

## Analisis Sentimen Pengguna X Terhadap Distribusi Smart-TV Di Sekolah : Perbandingan Naïve Bayes & K-NN

Salman Ahmed Saladin Ivanza<sup>1</sup>, Moh. Bagus Aditiya Pratama<sup>2</sup>, Dwi Arman Prasetya<sup>3</sup>

<sup>123</sup>UPN “Veteran” Jawa Timur

<sup>123</sup>Surabaya, Indonesia

Email: <sup>1</sup>[23083010035@student.upnjatim.ac.id](mailto:23083010035@student.upnjatim.ac.id),

<sup>2</sup>[23083010025@student.upnjatim.ac.id](mailto:23083010025@student.upnjatim.ac.id), <sup>3</sup>[arman.prasetya.sada@upnjatim.ac.id](mailto:arman.prasetya.sada@upnjatim.ac.id)

### Abstract

*Social media is a widely used means of communication in Indonesia, one of which is X (Twitter). This platform allows users to share their opinions on various topics that can be processed for sentiment analysis. This study designed a system for classifying public sentiment into positive and negative categories using the Naïve Bayes and K-Nearest Neighbor (K-NN) methods with Term Frequency-Inverse Document Frequency (TF-IDF) feature weighting. The dataset consisted of 981 tweets related to the distribution of Smart TVs in schools in Indonesia, obtained from May 1 to October 25, 2025. The evaluation results show that the accuracy of Naïve Bayes is 80.72% and the accuracy of K-NN is 82.56%. Naïve Bayes has a precision of 0.76 and a recall of 0.44 in the positive class, as well as a precision of 0.83 and a recall of 0.95 in the negative class, with a macro average F1-Score of 0.72. K-NN had a precision of 0.79 and a recall of 0.44 in the positive class, as well as a precision of 0.83 and a recall of 0.96 in the negative class, with a macro average F1-Score of 0.73. Based on these results, K-NN provided better overall performance than Naïve Bayes.*

**Keywords:** K-Nearest Neighbor (K-NN); Naive Bayes; Sentiment Analysis; Social Media; Steamlit, TF-IDF

### Abstraksi

*Media sosial merupakan sarana komunikasi yang banyak digunakan di Indonesia, salah satunya X (Twitter). Platform ini memungkinkan pengguna membagikan opini mengenai berbagai topik yang dapat diolah untuk analisis sentimen. Penelitian ini merancang sistem klasifikasi sentimen publik ke dalam kategori positif dan negatif menggunakan metode Naïve Bayes dan K-Nearest Neighbor (K-NN) dengan pembobotan fitur Term Frequency-Inverse Document Frequency (TF-IDF). Dataset terdiri dari 981 tweet terkait distribusi Smart-TV di sekolah di Indonesia, yang diperoleh pada 1 Mei – 25 Oktober 2025. Hasil evaluasi menunjukkan akurasi Naïve Bayes sebesar 80.72% dan akurasi K-NN sebesar 82.56%. Naïve Bayes memiliki precision 0.76 dan recall 0.44 pada kelas positif, serta precision 0.83 dan recall 0.95 pada kelas negatif, dengan macro average F1-Score 0.72. K-NN memiliki precision 0.79 dan recall 0.44 pada kelas positif, serta precision 0.83 dan recall 0.96 pada kelas negatif, dengan macro average F1-Score 0.73. Berdasarkan hasil tersebut, K-NN memberikan performa keseluruhan yang lebih baik dibandingkan Naïve Bayes.*

**Kata Kunci:** Analisis Sentimen; K-Nearest Neighbor (K-NN); Media Sosial; Naïve Bayes, Steamlit, TF-IDF

## **1. PENDAHULUAN**

Fasilitas pendidikan di Indonesia masih menghadapi tantangan dibandingkan negara ASEAN seperti Singapura dan Jepang. Laporan ITU mencatat sekitar 19% sekolah belum memiliki koneksi internet, dengan disparitas regional yang signifikan [1]. Aini, Kurniawan, dan Sulistiyowati melaporkan bahwa 61.53% siswa SD berada di bawah standar minimum literasi membaca dan 46.67% di bawah standar numerasi dasar, menunjukkan keterbatasan infrastruktur dan kapasitas pengajaran [2]. Di tengah kondisi tersebut, perkembangan teknologi dan media sosial, khususnya X (Twitter), membuka ruang baru bagi masyarakat untuk menyampaikan opini melalui cuitan.

Platform X (Twitter) berperan sebagai ruang digital tempat masyarakat Indonesia berinteraksi dan menyebarkan informasi. Ribuan hingga jutaan tweet dibuat setiap hari, menjadikan platform ini sumber data penting untuk analisis opini publik, termasuk mengenai fasilitas pendidikan [3]. We Are Social melaporkan bahwa pada awal 2025 terdapat 25.2 juta pengguna X di Indonesia, atau 8.8% dari populasi [4]. Dengan volume data yang besar, X menjadi media strategis untuk mengamati persepsi masyarakat terhadap kebijakan seperti distribusi Smart-TV ke sekolah.

Pada September 2025, pemerintah merencanakan penyaluran 330 ribu Smart-TV ke sekolah berbagai jenjang sebagai upaya modernisasi sarana pembelajaran [5]. Smart-TV diharapkan mampu meningkatkan akses pendidikan daring, terutama di daerah terpencil. Untuk menganalisis tanggapan publik, digunakan metode analisis sentimen seperti Naïve Bayes dan K-Nearest Neighbor (K-NN) dengan pembobotan Term Frequency–Inverse Document Frequency (TF-IDF) [6]. Metode-metode ini terkenal efektif dalam klasifikasi teks dan analisis opini dari data teks media sosial.

