

Klasifikasi Emosi *Supporter* Persebaya Di *Twitter* Dengan Metode *Long Short Term Memory*(*Lstm*)

^{1*}Muchamad Gilang Nauri R, ²Ardi Sanjaya, ³Riski Aswi Ramadhani

¹²³ Universitas Nusantara PGRI Kediri

E-mail: ¹*langhrdn@gmail.com, ²dersky@gmail.com, ³riskyaswiramadhani@gmail.com

Penulis Korespondensi : Muchamad Gilang Nauri R

Abstrak— *Twitter* menjadi ruang aktif bagi pendukung Persebaya Surabaya untuk menyuarakan opini dan emosi mereka. Penelitian ini bertujuan untuk mengklasifikasikan sentimen komentar pendukung di *Twitter* ke dalam kategori positif, negatif, dan netral. Data diperoleh melalui pengumpulan komentar *twitter*, kemudian dilabelo menggunakan *TextBlob* dan divalidasi oleh dosen bahasa. Setelah melalui tahapan *preprocessing* dengan *stemmer* Sastrawi dan representasi *word embedding*, data dianalisis menggunakan model *Long Short-Term Memory* (*LSTM*). Hasil menunjukkan bahwa model mampu mengklasifikasikan sentimen dengan cukup akurat, meskipun masih terdapat kendala dalam memahami kritik halus atau konteks implisit. Penelitian ini diharapkan dapat menjadi landasan dalam memahami opini publik terhadap klub serta mendorong pengembangan sistem analisis sentimen di ranah olahraga dan media sosial berbahasa Indonesia.

Kata Kunci— Analisis Sentimen, *LSTM*, *Twitter*

Abstract— *Twitter* has become an active space for Persebaya Surabaya supporters to express their opinions and emotions. This study aims to classify the sentiments of supporters' comments on *Twitter* into positive, negative, and neutral categories. The data was collected from *Twitter* comments, labeled using *TextBlob*, and validated by a language expert. After undergoing *preprocessing* using the Sastrawi *stemmer* and *word embedding* representation, the data was analyzed using the *Long Short-Term Memory* (*LSTM*) model. The results show that the model is able to classify sentiments with reasonable accuracy, although challenges remain in understanding subtle criticism or implicit context. This study is expected to serve as a foundation for understanding public opinion toward the club and to encourage the development of sentiment analysis systems in the context of sports and Indonesian-language social media.

Keywords— Sentiment Analysis, *LSTM*, *Twitter*

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Dalam era digital saat ini, media sosial telah menjadi wadah utama bagi masyarakat untuk mengekspresikan opini, emosi, dan aspirasi mereka secara terbuka. Salah satu *platform* media sosial yang banyak digunakan adalah *Twitter*, di mana pengguna dapat membagikan pandangan mereka terhadap berbagai peristiwa, termasuk pertandingan sepak bola [1]. Klub sepak bola Persebaya Surabaya memiliki basis *supporter* yang sangat loyal dan aktif di media sosial[2]. Komentar-komentar mereka kerap mengandung emosi yang kuat, baik berupa dukungan, kebanggaan, kekecewaan, maupun kemarahan terhadap performa tim kesayangan

mereka. Analisis terhadap ekspresi emosi ini dapat memberikan wawasan penting bagi klub, media, bahkan investor dan peneliti dalam memahami massa pendukung sepak bola di Indonesia [3].


Permasalahan yang muncul adalah bagaimana mengklasifikasikan emosi-emosi tersebut secara otomatis dari data teks dalam jumlah besar. Analisis manual jelas tidak efisien dan tidak praktis, mengingat peningkatan komentar di *twitter* sangat cepat. Oleh karena itu, diperlukan suatu pendekatan berbasis kecerdasan buatan, untuk mengklasifikasikan emosi dari teks secara akurat [4]. Salah satu metode yang terbukti efektif untuk mengolah data teks sekuensial seperti komentar adalah *Long Short-Term Memory (LSTM)*, sebuah varian dari *Recurrent Neural Network (RNN)* yang mampu menangkap ketergantungan jangka panjang dalam urutan kata [5].

