

Analisis Sentimen Opini Publik Platform X Terhadap Bencana Banjir Bandang Di Sumatra Menggunakan Algoritma SVM

Hilman Ihza Amrullah, Agung Nugroho, Asep Suprianto

Jurusan Teknik Informatika, Fakultas Teknik

Universitas Pelita Bangsa

hilmanamr22@gmail.com, agung@pelitabangsa.ac.id, asep.supriyanto@pelitabangsa.ac.id

Abstract- The flash floods that occurred on the island of Sumatra had a major impact and became the focus of public attention. This event has sparked various opinions and public responses shared through social media platforms, particularly Platform X. However, the large number of opinions in the form of unstructured text makes manual analysis difficult. Therefore, this study aims to analyze public sentiment on Platform X regarding the flash flood disaster on the island of Sumatra using a machine learning-based sentiment analysis method. The data used in this study was collected from public posts on Platform X through a data crawling process. After that, the data underwent preprocessing, sentiment labeling using a lexicon-based approach, and feature weighting using the Term Frequency–Inverse Document Frequency (TF-IDF) method. The classification process was performed using the SVM algorithm and evaluated using a confusion matrix. The results show that negative sentiment dominates public opinion, accounting for 71.34%. The SVM model achieved an accuracy of 83.40%, a precision of 83.90%, a recall of 52.10%, and an F1-score of 64.30%. These results indicate that the SVM algorithm performs well in classifying public sentiment regarding the flash floods in Sumatra. This study demonstrates that machine learning-based sentiment analysis can be used to objectively understand public perception and serve as a source of supporting information in evaluating disaster response efforts.

Keywords: Sentiment Analysis, Severe Flooding, Platform X, TF-IDF, Support Vector Machine.

Abstrak- Bencana banjir bandang yang terjadi di Pulau Sumatra memberikan dampak yang besar dan menjadi sorotan masyarakat. Kejadian ini telah munculnya berbagai opini dan respons publik yang dibagikan melalui platform media sosial, khususnya Platform X. Namun, banyaknya opini yang berbentuk teks dan tidak terstruktur membuat analisis secara manual menjadi sulit. Oleh karena itu, penelitian ini bertujuan untuk menganalisis sentimen publik di Platform X terkait bencana banjir bandang di Pulau Sumatra dengan menggunakan metode analisis sentimen berbasis machine learning. Data yang digunakan dalam penelitian diambil dari unggahan masyarakat di Platform X melalui proses crawling data. Setelah itu, data akan melalui tahap preprocessing, pelabelan sentimen dengan pendekatan berbasis lexicon, serta pembobotan fitur dengan metode Term Frequency–Inverse Document Frequency (TF-IDF). Proses klasifikasi dilakukan menggunakan algoritma SVM dan dievaluasi menggunakan confusion matrix. Hasil penelitian menunjukkan bahwa sentimen negatif mendominasi opini publik dengan persentase sebesar 71,34%. Model SVM menghasilkan nilai accuracy sebesar 83,40%, precision sebesar 83,90%, recall sebesar 52,10%, dan F1-score sebesar 64,30%. Hasil tersebut menunjukkan bahwa algoritma SVM memiliki kinerja yang baik dalam mengklasifikasikan sentimen opini publik terhadap bencana banjir bandang di Sumatra. Penelitian ini membuktikan bahwa analisis sentimen berbasis machine learning dapat digunakan untuk memahami persepsi masyarakat secara objektif dan menjadi sumber informasi pendukung dalam evaluasi penanganan bencana.

Kata Kunci: Analisis Sentimen, Banjir Bandang, Platform X, TF-IDF, Support Vector Machine.

1. Pendahuluan

Banjir bandang merupakan salah satu fenomena hidrometeorologi yang menjadi isu penting di Indonesia mengingat frekuensi terjadinya yang tinggi serta dampak yang muncul bagi kehidupan masyarakat. Fenomena ini tidak hanya menyebabkan kerusakan pada lingkungan dan infrastruktur, tetapi juga memengaruhi kondisi sosial dan

ekonomi masyarakat di daerah yang terkena dampak. Di Pulau Sumatra, kejadian banjir bandang mengalami peningkatan yang signifikan seiring dengan intensitas curah hujan yang tinggi, perubahan penggunaan lahan, serta dampak dari sistem iklim regional. Pada akhir tahun 2025, bencana ini menyebabkan lebih dari 1.177 orang

Vol.17 no.1 | Juni 2026

EXPLORE: ISSN: 2087-2062, Online ISSN: 2686-181X / DOI: <http://dx.doi.org/10.36448/jsit.v17i1.4832>



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)

kehilangan nyawa, ratusan orang dilaporkan hilang, dan lebih dari 242.000 penduduk harus dievakuasi hingga awal Januari 2026 [1].