Penelitian terdahulu menunjukkan efektivitas kedua metode tersebut. Dina, Haryanti, dan Haq melaporkan bahwa Naïve Bayes mencapai akurasi 71.55% dalam mengidentifikasi komentar negatif pada TikTok [7]. Sementara penelitian Afifi mengenai layanan internet PT Indosat TBK menemukan bahwa K-NN menghasilkan akurasi 81% dan mendeteksi lebih banyak sentimen negatif dibanding positif [8]. Namun, perbandingan langsung keduanya dalam konteks distribusi Smart-TV di sekolah Indonesia masih minim. Keduanya dipilih karena karakteristik masing-masing: Naïve Bayes sederhana dan cepat untuk dataset kecil, sedangkan K-NN mampu menangkap pola kompleks meski lebih mahal secara komputasi.

Analisis sentimen ini diharapkan memberikan gambaran jelas mengenai persepsi publik terhadap program distribusi Smart-TV dan menjadi bahan evaluasi bagi pembuat kebijakan. Penelitian ini juga diharapkan mendorong studi lanjutan mengenai analisis sentimen berbasis media sosial serta memperkuat strategi pengembangan fasilitas pendidikan digital yang adaptif dan inklusif. Dengan menemukan metode analisis yang paling sesuai, kebijakan pendidikan dapat lebih responsif dan berkelanjutan.

## 2. TINJAUAN PUSTAKA

### 2.1. Klasifikasi

Klasifikasi adalah metode utama *data mining* yang berfungsi untuk mengelompokkan data ke dalam kategori atau kelas tertentu. Pengelompokan ini didasarkan pada pola yang ditemukan dari data sampel, dan tujuannya adalah menentukan objek data sebagai salah satu kategori yang telah didefinisikan sebelumnya [9].

### 2.2. Naïve Bayes

Metode *Naïve Bayes* adalah algoritma klasifikasi probabilistik yang didasarkan pada Teorema Bayes dengan asumsi independensi antarfitur. Algoritma ini menentukan probabilitas posterior suatu kelas melalui perkalian probabilitas setiap atribut terhadap kelas tersebut [10]. Rumus manual *Naive Bayes* dapat dituliskan sebagai berikut.

$$P(y|x_1, x_2, \dots, x_n) = \frac{P(y) \cdot \prod_{i=1}^n P(x_i|y)}{P(x_1, x_2, \dots, x_n)} \quad (1)$$

Dimana:

$P(y|x_1, x_2, \dots, x_n)$  adalah prioritas posterior kelas  $y$  diberikan fitur  $x_1, \dots, x_n$ ;

$P(y)$  adalah probabilitas prior kelas  $y$ ;

$P(x_i|y)$  adalah probabilitas *likelihood* fitur ke- $i$  diberikan kelas  $y$ ;

$P(x_1, x_2, \dots, x_n)$  adalah probabilitas dari fitur-fitur tersebut secara keseluruhan sebagai normalisasi.

### 2.3. K-Nearest Neighbor (K-NN)

Metode *K-Nearest Neighbor (K-NN)* merupakan algoritma *supervised learning* yang digunakan untuk tugas klasifikasi dan regresi. Prinsip kerjanya adalah menentukan kelas data baru berdasarkan mayoritas dari sejumlah “ $k$ ” data terdekat, dengan kedekatan dihitung menggunakan metrik jarak seperti *Euclidean* [11]. Rumus manual *K-Nearest Neighbor* dapat dituliskan sebagai berikut.

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2)$$

Dimana:

$D$  adalah jarak antara dua titik data  $x$  dan  $y$

$n$  adalah jumlah dimensi fitur

$x_i$  dan  $y_i$  masing-masing adalah nilai fitur ke- $i$  dari titik  $x$  dan  $y$

### 2.4. Term Frequency-Inverse Document Frequency (TF-IDF)

Pembobotan *Term Frequency–Inverse Document Frequency (TF-IDF)* adalah teknik untuk menilai tingkat kepentingan sebuah kata dalam suatu dokumen dengan mempertimbangkan seluruh kumpulan dokumen. Metode ini menggabungkan frekuensi kemunculan kata dalam dokumen tertentu (TF) dan kebalikan frekuensi kemunculannya pada seluruh dokumen (IDF) [12]. TF-IDF menurunkan bobot kata yang terlalu sering

muncul di banyak dokumen dan menonjolkan kata yang lebih spesifik serta informatif. Rumus manual TF-IDF ditunjukkan sebagai berikut.

$$TF(t, d) = \frac{f_{t,d}}{\sum_k f_{k,d}}$$
$$IDF(t, D) = \log \frac{N}{1 + |\{d \in D: t \in d\}|}$$
$$TF-IDF(t, d, D) = TF(t, d) \times IDF(t, D) \quad (3)$$

Dimana:

- $t$  adalah *term* (kata) yang dianalisis
- $d$  adalah dokumen tertentu dalam korpus  $D$
- $f_{t,d}$  adalah frekuensi kemunculan *term*  $t$  di dokumen  $d$
- $\sum_k f_{k,d}$  adalah total frekuensi semua *term* di dokumen  $d$
- $N$  adalah jumlah total dokumen dalam korpus  $D$
- $|\{d \in D: t \in d\}|$  adalah jumlah dokumen yang mengandung *term*  $t$

## 2.5. Analisis Sentimen

Analisis Sentimen adalah teknik data science yang mengidentifikasi dan mengelompokkan opini dalam teks ke dalam kategori positif, negatif, atau netral. Metode ini memanfaatkan Pemrosesan Bahasa Alami (NLP) untuk mengekstrak dan memahami informasi subjektif, sehingga opini dapat diklasifikasikan secara otomatis berdasarkan sikap emosional dalam data teks [13].

