

IMPLEMENTASI LSTM UNTUK ANALISIS SENTIMEN PERSEPSI MASYARAKAT TERHADAP BANJIR SUMATERA 2025 DI YOUTUBE

Kunti Najma Jalia^{1*}, Adi Suwondo²

Universitas Sains Al-Quran, Kabupaten Wonosobo, Indonesia¹

Email*: najmajalia@mhs.unsiq.ac.id

Universitas Sains Al-Quran, Kabupaten Wonosobo, Indonesia²

Email: adisuwondo@unsiq.ac.id

(*) *Corresponding Author*

ABSTRAK

Banjir Bandang Sumatera 2025 memicu diskursus publik yang luas di media sosial terkait penyebab bencana, khususnya antara faktor alam dan faktor manusia. Persepsi publik terhadap kausalitas bencana menjadi penting untuk dipahami sebagai dasar evaluasi literasi kebencanaan dan strategi komunikasi mitigasi. Penelitian ini bertujuan untuk menganalisis persepsi masyarakat terhadap penyebab Banjir Bandang Sumatera 2025 menggunakan pendekatan analisis sentimen berbasis algoritma *Long Short-Term Memory* (LSTM) pada data komentar YouTube. Sebanyak 15.259 komentar dikumpulkan menggunakan YouTube Data API, kemudian diproses melalui tahap preprocessing dan pelabelan otomatis berbasis leksikon. Data akhir sebanyak 11.043 komentar digunakan untuk pelatihan dan pengujian model. Hasil eksperimen menunjukkan bahwa model LSTM mencapai akurasi sebesar 96,29% dengan nilai ROC-AUC sebesar 0,99. Analisis distribusi sentimen mengungkapkan dominasi narasi Faktor Manusia sebesar 57% dibandingkan Faktor Alam/Doa sebesar 43%. Temuan ini menunjukkan meningkatnya kesadaran kritis publik terhadap peran manusia dan tata kelola lingkungan dalam risiko bencana. Penelitian ini memberikan kontribusi empiris dalam pemetaan persepsi publik berbasis data media sosial dan menunjukkan bahwa pendekatan LSTM efektif untuk analisis sentimen kebencanaan berbahasa Indonesia.

Kata kunci: Analisis bencana, analisis sentimen, komentar youtube, *Long Short-Term Memory*, penambangan media sosial.

ABSTRACT

Sumatra Flash Flood triggered extensive public discussion on social media regarding the causes of the disaster, particularly between natural factors and human factors. Understanding public perception is important for evaluating disaster literacy and mitigation communication strategies. This study analyzes public perceptions of the disaster's causes using sentiment analysis based on the Long Short-Term Memory (LSTM) algorithm applied to YouTube comments. A total of 15,259 comments were collected using the YouTube Data API and processed through data cleaning and lexicon-based automatic labeling. After data selection, 11,043 comments were used for model training and testing. The experimental results show that the LSTM model achieved an accuracy of 96.29% and a ROC-AUC value of 0.99. Sentiment distribution analysis indicates that 57% of comments emphasize human factors, while 43% highlight natural factors or religious interpretations. These findings suggest an increasing public

awareness of the human role in disaster risk and demonstrate the effectiveness of LSTM for Indonesian-language disaster sentiment analysis.

Keywords: Disaster analysis, Long Short-Term Memory, sentiment analysis, social media mining, youtube comments.

1. PENDAHULUAN

Banjir bandang dan tanah longsor di Sumatera pada akhir tahun 2025 menjadi tragedi hidrometeorologi terbesar dalam satu dekade terakhir dengan dampak katastrofik [1]. Data BNPB per 13 Desember 2025 mencatat 1.006 korban jiwa, 217 orang dinyatakan hilang, serta 654.652 penduduk mengungsi akibat anomali cuaca yang dipicu oleh Siklon Tropis Senyar, dengan intensitas curah hujan ekstrem melebihi 300 mm per hari [2]. Degradasi ekosistem hulu Daerah Aliran Sungai (DAS) turut memperparah intensitas bencana hingga melumpuhkan infrastruktur di tiga provinsi terdampak [3].

Skala bencana tersebut memicu lonjakan atensi publik di media sosial, khususnya YouTube, yang bertransformasi menjadi ruang dialektika sosial berskala masif [4]. Ribuan interaksi digital merekam polarisasi persepsi publik mengenai kausalitas bencana, yang terbelah antara narasi teologis berbasis takdir dan narasi antropogenik yang menyoroti kelalaian manusia serta degradasi lingkungan [5], [6]. Analisis terhadap dinamika sentimen ini menjadi krusial untuk memetakan literasi kebencanaan masyarakat sebagai dasar evaluasi kebijakan mitigasi bencana di masa mendatang.

