

## PREDIKSI INTERAKSI PENGGUNA MEDIA SOSIAL X DENGAN ALGORITMA MACHINE LEARNING

Dian Syamdova<sup>1</sup>, Raden Teddy Iswahyudi<sup>2\*</sup>

<sup>1,2</sup>. Program Studi Teknik Informatika Fakultas Ilmu Komputer Universitas Esa Unggul

Email : diansyamdova24@gmail.com; raden.teddy@esaunggul.ac.id

### ABSTRAK

Media sosial kini menjadi ruang komunikasi publik yang penting, termasuk bagi instansi pemerintah dalam menyampaikan informasi kepada masyarakat. Penelitian ini bertujuan memprediksi tingkat interaksi pengguna pada akun resmi Kementerian Pertanian Republik Indonesia (Kementan RI) di platform X (Twitter) menggunakan algoritma machine learning. Data penelitian berupa 334 tweet yang dipublikasikan pada periode April hingga Juni 2025, dianalisis berdasarkan jumlah like, reply, dan repost. Proses pra-pemrosesan mencakup pembersihan teks, normalisasi, penghapusan stopwords, serta transformasi teks ke dalam representasi numerik dengan TF-IDF. Empat algoritma diuji, yaitu Naive Bayes, Logistic Regression, Support Vector Machine (SVM), dan K-Nearest Neighbors (KNN). Evaluasi kinerja model menggunakan metrik akurasi, presisi, recall, F1-score, macro average, dan weighted average untuk menangani distribusi data yang tidak seimbang. Hasil penelitian menunjukkan bahwa algoritma Naive Bayes memberikan performa terbaik dengan akurasi 82% dan F1-score 0.74, terutama pada klasifikasi interaksi rendah. Logistic Regression dan KNN menunjukkan performa cukup baik namun belum stabil, sedangkan SVM memiliki performa paling rendah, khususnya pada deteksi interaksi tinggi. Temuan ini menunjukkan bahwa Naive Bayes dapat direkomendasikan sebagai algoritma utama dalam prediksi interaksi media sosial X. Selain itu, hasil penelitian ini dapat menjadi landasan untuk menyusun strategi komunikasi digital pemerintah yang lebih efektif, berbasis data dan prediksi tingkat keterlibatan audiens.

**Kata kunci :** Media sosial, Machine learning, Naive Bayes, Prediksi interaksi, Twitter/X

### ABSTRACT

*Social media has become an essential platform for public communication, including government institutions in delivering information to society. This study aims to predict user interaction levels on the official account of the Indonesian Ministry of Agriculture (Kementan RI) on X (formerly Twitter) by applying machine learning algorithms. The dataset consists of 334 tweets published between April and June 2025, analysed based on the number of likes, replies, and reposts. Preprocessing steps included text cleaning, normalisation, stopword removal, and transforming the text into numerical representations using TF-IDF. Four algorithms were tested: NB, Logistic Regression, Support Vector Machine (SVM), and K-Nearest Neighbors (KNN). Model performance was evaluated using accuracy, precision, recall, F1-score, macro average, and weighted average to account for class imbalance in the dataset. The results indicate that NB achieved the best performance with an accuracy of 82% and an F1-score of 0.74, particularly effective in classifying low engagement posts. Logistic Regression and KNN yielded fair results but lacked stability, while SVM performed the weakest, especially in detecting high engagement posts. These findings suggest that NB can be recommended as the primary algorithm for predicting social media engagement. Furthermore, the results provide an empirical basis for optimising government digital communication strategies by leveraging predictive analytics to enhance audience engagement.*

**Keywords:** Social media, Machine learning, Naive Bayes, Engagement prediction, Twitter/X

## 1. PENDAHULUAN

Perkembangan pesat teknologi informasi telah mengubah cara masyarakat berinteraksi dan mengakses informasi secara fundamental. Transformasi signifikan dari era digital ini adalah munculnya media sosial sebagai platform utama untuk komunikasi publik, diseminasi informasi, dan pembentukan opini publik secara daring (Arianto, 2022; Fauzi et al., 2023; van Vliet et al., 2020). Salah satu

platform yang menonjol adalah X, yang sebelumnya dikenal sebagai Twitter, sebuah layanan mikroblogging yang memungkinkan pengguna untuk berbagi pesan singkat hingga 280 karakter secara cepat dan real-time. Fitur-fitur ini menjadikan X sebagai forum diskusi publik yang dinamis bagi individu, organisasi, dan lembaga pemerintah (Karami & al., 2020; M. L. Khan et al., 2021; Rasyid Julianto, 2023).

Kementerian Pertanian Republik Indonesia merupakan contoh institusi yang memanfaatkan X untuk komunikasi digital dengan publik. Melalui akun resminya, Kementan menyebarkan berbagai informasi mengenai kebijakan pertanian, layanan publik, program pembangunan, dan edukasi. Namun, efektivitas strategi komunikasi digital ini masih menghadapi kendala, khususnya terkait rendahnya tingkat interaksi pengguna terhadap konten yang dipublikasikan. Tingkat interaksi, seperti jumlah suka (likes), balasan (reply), dan retweet (repost), secara langsung mengindikasikan sejauh mana pesan berhasil mencapai dan melibatkan audiens (Arianto, 2022; Fauzi et al., 2023; Rachmawati et al., 2025). Dalam ekosistem digital yang berbasis data, metode evaluasi performa konten konvensional menjadi kurang relevan. Diperlukan strategi prediktif yang mampu memperkirakan tingkat keterlibatan (*engagement*) suatu konten sebelum dipublikasikan. Pendekatan yang relevan dan berkembang pesat dalam hal ini adalah machine learning, yang memungkinkan sistem untuk belajar dari data historis dan membuat prediksi berdasarkan berbagai fitur seperti waktu unggah, jenis konten, panjang karakter, dan kata kunci (Andariesta & Wasesa, 2023; M. Assiroy & al., 2023; Mahesh, 2020). Aktivitas interaksi pengguna pada suatu konten, termasuk likes, reply, dan reposts, merepresentasikan popularitas, jangkauan informasi, dan pengaruh sebuah postingan. Oleh karena itu, prediksi tingkat interaksi pada platform media sosial X menjadi area penelitian yang penting dalam komunikasi publik, bisnis digital, dan tata kelola pemerintahan (Andariesta & Wasesa, 2023; L. Khan & al., 2021). Untuk memastikan prediksi yang akurat dan andal, pemilihan algoritma machine learning yang tepat sangat krusial, mengingat sifat data media sosial yang dinamis, tidak terstruktur, dan sering kali mengandung noise (Ho & Beyan, 2020; Mahesh, 2020). Evaluasi kinerja keempat model machine learning dilakukan menggunakan beberapa metrik evaluasi untuk menilai kemampuan prediksi tingkat *engagement* postingan. Metrik yang digunakan mencakup akurasi, presisi, recall, dan F1-score, serta rata-rata. Pemilihan metrik ini bertujuan untuk memastikan model tidak hanya berkinerja baik secara keseluruhan, tetapi juga mampu

