

# Mendeteksi Emosi Berdasarkan Postingan Sosial Media X Menggunakan Algoritma Long Short-Term Memory

## *Detecting Emotions Based on Social Media X Posts Using Long Short-Term Memory Algorithm*

**Irni Irana Ainin Nadhiroh<sup>1</sup>, Mohammad Zoqi Sarwani<sup>\*2</sup>, Muhammad Udin<sup>3</sup>**

<sup>1,2,3</sup> Teknik Informatika, Fakultas Teknologi Informasi, Universitas Merdeka Pasuruan

E-mail : *ainin nadhiroh@student.unmerpas.ac.id<sup>1</sup>, zoqi.sarwani@unmerpas.ac.id<sup>\*2</sup>, imelekacong28@gmail.com<sup>3</sup>*

*\*Corresponding author*

Received 6 July 2025; Revised 16 July 2025; Accepted 24 July 2025

**Abstrak-**Emosi merupakan aspek penting dalam komunikasi manusia yang sering muncul melalui unggahan di media sosial. Emosi tersebut diekspresikan dalam teks berbahasa Indonesia di platform media sosial X. Penelitian ini bertujuan untuk mendeteksi lima kategori emosi, yaitu marah, takut, senang, cinta, dan sedih. Model yang digunakan adalah algoritma *Long Short-Term Memory* (LSTM) dengan representasi kata dari *FastText*. Model dilatih menggunakan metode *EarlyStopping* dan dievaluasi dengan metrik akurasi, presisi, recall, dan F1-score. Hasil menunjukkan bahwa model mencapai akurasi sebesar 79% pada data testing dengan performa yang relatif seimbang untuk setiap kategori emosi. Penelitian ini menunjukkan bahwa *FastText* dan LSTM efektif untuk mendeteksi emosi dalam teks media sosial berbahasa Indonesia. Penelitian ini diharapkan bermanfaat dalam pengembangan penelitian berbasis emosi, seperti analisis sentimen, pemantauan opini publik, dan sistem pendukung kesehatan mental.

**Kata Kunci** – Deteksi Emosi, Sosial Media, Long Short-Term Memory, FastText

**Abstract-***Emotion is an essential aspect of human communication that often appears in social media posts. These emotions are expressed in Indonesian-language posts on the social media platform X. This study aims to detect five categories of emotion that consist of anger, fear, joy, love, and sadness. The model used is Long Short-Term Memory (LSTM) algorithm with FastText word embeddings. The model was trained using EarlyStopping and evaluated using accuracy, precision, recall, and F1-score. The results show that the model achieved 79% accuracy on the testing set with relatively balanced performance across all emotion classes. This research shows that the combination of FastText and LSTM is effective for emotion detection in Indonesian social media text. This research is expected to contributes to the development of emotion based research, such as sentiment analysis, public opinion monitoring, and mental health support systems.*

**Keywords** – *Emotions Detection, Social Media, Long Short-Term Memory, FastText*

## 1. PENDAHULUAN

Media sosial saat ini menjadi salah satu sumber utama dalam mengekspresikan emosi manusia secara spontan, terutama melalui platform seperti X. Setiap individu dapat mengekspresikan emosi seperti kebahagiaan, kesedihan, ketakutan, kemarahan, dan rasa cinta yang dapat dimanfaatkan sebagai sumber data untuk memahami dinamika emosional masyarakat secara lebih luas.

Analisis emosi berbasis teks dari media sosial berpotensi sangat luas dalam berbagai bidang. Informasi emosional dapat digunakan untuk memantau opini publik terhadap isu sosial,

merancang strategi komunikasi yang lebih empatik, serta mendeteksi kondisi emosional yang berkaitan dengan kesehatan mental. Meskipun telah banyak studi yang mengeksplorasi deteksi emosi, pendekatan terhadap teks berbahasa Indonesia masih menghadapi tantangan tersendiri, khususnya dalam menangani bahasa informal, singkatan, serta kosakata *slang* yang terus berubah dan berkembang. [1]