Pendekatan komputasi berbasis *Machine Learning* telah banyak digunakan dalam analisis sentimen kebencanaan selama satu dekade terakhir. Tinjauan sistematis terhadap 139 studi menunjukkan bahwa algoritma konvensional, seperti *Support Vector Machine* (SVM) dan *Naïve Bayes*, masih mendominasi karena efisiensi komputasinya pada dataset berskala moderat [7]. Studi terdahulu membuktikan efektivitas SVM dalam mengidentifikasi kebutuhan darurat pascagempa secara cepat [8]. Kinerja pendekatan tersebut menurun ketika diterapkan pada data media sosial yang bersifat informal, tidak terstruktur, dan mengandung ambiguitas makna [9], [10]. Ketergantungan pada fitur leksikal sederhana membatasi kemampuan model dalam memahami konteks komunikasi krisis.

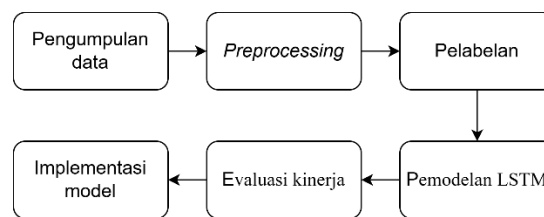
Keterbatasan tersebut terutama muncul karena model konvensional tidak mampu menangkap konteks kalimat dan hubungan antar kata dalam teks panjang [11]. Penelitian terdahulu menunjukkan bahwa pada arus informasi bencana yang cepat dan tumpang tindih, pendekatan berbasis pencocokan kata sering gagal membedakan fakta dan opini ambigu [12]. Studi lain menekankan bahwa emosi publik dalam situasi krisis memiliki kompleksitas tinggi yang sulit dimodelkan dengan metode tradisional [13]. Kesenjangan metodologis tersebut mendorong penerapan arsitektur *Deep Learning* berbasis *Long Short-Term Memory* (LSTM), yang dirancang untuk memodelkan dependensi jangka panjang dalam data teks [14].

Penelitian analisis sentimen kebencanaan masih didominasi oleh pendekatan evaluatif sederhana yang mengklasifikasikan opini publik ke dalam kategori positif dan negatif [15]. Kerangka tersebut belum mampu merepresentasikan persepsi publik dalam dimensi kausal yang menjelaskan penyebab bencana secara eksplisit. Pemisahan antara narasi teologis (faktor takdir atau alam) dan narasi antropogenik (faktor manusia) yang menekankan peran manusia masih jarang dikaji secara sistematis, khususnya pada data komentar YouTube yang bersifat naratif dan argumentatif. Ketiadaan pemetaan persepsi kausal pada platform tersebut menunjukkan adanya kesenjangan penelitian dalam kajian kebencanaan berbasis data media sosial.

Penelitian ini bertujuan untuk mengimplementasikan pendekatan *Deep Learning* berbasis *Long Short-Term Memory* (LSTM) dalam mengklasifikasikan persepsi publik terhadap penyebab Banjir Bandang Sumatera 2025 serta mengukur kinerja model melalui evaluasi akurasi klasifikasi. Analisis difokuskan pada pemisahan atribusi kausal antara faktor alam dan faktor manusia berdasarkan data komentar YouTube. Hasil penelitian diharapkan memberikan kontribusi empiris berupa pemetaan dominasi opini publik berbasis data yang dapat dimanfaatkan oleh pemangku kebijakan dalam merumuskan strategi komunikasi mitigasi bencana yang lebih adaptif dan responsif. Kontribusi ini memiliki relevansi terhadap *Sustainable Development Goals* (SDGs) poin 11 dan 13, serta selaras dengan arah kebijakan nasional dalam Asta Cita terkait penguatan ketahanan bencana dan tata kelola lingkungan.

2. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental untuk mengembangkan model klasifikasi sentimen berbasis *Deep Learning*. Kerangka metodologis mencakup enam tahapan utama: pengumpulan data, *preprocessing*, pelabelan, pemodelan LSTM, evaluasi kinerja, dan implementasi model ke dalam sistem berbasis *website*. Gambar 1 mengilustrasikan alur metodologi penelitian secara keseluruhan.