mengklasifikasikan semua kelas interaksi secara tepat dan proposional, bahkan ketika terdapat ketidakseimbangan dalam distribusi data (Hinojosa Lee et al., 2024; Rismaya & al., 2025).

## 2. METODOLOGI

Pendekatan ini memungkinkan analisis komprehensif terhadap kapabilitas model dalam memprediksi sentimen atau interaksi pengguna terhadap kebijakan pemerintah (Pramudita & al., 2024; Retnoningrum & al., 2024). Analisis ini juga dapat memberikan wawasan mengenai faktor-faktor yang mendorong atau menghambat keterlibatan publik, sehingga memungkinkan optimasi strategi komunikasi di masa depan (Bhattacharya & al., 2024). Metode machine learning seperti regresi logistik dan random forest telah terbukti efektif dalam memprediksi tingkat keterlibatan pengguna dengan mengidentifikasi pola-pola signifikan dalam data historis (Nelissen & al., 2018). Pendekatan ini memanfaatkan kemampuan algoritma untuk mengidentifikasi korelasi kompleks antara fitur-fitur konten dan respons pengguna, sehingga menghasilkan model prediktif yang robust (Pratama & al., 2019; Pratiwi & al., 2023). Algoritma seperti *Support Vector Machine* (SVM) juga dapat dimanfaatkan untuk mengklasifikasikan sentimen dan mengidentifikasi tema-tema dalam teks untuk pemahaman yang lebih komprehensif mengenai keterlibatan pengguna. Metode seperti *random subspace regression* dengan *bootstrap* juga dapat digunakan untuk mencapai estimasi koefisien yang handal, interval kepercayaan, p-value, dan skor kepentingan untuk setiap fitur yang dipertimbangkan (Wichitakorn et al., 2023). Dalam konteks prediksi interaksi di media sosial, teknik-teknik ini memungkinkan identifikasi elemen-elemen konten yang paling berpengaruh terhadap respons pengguna, seperti penggunaan kata kunci tertentu atau struktur kalimat. Metrik evaluasi yang sering digunakan untuk mengukur kinerja model-model ini, termasuk akurasi, presisi, recall, dan F1-score, sangat penting untuk menilai seberapa efektif model dapat mengidentifikasi sentimen positif atau negatif dan memprediksi keterlibatan pengguna secara akurat (Arsi & Waluyo, 2021). Penggunaan algoritma seperti Random Forest

dan XGBoost telah terbukti menghasilkan akurasi yang tinggi dalam analisis sentimen pada platform serupa (Saklani et al., 2025).

## 2.1 Pengumpulan Data

Data penelitian dikumpulkan dari akun resmi Kementerian Pertanian Republik Indonesia (Kementan RI) di X (Twitter) selama periode April hingga Juni 2025. Dataset yang diperoleh terdiri dari 334 tweet, di mana setiap postingan di analisis berdasarkan jumlah like, reply, dan repost.

Deskripsi Dataset;

Sumber data: Akun resmi Kementerian Pertanian Republik Indonesia (Kementan RI) di media sosial X (Twitter).

Periode pengambilan data: April – Juni 2025.

Jumlah data: 334 tweet.

Unit analisis: Setiap tweet yang diposting oleh akun resmi Kementan RI.

Fitur/atribut yang dikumpulkan:

Teks tweet (konten utama postingan).

Tanggal dan waktu posting.

Jumlah like (interaksi positif pengguna).

Jumlah reply (respon/komentar pengguna).

Jumlah repost/retweet (penyebaran ulang konten).

Dalam bentuk tabel 1. menunjukkan struktur dataset:

ID_Tweet	Tanggal	Teks_Tweet	Jumlah_Like	Jumlah_Reply	Jumlah_Repost
1,2025-06-17,	isi tweet	1,301,49,17			
2,2025-05-22,	isi tweet	2,263,6,89			
3,2025-05-27,	isi tweet	3,101,93,18			
4,2025-06-17,	isi tweet	4,41,64,111			
5,2025-04-19,	isi tweet	5,229,100,160			
6,2025-06-03,	isi tweet	6,274,94,188			
7,2025-04-21,	isi tweet	7,351,37,48			
8,2025-06-30,	isi tweet	8,332,57,49			
9,2025-04-27,	isi tweet	9,459,5,12			
10,2025-05-21,	isi tweet	10,315,22,84			
...					
...					
330,2025-06-10,	isi tweet	330,446,100,94			
331,2025-05-02,	isi tweet	331,301,25,2			
332,2025-06-24,	isi tweet	332,485,47,80			
333,2025-05-10,	isi tweet	333,179,82,22			
334,2025-04-11,	isi tweet	334,256,43,96			

Pengumpulan data ini dilakukan untuk memperoleh gambaran tingkat interaksi pengguna terhadap konten yang dipublikasikan oleh Kementan RI, serta menjadi dasar untuk membangun model prediksi menggunakan algoritma machine learning (Andariesta & Wasesa, 2023; Arianto, 2022).