Besarnya dampak yang ditimbulkan oleh banjir bandang menjadikan peristiwa ini sebagai perhatian publik. Dalam era digital ini, masyarakat tidak hanya mendapatkan informasi dari media tradisional, tetapi juga aktif menyampaikan pendapat, kritik, dan respons melalui media sosial. Platform X (Twitter) telah berfungsi sebagai ruang publik digital yang memungkinkan masyarakat untuk dengan cepat dan langsung menyampaikan pandangan terhadap berbagai peristiwa, termasuk bencana alam. Opini publik yang muncul di Platform X mencerminkan pandangan masyarakat mengenai situasi di lapangan, respons pemerintah, dan sejauh mana penanganan bencana yang dilakukan efektif [2].

Namun, data opini publik yang diperoleh dari Platform X umumnya berupa teks singkat, bersifat tidak terstruktur dan sangat banyak, sehingga menyulitkan untuk dianalisis dengan cara manual. Oleh sebab itu, diperlukan metode komputasi untuk mengolah data teks tersebut secara sistematis. Salah satu metode yang sering digunakan adalah analisis sentimen, yang merupakan bagian dari *Natural Language Processing* (NLP) yang bertujuan untuk mendeteksi dan mengklasifikasikan pendapat atau opini ke dalam kategori sentimen tertentu, seperti positif dan negatif. Dalam konteks bencana, analisis sentimen dapat digunakan untuk mendapatkan gambaran kuantitatif mengenai kecenderungan sikap masyarakat terhadap suatu peristiwa dan penanganan yang dilakukan oleh pihak yang berkepentingan [3].


Dalam penerapan pengolahan analisis sentimen terhadap teks yang diambil dari media sosial, berbagai algoritma *machine learning* dapat digunakan untuk klasifikasi, salah satunya adalah *Support Vector Machine* (SVM). Algoritma SVM terkenal dengan kemampuannya yang sangat baik dalam menangani data dengan banyak dimensi, seperti halnya data dari media sosial, serta mampu memberikan hasil klasifikasi yang konsisten. Beberapa studi sebelumnya menunjukkan bahwa SVM efektif digunakan untuk klasifikasi sentimen opini masyarakat dan mampu mencapai tingkat akurasi yang tinggi, sehingga dianggap cocok untuk digunakan dalam analisis sentimen berdasarkan media sosial [4].

Meskipun banyak penelitian tentang analisis sentimen yang berbasis media sosial telah banyak dilakukan, sebagian besar dari penelitian tersebut hanya membahas bencana banjir secara umum atau menggunakan platform media sosial selain Platform X. Selain itu, penelitian yang secara khusus menggali sentimen publik di Platform X mengenai bencana banjir bandang di Sumatra masih terbatas. Sebelum proses klasifikasi dilakukan, data teks akan melalui tahap pembobotan fitur menggunakan metode *Term Frequency-Inverse Document Frequency* (TF-IDF). TF-IDF merupakan metode ekstraksi fitur yang digunakan untuk menentukan tingkat kepentingan suatu kata dalam sekumpulan dokumen dengan memberikan bobot lebih tinggi pada kata yang sering muncul pada suatu dokumen, tetapi jarang ditemukan pada dokumen lainnya. Berdasarkan kekurangan dalam penelitian

tersebut, penelitian ini dilakukan untuk menganalisis sentimen publik di Platform X (Twitter) terkait bencana banjir bandang di Sumatra dengan menggunakan algoritma *Support Vector Machine* (SVM), dengan tujuan memberikan gambaran yang objektif tentang pandangan masyarakat serta melengkapi penelitian sebelumnya dalam bidang analisis sentimen bencana banjir. [5]

2. Metodologi

Metode penelitian ini dijelaskan untuk menganalisis sentimen opini publik terhadap bencana banjir bandang di Pulau Sumatra. Metode penelitian ini dirancang untuk mengolah data teks dari opini publik yang diambil dari Platform X secara sistematis, dimulai dari pengumpulan data hingga penilaian hasil klasifikasi. Pendekatan *machine learning* digunakan dalam penelitian ini untuk mengklasifikasi sentimen publik ke dalam penelitian tertentu. Diagram berikut pada Gambar 1 menunjukkan alur metode penelitian tersebut.



Gambar 1. Diagram Alur Penelitian

Dapat dilihat pada Gambar 1 diatas alur penelitian dimulai dengan pengumpulan data berupa pendapat masyarakat dari platform X. Setelah itu, dilakukan tahap preprocessing, yang mencakup cleaning, case folding, normalisasi, tokenizing, stopword, dan stemming untuk mempersiapkan data. Selanjutnya, data tersebut diberi label sentimen, diubah menjadi format numerik menggunakan pendeketakan TF-IDF, dan dipisahkan menjadi dataset untuk pelatihan dan pengujian. Model klasifikasi dibentuk dengan menerapkan algoritma SVM pada data pelatihan, yang kemudian dievaluasi menggunakan data pengujian untuk mengukur kinerjanya.