## 2.6. Smart TV

*Smart TV* merupakan teknologi televisi yang mengintegrasikan fungsi TV konvensional dengan koneksi internet dan aplikasi interaktif. Perangkat ini dapat dimanfaatkan sebagai media pembelajaran untuk meningkatkan keterlibatan siswa dan menyediakan pengalaman belajar yang lebih autentik melalui interaksi dengan media yang merepresentasikan kondisi dunia nyata [14].

## 2.7. X (Twitter)

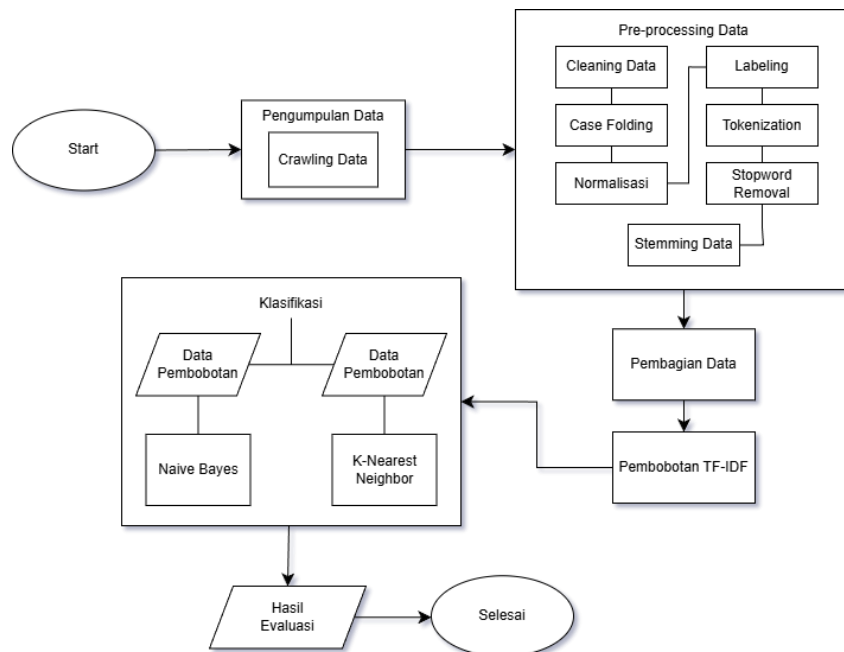
X (Twitter) adalah platform mikroblogging global yang diluncurkan pada Juli 2006. Platform ini memungkinkan pengguna berbagi pesan singkat dan ide, dengan jumlah pengguna aktif sekitar 557 juta pada tahun 2025. X menjadi sumber data penting untuk penelitian karena unggahannya bersifat real-time dan publik, sehingga mendukung analisis isi digital dan studi sentimen melalui API serta teknik data mining untuk memperoleh wawasan interaksi sosial berskala besar [15].

## 2.8. Natural Language Processing (NLP)

Natural Language Processing (NLP) berperan dalam analisis sentimen dengan mengotomatiskan identifikasi opini pada teks berbahasa alami. Proses ini mencakup tokenisasi, stopwords removal, dan stemming sebagai tahap persiapan sebelum klasifikasi. Pendekatan modern menggunakan model transformer seperti IndoBERT, yang mencapai akurasi 84.94% dalam analisis sentimen kebijakan publik dan unggul dalam menangani konteks serta variasi bahasa media sosial Indonesia melalui tokenisasi dan label mapping

husus [16]. NLP memungkinkan pemrosesan bahasa informal secara lebih efektif dan menghasilkan klasifikasi yang lebih akurat dibandingkan metode tradisional.

### 3. METODE PENELITIAN



Gambar 1. Flowchart Analisis

Berikut ini adalah penjelasan dari alur *flowchart* gambar 1 di atas:

a. Pengumpulan data (*Crawling Data*)

Proses pengambilan data dilakukan dengan teknik *crawling* menggunakan API untuk mengumpulkan tweet secara otomatis dari platform X (Twitter). Query pencarian dibentuk secara eksplisit dengan kata kunci dan operator “smart tv sekolah lang:id since:2025-05-01” dengan batas maksimum 1500 tweet, sehingga hanya tweet berbahasa indonesia yang dipublikasikan setelah 1 Mei 2025 yang diambil. Seluruh data bersumber dari akun publik, tanpa melibatkan tweet dari akun privat atau terbatas. Untuk menjaga anonimitas, tahap *preprocessing* menerapkan penghapusan seluruh teks *username* sehingga identitas pengguna tidak tercantum dalam data akhir.