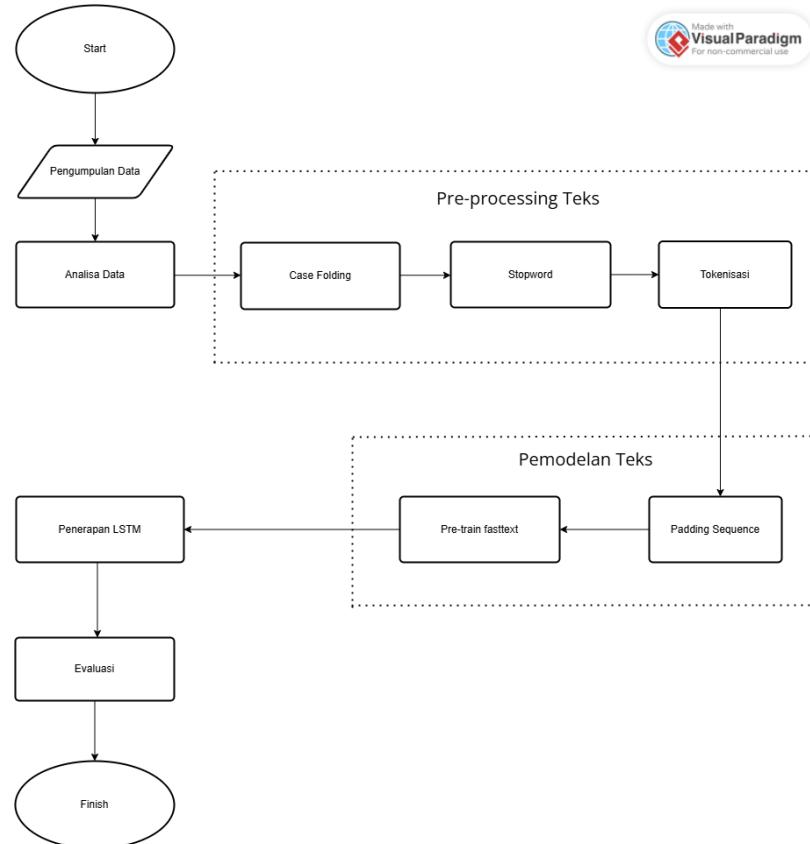
*Natural Language Processing* (NLP) berperan penting dalam memahami bahasa manusia secara alami [2] dan mampu membantu mengidentifikasi ekspresi emosional yang kompleks. [3] Salah satu pendekatan yang efektif adalah algoritma *Long Short-Term Memory* (LSTM), yaitu jenis dari *Recurrent Neural Network* (RNN) yang dapat mempertahankan konteks pada data berurutan seperti teks panjang [4] Berbagai penelitian telah menunjukkan keberhasilan penerapan LSTM dalam konteks tersebut. Penelitian oleh Winardi [5] memperoleh tingkat keberhasilan sebesar 90% dalam memprediksi sentimen pada sosial media X, sementara Cahyadi [6] memperoleh akurasi sebesar 79,64% pada analisis sentimen terhadap unggahan Instagram. LSTM juga telah diterapkan dalam penelitian berbasis Bahasa Bengkulu untuk analisis sentimen secara spesifik [7]. Penelitian lain milik Wibowo [8] juga mendapatkan akurasi sebesar 83% untuk analisis ujaran kebencian pada sosial media X. Hal ini memperkuat LSTM sebagai algoritma yang andal dalam memahami emosi dalam berbagai konteks linguistik.

Sebagian penelitian terdahulu terkait deteksi emosi masih menghadapi tantangan dalam hal akurasi dan adaptasi terhadap karakteristik bahasa tidak baku. Penelitian oleh Putra Negara [9] menggunakan algoritma *K-Nearest Neighbor* (KNN) dan *Logistic Regression* pada data X berbahasa Indonesia dan hanya mencapai akurasi sekitar 65%. Pendekatan BERT-CNN yang digunakan oleh Algifari [10] juga mencatat akurasi sekitar 61% dalam klasifikasi emosi dari sosial media X. Sedangkan untuk penelitian oleh Riza [11] yang menggunakan LSTM dan *fasttext* mendapatkan akurasi 73,15% dikarenakan data yang digunakan sedikit, yaitu hanya 1304 total data. Penelitian lain yang mendeteksi lima emosi yang sama menggunakan Decision Tree oleh Nurfauzan [12] menghasilkan akurasi terbaik sebesar 55%. Berbagai penelitian tersebut menunjukkan bahwa tantangan tidak hanya berasal dari kompleksitas bahasa informal dan penggunaan singkatan, tetapi juga dari keterbatasan metode dalam menangkap konteks emosional secara menyeluruh. Oleh karena itu, dibutuhkan pendekatan yang tidak hanya kuat secara arsitektur, tetapi juga fleksibel dalam memahami dinamika bahasa informal dan singkatan yang berkembang.