A. Pengumpulan Data

Pengumpulan data dalam penelitian ini bertujuan untuk mendapatkan pandangan masyarakat mengenai bencana banjir bandang di Pulau Sumatra melalui platform X. Data yang digunakan adalah data sekunder yang berupa tweet dengan kata kunci yang berhubungan dengan banjir bandang. Pengumpulan data dilakukan dengan metode crawling, yaitu cara pengambilan data publik secara otomatis berdasarkan kata kunci tertentu guna mendapatkan informasi dengan cara yang efisien dan terstruktur [6][7]. Proses Crawling menggunakan Python di Google Colab dengan Tweet Harvest, Proses crawling dilakukan pada rentang waktu 25 November 2025 hingga 4 Januari 2026, sehingga data yang dihasilkan mencerminkan respons masyarakat selama bencana tersebut. Data yang diperoleh kemudian digunakan untuk analisis sentimen.

B. Preprocessing Data

Pada tahap preprocessing ini dilakukan untuk mempersiapkan data teks sebelum dianalisis dengan menghilangkan elemen yang tidak penting. Proses ini mencakup cleaning, case folding, normalisasi, tokenization, stopword removal, dan stemming yang dilakukan secara berurutan untuk menghasilkan data yang lebih terstruktur dan bersih.

1. Cleaning

Tahap cleaning adalah langkah pertama dalam preprocessing yang bertujuan untuk menghilangkan bagian-bagian teks yang tidak berkaitan dengan analisis sentimen. Pada fase ini, elemen-elemen seperti karakter non-alfabet, tanda baca, angka, URL, tagar, nama pengguna, dan simbol lainnya dihapus untuk mengurangi noise dan memastikan data hanya berisi informasi yang relevan [8]. Proses ini sangat penting agar hasil pengolahan teks menjadi lebih baik dan tidak mempengaruhi performa model klasifikasi di tahap berikutnya.

2. Case Folding

Tahap case folding adalah proses yang mengkonversi semua huruf dalam teks menjadi huruf kecil untuk memastikan konsistensi data [9]. Tujuan dari langkah ini adalah untuk mencegah variasi dalam representasi kata karena penggunaan huruf kapital, sehingga kata-kata yang memiliki arti serupa, seperti "Banjir" dan "banjir",

dianggap sebagai bentuk yang sama dalam analisis sentimen.

3. Normalisasi

Tahap normalisasi memiliki tujuan untuk memperbaiki kata-kata yang tidak sesuai standar, singkatan, atau bentuk tidak resmi menjadi kata-kata yang telah sesuai menurut aturan bahasa Indonesia [8]. Proses ini dilakukan dengan bantuan kamus kata baku yang diambil dari daftar list kata baku pada github berikut https://github.com/analysisdatasentiment/kamus_kata_baku.git untuk menyamakan berbagai variasi penulisan, contohnya "banjiiirr", "gk", dan "tdk" diubah menjadi "banjir" dan "tidak". Melalui normalisasi, data menjadi lebih seragam sehingga analisis sentimen dapat dilakukan dengan lebih mudah.

4. Tokenizing

Tahap tokenisasi adalah langkah di mana teks dipecah menjadi bagian-bagian kecil yang disebut kata atau token [9]. Pemisahan ini dilakukan dengan memperhatikan spasi atau tanda tertentu sehingga menghasilkan sekumpulan kata yang memudahkan untuk analisis dan pengolahan pada langkah berikutnya, seperti stopword dan stemming.

5. Stopword Removal

Tahap stopword removal bertujuan untuk menghapus istilah-istilah biasa yang tidak memberikan dampak berarti pada arti sentimen, seperti "dan", "yang", "di", "ke", dan "dari" [9]. Proses ini dilakukan untuk mengurangi dimensi data dan mengarahkan analisis pada kata-kata yang lebih bermakna, sehingga meningkatkan kinerja model klasifikasi.

6. Stemming

Tahap stemming adalah langkah untuk mengubah kata-kata yang memiliki imbuhan menjadi bentuk aslinya dengan cara menghapus awalan, sisipan, dan akhiran [9]. Tujuan dari langkah ini adalah untuk menyatukan variasi kata yang memiliki arti serupa, misalnya "terendam", "merendam", dan "perendaman" menjadi "rendam", sehingga hal ini dapat meningkatkan konsistensi data dan ketepatan dalam analisis sentimen.