b. *Pre-Processing*

*Pre-processing* dilakukan sebagai satu rangkaian utuh yang mencakup *Cleaning Data* untuk menghilangkan elemen tidak relevan seperti URL, tanda baca, simbol, emotikon, dan karakter non-alfabetik. Teks kemudian melalui *Case Folding* dengan mengubah seluruh huruf menjadi kecil, diikuti *Normalisasi* untuk menyelaraskan ejaan, singkatan, dan kata tidak baku. Setelah itu dilakukan *Labeling Data* secara semi-otomatis menggunakan model IndoBERT sebagai pemberi label awal yang kemudian diperiksa dan disesuaikan agar kategori sentimen akurat. Proses dilanjutkan dengan *Tokenization* untuk memecah kalimat menjadi token, *Stopword*

*Removal* untuk menghapus kata umum yang tidak memiliki kontribusi makna penting, dan diakhiri dengan *Stemming* yang mengubah kata ke bentuk dasar untuk mengurangi variasi dan kompleksitas data.

c. Pembagian Data

Dataset dibagi menjadi dua subset, yaitu data pelatihan dan data pengujian. Proporsi yang digunakan adalah 80 persen untuk data pelatihan agar model memperoleh informasi yang cukup selama proses pembelajaran, dan 20 persen untuk mengevaluasi performa model secara objektif.

d. Pembobotan *TF-IDF* (*Term Frequency-Inverse Document Frequency*)

Menghitung bobot setiap kata berdasarkan frekuensi kemunculan kata dalam dokumen dibandingkan dengan seluruh kumpulan dokumen. *TF-IDF* menonjolkan kata-kata yang informatif dan mengurangi pengaruh kata umum sehingga memaksimalkan efektivitas fitur untuk klasifikasi.

e. Klasifikasi Sentimen

1. *Naïve Bayes*

Algoritma ini menggunakan *Multinomial Naïve Bayes* dengan parameter *smoothing default*  $\alpha = 1$  sebagai *hyperparameter* utama. Implementasi dilakukan menggunakan *library* *scikit-learn*, dan proses prediksi sentimen dijalankan berdasarkan probabilitas kelas yang dihasilkan model dari fitur teks yang telah direpresentasikan sesuai tahap sebelumnya.

2. *K-Nearest Neighbor (K-NN)*

Model *K-NN* diimplementasikan dengan menentukan nilai *k* optimal melalui pencarian pada rentang  $k = 1 - 20$ , di mana pemilihan nilai terbaik didasarkan pada akurasi tertinggi. Metrik jarak yang digunakan adalah *cosine distance* dan seluruh pemodelan dilakukan menggunakan *library* *scikit-learn* untuk menentukan kelas sentimen berdasarkan mayoritas tetangga terdekat.

f. Hasil Evaluasi

Model dievaluasi menggunakan metrik performa seperti akurasi, *precision*, *recall*, dan *F1-score* untuk mengukur seberapa tepat model-model mengklasifikasikan sentimen tweet. Evaluasi ini memastikan kehandalan dan validitas hasil analisis sentimen yang diperoleh

## 4. HASIL DAN PEMBAHASAN

### 4.1. Pengumpulan Data

Data penelitian ini diperoleh dari jejaring sosial X (Twitter) melalui proses *scraping* untuk mengumpulkan tweet yang membahas topik serupa. Pengambilan data dilakukan terhadap tweet yang memuat kata kunci “smart TV sekolah”, menggunakan tool “*Tweet Harvest*” yang dikembangkan oleh Helmi Satria. Rentang waktu pengambilan data berlangsung dari 1 Mei hingga 25 Oktober 2025 dan menghasilkan 981 tweet terkait distribusi smart TV di Indonesia. Proses *scraping* dijalankan menggunakan pemrograman Python pada Google Colab, sebagaimana ditunjukkan pada gambar 2 berikut.

```
# Crawl Data
filename = 'smart-tv'
search_keyword = 'smart tv sekolah lang:id since:2025-05-01'
limit = 1500

Inpx -y tweet-harvest@2.6.1 -o "{filename}" -s "{search_keyword}" --tab "LATEST" -l {limit} --token {twitter_auth_token}

"Tweet Harvest [v2.6.1]"
Research by Helmi Satria
Use it for Educational Purposes only!

This script uses Chromium Browser to crawl data from Twitter with your Twitter auth token.
Please enter your Twitter auth token when prompted.

Note: Keep your access token secret! Don't share it with anyone else.
Note: This script only runs on your local device.

Opening twitter search page...

Found existing file ./tweets-data/smart-tv.csv, renaming to ./tweets-data/smart-tv.old.csv
-- Scrolling... (1) (2) (3)
Filling in keywords: smart tv sekolah lang:id since:2025-05-01
```

Gambar 2. Proses Scraping

Hasil dari *scraping* berupa data teks yang masih sangat mentah sehingga perlu adanya beberapa tahapan sebelum memasuki proses klasifikasi. Berikut gambar 3 adalah tampilan data tweet yang telah digabungkan menjadi dataset untuk penelitian ini.

```
import pandas as pd

# Specify the path to your CSV file
file_path = f"tweets-data/smart-tv.csv"

# Read the CSV file into a pandas DataFrame
df = pd.read_csv(file_path, delimiter=",")

# Display the DataFrame
display(df["full_text"])

full_text
0    Presiden Prabowo Subianto melanjutkan program ...
1    Disdik Batam Gas Digitalisasi Ratusan Sekolah ...
2    Pesan dari anak-anak di perbatasan Indonesia & ...
3    @WisanggeniLagi @newding30 @Ary_PrasKe2 @Bobb...
4    Knp yaa mereka suka bgf Nganggarin hal yg ga p...
```

Gambar 3. Hasil Scraping

## 4.2. Data Preprocessing

*Data preprocessing* adalah tahapan penyiapan data mentah menjadi data yang lebih siap untuk dianalisis lebih lanjut dengan memperbaiki format yang sesuai dengan kebutuhan analisis. Tabel 1 Berikut adalah hasil dari setiap tahapan dalam *preprocessing*.