Sejumlah penelitian terdahulu telah menggunakan *LSTM* dalam tugas klasifikasi sentimen dan emosi. Salah satunya dilakukan oleh Hazarika, yang menunjukkan bahwa metode ini efektif dalam mengenali emosi seperti marah, bahagia, dan sedih pada percakapan daring [6]. Sementara itu, Abdul-Mageed dan Ungar juga membuktikan bahwa *LSTM* dapat digunakan secara efektif untuk mengklasifikasikan emosi dalam data *Twitter* berbahasa *Inggris* dengan hasil yang cukup baik [7]. Namun, masih sedikit penelitian yang secara khusus menyoroti klasifikasi emosi pada konteks *supporter* sepak bola di Indonesia, khususnya yang menggunakan data berbahasa Indonesia atau dialek khas daerah seperti yang digunakan oleh Bonek, pendukung Persebaya.

Berdasarkan permasalahan yang telah diuraikan, penelitian ini bertujuan untuk membangun sistem analisis sentimen terhadap data yang diperoleh dari *Twitter* yang membahas tentang Tim sepakbola Persebaya Surabaya. Sebelum dianalisis, data terlebih dahulu melalui proses pelabelan menggunakan metode *TextBlob*. Untuk memastikan akurasi pelabelan, data yang telah diberi label kemudian divalidasi oleh seorang ahli bahasa Indonesia, dalam hal ini saya meminta tolong kepada dosen bahasa Indonesia dari kampus saya. Selanjutnya, data diproses melalui tahapan *preprocessing* teks menggunakan *stemmer* Sastrawi untuk membersihkan dan menyederhanakan struktur kata. Selanjutnya, dilakukan proses *word embedding* untuk mengubah kata-kata dalam *tweet* menjadi representasi vektor numerik agar dapat dikenali dan diproses oleh model pembelajaran mesin. Setelah itu, data dimasukkan ke dalam model *Long Short-Term Memory (LSTM)* untuk diklasifikasikan ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Dengan adanya penelitian ini, diharapkan sistem yang dikembangkan dapat membantu dalam memahami opini atau emosi publik secara otomatis, khususnya dalam konteks pembahasan tentang Persebaya Surabaya di *twitter*.

II. METODE

2.1 Langkah Penelitian



Gambar 1. Langkah Penelitian

Berdasarkan langkah penelitian ini, tahapan pertama yang dilakukan adalah perolehan data. Proses ini diawali dengan studi literatur guna memahami teori-teori serta penelitian terdahulu yang relevan, kemudian dilanjutkan dengan pengumpulan data dari platform *Twitter*. Data dikumpulkan menggunakan alat bantu *Twitter Harvest*, yang panduan penggunaannya merujuk pada video tutorial dari channel *YouTube* Helmi Satria. Data yang diperoleh berupa komentar

yang berkaitan dengan Persebaya Surabaya dan komunitas pendukungnya. Selanjutnya, dilakukan proses pelabelan emosi atau sentimen pada data komentar menggunakan pustaka *TextBlob*, yang secara otomatis mengklasifikasikan komentar ke dalam tiga kategori, yaitu positif, negatif, dan netral berdasarkan nilai polaritasnya. Setelah data diberi label, tahap berikutnya adalah *preprocessing* teks yang mencakup pembersihan data, tokenisasi, penghapusan *stopword*, serta *stemming* menggunakan *stemmer* Sastrawi untuk menyesuaikan dengan karakteristik bahasa Indonesia. Selanjutnya, data yang telah diproses digunakan dalam proses pelatihan model klasifikasi sentimen menggunakan algoritma *Long Short-Term Memory (LSTM)*, yang dipilih karena kemampuannya dalam memahami urutan kata dalam teks. Setelah model dibangun, dilakukan perancangan sistem aplikasi prediksi sentimen berbasis web untuk mengintegrasikan model ke dalam antarmuka pengguna yang interaktif. Tahap terakhir adalah evaluasi sistem dan model, yang mencakup pengujian akurasi prediksi serta pengujian fungsionalitas sistem untuk memastikan kinerja model dalam mengklasifikasikan sentimen secara optimal.