C. Pelabelan Data (Labeling)

Pelabelan data dilakukan dengan menerapkan metode lexicon-based yaitu suatu pendekatan yang memanfaatkan kamus sentimen berisi kata-kata positif dan negatif untuk menetapkan polaritas dari teks [10]. Dalam penelitian ini, kamus yang dipakai diambil dari repositori GitHub <https://github.com/fajri91/InSet.git>. Langkah pelabelan ini dilakukan dengan mencocokkan kata-kata di dalam teks dengan kamus lexicon, selanjutnya menghitung total nilai sentimen untuk menentukan label. Hasil dari pelabelan ini dijadikan sebagai dasar dalam proses klasifikasi sentimen pada tahap berikutnya.

D. Pembobotan TF-IDF

Tahap pembobotan TF-IDF dilakukan untuk mengkonversi teks menjadi format numerik sehingga dapat ditangani oleh algoritma klasifikasi seperti SVM. TF-IDF menilai seberapa pentingnya suatu kata dalam dokumen dengan mengaitkan jumlah kemunculan kata (TF) dan kebalikan dari jumlah dokumen yang berisi kata



tersebut (IDF) [5]. Berikut adalah rumus untuk menghitung TF-IDF:

$$W_{dt} = TF_{dt} \times IDF_{ft} + 1$$

Keterangan:

W_{dt} = bobot dokumen ke-d terhadap kata ke-t

W_{dt} = banyaknya kata yang dicari pada sebuah dokumen

W_{dt} = Inversed Document Frequency $\left(\log\left(\frac{N}{df}\right)\right)$

N = total dokumen

df = banyak dokumen yang mengandung kata yang dicari

Dengan cara ini, kata-kata yang memberikan informasi lebih akan memiliki nilai yang lebih besar, sehingga hasil dari pembobotan tersebut dapat dimanfaatkan sebagai landasan dalam proses distribusi data dan pengembangan model klasifikasi.

E. Pembagian Data

Setelah data teks diubah menjadi bentuk numerik dengan metode TF-IDF, langkah berikutnya adalah membagi data. Data tersebut dibagi menjadi dua bagian, menjadi data pelatihan dan data pengujian, untuk memastikan bahwa proses pelatihan dan pengujian model berlangsung secara terpisah. Pembagian ini penting agar kemampuan model bisa dinilai secara adil menggunakan data yang tidak pernah digunakan selama pelatihan [11].

F. Klasifikasi Support Vector Machine (SVM)

Pada langkah ini, data pelatihan dimanfaatkan untuk mengembangkan model klasifikasi sentimen dengan menggunakan algoritma Support Vector Machine (SVM), yang merupakan teknik pembelajaran terawasi yang dapat mengatasi klasifikasi data baik yang linear maupun non-linear [12]. Berikut adalah rumus untuk menghitung SVM:

$$F(x) = w \cdot x + b$$

Keterangan:

w = vektor bobot

b = bias

x = vektor fitur data

SVM dipilih karena kemampuannya yang baik dalam mengolah data berdimensi tinggi seperti teks. Model yang telah dibuat selanjutnya digunakan untuk mengklasifikasikan data pengujian ke dalam kelompok sentimen sebagai persiapan untuk tahap evaluasi.

G. Evaluasi Model

Evaluasi terhadap model dilakukan untuk menilai kinerja dari klasifikasi sentimen dengan memanfaatkan confusion matrix, yang merupakan tabel untuk menilai seberapa baik model dalam mengklasifikasikan data dengan benar atau salah [13]. Terdapat empat elemen utama dalam confusion matrix yang dapat dilihat pada tabel 1 berikut:

Tabel 1 Confusion Matrix

Actual Values	Predicted Values	
	Positive (0)	Negative (1)
Positive (0)	TP	FP
Negative (1)	FN	TN

Dari confusion matrix, performa model diukur dengan menggunakan metrik akurasi, presisi, recall, dan F1-score, yang menunjukkan seberapa baik model dalam mengklasifikasikan sentimen secara akurat sebelum melanjutkan ke analisis lebih mendalam. Berikut rumus perhitungannya:

$$Accuracy : \frac{(TP+TN)}{TP+TN+FP+FN}$$

$$Precision : \frac{TP}{TP+FP}$$

$$Recall : \frac{TP}{TP+FN}$$

$$F1 - Score : 2 \times \frac{Precision \times Recall}{Precision+Recall}$$

3. Hasil dan Pembahasan

A. Hasil Pengujian

1. Dataset

Pada penelitian ini proses pengumpulan data dilakukan menggunakan tools Google Colaburatory dengan query “banjir bandang sumatra”, limit data sebesar 2800 data, dan language “id”. Data yang di dapat pada saat proses crawling yaitu 2448 data dan total keseluruhan data akhir 2399.

