualisasi yang dihasilkan.

Dengan visualisasi ini peneliti dapat menganalisis kecenderungan model, misalnya apakah model lebih sering salah dalam membedakan sentimen negatif dan netral, atau apakah kelas tertentu mengalami dominasi prediksi sehingga menyebabkan ketidakseimbangan performa.



Gambar 3 confusion matrix MNB

Confusion matrix pada Tahap ini menunjukkan bahwa model MNB awal memiliki kecenderungan kuat untuk mengklasifikasikan komentar ke dalam kelas negatif. Hal ini terlihat dari tingginya jumlah prediksi benar pada kelas negatif (1.157), namun di sisi lain sebagian besar data netral (375) dan positif (217) salah diprediksi sebagai negatif. Jumlah prediksi benar pada kelas netral (19) dan positif (33) sangat rendah, mengindikasikan lemahnya kemampuan model dalam membedakan kedua kelas tersebut. Temuan ini menegaskan bahwa model masih mengalami bias kelas dan membutuhkan perbaikan lebih lanjut pada tahap pemodelan berikutnya.

Pertama, kode melakukan pemanggilan kembali variabel global hasil dari Tahap 5.1, yaitu *X\_train\_global*, *Y\_train\_global*, *X\_test\_global*, dan *Y\_test\_global*. Pemanggilan ini memastikan konsistensi data yang digunakan antara model awal dan model yang telah diperbaiki, sehingga evaluasi performa dapat dibandingkan secara objektif. Validasi keberadaan variabel-variabel tersebut dilakukan melalui blok *try—except* untuk mencegah kesalahan eksekusi akibat ketidaksiapan data.

Tahap berikutnya adalah penerapan *Random Under-Sampling* (RUS) menggunakan kelas *RandomUnderSampler*. Teknik ini secara sengaja mengurangi jumlah sampel pada kelas mayoritas sehingga distribusi kelas pada data pelatihan menjadi lebih seimbang. Output menunjukkan jumlah sampel awal dan setelah proses RUS, memberikan gambaran objektif mengenai tingkat pengurangan sampel yang dilakukan. Penggunaan RUS menjadi relevan karena model baseline sebelumnya menunjukkan kecenderungan bias terhadap kelas mayoritas, yang mengakibatkan penurunan kinerja prediksi pada kelas minoritas.

Setelah data diseimbangkan, proses dilanjutkan dengan optimasi hiperparameter melalui *Grid Search*. Parameter yang dioptimalkan adalah nilai *alpha*, yaitu parameter smoothing pada *Multinomial Naïve Bayes* yang berfungsi mencegah probabilitas nol pada fitur yang tidak muncul dalam data. *Grid Search* menelusuri kombinasi parameter [0.1, 1.0, 5.0] menggunakan validasi silang (*cross-validation*) sebanyak tiga lipatan serta metrik evaluasi berupa *F1-weighted*. Pemilihan metrik ini tepat karena mempertimbangkan ketidakseimbangan kelas dan memberikan bobot sesuai proporsi kelas. Eksekusi dilakukan secara *serial* (*n\_jobs=1*) untuk menghindari kebutuhan memori berlebih pada lingkungan runtime.

Setelah parameter terbaik diperoleh, model final *mnf\_final\_rus* dibentuk dengan nilai *alpha* yang paling optimal. Model kemudian dilatih kembali menggunakan data yang telah diseimbangkan oleh RUS. Prediksi dilakukan terhadap data uji, dan performanya dievaluasi menggunakan akurasi keseluruhan serta *classification report* yang mencakup nilai *precision*, *recall*, dan *F1-score* untuk setiap kelas sentimen. Kode kemudian menghasilkan *confusion matrix* final yang menjadi representasi visual dari distribusi prediksi model, membantu memahami pola kesalahan model setelah optimasi.

Terakhir, model yang telah dioptimalkan disimpan dalam bentuk file .pkl menggunakan pustaka pickle. Penyimpanan model ini memungkinkan pemanggilan ulang tanpa perlu melakukan pelatihan ulang, sehingga efisiensi penggunaan model dapat ditingkatkan pada tahap implementasi atau pengujian lanjutan

Pada tahap ini dilakukan evaluasi terhadap model *Multinomial Naive Bayes* yang telah melalui proses *hyperparameter tuning* serta penyeimbangan data menggunakan *Random Under-Sampling (RUS)*. Proses tuning dilakukan terhadap parameter *smoothing alpha*, sedangkan RUS diterapkan untuk mengurangi dominasi kelas mayoritas pada data latih. Model yang telah terlatih kemudian diuji menggunakan data *testing* yang tidak digunakan selama proses pelatihan.

Hasil evaluasi ditampilkan melalui nilai akurasi keseluruhan, *classification report*, serta *confusion matrix*, yang secara keseluruhan memberikan gambaran mengenai kemampuan model dalam mengklasifikasikan tiga kategori sentimen, yaitu Negatif, Netral, dan Positif.