Tabel 1. hasil dari setiap tahapan dalam *preprocessing*

Teks	Hasil <i>Cleaning</i>	Hasil <i>Case Folding</i>	Hasil Normalisasi
@txtdrimedia Jd smart tv di sekolah gunanya buat karaoke dan mesra2an	Jd smart tv di sekolah gunanya buat karaoke dan mesraan	jd smart tv di sekolah gunanya buat karaoke dan mesraan	jadi smart tv di sekolah gunanya buat karaoke dan mesraan
Hasil <i>Labeling</i>	Hasil <i>Tokenize</i>	Hasil <i>Stopword Removal</i>	Hasil <i>Stemming</i>
negative	['jadi', 'smart', 'tv', 'di', 'sekolah', 'gunanya', 'buat', 'karaoke', 'dan', 'mesraan']	['smart', 'tv', 'sekolah', 'gunanya', 'karaoke', 'mesraan']	smart tv sekolah guna karaoke mesra

### 4.3. Pembobotan TF-IDF

TF-IDF merupakan proses menghitung bobot setiap kata berdasarkan frekuensi kemunculan kata dalam dokumen dibandingkan dengan seluruh kumpulan dokumen sebelum memasuki tahapan *modeling*. Tabel 2 berikut adalah salah satu contoh hasil pembobotan TF-IDF pada DataFrame:


Tabel 2. Proses Pembobotan TF-IDF

Teks	Sentiment	Hasil Pembobotan TF-IDF
smart tv sekolah guna karaoke mesra	Negative	{'Positif': np.float64(7.311211449775725e-19) 'Negatif': np.float64(1.445624732350089e-16)}

### 4.4. Klasifikasi Sentimen

#### 4.4.1. Metode Naïve Bayes

Pada gambar 4 menunjukkan visualisasi distribusi kelas antara aktual dan prediksi di setiap kelas sentimen dari metode *Naïve Bayes*.



Gambar 4. Distribusi Hasil Klasifikasi Metode Naïve Bayes

Gambar 4 menunjukkan perbandingan distribusi antara jumlah data aktual dan prediksi model pada setiap kelas sentimen. Kelas negatif diprediksi sebanyak 173 dari 145 data aktual, sedangkan kelas positif hanya 22 dari 50 data aktual. Pola ini mengindikasikan bahwa model lebih cenderung mengklasifikasikan teks sebagai negatif, sehingga recall kelas negatif tinggi sementara banyak data positif salah terdeteksi sebagai negatif. Untuk mengatasi ketidakseimbangan tersebut, diperlukan tahap mitigasi data guna menyeimbangkan distribusi kelas agar bias dapat diminimalkan. Proses ini dapat dilakukan melalui beberapa metode, seperti oversampling (SMOTE), undersampling, cost-sensitive learning, dan threshold tuning. Tabel 3 berikut merupakan hasil mitigasi yang diperoleh.

Tabel 3. Hasil Mitigasi Data Metode Naïve Bayes

Metode	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Baseline	80.51	82.97	80.51	76.11
Oversampling (SMOTE)	78.97	79.11	78.97	79.04



Metode	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Undersampling	75.38	77.14	75.38	76.06
Cost-Sensitive	78.46	78.75	78.46	78.60
Threshold Tuning (0.30)	82.05	81.27	82.05	80.27

Tabel 4. Confusion Matrix Metode Naïve Bayes

Metode	True Negative (TN)	False Positive (FP)	False Negative (FN)	True Positive (TP)
Baseline	144	1	37	13
Oversampling (SMOTE)	124	21	20	30
Undersampling	116	29	19	31
Cost-Sensitive	123	22	20	30
Threshold Tuning (0.30)	138	7	28	22

Tabel 3 dan 4 menampilkan hasil confusion matrix dan metrik evaluasi dari proses mitigasi data. Metode Baseline memperoleh Accuracy 80.51%, Precision 82.97%, Recall 80.51%, dan F1-Score 76.11%, dengan kinerja baik pada kelas negatif namun masih lemah dalam mendeteksi kelas positif. Metode Oversampling (SMOTE) mencapai Accuracy 78.97%, dengan penurunan akurasi namun peningkatan F1-Score yang menunjukkan deteksi dua kelas lebih seimbang. Metode Undersampling menghasilkan Accuracy 75.38%, menurun karena berkurangnya informasi pada kelas negatif. Metode Cost-Sensitive memperoleh Accuracy 78.46%, lebih hati-hati terhadap kelas minoritas tetapi belum optimal. Metode Threshold Tuning pada nilai 0.30 memberikan Accuracy 82.05% dan menunjukkan peningkatan keseimbangan deteksi antar kelas dengan tetap menjaga performa keseluruhan. Oleh karena itu, metode terbaik ditetapkan pada Threshold Tuning karena memberikan kombinasi metrik tertinggi dan meningkatkan kemampuan model dalam mengenali kelas minoritas tanpa menurunkan akurasi secara signifikan.