Tabel 2 Dataset

Query	Data Crawling	Data Akhir
Banjir bandang sumatra	2448	2439

2. Preprocessing Data


Preprocessing data adalah tahap awal yang bertujuan untuk meningkatkan kualitas data teks sebelum melakukan analisis. Proses yang dilakukan mencakup cleaning, case folding, normalisasi, tokenizing, stopword removal, dan stemming. Setiap langkah ditujukan untuk menghapus noise, menyamakan bentuk kata, serta menyederhanakan format teks agar data menjadi lebih seragam dan mewakili untuk tahap klasifikasi.

3. Pelabelan Data

Pada proses pelabelan sentimen, data yang sudah melewati tahap preprocessing selanjutnya dikategorikan



menjadi dua jenis sentimen, yaitu positif dan negatif. Tujuan dari pelabelan ini adalah untuk memahami arah opini atau reaksi dari pengguna mengenai topik yang diteliti. Dengan pelabelan sentimen, data dapat dianalisis untuk mengidentifikasi sentimen yang paling mendominasi dalam kumpulan tweet yang telah dikumpulkan.



Gambar 2. Pelabelan Positif dan negatif

Hasil analisis menunjukkan bahwa sentimen negatif lebih banyak muncul dengan total 1740 data (71,34%), sementara sentimen positif berjumlah 699 data (28,66%). Ini menandakan bahwa pandangan masyarakat terhadap masalah yang ditelaah lebih banyak bersifat negatif.

4. Pembobotan TF-IDF

Setelah melakukan tahapan preprocessing, data teks selanjutnya diproses dengan menggunakan pendekatan TF-IDF (Term Frequency–Inverse Document Frequency). Pendekatan ini digunakan untuk menilai seberapa penting suatu kata dalam rangkaian dokumen atau teks yang sedang dianalisis. TF-IDF berfungsi dengan menghitung frekuensi kemunculan sebuah kata di dalam dokumen serta mempertimbangkan jarangness kata tersebut muncul di seluruh dokumen. Nilai TF-IDF yang lebih tinggi untuk suatu kata menunjukkan bahwa kata itu dianggap semakin signifikan atau lebih mewakili topik yang sedang dibahas dalam data.

Tabel 3 Hasil Pembobotan TF-IDF


No	Kata	Nilai TF-IDF
1	sumatra	0.059746
2	banjir	0.058320
3	bencana	0.034918
4	korban	0.033709
5	aceh	0.033366
6	bantu	0.029699
7	perintah	0.026622
8	longsor	0.024506
9	warga	0.020679

10	dampak	0.020503
----	--------	----------

Berdasarkan nilai TF-IDF, kata "sumatra" (0,059746) dan "banjir" (0,058320) memiliki skor tertinggi, diikuti oleh kata seperti "bencana", "korban", dan "aceh". Hal ini menunjukkan bahwa kata-kata tersebut paling dominan dan relevan dalam merepresentasikan topik bencana banjir di Sumatra. Dengan demikian, TF-IDF efektif dalam mengidentifikasi kata-kata penting dalam data.

5. Pembagian Data

Setelah menyelesaikan tahap pembobotan kata dengan metode TF-IDF, langkah berikutnya adalah pemisahan data. Pemisahan data bertujuan untuk membagi dataset menjadi data pelatihan dan data pengujian. Data pelatihan dimanfaatkan oleh model untuk memahami pola dari data yang ada, sementara data pengujian digunakan untuk menilai seberapa baik model dapat melakukan prediksi pada data yang belum pernah dilihat sebelumnya.



Gambar 3 Split Data

Berdasarkan hasil pembagian data, diperoleh 1.951 data (80%) sebagai data pelatihan (*training data*) dan 488 data (20%) sebagai data pengujian (*testing data*) dari total 2.439 data. Jumlah data pelatihan yang lebih besar menunjukkan bahwa sebagian besar dataset digunakan untuk membantu algoritma Support Vector Machine (SVM) mempelajari pola sentimen yang terkandung dalam opini publik terkait bencana banjir bandang di Sumatra. Sementara itu, data pengujian digunakan untuk mengevaluasi kemampuan model dalam mengklasifikasikan data yang belum pernah diproses sebelumnya. Dengan demikian, pembagian data dengan rasio 80:20 dinilai cukup efektif karena dapat menjaga keseimbangan antara proses pembelajaran model dan proses evaluasi kinerja model.