## 2.2 Pra-pemrosesan Data

Sebelum digunakan dalam model machine learning, data teks menjalani tahap pra-pemrosesan yang meliputi pembersihan teks, normalisasi huruf, dan penghapusan karakter khusus maupun stopwords. Tahap ini penting untuk mengurangi noise dan meningkatkan kualitas fitur yang diekstraksi. Selanjutnya, fitur diubah menjadi representasi numerik menggunakan TF-IDF agar dapat diproses oleh algoritma machine learning. Selain itu, dilakukan penanganan ketidakseimbangan data untuk memastikan bahwa distribusi kelas tidak mendominasi hasil prediksi, sehingga setiap model dapat belajar secara optimal dari dataset yang ada (Dhankhar et al., 2021; Ho & Beyan, 2020)

## 2.3 Algoritma Machine Learning

Dalam penelitian ini, empat algoritma machine learning digunakan untuk memprediksi tingkat interaksi, yaitu Naive Bayes (NB), Logistic Regression (LR), Support Vector Machine (SVM), dan K-Nearest Neighbors (KNN). NB merupakan metode klasifikasi berbasis probabilitas yang mengasumsikan independensi antar fitur, sehingga sering efektif untuk dataset teks berdimensi tinggi (Blanquero et al., 2021; Chen et al., 2021), digunakan untuk memprediksi probabilitas keterlibatan pengguna terhadap postingan (Assiroj et al., 2023). SVM memisahkan kelas dengan hyperplane optimal, sehingga mampu memberikan prediksi yang baik pada data dengan margin antar kelas yang jelas (Bansal et al., 2022; Gatera et al., 2023). Sedangkan KNN melakukan klasifikasi berdasarkan kedekatan antar sampel dalam ruang fitur, sehingga hasilnya dipengaruhi oleh distribusi dan noise pada data (Corso et al., 2021). Dalam konteks prediksi tingkat interaksi pengguna media sosial X, pemilihan algoritma machine learning yang tepat sangat penting. Dokumen yang diperoleh (table 1) menyebutkan beberapa algoritma yang relevan, dengan uraian detail untuk salah satunya.

### a. Naive Bayes (NB)

NB adalah algoritma yang sangat efektif dalam mengklasifikasikan data berbasis teks, seperti tweet pada media sosial. Algoritma ini

bekerja berdasarkan prinsip probabilitas, di mana setiap fitur dianggap independen. Metode ini cocok untuk tugas klasifikasi teks dengan dimensi yang tinggi karena kecepatan dan kemampuannya dalam menangani dataset besar. NB sering digunakan untuk klasifikasi spam, analisis sentimen, dan tugas serupa di media sosial (Blanquero et al., 2021; Sankar et al., 2024).

$$P(C | \mathbf{x}) = \frac{P(\mathbf{x} | C) P(C)}{P(\mathbf{x})}$$

$C$ ; Kelas atau kategori yang ingin diprediksi.

$\mathbf{x} = (x_1, x_2, \dots, x_d)$ ; Vektor fitur/atribut dari data input.

$P(C | \mathbf{x})$ ; Probabilitas posterior.

$P(\mathbf{x} | C)$ ; Likelihood.

#### b. Logistic Regression (LR)

LR adalah metode statistik yang digunakan untuk memodelkan hubungan antara variabel input dengan probabilitas suatu hasil. Dalam konteks ini, LR digunakan untuk memprediksi tingkat keterlibatan (engagement) pengguna berdasarkan kombinasi fitur-fitur konten. Keunggulan LR adalah kemampuannya dalam memberikan interpretasi yang jelas terhadap kontribusi setiap fitur dalam prediksi. LR cocok digunakan untuk klasifikasi biner dan multikelas, seperti memprediksi apakah suatu postingan akan mendapatkan like atau tidak (P. Assiroj et al., 2023).

#### c. Support Vector Machine (SVM)

SVM merupakan algoritma yang digunakan untuk klasifikasi dan regresi dengan tujuan mencari hyperplane yang memisahkan data ke dalam kelas yang berbeda. Keunggulan SVM adalah kemampuannya dalam menangani data yang tidak seimbang dan kompleks, serta kemampuannya menggunakan kernel untuk menangani data yang tidak dapat dipisahkan secara linier. SVM sangat berguna untuk tugas klasifikasi seperti membedakan antara interaksi tinggi dan rendah dalam postingan berdasarkan berbagai fitur (Bansal et al., 2022; Gatera et al., 2023)

#### d. K-Nearest Neighbors (KNN)

KNN adalah algoritma berbasis instance yang mengklasifikasikan data berdasarkan kedekatannya dengan tetangga terdekat. KNN sering digunakan dalam aplikasi yang memerlukan klasifikasi berbasis kedekatan antar sampel, seperti dalam analisis konten media sosial. Dengan menggunakan KNN, kita dapat mengidentifikasi pola lokal yang terjadi pada postingan media sosial yang serupa, serta memprediksi tingkat interaksi berdasarkan kedekatannya dengan postingan lain yang memiliki pola serupa (Corso et al., 2021).

#### 2.4 Evaluasi Model

Evaluasi performa model dilakukan menggunakan beberapa metrik, antara lain accuracy, precision, recall, dan F1-score, yang memungkinkan perbandingan kinerja algoritma secara objektif (Hinojosa Lee et al., 2024). Selain itu, macro average dan weighted average digunakan untuk memberikan penilaian yang adil pada dataset dengan distribusi kelas yang tidak seimbang. Penggunaan metrik-metrik ini penting untuk menilai kemampuan setiap algoritma dalam menangani data teks yang kompleks dan tidak merata, sekaligus menentukan algoritma yang paling optimal untuk memprediksi interaksi postingan di media sosial (Andariesta & Wasesa, 2023; Sankar et al., 2024).

##### a. Accuracy

Accuracy mengukur proporsi prediksi yang benar dibandingkan dengan total prediksi yang dibuat. Metrik ini memberikan gambaran umum tentang seberapa sering model memprediksi dengan benar, namun mungkin kurang efektif jika distribusi data tidak seimbang. Misalnya, jika mayoritas tweet memiliki sedikit interaksi dan model hanya memprediksi kelas tersebut, maka accuracy yang tinggi tidak mencerminkan kinerja model secara keseluruhan. Oleh karena itu, metrik lain diperlukan untuk evaluasi yang lebih menyeluruh (Hinojosa Lee et al., 2024; Mahesh, 2020).