Gambar 1. Diagram alur metodologi

Pengumpulan Data

Data penelitian dikumpulkan dari *platform* YouTube menggunakan YouTube Data API v3. Proses scraping dilakukan pada 10 video yang membahas bencana Banjir Bandang Sumatera 2025 dari lembaga terpercaya, mencakup video dari berbagai perspektif untuk memastikan keragaman opini. Total data mentah yang berhasil dikumpulkan sebanyak 15.259 komentar yang mencakup atribut *video_id*, *username*, tanggal publikasi, jumlah *likes*, dan teks komentar asli. Data dikumpulkan pada periode November hingga Desember 2025, dengan rentang waktu publikasi video yang mencakup fase awal bencana hingga periode respons darurat

Preprocessing Data

Tahap *preprocessing* bertujuan untuk membersihkan dan menormalisasi data teks agar sesuai untuk pemodelan. *Pipeline preprocessing* terdiri dari enam tahapan yang dilakukan secara sekuensial:

1. *Case Folding*: Konversi seluruh teks ke huruf kecil untuk menghilangkan variasi kapitalisasi.
2. *Noise Removal*: Penghapusan elemen non-tekstual meliputi URL, *mention* (@username), *hashtag* (#), alamat email, dan emoji.
3. *Punctuation & Number Removal*: Eliminasi tanda baca dan angka yang tidak berkontribusi pada makna sentimen.

4. *Slang Normalization*: Normalisasi bahasa gaul dan singkatan media sosial Indonesia menggunakan kamus khusus (contoh: “yg” → “yang” dan “ga” → “tidak”).
5. *Stemming*: Reduksi kata ke bentuk dasar menggunakan library Sastrawi untuk bahasa Indonesia.
6. *Duplicate Removal*: Eliminasi komentar duplikat untuk menghindari bias dalam pelatihan model.

Tahapan *preprocessing* ini penting untuk memastikan konsistensi analisis dan membersihkan data dari unsur yang tidak relevan seperti yang diterapkan pada penelitian sentimen Bahasa Indonesia sebelumnya [16], [17]. Tabel 1 menunjukkan contoh transformasi teks sebelum dan sesudah *preprocessing*.

Tabel 1. Contoh hasil *preprocessing*

Teks asli	Teks setelah <i>preprocessing</i>
Hutan gundul krn tambang ilega!!! 😞	hutan gundul karena tambang ilegal
Semoga yg terkena bencana diberi kesabaran 🙏	moga yang kena bencana beri sabar

Pelabelan Otomatis

Berbeda dengan analisis sentimen konvensional yang hanya mengukur polaritas emosi, penelitian ini menerapkan pendekatan pelabelan berbasis Atribusi Kausalitas Bencana. Pendekatan ini bertujuan memetakan persepsi publik ke dalam dua dimensi kognitif utama mengenai penyebab bencana. Proses pelabelan dilakukan menggunakan teknik *Lexicon-Based Scoring* dengan taksonomi yang dikembangkan khusus untuk konteks sosiologi bencana:

1. Manusia Kelas Narasi Antropogenik (Faktor Manusia)
Label ini diberikan pada komentar yang mengatribusikan penyebab bencana kepada aktivitas manusia, kelalaian struktural, atau kebijakan.
2. Kelas Narasi Teologis (Faktor Alam/Doa)
Label ini diberikan pada komentar yang mengatribusikan bencana sebagai peristiwa eksternal (takdir/ujian) atau respons empati religius.

Secara matematis, proses penentuan label dilakukan dengan menghitung bobot skor kumulatif kata kunci yang muncul dalam setiap dokumen komentar. Bobot skor atribusi Antropogenik atribusi Teologis dihitung menggunakan Persamaan (1) dan (2).

$$S_{antro} = \sum_{\omega \in C} count(\omega \in L_{antro}) \quad (1)$$

$$S_{teo} = \sum_{\omega \in C} count(\omega \in L_{teo}) \quad (2)$$

Dimana merepresentasikan setiap kata (token) dalam komentar, sedangkan dan adalah himpunan kata kunci untuk masing-masing kategori. Penentuan label akhir untuk setiap komentar didasarkan pada fungsi keputusan (*decision function*) pada Persamaan (3).

$$Y(C) = \begin{cases} \text{Faktor Manusia, if } S_{antro} \geq S_{teo} \\ \text{Faktor Alam/Doa, otherwise} \end{cases} \quad (3)$$

Model ini memprioritaskan label Faktor Manusia saat skor seimbang dengan mengadopsi konsep *Information Utility*, di mana atribusi kelalaian manusia dikategorikan sebagai *actionable information* yang mendesak untuk mitigasi, sedangkan narasi teologis cenderung bersifat *non-actionable*. Strategi ini krusial mengingat atribusi semata pada takdir dapat melemahkan resiliensi masyarakat [18], serta merespons pola politisasi elit yang kerap menyalahkkan faktor alam untuk menutupi kegagalan tata kelola [19].