6. Klasifikasi Support Vector Machine (SVM)

Pada tahap klasifikasi, digunakan algoritma Support Vector Machine (SVM) untuk mengelompokkan data ke dalam sentimen positif dan negatif. Model SVM dengan kernel linear dipilih karena efektif dalam menangani data berdimensi tinggi hasil pembobotan TF-IDF. Model dilatih menggunakan data training dan selanjutnya digunakan untuk memprediksi data testing guna mengukur kemampuan klasifikasi. Hasil prediksi tersebut kemudian digunakan untuk evaluasi kinerja model.

B. Pembahasan

1. Evaluasi Model Menggunakan Confusion Matrix

Pada fase evaluasi model, diterapkan confusion matrix untuk menilai performa model klasifikasi yang



Gambar 4 Confusion matrix

telah dibuat dengan metode Support Vector Machine (SVM). Confusion matrix adalah sebuah metode evaluasi yang digunakan untuk membandingkan hasil prediksi model dengan label asli pada data yang diuji. Dengan menggunakan confusion matrix, kita dapat melihat jumlah prediksi yang akurat dan yang tidak tepat, sehingga memberikan gambaran tentang kemampuan model dalam melakukan klasifikasi sentimen positif dan negatif.

Berdasarkan confusion matrix, model SVM mampu mengklasifikasikan 334 data negatif dengan benar dan 73 data positif, namun masih terdapat kesalahan klasifikasi pada 14 data negatif dan 67 data positif. Hal ini menunjukkan bahwa model lebih akurat dalam mengidentifikasi sentimen negatif. Nilai tersebut kemudian digunakan untuk menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score.

2. Accuracy

Accuracy adalah salah satu matrix evaluasi yang digunakan untuk menilai seberapa tepat model dalam mengklasifikasikan data. Angka accuracy mencerminkan jumlah data yang dapat diprediksi dengan benar oleh model dibandingkan dengan total data yang diuji. Dalam studi ini, nilai accuracy dihitung berdasarkan hasil dari confusion matrix yang diperoleh dari proses klasifikasi dengan menggunakan metode Support Vector Machine (SVM). Rumus perhitungan accuracy adalah sebagai berikut:

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

$$= \frac{(73 + 334)}{73 + 334 + 14 + 67} = \frac{407}{488} = 83,40\%$$

Hasil perhitungan tersebut menunjukkan bahwa model SVM yang digunakan dalam penelitian ini mampu mengklasifikasikan data sentimen dengan tingkat ketepatan sebesar 83,40% dari seluruh data uji yang digunakan.

3. Precision

Precision adalah salah satu ukuran yang digunakan untuk menilai seberapa tepat model dalam meramalkan kelas tertentu. Nilai dari precision mengindikasikan seberapa banyak data yang diprediksi sebagai kelas positif oleh model benar-benar merupakan bagian dari kelas positif sesuai dengan label yang benar. Ukuran ini sangat penting untuk memahami seberapa akurat model dalam membuat prediksi terhadap data yang dikategorikan sebagai positif. Rumus perhitungan precision adalah sebagai berikut:

$$\text{Precision} = \frac{TP}{TP + FP} = \frac{73}{73 + 14} = \frac{73}{87} = 83,90\%$$

Hasil perhitungan tersebut menunjukkan bahwa model SVM memiliki tingkat ketepatan sebesar 83,90% dalam memprediksi data yang termasuk ke dalam kelas sentimen positif. Hal ini berarti sebagian besar data yang diprediksi sebagai sentimen positif oleh model memang benar merupakan data dengan sentimen positif.

4. Recall

Recall adalah metrix evaluasi yang digunakan untuk menilai seberapa efektif suatu model dalam mengidentifikasi semua data yang benar-benar termasuk kategori tertentu. Nilai recall mencerminkan seberapa banyak data yang secara nyata positif dapat diprediksi dengan akurat oleh model sebagai positif. Metrik ini penting untuk memahami seberapa baik model dalam menemukan data yang berada dalam kategori positif.

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{73}{73 + 67} = \frac{73}{140} = 52,10\%$$

Hasil perhitungan tersebut menunjukkan bahwa model SVM mampu mengenali data dengan sentimen positif sebesar 52,1% dari seluruh data yang sebenarnya memiliki sentimen positif pada data uji.

5. F1-Score

Hasil perhitungan tersebut menunjukkan bahwa model SVM mampu mengenali data dengan sentimen positif sebesar 52,1% dari seluruh data yang sebenarnya memiliki sentimen positif pada data uji.

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

$$= 2 \times \frac{83,90\% \times 52,10\%}{83,90\% + 52,10\%} = 64,30\%$$

Hasil tersebut menunjukkan bahwa model SVM pada penelitian ini memiliki nilai F1-Score sebesar 64,30%. Nilai ini menggambarkan keseimbangan antara ketepatan model dalam memprediksi data positif dan kemampuan model dalam mengenali seluruh data yang termasuk dalam kelas sentimen positif.