Tabel 5. Hasil Klasifikasi Metode Naïve Bayes


Teks	Actual	Predicted
program smart tv untuk ribu sekolah anggaran rp t bertujuan tingkatkan akses pendidikan di daerah terpencil menurut pemerintah prabowo belum ada bukti resmi harga kali lipat harga pasar smart tv hisense sekitar rp jutaanit kemiskinan memang tantangan besar bps	positif	negatif
dulu aku sekolah cuma pakai buku lusuh sekarang anakanak sudah pakai smart tv bangga banget	positif	negatif
video viral menunjukkan oknum guru di sdn ciodeng menggunakan smart tv donasi presiden prabowo untuk karaoke selama jam sekolah tv ini bagian dari program bantuan unit untuk pendidikan netizen soroti potensi pelanggaran pp no hingga sept belum ada	negatif	positif

Tabel 5 memperlihatkan perbedaan antara label asli dan prediksi, dengan kesalahan yang muncul pada teks bermakna ganda atau ber konteks ambigu. Beberapa kalimat positif terbaca negatif karena model menafsirkan kata seperti kritik atau proyek sebagai penanda negatif. Pada kalimat pertama, model gagal membaca nuansa campuran antara pujian dan kritik. Pada kalimat kedua, kata lusuh memicu penilaian negatif meski terdapat sarkasme. Pada kalimat ketiga, ironi pada frasa donasi presiden dan program

bantuan justru diprediksi positif. Temuan ini menunjukkan model masih kesulitan memahami ironi, makna halus, dan konteks campuran dalam Bahasa Indonesia.

#### 4.4.2. Metode K-Nearest Neighbor

Pada gambar 5 menunjukkan visualisasi distribusi kelas antara aktual dan prediksi di setiap kelas sentimen dari metode *K-Nearest Neighbor*.



Gambar 5. Distribusi Hasil Klasifikasi Metode *K-Nearest Neighbor*

Gambar 5 menunjukkan perbandingan jumlah data aktual dan hasil prediksi model pada setiap kelas. Kelas negatif diprediksi sebanyak 167 dari 145 data aktual, sedangkan kelas positif hanya 28 dari 50 data aktual. Pola ini menegaskan bahwa model lebih cenderung mengklasifikasikan teks sebagai negatif, sehingga recall pada kelas negatif tinggi sementara banyak data positif salah terdeteksi sebagai negatif. Untuk mengatasi ketidakseimbangan tersebut, diperlukan tahap mitigasi data guna menyeimbangkan distribusi kelas. Proses ini dapat dilakukan menggunakan beberapa metode, yaitu oversampling (SMOTE), undersampling, cost-sensitive learning, dan threshold tuning. Berikut merupakan hasil mitigasi yang diperoleh.

Tabel 6. Hasil Mitigasi Data Metode K-NN

Metode	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Baseline	82.56	82.04	82.56	80.72
Oversampling (SMOTE)	62.05	72.86	62.05	74.46
Undersampling	69.23	74.39	69.23	70.82
Cost-Sensitive	62.56	73.07	62.56	64.93
Threshold Tuning (0.30)	77.95	78.77	77.95	72.21

Tabel 7. Confusion Matrix Metode K-NN

Metode	True Negative (TN)	False Positive (FP)	False Negative (FN)	True Positive (TP)
Baseline	139	6	28	22
Oversampling (SMOTE)	86	59	15	35
Undersampling	103	42	18	32
Cost-Sensitive	87	58	15	35
Threshold Tuning (0.80)	143	2	41	9

Tabel 6 dan 7 menunjukkan hasil confusion matrix dan metrik evaluasi dari berbagai teknik mitigasi. Metode Baseline memberikan hasil paling seimbang dengan Accuracy 82.56%, Precision 82.04%, Recall 82.56%, dan F1-Score 80.72%, meskipun masih cenderung bias ke kelas mayoritas. Oversampling (SMOTE) meningkatkan sensitivitas kelas positif tetapi menurunkan akurasi menjadi 62.05% karena meningkatnya kesalahan prediksi. Undersampling menghasilkan Accuracy 69.23% namun menghilangkan banyak informasi dari kelas negatif. Cost-Sensitive mencapai Accuracy 62.56% dengan peningkatan kehati-hatian terhadap kelas positif, tetapi belum stabil. Threshold Tuning menghasilkan Accuracy 77.95% dan menekan false positive, namun semakin banyak data positif yang tidak terdeteksi. Secara keseluruhan, Baseline menjadi metode paling efektif karena mempertahankan distribusi data asli dan menjaga performa model tetap seimbang tanpa kehilangan informasi penting.

Tabel 8. Hasil Klasifikasi Metode K-Nearest Neighbor

Teks	Actual	Predicted
mengapa repotrepot menaikkan gaji guru kalau kita bisa membagikan smart tv ke sekolah toh guru hanya pelengkap dekorasi ruang kelas pendidikan bukan soal kualitas pengajar tapi seberapa mahal alat elektronik yang dipajang di ruang kelas	positif	negatif
ya rencana distribusi smart tv ke sekolah bisa bermanfaat untuk pendidikan jarak jauh dan akses materi berkualitas di daerah terpencil namun efektivitasnya tergantung infrastruktur seperti internet listrik dan pelatihan guru ada kritik bahwa prioritas seharusnya	negatif	positif
jangan selalu berburuk sangka kalau menunggu semuanya sempurna semua program tidak akan berjalan smart tv untuk sekolah juga tidak selesai di tahun ini semua dikerjakan secara bertahap jadi masih ada waktu sambil memperbaiki sekolah yang rusak	positif	negatif

Tabel 8 menunjukkan bahwa model K-NN masih kesulitan menangani kalimat yang memuat ironi, sarkasme, atau makna ganda. Kalimat yang tampak positif namun sebenarnya merupakan kritik tajam sering diprediksi sebagai sentimen positif, sementara pernyataan informatif yang mengandung evaluasi negatif kerap terbaca netral atau positif karena struktur bahasanya yang halus. Ajakan yang bermakna dukungan pun dapat salah dipahami akibat kemunculan kata bernada negatif di dalamnya. Kekeliruan ini terutama disebabkan oleh ketergantungan model pada pola kata permukaan sehingga tidak mampu menangkap nuansa pragmatik dan isyarat implisit dalam bahasa pengguna.