Arsitektur Model LSTM

Arsitektur *Long Short-Term Memory* (LSTM) dipilih karena kemampuannya dalam memodelkan dependensi jangka panjang pada data sekuensial. Model dibangun menggunakan TensorFlow/Keras dengan total 1.080.602 parameter yang dapat dilatih. Arsitektur terdiri dari empat lapisan: (1) *Embedding layer* dengan dimensi 100 dan kosakata maksimum 10.000 kata (1.000.000 parameter) untuk merepresentasikan kata dalam ruang vektor padat (*dense vector*); (2) *SpatialDropout1D* dengan rate 0,2 untuk mencegah *overfitting* pada fitur *embedding*; (3) LSTM layer dengan 100 unit neuron (80.400 parameter), dropout 0,2, dan *recurrent_dropout* 0,2 sebagai ekstraktor fitur sekuensial yang mempelajari urutan dan konteks kalimat; (4) Dense layer dengan 2 unit dan aktivasi *softmax* (202 parameter) untuk klasifikasi biner. Panjang sekuens input ditetapkan pada 100 token dengan teknik padding untuk menyeragamkan dimensi input. Tabel 2 menyajikan detail arsitektur model beserta jumlah parameter pada setiap lapisan.

Tabel 2. Arsitektur model LSTM

Layer	Output shape	Parameter
<i>Embedding</i>	(None, 100, 100)	1.000.000
<i>SpatialDropout1D</i>	(None, 100, 100)	0
LSTM	(None, 100)	80.400
<i>Dense (Softmax)</i>	(None, 2)	202
Total	-	1.080.602

Konfigurasi Training

Proses pelatihan (*training*) model dikonfigurasi dengan parameter sebagai berikut: *optimizer* Adam dengan *learning rate default*, *loss function categorical_crossentropy* untuk klasifikasi multi kelas, dan metrik evaluasi *accuracy*. Data dibagi dengan rasio 80:20 untuk *training* dan testing, menghasilkan 8.834 data latih dan 2.209 data uji. Hal ini diterapkan untuk memastikan distribusi kelas yang proporsional pada kedua subset.

Mekanisme *Early Stopping* diimplementasikan untuk mencegah *overfitting* dengan memantau *validation loss* (*monitor='val_loss'*, *patience=3*). Pelatihan akan berhenti secara otomatis jika *validation loss* tidak mengalami penurunan selama 3 *epoch* berturut-turut, dan bobot model terbaik akan dipulihkan. Batch size ditetapkan sebesar 64 dengan maksimum 15 *epoch*.

Metrik Evaluasi

Evaluasi kinerja model dilakukan menggunakan metrik standar klasifikasi yang meliputi:

1. Confusion Matrix

Confusion Matrix merupakan tabel representasi performa model klasifikasi yang memetakan perbandingan antara hasil prediksi sistem terhadap label aktual data.

2. Akurasi (*Accuracy*)

Akurasi mengukur rasio prediksi benar terhadap keseluruhan data komentar yang diuji. Parameter ini merepresentasikan ketepatan model membedakan komentar berisi kritik (Faktor Manusia) dan respons teologis (Faktor Alam/Doa). Perhitungan akurasi menggunakan Persamaan (4).

$$Accuracy = \frac{TP + TN}{TP + TN + FB + FN} \quad (4)$$

3. Presisi (*Precision*)

Presisi mengukur tingkat keandalan model dalam memprediksi kelas positif. Nilai ini menunjukkan persentase komentar yang benar-benar berisi kritik terhadap faktor manusia dari seluruh komentar berlabel prediksi Faktor Manusia. Presisi tinggi mengindikasikan rendahnya tingkat kesalahan positif (*False Positive*). Nilai presisi dihitung berdasarkan Persamaan (5).

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

4. Recall

Recall atau sensitivitas mengukur kemampuan model menemukan kembali informasi relevan. Metrik ini menghitung proporsi komentar kritik (Faktor Manusia) yang berhasil dikenali dari total komentar kritik aktual pada dataset. Nilai recall penting untuk memastikan opini kritis masyarakat tidak luput dari deteksi sistem. Perhitungan *recall* menggunakan Persamaan (6).

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

5. F1-Score:

F1-Score merupakan hasil rata-rata harmoni dari precision dan recall. Parameter ini mengevaluasi keseimbangan performa model, khususnya saat terdapat ketimpangan jumlah data antar kelas. *F1-Score* memastikan model memiliki kinerja optimal secara menyeluruh tanpa bias ke salah satu metrik. Nilai c diperoleh melalui Persamaan (7).

$$F1 - Score = 2x \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

6. ROC-AUC

Receiver Operating Characteristic - Area Under Curve (ROC-AUC) mengukur kemampuan diskriminatif model memisahkan kelas Faktor Manusia dan Faktor Alam pada berbagai ambang batas (*threshold*). Kurva ROC terbentuk dari perbandingan *True Positive Rate* (TPR) dan *False positive rate* (FPR).