##### b. Precision

Precision mengukur seberapa akurat model dalam mengklasifikasikan data positif (interaksi tinggi). Precision penting karena

kita ingin mengetahui seberapa banyak interaksi yang diprediksi sebagai positif benar-benar merupakan interaksi yang sebenarnya positif, seperti likes, reply, atau reposts. Metrik ini memastikan model tidak memberikan terlalu banyak prediksi positif yang salah, sehingga strategi komunikasi dapat lebih tepat sasaran (P. Assiroj et al., 2023; Blanquero et al., 2021).

#### c. Recall

Recall mengukur kemampuan model untuk menangkap seluruh data positif yang ada, atau seberapa banyak interaksi yang relevan dapat ditemukan oleh model. Recall penting untuk memastikan model tidak melewatkan interaksi yang seharusnya diprediksi sebagai tinggi, terutama pada data yang tidak seimbang di mana interaksi positif mungkin lebih jarang (Bansal et al., 2022; Jackins et al., 2021).

#### d. F1-score

F1-score adalah rata-rata harmonis antara precision dan recall. Metrik ini memberikan gambaran yang lebih seimbang tentang kinerja model, terutama ketika terdapat ketidakseimbangan antara precision dan recall. F1-score memberikan bobot yang adil terhadap kedua metrik tersebut, sehingga kinerja model dapat dinilai lebih objektif pada dataset yang tidak seimbang, seperti interaksi rendah pada Twitter (Bansal et al., 2022).

#### e. Macro Average dan Weighted Average

Macro Average menghitung rata-rata metrik evaluasi di seluruh kelas tanpa mempertimbangkan ukuran kelas. Hal ini memberikan pandangan yang lebih adil ketika distribusi kelas tidak seimbang, meskipun bisa memberi bobot lebih pada kelas yang lebih kecil. Macro Average berguna untuk mengevaluasi performa model secara keseluruhan tanpa memberi preferensi pada kelas dominan (Hinojosa Lee et al., 2024; Song et al., 2021).

### 3. TINJAUAN LITERASI

Media sosial X, sebelumnya dikenal sebagai Twitter, telah menjadi platform komunikasi digital yang sangat dinamis, menyediakan

forum bagi interaksi pengguna melalui berbagai cara seperti like, reply, dan repost. Analisis jejaring sosial digital ini penting karena memungkinkan peneliti untuk memahami bagaimana konten menyebar dan faktor-faktor yang memengaruhi respons audiens. Salah satu elemen penting dalam media sosial adalah bagaimana strategi pemasaran dan komunikasi berkembang. Dalam konteks ini, penciptaan konten yang menarik dan penggunaan media berbasis visual, seperti video, telah diidentifikasi sebagai faktor kunci dalam menarik perhatian pengguna. Penelitian menunjukkan bahwa media sosial mempermudah penyampaian informasi dengan cara yang lebih cepat dan lebih terjangkau, serta memungkinkan penggunanya untuk berinteraksi secara aktif, yang pada gilirannya dapat memengaruhi hasil perilaku audiens (Maitri et al., 2023; Sandeep et al., 2023). Interaksi ini tidak hanya terbatas pada promosi produk, tetapi juga meliputi komunikasi informasi yang lebih luas, termasuk dalam bidang kesehatan dan edukasi (Lian et al., 2024). Usaha untuk memahami penyebaran konten di media sosial juga telah dilakukan melalui analisis persepsi dan kehadiran audiens, yang menunjukkan bahwa karakteristik audiens dapat secara signifikan memengaruhi efektivitas pesan (Yunan et al., 2020; Zou, 2023). Misalnya, dalam penelitian yang menganalisis kontribusi influencer di media sosial, tampak bahwa influencer berperan sebagai pemimpin opini yang dapat memengaruhi sikap dan perilaku audiens secara efektif (Silfia & Irwansyah, 2022).

Namun, tantangan terkait dengan penyebaran informasi juga mencakup masalah seperti misinformation dan fake news. Penelitian tentang penyebaran informasi yang tidak akurat menunjukkan bahwa media sosial dapat berfungsi sebagai saluran utama bagi penyebaran berita palsu, yang, jika tidak ditangani, dapat berdampak negatif pada masyarakat (Alonso et al., 2021; HAMIMED et al., 2024). Oleh karena itu, penting untuk mengembangkan mekanisme deteksi informasi yang handal untuk mengidentifikasi dan mengatasi konten yang meragukan (Himdi et al., 2022).

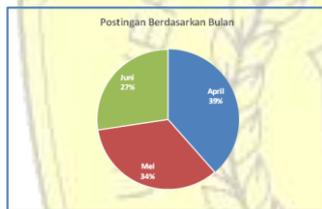
Di dalam konteks ini, keterlibatan pengguna dalam media sosial tidak hanya sebagai penerima pasif, tetapi lebih sebagai partisipan aktif yang membentuk dan membagikan informasi. Dengan demikian, analisis jejaring

sosial menjadi alat yang vital bagi peneliti dan praktisi untuk memahami dinamika konten dan interaksi yang sedang berlangsung di platform-platform ini, dan bagaimana ini berdampak pada perilaku dan sikap pengguna (Xiao et al., 2024; Yan et al., 2021). Melalui eksplorasi lebih jauh mengenai faktor-faktor yang memengaruhi interaksi ini, serta pengembangan strategi komunikasi yang lebih baik, kita dapat meningkatkan efektivitas penyampaian informasi di media sosial dan, secara lebih luas, dalam komunikasi digital secara keseluruhan.

#### 4. HASIL DAN PEMBAHASAN

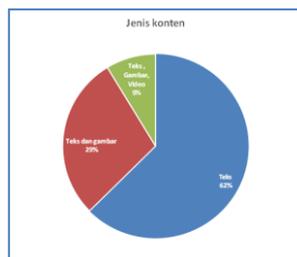
##### 4.1 Hasil dan Analisis Deskriptif Penelitian

Dari hasil data yang dikumpulkan, penelitian ini memiliki total 334 tweet yang terbagi di tweet bulan April, Mei, dan Juni dengan proporsi sebagai berikut.