Tabel 4 Hasil Evaluasi Model SVM

Metrix Evaluasi	Nilai
Accuracy	83,40%
Precision	83,90%
Recall	52,10%
F1-Score	64,30%

Berdasarkan tabel hasil evaluasi model yang telah disajikan, model Support Vector Machine (SVM) menunjukkan tingkat akurasi sebesar 83,40%, menunjukkan seberapa tepat model ini dalam mengklasifikasikan data secara keseluruhan. Nilai precision yang mencapai 83,90% mengindikasikan bahwa sebagian besar data yang diidentifikasi sebagai sentimen positif oleh model adalah prediksi yang akurat. Namun, nilai recall yang sebesar 52,10% menunjukkan bahwa model ini masih mengalami kesulitan dalam mengidentifikasi semua data yang seharusnya masuk dalam kategori sentimen positif. Di sisi lain, nilai F1-Score yang mencapai 64,30% menggambarkan keseimbangan antara precision dan recall dalam kinerja model klasifikasi yang diterapkan dalam penelitian ini.

6. Wordcloud Sentimen

Pada tahap ini dilakukan visualisasi data menggunakan wordcloud untuk melihat kata-kata yang paling sering muncul pada masing-masing kategori sentimen. Wordcloud merupakan teknik visualisasi teks yang menampilkan kumpulan kata dengan ukuran yang berbeda sesuai dengan tingkat kemunculannya dalam data. Semakin besar ukuran suatu kata pada wordcloud, maka semakin sering kata tersebut muncul dalam kumpulan data tweet yang dianalisis. Visualisasi ini membantu dalam memahami topik atau isu yang paling banyak dibahas oleh pengguna pada sentimen positif maupun sentimen negatif.

1) Wordcloud Sentimen Negatif



Gambar 5 Wordcloud Sentimen Negatif

Berdasarkan visualisasi wordcloud sentimen negatif pada gambar di atas, terlihat beberapa kata yang memiliki ukuran paling besar seperti “banjir”, “sumatra”, “bencana”, “korban”, dan “bantu”. Hal ini menunjukkan bahwa kata-kata tersebut merupakan kata yang paling sering muncul pada tweet dengan sentimen negatif. Kemunculan kata-kata tersebut mengindikasikan bahwa banyak pengguna media sosial membahas mengenai peristiwa banjir yang terjadi di wilayah Sumatra serta

dampak yang ditimbulkan seperti korban dan kerusakan yang terjadi. Selain itu terdapat juga kata-kata lain seperti “warga”, “perintah”, “dampak”, dan “longsor” yang menggambarkan kondisi bencana serta respon masyarakat terhadap peristiwa tersebut.

2) Wordcloud Sentimen Positif



Gambar 6 Wordcloud Sentimen Positif

Berdasarkan visualisasi wordcloud sentimen positif pada gambar di atas, terlihat kata-kata yang sering muncul seperti “banjir”, “sumatra”, “bantu”, “aceh”, dan “bencana”. Kata-kata tersebut menunjukkan bahwa banyak tweet dengan sentimen positif yang membahas tentang bantuan, dukungan, dan respon terhadap bencana banjir yang terjadi. Selain itu terdapat juga kata-kata seperti “perintah”, “tangan”, “doa”, dan “pulih” yang menunjukkan adanya harapan, dukungan, serta upaya pemulihan terhadap wilayah yang terdampak bencana. Hal ini menggambarkan bahwa meskipun terdapat banyak pembahasan mengenai bencana, sebagian pengguna media sosial juga memberikan dukungan serta solidaritas kepada masyarakat yang terdampak.

4. Kesimpulan

Berdasarkan hasil penelitian, analisis sentimen terhadap opini publik di Platform X mengenai bencana banjir bandang di Sumatra menunjukkan dominasi sentimen negatif sebesar 71,34%. Metode TF-IDF berhasil mengidentifikasi kata-kata penting yang merepresentasikan topik pembahasan, sementara algoritma Support Vector Machine (SVM) dengan kernel linear mampu mengklasifikasikan data dengan cukup baik. Hasil evaluasi menunjukkan nilai accuracy sebesar 83,40%, precision 83,90%, recall 52,10%, dan F1-score 64,30%. Hal ini menunjukkan bahwa model memiliki kinerja yang baik dalam klasifikasi secara umum, namun masih perlu peningkatan dalam mengenali data sentimen positif. Secara keseluruhan, penelitian ini membuktikan bahwa analisis sentimen berbasis machine learning dapat digunakan untuk memahami persepsi masyarakat terhadap suatu peristiwa melalui media sosial.