7. Learning Curve

Learning Curve memvisualisasikan perbandingan metrik kinerja (akurasi dan *loss*) antara data latih dan data validasi di setiap *epoch*. Analisis grafik ini bertujuan mendeteksi indikasi *overfitting*, *underfitting*, serta memantau stabilitas konvergensi model selama proses pelatihan.

Implementasi Sistem

Tahap terakhir dari metodologi ini adalah implementasi model ke dalam antarmuka aplikasi berbasis *website* untuk memvalidasi kegunaan model secara praktis. Model LSTM dengan bobot terbaik akan diintegrasikan menggunakan *framework* Streamlit. Sistem dirancang untuk menerima input berupa teks komentar manual maupun tautan (URL) video YouTube yang akan diproses melalui tahapan *preprocessing* dan tokenisasi

Performa Model LSTM

Proses *training* model berhenti secara otomatis pada *epoch* ke-6 melalui mekanisme *Early Stopping*, mengindikasikan konvergensi optimal telah tercapai sebelum batas maksimum 15 *epoch*. Hal ini menunjukkan bahwa arsitektur model dan konfigurasi hyperparameter yang dipilih mampu mempelajari pola dalam data dengan efisien tanpa memerlukan iterasi berlebihan yang dapat menyebabkan *overfitting*. Evaluasi pada data uji (2.209 sampel) menghasilkan akurasi sebesar 96,29% dengan nilai *loss* 0,1191. Tabel 3 menyajikan *classification report* lengkap untuk setiap kelas

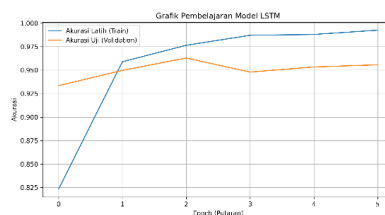
Tabel 3. *Classification report* model LSTM

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
Faktor Alam/Doa	0.95	0.96	0.95	937
Faktor Manusia	0.97	0.96	0.97	1.272
<i>Average</i>	0.96	0.96	0.96	2.209

Analisis per kelas menunjukkan bahwa model memiliki performa superior dalam mendeteksi kategori Faktor Manusia dengan *precision* 0,97 dan *F1-Score* 0,97. Tingginya skor pada kelas ini mengindikasikan bahwa narasi kritik terhadap faktor manusia memiliki pola linguistik yang sangat distingtif dan konsisten. Kata-kata seperti “tambang”, “hutan”, “gundul”, “pejabat”, dan “tanggung jawab” membentuk mudah dikenali oleh model LSTM.

Performa pada kelas Faktor Alam/Doa juga sangat baik dengan *precision* 0,95, *recall* 0,96, dan *F1-Score* 0,95. Meskipun sedikit lebih rendah dibandingkan kelas Faktor Manusia, skor ini tetap menunjukkan kemampuan model yang sangat baik dalam mengidentifikasi respons empati dan perspektif teologis. Variasi ekspresi keagamaan dan simpati yang lebih beragam dapat menjadi faktor penyebab perbedaan ini.

Analisis *Learning Curve* dan Konvergensi



Gambar 5. Grafik *learning curve* LSTM

Visualisasi *learning curve* pada Gambar 5 menunjukkan konvergensi model yang stabil dengan perbedaan kecil antara akurasi pelatihan dan validasi. Akurasi validasi tetap konsisten pada kisaran 94-96%, sementara akurasi pelatihan meningkat secara progresif. Mekanisme *Early Stopping* berhasil mencegah *overfitting* dengan memilih bobot terbaik pada *epoch* ke-3 seperti disajikan pada Gambar 6.

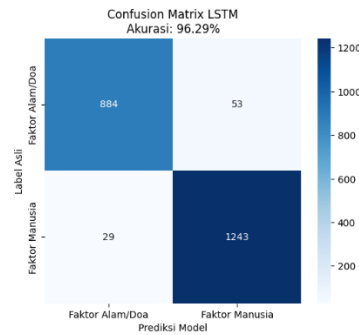
Tidak terdeteksi indikasi *overfitting* yang signifikan karena kurva *training* dan *validation* bergerak paralel tanpa divergensi yang berarti. Hal ini mengonfirmasi efektivitas mekanisme regularisasi yang diterapkan, meliputi *SpatialDropout1D* dengan *rate* 0,2 dan *recurrent dropout* pada layer LSTM. *Early Stopping* berhasil menghentikan *training* pada titik optimal sebelum model mulai menghafal *noise* dalam data *training*.