Berdasarkan penelitian deteksi emosi terdahulu, penelitian ini akan menggunakan algoritma *Long Short-Term Memory* (LSTM) dan *fasttext* dengan tujuan untuk mengidentifikasi lima emosi utama (kebahagiaan, kesedihan, ketakutan, kemarahan, dan rasa cinta) dalam teks yang berasal dari media sosial X. Melalui pendekatan ini, diharapkan model yang dihasilkan mampu meningkatkan ketepatan dalam proses klasifikasi emosi dibandingkan dengan penelitian sebelumnya, serta mendukung pengembangan teknologi analisis emosi berbasis *Natural Language Processing* (NLP). Dengan demikian, penelitian ini diharapkan mampu memberikan kontribusi terhadap pengembangan sistem deteksi emosi berbasis teks yang lebih akurat dan relevan dalam konteks linguistik Indonesia, serta dapat dimanfaatkan untuk berbagai keperluan seperti analisis sentimen, pemantauan opini publik, dan sistem pendukung kesehatan mental.

## 2. METODE PENELITIAN

Proses perancangan sistem yang dilakukan untuk melakukan penelitian deteksi emosi berbasis teks terdiri dari pengumpulan data, analisa data, pre-processing teks, pemodelan teks, menerapkan algoritma LSTM, dan melakukan evaluasi. Proses ini dapat dilihat di gambar 1.



Gambar 1 Alur Perancangan Sistem

### 2.1. Pengumpulan Data

Pengumpulan data dilakukan secara online. Dataset yang digunakan berasal dari artikel GitHub yang berisikan 5048 tweet menggunakan Bahasa Indonesia yang terbagi menjadi lima emosi, yaitu *Anger* (marah), *Fear* (takut), *Joy* (senang), *Love* (cinta), dan *Sad* (sedih).

Tabel 1 Contoh Dataset Emosi

Tweet	Label
Pagi pagi udah dibuat emosi	<i>Anger</i>
Aku jadi takut deh	<i>Fear</i>
Lagi seneng soalnya dapat kabar baik	<i>Joy</i>
Sayang banget sama kamu	<i>Love</i>
Gue lagi sedih banget loh guys	<i>Sad</i>

### 2.2. Analisa Data

Analisa data bertujuan untuk memahami data saat proses pengolahan dan penelitian, agar mendapatkan hasil yang terbaik.

Pada analisa data, dilakukan pelabelan pada setiap emosi menggunakan label encoder.

- *Anger* : 0
- *Fear* : 1
- *Joy* : 2
- *Love* : 3

- Sad : 4

Data yang ada dibagi menjadi data train dan data testing. Pembagian data ini dilakukan agar menghindari *overfitting*, serta memberikan keseimbangan optimal antara proses pelatihan dan evaluasi.

- Split 1 = 70% data training dan 30% data testing
- Split 2 = 75% data training dan 25% data testing
- Split 3 = 80% data training dan 20% data testing
- Split 4 = 85% data training dan 15% data testing
- Split 5 = 90% data training dan 10% data testing

### 2.3. Pre-Processing Teks

Setelah proses analisa data, maka dilanjut dengan pre-processing teks dimana data akan dibersihkan dan akan diproses model. Berikut adalah tahapan pre-processing teks yang dilakukan:

#### 1) Case-Folding

*Case folding* merupakan proses mengubah seluruh huruf dalam teks menjadi huruf kecil (*lowercase*). Tujuannya adalah untuk menyamakan representasi kata yang secara semantik sama tetapi secara penulisan berbeda karena perbedaan huruf kapital.

#### 2) Stopword Removal

Menghapus *stopword* adalah proses menghapus kata-kata umum yang tidak memiliki makna penting dalam analisis teks. Tujuannya untuk mengurangi jumlah kata yang diproses, mempercepat komputasi, dan memfokuskan analisis pada kata-kata yang lebih bermakna.

#### 3) Tokenisasi

Tokenisasi adalah proses memecah teks menjadi bagian-bagian kecil yang disebut token, biasanya berupa kata. Tujuannya agar teks lebih mudah dianalisis oleh algoritma.