2.2 Text Preprocessing

Salah satu langkah pertama dalam penerapan *Natural Language Processing (NLP)* adalah proses *preprocessing* teks, yaitu tahapan untuk membersihkan dan menyiapkan data teks agar siap dianalisis lebih lanjut [8].

1. Data Cleansing

Pada tahap pembersihan data (*data cleansing*), dilakukan proses menghapus atau memperbaiki data yang bermasalah[9]. Seperti “Bikin Bonek Nangis!” menjadi “Bikin Bonek Nangis”.

2. Case Folding

Pada tahap *case folding*, seluruh huruf dalam teks diubah menjadi huruf kecil (*lowercase*)[10]. Contohnya “Mulai Moncer di Persebaya Surabaya” menjadi “mulai moncer di persebaya surabaya”.

3. Remove Stopwords

Remove Stopwords menghapus kata-kata umum seperti “yang”, “dan”, “di”, “dari”, dan sejenisnya[11]. Misalnya “Debut Ardi yang menggila di Persebaya” menjadi “Debut Ardi menggila Persebaya”

4. Tokenizing

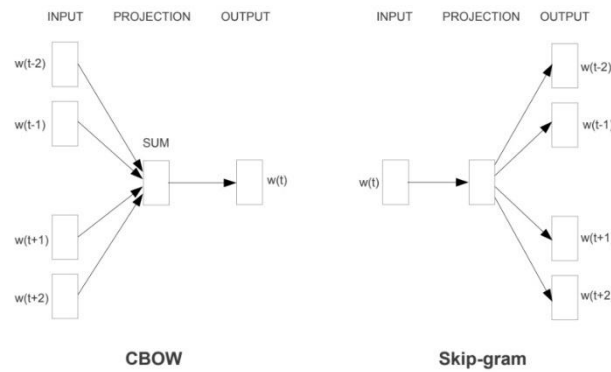
Pada tahap tokenisasi, teks dipecah menjadi bagian-bagian kecil yang disebut token[12]. Seperti “Gaya Bertahan Gilson Costa” menjadi “gaya, bertahan, gilson, costa”

5. Stemming

Stemming merupakan proses mengubah sebuah kata ke bentuk dasarnya dengan cara menghapus imbuhan, seperti awalan maupun akhiran[13]. Dalam penelitian ini, proses *stemming* dilakukan menggunakan *stemmer* Sastrawi yang dirancang khusus untuk Bahasa Indonesia[14]. Contoh “Pernah Bikin Persebaya Menangis” menjadi “pernah, buat, persebaya, tangis”

2.3 Word Embedding

Setelah data melalui tahapan *preprocessing*. Teknik *embedding* yang digunakan memanfaatkan lapisan *Embedding (Embedding Layer)* dari pustaka *Keras*. Setiap token atau kata yang telah diolah akan diubah menjadi vektor berdimensi tetap, yang kemudian digunakan sebagai input ke dalam model *Long Short-Term Memory (LSTM)* [15].



Gambar 2. Word Embedding

2.4 Long Short Term Memory

Long Short-Term Memory (LSTM) adalah jenis jaringan saraf tiruan yang termasuk dalam keluarga *Recurrent Neural Network (RNN)* dan dirancang khusus untuk mengolah data sekuensial seperti teks, suara, atau data deret waktu [16]. *LSTM* memiliki struktur sel memori yang memungkinkan informasi disimpan, diperbarui, dan dikeluarkan melalui tiga jenis gerbang utama:

1. *Forget Gate* : menentukan informasi apa yang harus dibuang dari sel memori.

$$f_t = \sigma(W_{vf}v_t + W_{hf}h_{t-1} + b_f) \quad (1)$$

Keterangan :

W_f : Bobot matriks *forget gate*

x_t : Data *input*

h_{t-1} : *Output* dari blok memori sebelumnya

b_f : Bias dari *forget gate*


σ : Fungsi *sigmoid*

2. *Input Gate* : memutuskan informasi baru apa yang akan disimpan.