Akurasi Model Model menghasilkan akurasi sebesar 67.07%, yang menunjukkan bahwa model mampu melakukan prediksi dengan benar pada sekitar dua pertiga dari keseluruhan data uji. Nilai ini termasuk moderat, mengingat tantangan yang muncul dari ketidakseimbangan kelas serta karakteristik teks pendek seperti Tweet. Analisis Classification Report

Berdasarkan *classification report*, diketahui bahwa:

1. Kelas Negatif memiliki performa terbaik dengan *precision* sebesar 0.87, *recall* sebesar 0.74, dan *f1-score* sebesar 0.80. Hal ini menunjukkan bahwa model mampu mengenali karakteristik sentimen Negatif dengan baik.
2. Kelas Netral menunjukkan performa terendah dengan *precision* 0.42 dan *recall* 0.41. Rendahnya performa pada kelas ini disebabkan oleh sifat sentimen Netral yang cenderung ambigu dan sering tumpang tindih secara linguistik dengan kelas lain.
3. Kelas Positif memiliki *recall* yang tinggi (0.77), menandakan bahwa sebagian besar data Positif berhasil teridentifikasi. Namun, *precision* relatif

rendah (0.44), yang menunjukkan bahwa model menghasilkan cukup banyak *false positive*, yaitu data yang diprediksi Positif padahal sebenarnya bukan.

#### Analisis Confusion Matrix

Hasil *confusion matrix* menunjukkan bahwa:

1. Sebagian besar data Negatif diprediksi dengan benar (857 dari 1160), meskipun terdapat misprediksi ke kelas Netral dan Positif.
2. Kelas Netral mengalami tingkat kesalahan prediksi yang cukup tinggi, terutama dialihkan ke kelas Negatif dan Positif secara hampir seimbang.
3. Kelas Positif menunjukkan kinerja yang cukup baik dalam hal *recall*, namun masih terdapat kesalahan prediksi ke kelas Netral dan Negatif.

Pola kesalahan tersebut memperlihatkan bahwa meskipun RUS membantu meningkatkan kualitas prediksi pada kelas minoritas, karakteristik linguistik kelas Netral tetap menjadi tantangan terbesar bagi model.

## CONCLUSION

Penelitian ini membahas analisis sentimen publik terhadap polemik dana APBD mengendap antara Purbaya Yudhi Sadewa dan Dedi Mulyadi yang dianalisis melalui komentar pada video YouTube. YouTube dipilih sebagai sumber data karena kolom komentar pada platform tersebut menjadi ruang bagi masyarakat untuk menyampaikan opini, kritik, maupun dukungan terhadap isu politik dan kebijakan publik. Penelitian ini bertujuan untuk mengetahui kecenderungan sentimen masyarakat serta mengevaluasi kinerja algoritma Naïve Bayes dalam mengklasifikasikan sentimen komentar tersebut.

Metode penelitian yang digunakan adalah pendekatan kuantitatif eksperimental dengan memanfaatkan teknik text mining dan machine learning. Data komentar YouTube dikumpulkan melalui proses web scraping menggunakan perangkat lunak yt-dlp, kemudian dilakukan tahap preprocessing yang meliputi case folding, cleaning, stop-word removal, normalisasi kata, dan stemming. Setelah itu dilakukan pelabelan sentimen secara otomatis menggunakan pendekatan leksikon untuk mengklasifikasikan komentar ke dalam tiga

kategori, yaitu positif, negatif, dan netral. Selanjutnya teks diubah menjadi bentuk numerik menggunakan metode TF-IDF, kemudian diklasifikasikan menggunakan algoritma Multinomial Naïve Bayes.

Hasil penelitian menunjukkan bahwa dari 9.337 komentar YouTube yang dianalisis, sentimen publik terhadap polemik dana APBD mengendap didominasi oleh sentimen negatif, yang menunjukkan tingginya kritik atau ketidakpuasan masyarakat terhadap isu tersebut. Sementara itu, sentimen netral dan positif muncul dalam jumlah yang lebih sedikit. Model klasifikasi menggunakan metode Naïve Bayes menghasilkan akurasi sebesar 67,07%, yang menunjukkan bahwa metode ini cukup efektif dalam mengklasifikasikan sentimen pada data komentar YouTube.

#### REFERENCE

- [1] V. Suter, M. Shahrezaye, and M. Meckel, "COVID-19 induced misinformation on YouTube: An analysis of user commentary," *Frontiers in Political Science*, vol. 4, 2022, doi: 10.3389/fpos.2022.849763.
- [2] I. Dąbrowska, "Polarisation in comments under videos featuring Volodymyr Zelensky published on YouTube," *Polish Political Science Review*, vol. 12, no. 2, pp. 98–116, 2024, doi: 10.2478/ppsr-2024-0014.
- [3] V. Castillero-Ostio, "Content management on YouTube by Spanish think tanks," *Frontiers in Political Science*, vol. 7, 2025, doi: 10.3389/fpos.2025.1524867.
- [4] S. Wu and P. Resnick, "Cross-partisan discussions on YouTube: Conservatives talk to liberals but liberals don't talk to conservatives," *Proceedings of the ACM on Human-Computer Interaction*, vol. 5, no. CSCW1, pp. 1–25, 2021.
- [5] D. Röchert, G. Neubäumer, B. Ross, F. Brachten, and S. Stieglitz, "Opinion-based homogeneity on YouTube: Combining sentiment and social network analysis," *Computational Communication Research*, vol. 2, no. 1, pp. 81–108, 2020, doi: 10.5117/CCR2020.1.004.ROCH.