Tabel 2 Proses Pre-Processing Teks

Pre-processing	Tweet
Teks sebelum <i>pre-processing</i>	Lagi seneng soalnya dapat kabar baik
Teks setelah <i>case-folding</i>	lagi seneng soalnya dapat kabar baik
Teks setelah menghapus stopword	seneng kabar baik
Teks setelah tokenisasi	['seneng', 'kabar', 'baik']
Teks setelah <i>pre-processing</i>	['seneng', 'kabar', 'baik']

### 2.4. Pemodelan Teks

Setelah *pre-processing* teks telah berhasil dilakukan pada data, maka selanjutnya adalah melakukan pemodelan teks menggunakan *fasttext*. Berikut adalah tahapan-tahapan yang akan dilakukan saat pemodelan teks :

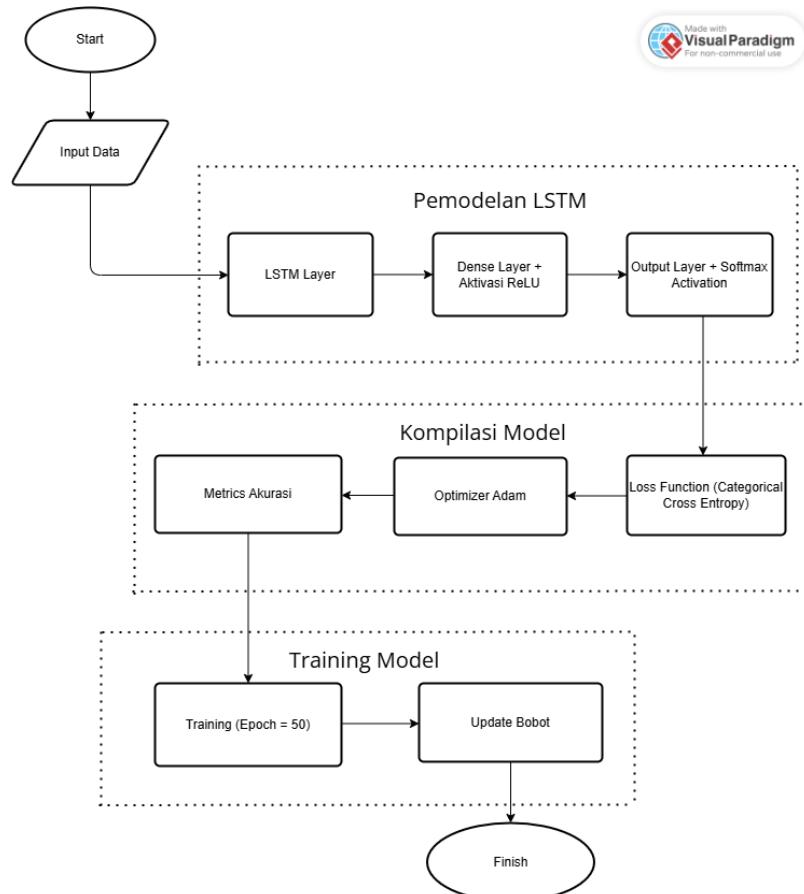
#### 1) Padding Sequence

Karena panjang setiap kalimat berbeda, dilakukan padding agar seluruh kalimat memiliki panjang sebanyak 30 kata per kalimat. Token khusus ditambahkan pada kalimat yang lebih pendek dari 30 kata.

#### 2) Pre-train *fasttext*

Model *embedding* yang digunakan dalam penelitian ini adalah *FastText pre-train* untuk Bahasa Indonesia, yang dilatih menggunakan Wikipedia Bahasa Indonesia. Model ini menghasilkan representasi vektor kata berdimensi 300. Setiap token dalam kalimat dipetakan ke dalam vektor berdimensi 300, sehingga satu kalimat direpresentasikan sebagai sebuah matriks berukuran 30×300.

## 2.5. Penerapan LSTM



Gambar 2 Alur Pemodelan LSTM

Tahap selanjutnya adalah penerapan algoritma LSTM terhadap representasi vektor yang sudah didapat dari proses word embedding menggunakan *fasttext*. Arsitektur LSTM yang akan digunakan adalah *many-to-one* karena target hanya satu *output* per *input sequence*, cocok untuk klasifikasi emosi satu label dari satu kalimat. Tahapan yang akan dilakukan adalah sebagai berikut:

### 1) Input Data

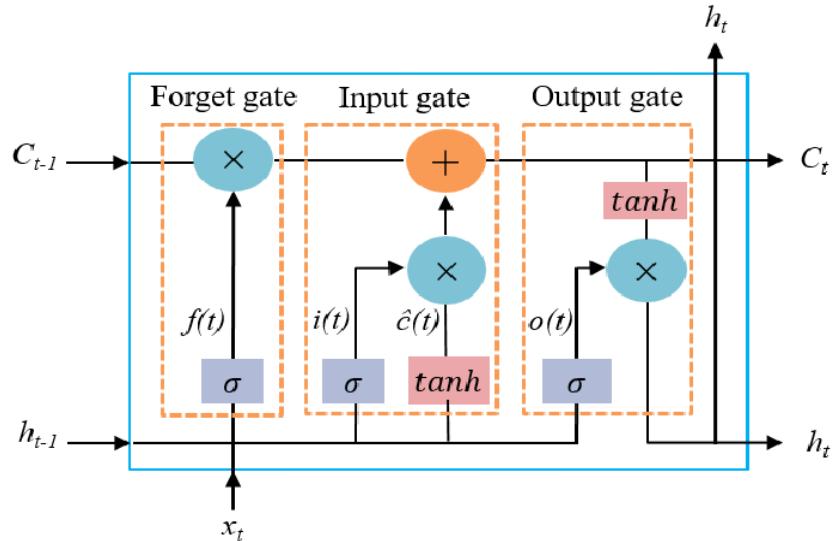
Data yang digunakan adalah data yang sebelumnya sudah di *word embedding* oleh *fasttext* berupa representasi vektor.

### 2) Pemodelan LSTM

Pada tahap pemodelan LSTM, ada beberapa langkah yang dilakukan, yaitu:

- LSTM Layer

Lapisan LSTM menerima input berupa urutan vektor embedding dan memprosesnya secara temporal. Setiap unit LSTM terdiri atas tiga gerbang utama: *input gate*, *forget gate*, dan *output gate*, yang bekerja bersama untuk memutuskan informasi apa yang disimpan, dibuang, dan diteruskan. Hal ini memungkinkan LSTM menangani ketergantungan konteks jangka panjang antar kata.



Gambar 3 Arsitektur LSTM [13]

- *Forget gate (ft)*:

$$f_t = \sigma(W_f \cdot [h_t - 1, x_t] + b_f)$$

Tujuannya untuk menentukan informasi apa yang perlu dilupakan dari status sebelumnya.

- *Input gate (it)*:

$$i_t = \sigma(W_i \cdot [h_t - 1, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_t - 1, x_t] + b_c)$$

Tujuannya untuk mengatur informasi baru apa yang disimpan ke sel memori.

- *Cell state (ct)*:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Tujuannya untuk membawa informasi lintas waktu; bagian penting dari memori internal.

- *Output gate (ot)*:

$$o_t = \sigma(W_o \cdot [h_t - 1, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

Tujuannya menentukan bagian dari sel memori yang akan digunakan untuk output saat ini.

#### b. Dense Layer dan Aktivasi *ReLU*

Memproses output dari jaringan neural lebih lanjut menggunakan lapisan *Dense (fully connected layer)*. Lapisan ini berfungsi untuk menghubungkan seluruh neuron dari lapisan sebelumnya ke semua neuron di lapisan berikutnya. Penggunaan kombinasi *Dense layer* dan *ReLU* setelah LSTM bertujuan agar model dapat memproses ulang representasi fitur yang telah dipelajari oleh LSTM sebelum akhirnya diklasifikasikan oleh lapisan output.

c. Output Layer dan *Softmax Activation*

Setelah proses representasi fitur oleh lapisan LSTM dan *Dense*, hasilnya diteruskan ke lapisan output. Lapisan output ini menggunakan fungsi aktivasi *Softmax* untuk menangani masalah klasifikasi multi-kelas. *Softmax* mengubah output dari lapisan sebelumnya menjadi probabilitas untuk setiap kelas, di mana total seluruh nilai probabilitas berjumlah 1.

Dalam penelitian ini, dilakukan pemodelan untuk memprediksi lima kategori emosi, yaitu: kebahagiaan, kesedihan, kemarahan, ketakutan, dan rasa cinta. Oleh karena itu, lapisan output terdiri dari 5 neuron, masing-masing mewakili satu kelas emosi.

3) Kompilasi Model

a. *Loss Function (Categorical Cross Entropy)*

Fungsi *loss* (*loss function*) yang digunakan dalam penelitian ini adalah *categorical crossentropy*, yang cocok untuk masalah klasifikasi multi-kelas. [14]

4) Training Model

a. Training

Model dilatih selama sejumlah 50 *epoch* menggunakan metode *Early Stopping*. Teknik ini menghentikan pelatihan lebih awal jika tidak terjadi peningkatan akurasi pada data validasi selama beberapa *epoch*, sehingga mencegah *overfitting* dan menghemat waktu komputasi.