#### 4.5. Hasil Evaluasi Model

Pada tabel 9 dan 10 menunjukkan *Classification Report Naïve Bayes* dan *K-Nearest Neighbor* dimana terdapat nilai evaluasi kinerja model setiap kelas sentimen, seperti *Precision*, *Recall*, dan *F-1 Score*.

Tabel 9. Classification Report Naïve Bayes

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Positif	0.76	0.44	0.56	50
Negatif	0.83	0.95	0.89	145

	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>	<b>Support</b>
<i>Accuracy</i>			0.82	195
<i>Macro AVG</i>	0.79	0.70	0.72	195
<i>Weighted AVG</i>	0.81	0.82	0.80	195

Tabel 10. Classification Report K-Nearest Neighbor

	<b>Precision</b>	<b>Recall</b>	<b>F1-Score</b>	<b>Support</b>
Positif	0.79	0.44	0.56	50
Negatif	0.83	0.96	0.89	145
<i>Accuracy</i>			0.83	195
<i>Macro AVG</i>	0.81	0.70	0.73	195
<i>Weighted AVG</i>	0.82	0.83	0.81S	195

Berdasarkan Tabel 9 dan Tabel 10, dua metode klasifikasi sentiment yaitu *Naïve Bayes* dan *K-Nearest Neighbor* (*K-NN*) menunjukkan hasil yang baik, tetapi memiliki karakteristik berbeda. Metode *Naïve Bayes* memiliki akurasi 82% dengan *precision* tinggi pada kelas negatif (0.83) dan *recall* tinggi (0.95) yang berarti model lebih baik dalam mengklasifikasikan kelas negatif dibandingkan dengan kelas positif yang memiliki nilai *precision* cukup tinggi (0.76) dan *recall* yang sangat rendah (0.44).

*K-NN* menunjukkan akurasi sedikit lebih tinggi, yaitu 83%, dengan keseimbangan antara *precision* dan *recall* di kedua kelas. *Precision* untuk kelas positif adalah 0.79 dan *recall* 0.44, sementara kelas negatif memiliki *precision* 0.83 dan *recall* 0.96. *Macro average F1-Score* untuk *Naïve Bayes* adalah 0.72, dan untuk *K-NN* adalah 0.73, menunjukkan *K-NN* lebih stabil antar kelas. Secara keseluruhan, *K-NN* lebih baik dalam menjaga keseimbangan antara deteksi sentimen positif dan negatif, sementara *Naïve Bayes* lebih efektif dalam mendeteksi sentimen negatif, tetapi kurang sensitif terhadap sentimen positif. Temuan ini penting untuk analisis sentimen yang memerlukan keseimbangan dalam deteksi kedua jenis sentimen.

## 5. KESIMPULAN

Dataset terdiri atas 982 tweet periode 1 Mei–25 Oktober 2025. Pelabelan dilakukan secara semi-otomatis melalui pemanfaatan IndoBERT untuk mengidentifikasi sentimen positif dan negatif, menghasilkan komposisi 726 negatif dan 249 positif yang menunjukkan ketidakseimbangan kelas. Algoritma *K-NN* mencatat akurasi 82.56% dengan *F1-Score* 80.72. Hasil ini menunjukkan bahwa pendekatan berbasis kedekatan vektor mampu merepresentasikan pola sentimen secara konsisten pada data yang telah ditransformasikan.

*Naïve Bayes* mencapai akurasi 82.05% dan *F1-Score* 80.72. Meskipun berada sedikit di bawah *K-NN*, model ini tetap memberikan performa klasifikasi yang kompetitif dan efisien pada teks berdimensi tinggi. Metode *K-Nearest Neighbor* (*K-NN*) lebih handal dalam menerapkan sistem analisis sentimen yang menuntut keseimbangan antara deteksi positif dan negatif, sedangkan metode *Naïve Bayes* tetap berguna dalam mendeteksi secara cepat pada kasus dimana prioritas diberikan pada identifikasi kelas mayoritas.