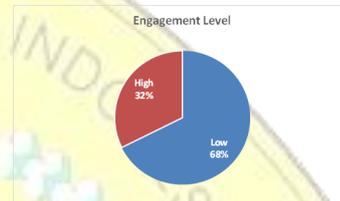
Gambar 1 Data Postingan

Berdasarkan grafik yang ditampilkan, jumlah postingan selama tiga bulan terakhir terbagi dengan proporsi yang jelas. Bulan April mendominasi dengan 39% dari total 334 postingan, yang berjumlah sekitar 130 postingan. Diikuti oleh bulan Mei yang menyumbang 34% dari total postingan, setara dengan 113 postingan. Sementara itu, bulan Juni mencatatkan kontribusi terendah, dengan 27% dari total postingan, atau sekitar 91 postingan.



Gambar 2 Jenis Konten Postingan

Berdasarkan grafik di atas, jenis konten yang paling dominan adalah teks, yang mencakup 62% dari total postingan. Diikuti oleh kombinasi teks dan gambar, yang menyumbang 29% dari keseluruhan postingan. Sementara itu, konten yang mencakup teks, gambar, dan video hanya berkontribusi 9%. Grafik ini menunjukkan bahwa mayoritas postingan lebih sering menggunakan teks sebagai konten utama, dengan penambahan gambar sebagai elemen pendukung, sedangkan konten yang melibatkan multimedia lengkap relatif jarang digunakan.



Gambar 3 Interaksi Postingan

Berdasarkan grafik di atas, tingkat engagement low mendominasi dengan kontribusi 68% dari total postingan, menunjukkan bahwa sebagian besar postingan tidak mendapatkan interaksi yang signifikan. Sementara itu, tingkat engagement high hanya menyumbang 32%, yang menunjukkan bahwa meskipun ada beberapa postingan yang mendapatkan respon yang lebih aktif, mayoritas postingan masih memiliki tingkat interaksi yang rendah.



Gambar 4 Interaksi Postingan Berdasarkan Jenis Konten

Berdasarkan grafik di atas, jenis konten yang paling banyak mendapatkan low engagement adalah teks, dengan proporsi 60,5% dari total postingan. Sementara itu, untuk high engagement, jenis konten yang paling banyak mencatatkan interaksi tinggi adalah teks dan gambar, yang

berkontribusi 22,8% dari total postingan. Hal ini menunjukkan bahwa kombinasi teks dengan gambar mampu menarik perhatian audiens lebih baik dibandingkan dengan teks saja. Sedangkan konten yang mencakup teks, gambar, dan video, meskipun hanya berkontribusi 7,5% dari total postingan, menunjukkan potensi besar dalam menarik perhatian audiens meskipun jumlahnya lebih sedikit.

#### 4.2 Hasil dan Analisis

Pada tahapan ini, penelitian dilakukan dengan menguji empat model machine learning untuk memprediksi tingkat interaksi (engagement) pada postingan Twitter Kementerian Pertanian Republik Indonesia berdasarkan teks yang dimuat pada tweets. Dataset yang digunakan telah diproses melalui beberapa tahap, yaitu pembersihan data, penghilangan stopwords, tokenisasi, dan transformasi teks menggunakan TF-IDF (Term Frequency-Inverse Document Frequency).

##### a. Naive Bayes (NB)

Classification Report - Naive Bayes				
	precision	recall	f1-score	support
Low Engagement	0.82	0.96	0.88	48
High Engagement	0.82	0.47	0.60	19
accuracy			0.82	67
macro avg	0.82	0.72	0.74	67
weighted avg	0.82	0.82	0.80	67

**Gambar 5 Classification NB**

Model NB menunjukkan kinerja yang sangat baik dalam memprediksi kelas Low Engagement dengan precision 0.82, recall 0.96, dan F1-Score 0.88, menandakan kemampuan tinggi dalam mengidentifikasi postingan dengan interaksi rendah. Namun, pada kelas High Engagement, meskipun precision cukup baik (0.82), recall rendah (0.47) membuat F1-Score hanya 0.60, sehingga model kurang optimal dalam mendeteksi postingan dengan interaksi tinggi. Secara keseluruhan, model mencapai accuracy 0.82 dengan Macro Average precision 0.72, recall 0.74, dan F1-Score 0.74, serta Weighted Average precision 0.82, recall 0.80, dan F1-Score 0.80, yang menunjukkan kecenderungan model lebih dominan pada prediksi kelas Low Engagement.

##### b. Logistic Regression (LR)

Classification Report - Logistic Regression				
	precision	recall	f1-score	support
Low Engagement	0.78	0.94	0.85	48
High Engagement	0.67	0.32	0.43	19
accuracy			0.76	67
macro avg	0.72	0.63	0.64	67
weighted avg	0.74	0.76	0.73	67

**Gambar 6 Classification LR**

Model LR menunjukkan kinerja yang cukup baik dalam memprediksi Low Engagement dengan precision 0.78, recall 0.94, dan F1-Score 0.85, menandakan kemampuan tinggi dalam mengidentifikasi postingan dengan interaksi rendah. Namun, pada kelas High Engagement, meskipun precision mencapai 0.67, recall rendah (0.32) membuat F1-Score hanya 0.43, sehingga model masih kesulitan mendeteksi postingan dengan interaksi tinggi. Secara keseluruhan, model memperoleh accuracy 0.76 dengan Macro Average precision 0.72, recall 0.63, dan F1-Score 0.64, serta Weighted Average precision 0.74, recall 0.76, dan F1-Score 0.73, yang menunjukkan kecenderungan model lebih dominan dalam memprediksi kelas Low Engagement.