Gambar 6. Proses *training* model LSTM

Analisis Confusion Matrix

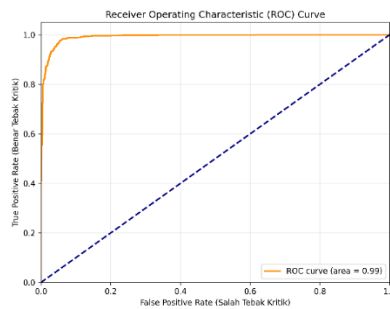
Confusion Matrix pada Gambar 7 menyajikan distribusi prediksi model terhadap masing-masing kelas dan menunjukkan kemampuan klasifikasi yang baik pada kedua kategori, ditandai oleh dominasi prediksi yang tepat pada diagonal utama matriks. Pola tersebut mengindikasikan bahwa model LSTM mampu membedakan persepsi publik antara faktor alam dan faktor manusia secara konsisten. Kesalahan prediksi yang muncul relatif terbatas dan sebagian besar dipengaruhi oleh ambiguitas semantik pada data komentar, khususnya pada narasi yang memuat unsur dari kedua kategori. Temuan ini menegaskan bahwa model mampu menangkap konteks narasi kausal secara efektif dalam analisis persepsi publik berbasis teks media sosial.



Gambar 7. *Confusion Matrix* LSTM

Analisis ROC-AUC

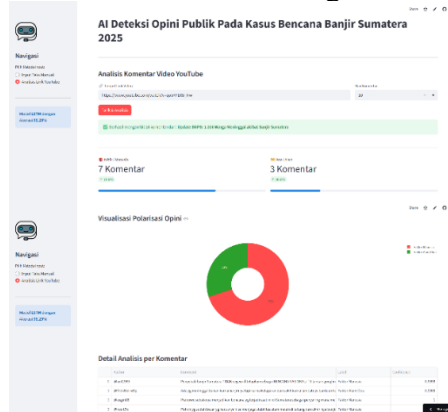
Kurva ROC-AUC pada Gambar 8 menunjukkan kemampuan diskriminatif model yang sangat baik dengan nilai AUC sebesar 0,9916. Nilai yang mendekati 1,0 ini mengindikasikan bahwa model memiliki kemampuan yang kuat dalam membedakan kedua kelas pada berbagai ambang probabilitas. Bentuk kurva yang mendekati sudut kiri atas menunjukkan bahwa model mampu mempertahankan *true positive rate* yang tinggi sekaligus menekan *false positive rate*. Nilai ROC-AUC yang tinggi ini menunjukkan stabilitas kinerja model terhadap variasi *threshold*, sehingga memberikan fleksibilitas dalam penyesuaian ambang keputusan sesuai kebutuhan sistem analisis sentimen berbasis data media sosial.



Gambar 8. Kurva ROC-AUC

Implementasi dan *Deployment* Sistem

Model LSTM yang telah dilatih diimplementasikan dalam aplikasi *website* menggunakan *framework* Streamlit dan di-*deploy* secara publik untuk mendemonstrasikan kelayakan sistem. Aplikasi mengintegrasikan model klasifikasi dan tokenizer untuk melakukan inferensi sentimen terhadap teks komentar secara *real time*, dengan optimasi kinerja melalui mekanisme *caching*.



Gambar 10. Tampilan analisis komentar video Youtube

Sistem menyediakan dua mode penggunaan, yaitu analisis komentar secara langsung dan analisis komentar dari tautan video YouTube melalui ekstraksi otomatis menggunakan YouTube Data API. Hasil analisis disajikan dalam bentuk ringkasan statistik, visualisasi interaktif, dan tabel detail komentar. Antarmuka aplikasi yang ditampilkan pada Gambar 9 dan Gambar 10 menunjukkan bahwa sistem siap digunakan sebagai alat pemantauan opini publik berbasis data media sosial.

Diskusi Temuan

Hasil penelitian menunjukkan bahwa opini publik terhadap penyebab bencana tidak bersifat tunggal, melainkan terpolarisasi antara narasi antropogenik dan teologis. Dominasi sentimen Faktor Manusia sebesar 57,0% mengindikasikan meningkatnya kesadaran masyarakat terhadap isu tata kelola lingkungan serta peran aktivitas manusia dalam memperbesar risiko bencana. Temuan ini mencerminkan kecenderungan publik untuk mengaitkan bencana dengan faktor non-alamiah dan tanggung jawab struktural.