5. Daftar Pustaka

- [1] A. Saputra, I. Nurdiani, U. S. Nurhidayah, and S. Maesaroh, "Analisis Sentimen Masyarakat Terhadap Penanganan Banjir Bandang di Pulau Sumatra Berdasarkan Komentar Youtube Menggunakan Metode Support Vector Machine

- (SVM),” *JURNAL ILMIAH MULTIDISIPLIN*, vol. 2, no. 1, Jan. 2026, doi: 10.63822/8d1vka43.
- [2] A. M. Maksun, Y. A. Sari, and B. Rahayudi, “Analisis Sentimen pada Twitter Bencana Alam di Kalimantan Selatan menggunakan Metode Naïve Bayes,” *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 12, pp. 5614–5621, Dec. 2021.
- [3] I. Amelia, F. M. Sarimole, and Tundo, “Analisis Sentimen Tanggapan Pengguna Media Sosial X Terhadap Program Beasiswa KIP-Kuliah dengan Menggunakan Algoritma Support Vector Machine (SVM),” *Jurnal Indonesia: Manajemen Informatika dan Komunikasi*, vol. 5, no. 3, Sep. 2024, [Online]. Available: <https://journal.stmiki.ac.id>
- [4] D. S. Sarassati and S. Y. J. Prasetyo, “Analisis Sentimen Terhadap Dampak Banjir Rob Dengan Menggunakan Metode Support Vector Machine,” *IT-Explore: Jurnal Penerapan Teknologi Informasi dan Komunikasi*, vol. 4, no. 2, pp. 233–244, 2025.
- [5] N. Hidayah and Dodiman, “Implementasi Algoritma Multinomial Naïve Bayes, TF-IDF dan Confusion Matrix dalam Pengklasifikasian Saran Monitoring dan Evaluasi Mahasiswa Terhadap Dosen Teknik Informatika Universitas Dayanu Ikhsanuddin,” *Jurnal Akademik Pendidikan Matematika*, vol. 10, no. 1, pp. 8–15, May 2024, doi: 10.55340/japm.v10i1.1491.
- [6] N. H. Wardani, E. Susilo, P. Purwanti, A. D. Sulistyono, and D. Wijanarko, “Implementasi Web Crawling Untuk Mengumpulkan Tweets Terkait Produk Perikanan Olahan Yang Diminati Masyarakat,” *Journal of Fisheries and Marine Research*, vol. 7, Aug. 2023, [Online]. Available: <http://jfmr.ub.ac.id>
- [7] R. D. R. Hendrartono, I. M. Hendrati, and W. Wardaya, “Implementasi Web Crawling Pada Website BPS Jawa Timur Pada Data Inflasi Di Jawa Timur,” *UMAT Jurnal Pengabdian Al-Shobar Untuk Masyarakat*, vol. 1, no. 2, pp. 6–13, Apr. 2024, [Online]. Available: <https://journal.alshobar.or.id/index.php/umat>
- [8] S. Shevira, I. M. A. D. Suarjaya, and P. W. Buana, “Pengaruh Kombinasi dan Urutan Pre-Processing pada Tweets Bahasa Indonesia,” *JITTER-Jurnal Ilmiah Teknologi dan Komputer*, vol. 3, no. 2, Aug. 2022.
- [9] Regina, T. H. Saragih, and D. Kartini, “Analisis Sentimen Brand Ambassador BTS Terhadap Tokopedia Menggunakan Klasifikasi Bayesian Network Dengan Ekstraksi Fitur TF-IDF,” *JIP (Jurnal Informatika Polinema)*, vol. 9, no. 4, Aug. 2023.
- [10] M. Al Khadafi, K. P. Kartika, and F. Febrinita, “Penerapan Metode Naïve Bayes Classifier Dan Lexicon Based Untuk Analisis Sentimen Cyberbullying Pada BPJS,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 6, no. 2, Sep. 2022.
- [11] K. Shah, S. Shah, V. Shah, and A. Godbole, “Optimization Of Data Splitting Methods For Machine Learning,” *Proceedings of the International Conference on Innovative Computing & Communication (ICICC)*, Mar. 2025, [Online]. Available: <https://ssrn.com/abstract=5190348>
- [12] M. R. Givari, M. R. Sulaeman, and Y. Umaidah, “Perbandingan Algoritma SVM, Random Forest Dan XGBoost Untuk Penentuan Persetujuan Pengajuan Kredit,” *JURNAL NUANSA INFORMATIKA*, vol. 16, no. 1, Jan. 2022.
- [13] Kevin, M. Enjeli, and A. Wijaya, “Analisis Sentimen Penggunaan Aplikasi Kinemaster Menggunakan Metode Naive Bayes,” *Jurnal Ilmiah Computer Science (JICS)*, vol. 2, no. 2, pp. 89–98, Jan. 2024, doi: 10.58602/jics.v2i2.24.