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (2)$$

3. *Output Gate* : memilih informasi apa yang akan dikeluarkan sebagai output dari sel memori.

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (3)$$



Gambar 3. Long Short Term Memory

2.5 Confusion Matrix

Confusion matrix merupakan alat evaluasi yang digunakan untuk menilai kinerja suatu model klasifikasi dengan cara membandingkan hasil prediksi model terhadap data sebenarnya[17]. Matriks ini menyajikan empat komponen utama, yaitu :

1. *True Positive (TP)*: jumlah data yang benar-benar positif dan berhasil diklasifikasikan sebagai positif oleh model,
2. *True Negative (TN)*: jumlah data yang benar-benar negatif dan juga diklasifikasikan sebagai negatif,
3. *False Positive (FP)*: jumlah data yang seharusnya negatif tetapi salah diklasifikasikan sebagai positif,
4. *False Negative (FN)*: jumlah data yang seharusnya positif namun salah diklasifikasikan sebagai negatif.

Accuracy adalah ukuran untuk mengetahui seberapa tepat model dalam memprediksi seluruh data dengan membandingkan jumlah prediksi benar terhadap total data.

$$Akurasi = \frac{TP+TN}{Total\ Data} \quad (4)$$

Precision mengukur ketepatan model dalam memprediksi data positif, yaitu seberapa banyak prediksi positif yang benar.

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

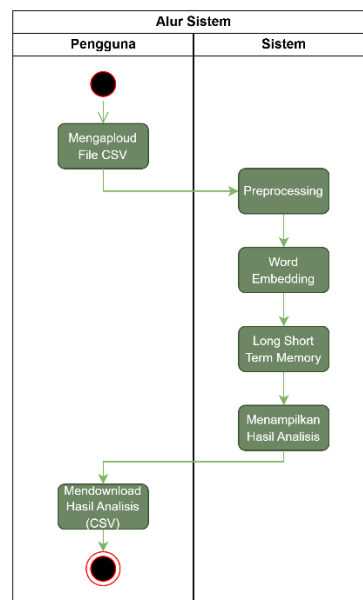
Recall menunjukkan kemampuan model dalam menemukan seluruh data positif yang sebenarnya.

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

F1-Score adalah rata-rata dari *precision* dan *recall*, yang memberikan gambaran seimbang antara keduanya dalam menilai performa model.

$$F1 - Score = 2 \cdot \frac{Presisi \cdot Recall}{Presisi + Recall} \quad (7)$$

2.6 Alur Sistem



Gambar 4. Alur Sistem

Sistem dimulai dengan pengguna mengunggah file *CSV* berisi *tweet* yang ingin dianalisis. Data kemudian dibersihkan dari karakter atau kata yang tidak relevan melalui proses *preprocessing*. Setelah itu, setiap kata diubah menjadi vektor angka melalui *word embedding* agar dapat dipahami oleh model. Vektor tersebut kemudian diproses oleh model *Long Short-Term Memory (LSTM)* untuk mengklasifikasikan sentimen *tweet* menjadi positif, negatif, atau netral. Hasil analisis ditampilkan kepada pengguna dalam bentuk yang mudah dipahami.

III. HASIL DAN PEMBAHASAN

3.1 Deskripsi Dataset

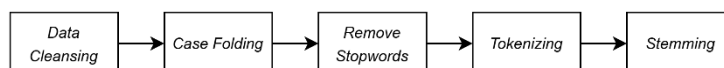
Data pada penelitian ini dikumpulkan dari *Twitter* dengan bantuan alat *Twitter Harvest*, berdasarkan panduan dari kanal *YouTube* Helmi Satria. Pengambilan data dilakukan dengan menggunakan kata kunci yang berkaitan dengan Persebaya Surabaya, seperti “Persebaya”, “Bonek”, dan istilah lainnya yang relevan. Data hasil *scraping* disimpan dalam format *.csv* dan memuat beberapa informasi penting, seperti isi teks *tweet*, waktu unggahan, jumlah *retweet*, jumlah balasan, dan tautan menuju *tweet* asli. Hasil *scraping* bisa dilihat pada gambar 5 berikut. Dataset yang diperoleh masih berupa data mentah, sehingga perlu melalui tahap pembersihan terlebih dahulu agar layak dan efektif digunakan dalam proses analisis.