Selama proses pelatihan, bobot-bobot diperbarui secara bertahap menggunakan algoritma Adam optimizer. Pembaruan bobot dilakukan berdasarkan hasil perhitungan *loss function (categorical crossentropy)*, dengan tujuan meminimalkan nilai *loss* agar output model semakin mendekati label sebenarnya.

b. Update Bobot

Pembaruan bobot  $w$  mengikuti prinsip *gradient descent*, dengan rumus dasar sebagai berikut:

$$w = w - \alpha \cdot \frac{\partial L}{\partial w}$$

Keterangan:

- $w$  adalah bobot model,
- $\alpha$  adalah *learning rate*,
- $\frac{\partial L}{\partial w}$  adalah turunan (*gradien*) dari fungsi *loss* terhadap bobot.

## 2.6. Evaluasi

Pada penelitian ini, evaluasi dilakukan dengan menggunakan metrik akurasi, presisi, recall, dan F1-score. Untuk menghitung keseluruhan performa model, dilakukan perhitungan sebagai berikut :

1. Akurasi, untuk mengukur seberapa banyak prediksi yang benar dari total keseluruhan data.

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

2. Precision, untuk mengukur ketepatan model dalam memprediksi suatu kelas.

$$\text{Precision} = \frac{TP}{TP + FP}$$

3. Recall, untuk mengukur kemampuan model dalam menemukan data yang benar-benar termasuk dalam suatu kelas.

$$\text{Recall} = \frac{TP}{TP + FN}$$

4. F1-Score menunjukkan keseimbangan antara precision dan recall, sehingga dapat digunakan untuk menilai sejauh mana model mampu melakukan klasifikasi secara akurat dan konsisten.

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

Setelah itu, akan menunjukkan hasil evaluasi berbentuk *confusion matrix*. *Confusion Matrix* digunakan untuk mengevaluasi kinerja model klasifikasi dengan membandingkan hasil prediksi model terhadap label sebenarnya. Melalui metriks ini, dapat dilihat jumlah prediksi yang benar dan salah pada masing-masing kelas, sehingga memberikan gambaran akurasi klasifikasi yang dilakukan oleh model.

### 3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk membangun model klasifikasi emosi berbasis teks menggunakan algoritma *Long Short-Term Memory* (LSTM) dengan representasi kata dari pretrained *FastText* Bahasa Indonesia. Dataset yang digunakan terdiri dari 5.048 *tweet* di sosial media X yang sudah dilabeli ke dalam lima kategori emosi, yaitu: marah, takut, senang, cinta, dan sedih. Dataset tersebut kemudian melewati tahap *pre-processing* sebelum masuk ke tahap pelatihan model.

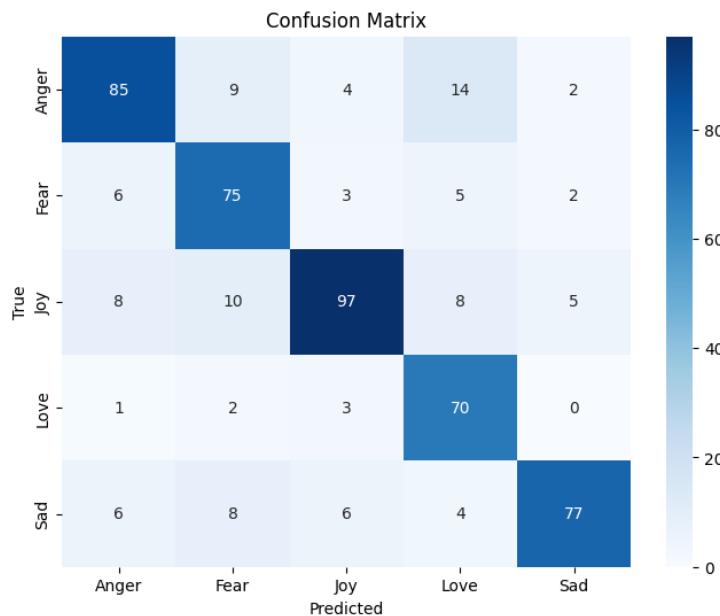
Setelah dilakukan pelatihan model selama 50 *epoch* dengan metode *EarlyStopping*, proses pelatihan berhenti pada epoch ke-x karena tidak ada peningkatan signifikan pada *validation loss*. Hasil akurasi terbaik yang didapatkan adalah sebesar 79% dengan perbandingan data train dan data testing sebesar 90:10 dan *random state* = 42

Berikut adalah hasil evaluasi performa model pada data testing :

Tabel 3 Hasil Evaluasi

Emosi	Precision	Recall	F1 - Score	Support
<i>Anger</i>	0.80	0.75	0.77	114
<i>Fear</i>	0.72	0.82	0.77	91
<i>Joy</i>	0.86	0.76	0.80	128
<i>Love</i>	0.69	0.92	0.79	76
<i>Sad</i>	0.90	0.76	0.82	101

Akurasi keseluruhan yang dicapai model adalah 79%, dengan skor rata-rata F1-score (macro average) sebesar 0.79.