Hasil analisis sentimen menunjukkan bahwa lebih banyak orang memiliki pendapat negatif daripada positif tentang distribusi smart TV di sekolah-sekolah di Indonesia. Hal ini dikarenakan rata-rata Masyarakat menilai peningkatan gaji guru dan pemerataan fasilitas sekolah dianggap lebih penting daripada distribusi smart TV, dimana diperparah dengan adanya kasus penyalahgunaan oleh pihak sekolah. Oleh karena itu, perlu ada evaluasi oleh pemerintah agar distribusi smart TV dapat lebih bermanfaat untuk pendidikan di Indonesia dengan memonitor penyalahgunaan dan memberikan edukasi penggunaan smart TV dengan bijak serta memanfaatkan analisis sentimen secara berkala agar dapat menilai kepuasan masyarakat terhadap kebijakan yang dilakukan

#### DAFTAR PUSTAKA

- [1] A. Wismadi, Connecting every school in Indonesia to the Internet : Policy landscape assessment. Geneva, Swiss: ITUPublications, 2023.
- [2] Q. Aini, A. Kurniawan, and T. Bina Sulistiyowati, "Digital Transformation: Best Practices of Educational Platform in Indonesia," *J. Transform.*, vol. 10, no. 1, pp. 42–59, 2024, doi: 10.21776/ub.transformative.2024.010.01.3.
- [3] D. Arsyanda, S. Rodiah, and A. S. Rohman, "Peran akun autobase X (twitter) dalam memenuhi kebutuhan informasi followers," *Pustaka Karya J. Ilm. Ilmu Perpust. dan Inf.*, vol. 13, no. 1, pp. 233–241, 2025, doi: 10.18592/pk.v13i1.15927.
- [4] S. Kemp, "Digital 2025: Indonesia." Accessed: Feb. 25, 2025. [Online]. Available: <https://datareportal.com/reports/digital-2025-indonesia>
- [5] B. News, "Polemik rencana Prabowo bagikan 330 ribu smart TV ke sekolah," BBC News Indonesia. Accessed: Sep. 15, 2025. [Online]. Available: <https://www.bbc.com/indonesia/articles/cdr6gndgl1go>
- [6] T. Abdilah, "KOMPARASI METODE NAÏVE BAYES DAN K-NEAREST NEIGHBORS TERHADAP ANALISIS SENTIMEN PENGGUNA APLIKASI ZENIUS," UNIVERSITAS JAMBI, 2023.
- [7] D. F. M. Dina, T. Haryanti, and M. A. Haq, "Analisis Sentimen Terhadap Komentar Pada Media Sosial Tiktok Yang Berpotensi Menyebabkan Depresi Menggunakan Metode Naive Bayes," *Comput. Insight J. Comput. Sci.*, vol. 7, no. 1, pp. 1–9, 2025, doi: 10.30651/comp\_insight.v7i1.26327.
- [8] W. Afifi, "Analisis Sentimen Pengguna Twitter Terhadap Layanan Internet PT Indosat Tbk Dengan Metode K-Nearest Neighbor (K-NN) Dan Naive Bayes Classifier (NBC)," UNIVERSITAS ISLAM NEGERI SYARIF HIDAYATULLAH, 2022.
- [9] F. Alghifari and D. Juardi, "Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naïve Bayes," *J. Ilm. Inform.*, vol. 9, no. 02, pp. 75–81, 2021, doi: 10.33884/jif.v9i02.3755.
- [10] Y. Sutaryana *et al.*, "Implementation Of Naïve Bayes Algorithm For Children's Clothing Recommendation-Yudi Sutaryana et.al Implementation Of Naïve Bayes Algorithm For Children's Clothing Recommendation," *Inform. dan Sains*, vol. 14, no. 03, p. 2024, 2024, doi: 10.54209/infosains.v14i03.
- [11] H. A. Dwi Fasnuari, H. Yuana, and M. T. Chulkamdi, "Penerapan Algoritma K-Nearest Neighbor (K-Nn) Untuk Klasifikasi Penyakit Diabetes Melitus Studi Kasus : Warga Desa Jatitengah," *Antivirus J. Ilm. Tek. Inform.*, vol. 16, no. 2, pp. 133–142, 2022.
- [12] H. Sari, G. Leonarde Ginting, and T. Zebua, "Penerapan Algoritma Text Mining Dan

- Tf-Idf Untuk Pengelompokan Topik Skripsi,” *Terap. Inform. Nusantara*, vol. 2, no. 7, pp. 414–432, 2021, [Online]. Available: <https://ejurnal.seminar-id.com/index.php/tin>
- [13] S. K. I. Irma, A. M. Yasin, and A. S. Irvan, “Analisis Sentimen Terhadap Penggunaan Aplikasi Shopee Menggunakan Algoritma Support Vector Machine (SVM),” *Jambura J. Electr. Electron. Eng.*, vol. 5, no. 1, pp. 32–35, 2023.
- [14] M. I. Ilmiyah Najahatul Nailin, “PENGUNAAN MEDIA PEMBELAJARAN SMART TV PADA MINAT BELAJAR SISWA DI MI TASYWIRUL AFKAR MADUMULYOOREJO DUKUN GRESIK Nailin,” *J. Ilm. Penelit. Mhs.*, vol. 2, no. 4, pp. 423–435, 2024.
- [15] U. I. Arsyah, M. Pratiwi, and A. Muhammad, “Twitter Sentiment Analysis of Public Space Opinions using SVM and TF-IDF Methods,” *Indones. J. Comput. Sci.*, vol. 13, no. 1, pp. 387–394, 2024, doi: 10.33022/ijcs.v13i1.3594.
- [16] M. R. Manoppo, I. C. Kolang, D. N. Fiat, R. Michelly, and C. Mawara, “ANALISIS SENTIMEN PUBLIK DI MEDIA SOSIAL TERHADAP KENAIKAN PPN 12 % DI INDONESIA MENGGUNAKAN INDOBERT ANALYSIS OF PUBLIC SENTIMENT ON SOCIAL MEDIA TOWARDS THE 12 % PPN INCREASE IN INDONESIA USING INDOBERT,” vol. 4, no. 2, pp. 152–163, 2025, doi: 10.69916/jkbt.v4i2.322.