##### c. Support Vector Machine (SVM)

Classification Report - Support Vector Machine (SVM)				
	precision	recall	f1-score	support
rendah	0.75	0.92	0.82	48
tinggi	0.50	0.21	0.30	19
accuracy			0.72	67
macro avg	0.62	0.56	0.56	67
weighted avg	0.68	0.72	0.67	67

**Gambar 7 Classification SVM**

Pada model SVM, hasil evaluasi menunjukkan bahwa model ini memiliki kinerja yang cukup baik dalam memprediksi Low Engagement, namun mengalami kesulitan dalam memprediksi High Engagement. Untuk Low Engagement, Precision mencapai 0.75, yang menunjukkan bahwa model cukup akurat dalam memprediksi postingan dengan interaksi rendah. Selain itu, Recall yang sangat tinggi, yaitu 0.92, menandakan bahwa model sangat efektif dalam mendeteksi sebagian besar postingan dengan engagement rendah, dengan hanya sedikit kesalahan deteksi. F1-Score untuk Low Engagement adalah 0.82, yang mencerminkan keseimbangan yang baik

antara precision dan recall dalam mendeteksi kelas ini. Namun, untuk High Engagement, meskipun Precision tetap cukup baik pada 0.50, Recall yang hanya 0.21 menunjukkan bahwa model mengalami kesulitan besar dalam mendeteksi postingan dengan tingkat interaksi tinggi. F1-Score untuk High Engagement adalah 0.30, yang mengindikasikan bahwa model perlu perbaikan signifikan dalam memprediksi postingan dengan engagement tinggi. Secara keseluruhan, model SVM memberikan Accuracy sebesar 0.72, yang menunjukkan bahwa model ini cukup efektif dalam memprediksi interaksi pada data secara keseluruhan. Dengan menggunakan Macro Average, model mencatat Precision 0.62, Recall 0.56, dan F1-Score 0.56, yang memberikan gambaran kinerja rata-rata model untuk kedua kelas. Pada Weighted Average, Precision meningkat menjadi 0.68, Recall 0.72, dan F1-Score 0.67, menunjukkan bahwa model lebih dominan dalam memprediksi kelas Low Engagement, yang lebih sering muncul dalam dataset.

d. K-Nearest Neighbors (KNN)

Classification Report - K-Nearest Neighbors (K-NN)				
	precision	recall	f1-score	support
rendah	0.82	0.83	0.82	48
tinggi	0.56	0.53	0.54	19
accuracy			0.75	67
macro avg	0.69	0.68	0.68	67
weighted avg	0.74	0.75	0.74	67

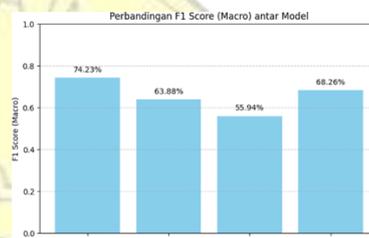
Gambar 8 Classification KNN

Hasil klasifikasi menggunakan algoritma K-Nearest Neighbors (K-NN) menunjukkan akurasi keseluruhan sebesar 75% dari 67 data uji, dengan performa yang lebih baik pada kelas rendah (precision 0.82, recall 0.83, f1-score 0.82) dibandingkan kelas tinggi (precision 0.56, recall 0.53, f1-score 0.54). Hal ini mengindikasikan bahwa model lebih mampu mengenali pola pada kelas rendah yang jumlah datanya lebih banyak (48 sampel), sementara pada kelas tinggi yang datanya hanya 19, model masih sering salah memprediksi sehingga recall rendah. Nilai rata-rata seimbang antar kelas (macro average) sebesar 0.68–0.69 dan weighted average sebesar 0.74–0.75 menunjukkan bahwa performa model cukup stabil, meskipun bias terhadap kelas mayoritas masih terlihat. Dengan demikian, K-NN cukup efektif untuk data mayoritas namun lemah

pada kelas minoritas, sehingga perbaikan dapat dilakukan dengan menyeimbangkan distribusi data, melakukan tuning parameter K, atau menggunakan algoritma lain yang lebih tangguh terhadap ketidakseimbangan data.

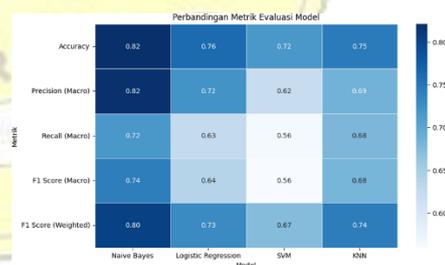
4.3 Visualisasi Hasil Evaluasi

Untuk memudahkan pemahaman perbandingan kinerja antara model-model yang diuji, berikut ini disajikan visualisasi hasil evaluasi dalam bentuk grafik yang menggambarkan perbandingan metrik evaluasi utama seperti Accuracy, Precision, Recall, F1-Score, dan F1-Score.



Gambar 9 F1-Score Antar Model

Grafik ini menunjukkan perbandingan F1-Score antara NB, LR, SVM, dan KNN. Dari grafik dapat dilihat bahwa NB memiliki F1-Score tertinggi (74.23%), diikuti oleh KNN (68.26%), LR (63.88%), dan SVM (55.94%).



Gambar 10 Perbandingan Kinerja Model

Pada grafik ini, diperlihatkan perbandingan Accuracy, Precision, Recall, F1-Score. NB menunjukkan performa terbaik di sebagian besar metrik, terutama dalam hal Accuracy (0.82) dan F1-Score (0.80). LR menunjukkan kinerja stabil meskipun sedikit lebih rendah dibandingkan NB. KNN memberikan hasil yang cukup baik dalam F1-Score (0.68), SVM memiliki performa yang

lebih rendah di semua metrik, terutama dalam Recall dan F1-Score

## 5. KESIMPULAN

Penelitian ini menyoroti pentingnya pemanfaatan algoritma machine learning dalam memprediksi tingkat interaksi pengguna media sosial X (Twitter) pada akun resmi Kementerian Pertanian Republik Indonesia. Berdasarkan analisis terhadap 334 tweet yang dipublikasikan selama periode April hingga Juni 2025, ditemukan bahwa mayoritas postingan cenderung menghasilkan interaksi rendah, sementara hanya sebagian kecil yang memperoleh interaksi tinggi. Kondisi ini menunjukkan bahwa strategi komunikasi digital pemerintah masih menghadapi tantangan dalam menarik perhatian audiens secara luas.

Empat algoritma machine learning yang diuji, yaitu NB, LR, SVM, dan KNN, menunjukkan variasi kinerja yang cukup signifikan. Hasil evaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score menunjukkan bahwa NB memberikan performa terbaik dengan akurasi 82% dan F1-score 0.74. Model ini terbukti lebih konsisten dalam mengklasifikasikan postingan dengan interaksi rendah, meskipun masih memiliki keterbatasan dalam mendeteksi interaksi tinggi. LR dan KNN menghasilkan performa yang cukup baik, namun masih menunjukkan ketidakkonsistenan terutama pada data tidak seimbang. Sementara itu, SVM menjadi model dengan performa terendah, terutama dalam hal recall untuk kelas interaksi tinggi.