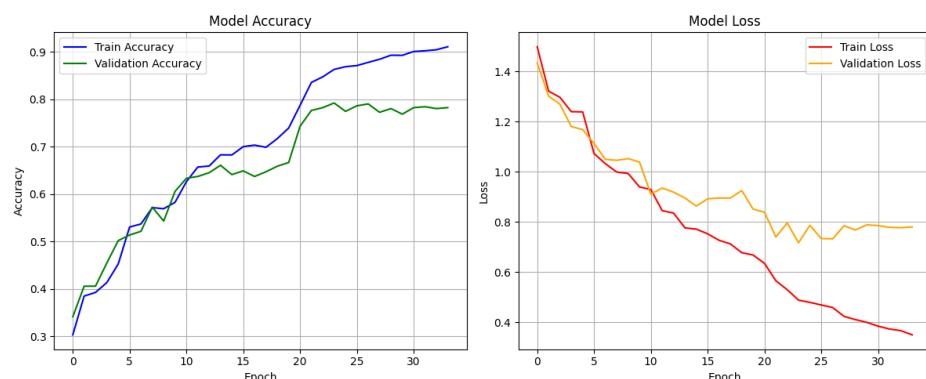


Gambar 4 Confusion Matrix dari Hasil Evaluasi

Berdasarkan confusion matrix pada Gambar 4.1, model menunjukkan kinerja klasifikasi yang baik secara umum, meskipun masih terdapat beberapa pola kesalahan pada proses klasifikasi.

- Emosi marah sebagian besar terkласifikasi dengan benar (85 dari 114), namun sering tertukar dengan cinta (14 kasus) dan takut (9 kasus). Hal ini mengindikasikan adanya kemiripan ekspresi linguistik di antara ketiga emosi tersebut.
- Emosi takut memiliki recall yang tinggi (0.82), dengan kesalahan klasifikasi terbanyak ke marah dan senang.
- Sementara itu, senang diklasifikasikan secara akurat pada sebagian besar kasus, meskipun masih salah diprediksi sebagai takut atau cinta dalam beberapa kasus.
- Emosi cinta menunjukkan recall tertinggi (0.92), tetapi precision-nya lebih rendah akibat banyaknya label lain yang salah diklasifikasikan sebagai cinta.
- Adapun sedih berhasil dikenali dengan baik, meskipun masih terdapat kesalahan prediksi ke label takut dan senang.

Grafik *loss* dan *accuracy* selama proses pelatihan menunjukkan tren yang stabil dan tidak menunjukkan indikasi overfitting, sebagaimana ditampilkan pada Gambar 5.



Gambar 5 Kurva Akurasi (Kiri) dan Kurva Loss (Kanan) Training Model

Gambar 5 menunjukkan grafik akurasi dan loss selama pelatihan model. Akurasi data train meningkat secara konsisten hingga mencapai lebih dari 90%, sementara akurasi validasi cenderung stabil di kisaran 78-80% setelah epoch ke-20. Penurunan train loss berlangsung stabil, sedangkan validation loss mulai mendatar dan sedikit fluktuatif setelah pertengahan pelatihan. Pola ini mengindikasikan adanya gejala awal overfitting. Penggunaan *EarlyStopping* berhasil menghentikan pelatihan sebelum overfitting semakin besar, sehingga model tetap mampu melakukan generalisasi dengan baik terhadap data testing.

#### 4. KESIMPULAN

Penelitian ini berhasil membuat model deteksi emosi berbasis teks menggunakan algoritma LSTM dengan *embedding FastText* untuk data media sosial X yang berbahasa Indonesia. Model mampu mengklasifikasikan lima kategori emosi, yaitu marah, takut, senang, cinta, dan sedih dengan akurasi sebesar 79% pada data testing. Algoritma LSTM efektif dalam memahami urutan kata, sementara *FastText* membantu dalam menangani berbagai singkatan dan bahasa informal, serta menunjukkan kinerja yang lebih baik dibandingkan metode konvensional. Hasil evaluasi menunjukkan bahwa model bekerja cukup baik, meskipun masih mengalami kesalahan klasifikasi pada emosi yang semantisnya berdekatan.