	created_at	full_text	reply_count	retweet_count	tweet_url
1	Mon Feb 03 04:4	@hooliganscenelD takut https://t.	137	63	https://x.com/SH
2	Sun Feb 02 23:2	@hooliganscenelD Aremania uda	6	1	https://x.com/tiar
3	Mon Feb 03 05:4	@hooliganscenelD Bagus sih Are	1	1	https://x.com/LN
4	Sun Feb 02 21:4	@hooliganscenelD Bagus sih ga	3	0	https://x.com/Akl
5	Mon Feb 03 09:1	@hooliganscenelD pake sempak	0	1	https://x.com/kar
6	Mon Feb 03 09:2	@hooliganscenelD Mbekk~ https://x.com/car	0	0	https://x.com/car
7					

Gambar 5. Deskripsi Dataset

3.2 Hasil Preprocessing

Proses *preprocessing* data dari *Twitter* dilakukan melalui beberapa tahapan, yang secara lengkap dapat dilihat pada gambar 6 berikut. Tahapan ini bertujuan untuk membersihkan dan menyiapkan data teks agar dapat dianalisis lebih lanjut secara akurat.



Gambar 6. Preprocessing

Data yang diperoleh dari *Twitter* akan diproses melalui beberapa tahapan sebagaimana ditunjukkan pada tabel 1. Hasil dari proses *preprocessing* tersebut disajikan secara rinci dalam *table* berikut.

Tabel 1. Preprocessing Data Tweet

Preprocessing	Hasil Tweet
<i>Tweet Asli</i>	Lain kali pasang pemain sesuai dengan posisinya !!! terbukti pemain yg di pasang bukan di posisi asli menjadi under perform. Setelah banyak pergantian pemain yg bukan di pos aslinya tadi permainan persebaya jadi kacau. Juru taktik sangat bertanggung jawab untuk hasil ini.....
<i>Data Cleansing</i>	Lain kali pasang pemain sesuai dengan posisinya terbukti pemain yg di pasang bukan di posisi asli menjadi under perform. Setelah banyak

	pergantian pemain yg bukan di pos aslinya tadi permainan persebaya jadi kacau. Juru taktik sangat bertanggung jawab untuk hasil ini
Case Folding	lain kali pasang pemain sesuai dengan posisinya terbukti pemain yg di pasang bukan di posisi asli menjadi under perform. setelah banyak pergantian pemain yg bukan di pos aslinya tadi permainan persebaya jadi kacau. juru taktik sangat bertanggung jawab untuk hasil ini.
Remove Stopwords	lain kali pasang pemain sesuai posisinya terbukti pemain pasang posisi asli under perform. setelah banyak pergantian pemain posisi aslinya permainan persebaya kacau. juru taktik bertanggung jawab hasil.
Tokenizing	['lain', 'kali', 'pasang', 'pemain', 'sesuai', 'posisinya', 'terbukti', 'pemain', 'pasang', 'posisi', 'asli', 'under', 'perform', 'setelah', 'banyak', 'pergantian', 'pemain', 'posisi', 'aslinya', 'permainan', 'persebaya', 'kacau', 'juru', 'taktik', 'bertanggung', 'jawab', 'hasil']
Stemming	['kali', 'pasang', 'main', 'sesuai', 'posisi', 'bukti', 'main', 'pasang', 'posisi', 'asli', 'under', 'perform', 'ganti', 'main', 'posii', 'asli', 'main', 'kacau', 'juru', 'taktik', 'tanggung', 'hasil']