Temuan ini menegaskan bahwa NB dapat direkomendasikan sebagai algoritma utama dalam prediksi interaksi media sosial, khususnya pada dataset dengan karakteristik teks berdimensi tinggi dan distribusi kelas yang tidak seimbang. Selain itu, hasil penelitian ini memberikan kontribusi praktis dalam mendukung strategi komunikasi digital pemerintah. Dengan memanfaatkan model prediktif, instansi dapat merancang konten yang lebih efektif, meningkatkan peluang keterlibatan publik, serta mengoptimalkan penyebaran informasi secara lebih luas.

Untuk penelitian selanjutnya, disarankan pengembangan model hybrid atau integrasi dengan metode deep learning, serta perluasan dataset dengan variasi konten multimedia agar

prediksi menjadi lebih akurat dan relevan pada kondisi dinamis media sosial.

## DAFTAR PUSTAKA

- Alonso, M. A., Vilares, D., Gómez-Rodríguez, C., & Vilares, J. (2021). Sentiment analysis for fake news detection. *Electronics (Switzerland)*, *10*(11). <https://doi.org/10.3390/electronics10111348>
- Andariesta, D. T., & Wasesa, M. (2023). Machine learning models to predict the engagement level of Twitter posts: Indonesian e-commerce case study. *Procedia Computer Science*, *227*, 823–832. <https://doi.org/10.1016/j.procs.2023.10.588>
- Arianto, B. (2022). Melacak Pelayanan Publik Berbasis Media Sosial Pada Masa Pandemi Covid-19 Di Provinsi Banten. *JRK (Jurnal Riset Komunikasi)*, *13*(1), 113. <https://doi.org/10.31506/jrk.v13i1.15788>
- Arsi, M., & Waluyo, A. (2021). Evaluasi Model Machine Learning dalam Prediksi Interaksi Digital. *Jurnal Sistem Komputer*.
- Assiroj, M., & al., et. (2023). Algoritma Machine Learning untuk Prediksi Konten. *Jurnal Sains Data*.
- Assiroj, P., Kurnia, A., & Alam, S. (2023). The performance of Naïve Bayes, support vector machine, and logistic regression on Indonesia immigration sentiment analysis. *Bulletin of Electrical Engineering and Informatics*, *12*(6), 3843–3852. <https://doi.org/10.11591/eei.v12i6.5688>
- Bansal, M., Goyal, A., & Choudhary, A. (2022). A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, *3*, 100071. <https://doi.org/10.1016/j.dajour.2022.100071>
- Bhattacharya, S., & al., et. (2024). Public Engagement and Policy Communication in Digital Era. *Government Information Quarterly*.

- Blanquero, R., Carrizosa, E., Ramírez-Cobo, P., & Sillero-Denamiel, M. R. (2021). Variable selection for Naïve Bayes classification. *Computers and Operations Research*, 135. <https://doi.org/10.1016/j.cor.2021.105456>
- Chen, H., Hu, S., Hua, R., & Zhao, X. (2021). Improved naive Bayes classification algorithm for traffic risk management. *Eurasip Journal on Advances in Signal Processing*, 2021(1). <https://doi.org/10.1186/s13634-021-00742-6>
- Corso, M. P., Perez, F. L., Stefanon, S. F., Yow, K. C., Ovejero, R. G., & Leithardt, V. R. Q. (2021). Classification of contaminated insulators using k-nearest neighbors based on computer vision. *Computers*, 10(9). <https://doi.org/10.3390/computers10090112>
- Dhankhar, A., Solanki, K., Dalal, S., & Omdev. (2021). Predicting students performance using educational data mining and learning analytics: A systematic literature review. *Lecture Notes on Data Engineering and Communications Technologies*, 59, 127–140. [https://doi.org/10.1007/978-981-15-9651-3\\_11](https://doi.org/10.1007/978-981-15-9651-3_11)
- Fauzi, N., Stiawati, T., & Ema Jumiaty, I. (2023). Strategi Komunikasi Pemerintah Kota Tangerang Untuk Memberikan Informasi Kepada Masyarakat Melalui Aplikasi Tangerang Live. *COMSERVA: Jurnal Penelitian Dan Pengabdian Masyarakat*, 3(1), 125–135. <https://doi.org/10.59141/comserva.v3i1.748>
- Gatera, A., Kuradusenge, M., Bajpai, G., Mikeka, C., & Shrivastava, S. (2023). Comparison of random forest and support vector machine regression models for forecasting road accidents. *Scientific African*, 21. <https://doi.org/10.1016/j.sciaf.2023.e01739>
- HAMIMED, L., Amad, M., & Boudries, A. (2024). A Collaborative and Real-Time Model for Trusties Content in Social Media. *Research Square*. <https://doi.org/10.21203/rs.3.rs-4359937/v1>
- Himdi, H., Weir, G., Assiri, F., & Al-Barhamtoshy, H. (2022). Arabic Fake News Detection Based on Textual Analysis. *Arabian Journal for Science and Engineering*, 47(8), 10453–10469. <https://doi.org/10.1007/s13369-021-06449-y>
- Hinojosa Lee, M. C., Braet, J., & Springael, J. (2024). Performance Metrics for Multilabel Emotion Classification: Comparing Micro, Macro, and Weighted F1-Scores. *Applied Sciences (Switzerland)*, 14(21). <https://doi.org/10.3390/app14219863>
- Ho, D.-A., & Beyan, O. (2020). Biases in Data Science Lifecycle. *ArXiv Preprint ArXiv:2009.09795*. <http://arxiv.org/abs/2009.09795>
- Ibáñez-Sánchez, S., Flavián, M., Casaló, L. V., & Belanche, D. (2022). Influencers and brands successful collaborations: A mutual reinforcement to promote products and services on social media. *Journal of Marketing Communications*, 28(5), 469–486. <https://doi.org/10.1080/13527266.2021.1929410>
- Jackins, V., Vimal, S., Kaliappan, M., & Lee, M. Y. (2021). AI-based smart prediction of clinical disease using random forest classifier and Naive Bayes. *Journal of Supercomputing*, 77(5), 5198–5219. <https://doi.org/10.1007/s11227-020-03481-x>
- Jin, S. V., Ryu, E., & Muqaddam, A. (2021). I trust what she's #endorsing on Instagram: moderating effects of parasocial interaction and social presence in fashion influencer marketing. *Journal of Fashion Marketing and Management*, 25(4), 665–681. <https://doi.org/10.1108/JFMM-04-2020-0059>
- Karami, A., & al., et. (2020). Twitter as a Public Communication Forum. *Journal of Information Systems*.
- Khan, L., & al., et. (2021). Government Communication on Twitter. *Journal of Public Affairs*.
- Khan, M. L., Ittefaq, M., Pantoja, Y. I. M., Raziq, M. M., & Malik, A. (2021). Public Engagement Model to Analyze Digital Diplomacy on Twitter: A Social Media Analytics Framework.