Untuk penelitian selanjutnya, disarankan untuk mencoba arsitektur model yang lebih kompleks seperti BiLSTM, serta memperluas cakupan data agar model memiliki kemampuan mendekripsi emosi yang lebih baik terhadap berbagai jenis ekspresi.

#### DAFTAR PUSTAKA

- [1] F. S. Zai and M. C. A. Sihite, “Perkembangan Bahasa Gaul Remaja Milenial Dalam Media Sosial,” *IDENTIK*, vol. 1, no. 3, pp. 19–24, Nov. 2024, doi: 10.70134/identik.v1i3.133.
- [2] D. Khurana, A. Koli, K. Khatter, and S. Singh, “Natural Language Processing: State of The Art, Current Trends and Challenges”.
- [3] Ragunathan S., “Emotional Detection From Text Using NLP Natural Language Processing With Prediction Probability.” 2024.
- [4] A. K. Hidayah and R. E. Putra, “Penerapan Metode Long Short Term Memory untuk Memprediksi Harga Beras di Indonesia,” vol. 06, 2024.
- [5] S. Winardi, A. W. Soejono, and D. Sari, “Analisis Sentimen Pada ChatGPT Menggunakan Algoritma Long Short Term Memory (LSTM),” vol. 6, no. 1, 2024.
- [6] R. Cahyadi, A. Damayanti, and D. Aryadani, “RECURRENT NEURAL NETWORK (RNN) DENGAN LONG SHORT TERM MEMORY (LSTM) UNTUK ANALISIS SENTIMEN DATA INSTAGRAM,” vol. 5, no. 1, 2020.
- [7] S. Nurhaeni, R. Faurina, F. P. Utama, and K. Anggriani, “Sentiment Analysis Komentar Berbahasa Bengkulu Menggunakan Long Short-Term Memory (LSTM),” *pseudocode*, vol. 10, no. 2, pp. 117–125, Sep. 2023, doi: 10.33369/pseudocode.10.2.117-125.
- [8] L. Yosia Wibowo, N. Annisa, P. Ananda Khairunnisa, V. Handrianus Pranatawijaya, and R. Priskila, “IMPLEMENTASI LONG SHORT-TERM MEMORY DALAM ANALISIS SENTIMEN PENGGUNA APLIKASI TWITTER YANG MENGANDUNG UJARAN KEBENCIAN,” *jati*, vol. 8, no. 3, pp. 3170–3174, May 2024, doi: 10.36040/jati.v8i3.9654.
- [9] A. B. P. Negara, H. Muhardi, and F. Sajid, “Perbandingan Algoritma Klasifikasi terhadap Emosi Tweet Berbahasa Indonesia,” *JEPIN*, vol. 7, no. 2, p. 242, Aug. 2021, doi: 10.26418/jp.v7i2.48198.

- [10] M. H. Algifari and E. D. Nugroho, “Emotion Classification of Indonesian Tweets using BERT Embedding,” *JAIC*, vol. 7, no. 2, pp. 172–176, Nov. 2023, doi: 10.30871/jaic.v7i2.6528.
- [11] M. A. Riza and N. Charibaldi, “Emotion Detection in Twitter Social Media Using Long Short-Term Memory (LSTM) and Fast Text,” *Int.J.Artif.Intell.Robot.*, vol. 3, no. 1, pp. 15–26, May 2021, doi: 10.25139/ijair.v3i1.3827.
- [12] A. Nurfauzan and W. Maharani, “Klasifikasi Emosi Pada Pengguna Twitter Menggunakan Metode Klasifikasi Decision Tree”.
- [13] S. Mohsen, A. Elkaseer, and S. G. Scholz, “Industry 4.0-Oriented Deep Learning Models for Human Activity Recognition,” *IEEE Access*, vol. 9, pp. 150508–150521, 2021, doi: 10.1109/access.2021.3125733.
- [14] R. F. Alya, M. Wibowo, and P. Paradise, “CLASSIFICATION OF BATIK MOTIF USING TRANSFER LEARNING ON CONVOLUTIONAL NEURAL NETWORK (CNN),” *J. Tek. Inform. (JUTIF)*, vol. 4, no. 1, pp. 161–170, Feb. 2023, doi: 10.52436/1.jutif.2023.4.1.564.