Dari perspektif metodologis, kinerja model LSTM dengan akurasi 96,29% dan nilai AUC sebesar 0,99 menegaskan efektivitas pendekatan *Deep Learning* dalam menganalisis sentimen kausal pada data media sosial berbahasa Indonesia yang bersifat informal dan kontekstual. Tingginya nilai kinerja ini dipengaruhi oleh karakteristik klasifikasi atribusi kausal yang memiliki perbedaan linguistik yang jelas antar kelas. Narasi Faktor Manusia secara konsisten memuat kosakata kritik terhadap aktivitas antropogenik dan tata kelola lingkungan, sementara narasi Faktor Alam/Doa didominasi oleh ekspresi empati dan religiusitas, sehingga memungkinkan model membangun batas klasifikasi yang kuat.

Keunggulan LSTM juga terletak pada kemampuannya memodelkan dependensi sekuensial dan konteks naratif komentar secara utuh, yang sulit dicapai oleh metode baseline sederhana seperti Naïve Bayes atau *Support Vector Machine* (SVM). Pendekatan konvensional tersebut umumnya mengandalkan fitur leksikal independen, sehingga kurang optimal dalam menangkap relasi sebab-akibat dan nuansa makna pada teks media sosial. Meskipun demikian, beberapa kesalahan klasifikasi masih ditemukan pada

komentar dengan ambiguitas semantik atau narasi campuran, yang menunjukkan bahwa hasil ini merepresentasikan efektivitas model dalam konteks analisis kausal bencana, bukan sebagai klaim generalisasi absolut terhadap seluruh opini publik daring.

4. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa penerapan model LSTM mampu mengklasifikasikan persepsi publik terhadap penyebab Banjir Bandang Sumatera 2025 berdasarkan komentar YouTube dengan kinerja yang sangat baik, ditunjukkan oleh tingkat akurasi sebesar 96,29% serta nilai AUC yang mendekati 1. Hasil analisis juga mengungkap dominasi narasi Faktor Manusia dengan proporsi sekitar 57%, yang merepresentasikan kecenderungan persepsi dan atribusi kausal masyarakat dalam ruang diskursus media sosial, bukan klaim terhadap kebenaran kausal bencana secara empiris. Temuan ini memberikan gambaran penting mengenai pola kesadaran publik terhadap isu degradasi lingkungan dan tata kelola bencana dalam konteks komunikasi kebencanaan.

Kelebihan pendekatan ini terletak pada kemampuannya mengolah data opini berskala besar secara otomatis serta menangkap konteks sekuensial dalam teks media sosial yang bersifat informal dan naratif. Meski demikian, penelitian ini masih memiliki keterbatasan, antara lain ambiguitas semantik pada sebagian komentar, penggunaan satu platform media sosial sebagai sumber data, serta belum dimasukkannya kategori sentimen netral. Oleh karena itu, pengembangan penelitian selanjutnya dapat diarahkan pada integrasi data lintas platform, penerapan model berbasis transformer untuk meningkatkan pemahaman konteks bahasa, serta pengembangan klasifikasi multikelas agar pemetaan persepsi publik menjadi lebih komprehensif dan mendekati kondisi nyata.

5. DAFTAR PUSTAKA

- [1] Maruli, "TRAGEDI SUMATRA 2025 — 'Banjir Neraka Sumatra Pecah Rekor: Korban Lewat 700 Jiwa, 1 Juta Warga Mengungsi, Negara Dikepung Krisis!,'" Gakorpan News. [Daring]. Tersedia pada: <https://www.gakorpan.com/tragedi-sumatra-2025-banjir-neraka-sumatra-pecah-rekor-korban-lewat-700-jiwa-1-juta-warga-mengungsi-negara-dikepung-krisis>
- [2] Matius Alfons Hutajulu, "Korban Tewas Bencana Sumatera Capai 1.006 Orang, 217 Masih Hilang", detikNews. [Daring]. Tersedia pada: <https://news.detik.com/berita/d-8258300/korban-tewas-bencana-sumatera-capai-1-006-orang-217-masih-hilang>
- [3] Agungnoe, "Bencana Banjir Bandang Sumatera, Pakar UGM Sebut Akibat Kerusakan Ekosistem Hutan di Hulu DAS," Universitas Gadjah Mada. [Daring]. Tersedia pada: <https://ugm.ac.id/id/berita/bencana-banjir-bandang-sumatra-pakar-ugm-sebut-akibat-kerusakan-ekosistem-hutan-di-hulu-das/>
- [4] SINDONews, "Ketua BNPB Dikecam Publik Usai Pernyataan soal Banjir Sumatera Dianggap 'Gaduh Medsos' | The Comment," 2025. [Daring]. Tersedia pada: <https://www.youtube.com/watch?v=HKix6SrVxGM>.
- [5] Kompas.com, "Pakar ITB Ungkap Penyebab Banjir Sumatera, Termasuk Hilangnya Resapan," Youtube, 2025. [Daring]. Tersedia pada: <https://www.youtube.com/watch?v=tfJC0bn9gHs>
- [6] Narasi, "Meliput Banjir Sumatera: Air Masih Tinggi, Jalan Terputus | Mata Najwa," Mata Najwa, 2025. [Daring]. Tersedia pada: <https://www.youtube.com/watch?v=ouR11bOMzVM>
- [7] B. Ilyas dan A. Sharifi, "A systematic review of social media-based sentiment analysis in disaster risk management," Int. J. Disaster Risk Reduct., vol. 123, hlm.