- International Journal of Communication*, 15, 1741–1769. <http://ijoc.org>
- Lian, X., Liang, C., & Li, J. (2024). Evaluation on social media health information communication based on machine learning technology. *Internet Technology Letters*, 7(6). <https://doi.org/10.1002/itl2.461>
- Mahesh, B. (2020). Machine Learning Algorithms: A Review. In *International Research Publication*. International Research Publication.
- Maitri, W. S., Suherlan, S., Prakosos, R. D. Y., Subagja, A. D., & Almaududi Ausat, A. M. (2023). Recent Trends in Social Media Marketing Strategy. *Jurnal Minfo Polgan*, 12(1), 842–850. <https://doi.org/10.33395/jmp.v12i1.12517>
- Nelissen, J., & al., et. (2018). Logistic Regression and Random Forest for Social Media Analysis. *Journal of Computational Social Science*.
- Pramudita, R., & al., et. (2024). Prediksi Interaksi Publik terhadap Kebijakan. *Jurnal Informatika Sosial*.
- Pratama, A., & al., et. (2019). Predictive Modeling of User Engagement with Machine Learning. *Jurnal Sistem Informasi*.
- Pratiwi, L., & al., et. (2023). Sentiment Classification in Social Media Using Machine Learning. *Indonesian Journal of Data Science*.
- Rachmawati, I., Restu Kuncoro, H., Lupita Sari, D., & Handayani Kasih, P. (2025). Analyzing of Twitter Content Strategy and Public Engagement of Indonesian Representatives Abroad. *SHS Web of Conferences*, 212, 02002. <https://doi.org/10.1051/shsconf/202521202002>
- Rasyid Julianto, I. (2023). Potensi Aplikasi Twitter Dan Tiktok Sebagai Media Pembelajaran Digital Bahasa Indonesia. *DIALEKTIKA Jurnal Pendidikan Bahasa Indonesia*, 2(2), 1–15.
- Retnoningrum, D., & al., et. (2024). Analisis Sentimen Kebijakan Pemerintah di Media Sosial. *Jurnal Komunikasi Digital*.
- Rismaya, T., & al., et. (2025). Analisis Evaluasi Model Prediksi Interaksi Digital. *Jurnal Informatika*.
- Saklani, S., Manchanda, M., Bisht, G., & Thapa, K. (2025). Comparing Random Forest and XGBoost for Sentiment Classification of Student Social Media Posts: A Case Study on Pre-Board Exam Stress. *2025 Global Conference in Emerging Technology (GINOTECH)*, 1–6. <https://doi.org/10.1109/ginotech63460.2025.11076620>
- Sandeep, G. P., Prashanth, P., Sreenivasulu, M., & Madavilata, A. (2023). Effectiveness of social media agricultural information on farmer's knowledge. *Environment Conservation Journal*, 24(1), 123–129. <https://doi.org/10.36953/ECJ.11432297>
- Sankar, P., Palanichamy, N., & Ng, K. W. (2024). Sentiment Analysis on Twitter Data for Depression Detection. *Journal of Logistics, Informatics and Service Science*, 11(3), 21–36. <https://doi.org/10.33168/JLISS.2024.0302>
- Silfia, I., & Irwansyah, I. (2022). Science communication by scientists and influencers on social media. *Jurnal Manajemen Komunikasi*, 7(1), 1. <https://doi.org/10.24198/jmk.v7i1.40508>
- Song, X., Liu, X., Liu, F., & Wang, C. (2021). Comparison of machine learning and logistic regression models in predicting acute kidney injury: A systematic review and meta-analysis. *International Journal of Medical Informatics*, 151. <https://doi.org/10.1016/j.ijmedinf.2021.104484>
- van Vliet, L., Törnberg, P., & Uitermark, J. (2020). The Twitter parliamentarian database: Analyzing Twitter politics across 26 countries. *PLoS ONE*, 15(9 September). <https://doi.org/10.1371/journal.pone.0237073>
- Wichitaksorn, N., Kang, Y., & Zhang, F. (2023). Random feature selection using random subspace logistic regression. *Expert Systems with Applications*, 217, 119535. <https://doi.org/10.1016/j.eswa.2023.119535>
- Xiao, H. B., Hu, F., Li, P. Y., Song, Y. R., & Zhang, Z. K. (2024). Information Propagation in Hypergraph-Based

- Social Networks. *Entropy*, 26(11).  
<https://doi.org/10.3390/e26110957>
- Yan, J., You, Y., Wang, Y., & Sheng, D. (2021). Understanding the Complexity of Business Information Dissemination in Social Media: A Meta-Analysis of Empirical Evidence from China. *Complexity*, 2021. <https://doi.org/10.1155/2021/7647718>
- Yunan, P., Zongshui, W., & Jian, Z. (2020). Research on the Influencing Factors of Brand Diffusion via Social Media. *E3S Web of Conferences*, 189. <https://doi.org/10.1051/e3sconf/202018903032>
- Zou, Q. (2023). Research on the Effect of Cross-Cultural Communication of Chinese Culture on YouTube Evidence from Hanfu. *Communications in Humanities Research*, 19(1), 96–107. <https://doi.org/10.54254/2753-7064/19/20231212>