- 105487, Jun 2025, doi: 10.1016/j.ijdr.2025.105487.
- [8] D. Contreras, S. Wilkinson, E. Alterman, dan J. Hervás, “Accuracy of a pre-trained sentiment analysis (SA) classification model on tweets related to emergency response and early recovery assessment: the case of 2019 Albanian earthquake,” *Nat. Hazards*, vol. 113, no. 1, hlm. 403–421, Agu 2022, doi: 10.1007/s11069-022-05307-w.
- [9] C. Hu, A. Peters, dan D. Kang, “LEAP: LLM-powered End-to-end Automatic Library for Processing Social Science Queries on Unstructured Data,” *Proc. VLDB Endow.*, vol. 18, no. 2, hlm. 253–264, Okt 2024, doi: 10.14778/3705829.3705843.
- [10] J. Khan, K. Ahmad, S. K. Jagatheesaperumal, dan K.-A. Sohn, “Textual variations in social media text processing applications: challenges, solutions, and trends,” *Artif. Intell. Rev.*, vol. 58, no. 3, hlm. 89, Jan 2025, doi: 10.1007/s10462-024-11071-z.
- [11] B. Omarov dan Z. Zhumanov, “Bidirectional Long-Short-Term Memory with Attention Mechanism for Emotion Analysis in Textual Content,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 6, 2023, doi: 10.14569/IJACSA.2023.0140615.
- [12] X. Chen, “Monitoring of Public Opinion on Typhoon Disaster Using Improved Clustering Model Based on Single-Pass Approach,” *Sage Open*, vol. 13, no. 3, hlm. 21582440231200098, Jul 2023, doi: 10.1177/21582440231200098.
- [13] B. Wan, P. Wu, C. K. Yeo, dan G. Li, “Emotion-cognitive reasoning integrated BERT for sentiment analysis of online public opinions on emergencies,” *Inf. Process. Manag.*, vol. 61, no. 2, hlm. 103609, Mar 2024, doi: 10.1016/j.ipm.2023.103609.
- [14] M. H. Fardana, W. S. J. Saputra, dan M. H. P. Swari, “Analysis And Prediction Of Motor Vehicle Carbon Dioxide Emissions Using A Hybrid Lstm And Arima Algorithm,” *J. Inform. Dan Tek. Elektro Terap.*, vol. 13, no. 3, Jul 2025, doi: 10.23960/jitet.v13i3.6782.
- [15] K. L. Tan, C. P. Lee, dan K. M. Lim, “A Survey of Sentiment Analysis: Approaches, Datasets, and Future Research,” *Appl. Sci.*, vol. 13, no. 7, hlm. 4550, Apr 2023, doi: 10.3390/app13074550.
- [16] I. P. Ramayasa, I. G. A. D. Saryanti, I. K. Dharmendra, and Edwar, “Perbandingan Metode Vektorisasi Pada Analisa Sentiment, Studi Kasus: Cyberbullying Pada Komentar Instagram,” *Jurnal Teknologi Informasi dan Komputer*, vol. 9, no. 5, pp. 505-512, Oct. 2023, doi: <https://doi.org/10.36002/jutik.v9i5.2645>.
- [17] I. G. B. Arinata, I. P. Satwika, and N. W. Utami, "Analisis Sentimen Pada EDOM STMIK Primakara Menggunakan Metode *Long Short-Term Memory*," *Jurnal Teknologi Informasi dan Komputer*, vol. 8, no. 4, pp. 327-332, Oct. 2022, doi: <https://doi.org/10.36002/jutik.v8i4.2086>.
- [18] F. E. L. Otto dan E. Raju, “Harbingers of decades of unnatural disasters,” *Commun. Earth Environ.*, vol. 4, no. 1, hlm. 280, Agu 2023, doi: 10.1038/s43247-023-00943-x.
- [19] D. Marks dan I. G. Baird, “The urban political ecology of worsening flooding in Phnom Penh, Cambodia: Neopatrimonialism, displacement, and uneven harm,” *Int. J. Disaster Risk Reduct.*, vol. 118, hlm. 105229, Feb 2025, doi: 10.1016/j.ijdr.2025.105229.