3.3 Hasil Training

Berdasarkan hasil pelatihan model *LSTM* pada gambar 7 selama 5 *epoch*, dapat dilihat bahwa akurasi pada data pelatihan mengalami peningkatan secara bertahap. Pada *epoch* pertama, model mencapai akurasi sebesar 92% dengan nilai *loss* 0.2330. Akurasi ini terus meningkat hingga mencapai 93.76% pada *epoch* kelima, dengan penurunan nilai *loss* menjadi 0.1888. Hal ini menunjukkan bahwa model semakin baik dalam mengenali pola dari data latih.

```
Epoch 1/5
200/200 ————— 146s 714ms/step - accuracy: 0.9200 - loss: 0.2330 - val_accuracy: 0.4199 - val_loss: 2.6060
Epoch 2/5
200/200 ————— 202s 712ms/step - accuracy: 0.9176 - loss: 0.2223 - val_accuracy: 0.3905 - val_loss: 2.9309
Epoch 3/5
200/200 ————— 198s 696ms/step - accuracy: 0.9273 - loss: 0.2051 - val_accuracy: 0.3815 - val_loss: 2.9790
Epoch 4/5
200/200 ————— 142s 697ms/step - accuracy: 0.9362 - loss: 0.1923 - val_accuracy: 0.3454 - val_loss: 3.2368
Epoch 5/5
200/200 ————— 139s 681ms/step - accuracy: 0.9376 - loss: 0.1888 - val_accuracy: 0.3815 - val_loss: 3.2104
```

Gambar 7. Hasil Training

Namun, performa model pada data validasi menunjukkan hasil yang kurang optimal. *Val_accuracy* (akurasi validasi) mengalami *fluktuasi* dan cenderung menurun, dimulai dari 41.99% di *epoch* pertama hingga menjadi 38.15% di *epoch* kelima. Di sisi lain, nilai *val_loss* meningkat signifikan dari 2.6060 pada *epoch* pertama menjadi 3.2104 di *epoch* kelima. Kondisi ini menandakan adanya *overfitting*, di mana model terlalu menyesuaikan diri dengan data latih sehingga tidak mampu melakukan generalisasi dengan baik terhadap data baru atau data uji.

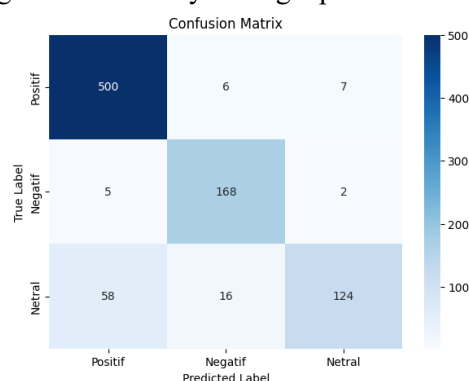
3.4 Evaluasi

Model *LSTM* pada gambar 8 dibawah yang digunakan dalam penelitian ini menunjukkan performa klasifikasi yang cukup baik dengan akurasi keseluruhan sebesar 89%. Pada kategori sentimen positif, model mampu mencapai *precision* sebesar 88,8% dan *recall* sebesar 97%, yang menghasilkan *f1-score* sebesar 93%. Hal ini menunjukkan bahwa model sangat efektif dalam mengidentifikasi *tweet* yang bernada positif. Untuk kategori negatif, *precision* mencapai 88,4% dan *recall* 96%, dengan *f1-score* 92%, yang juga menunjukkan performa kuat dalam mendeteksi sentimen negatif.

Precision :	[0.88809947 0.88421053 0.93233083]			
Recall :	[0.97465887 0.96 0.62626263]			
Classification Report:				
	precision	recall	f1-score	support
Positif	0.89	0.97	0.93	513
Negatif	0.88	0.96	0.92	175
Netral	0.93	0.63	0.75	198
accuracy			0.89	886
macro avg	0.90	0.85	0.87	886
weighted avg	0.90	0.89	0.89	886

Gambar 8. Evaluasi

Namun, hasil berbeda terlihat pada kategori netral. Meskipun *precision* tergolong tinggi, yaitu 93%, *recall*-nya hanya sebesar 62,6%, sehingga *f1-score* turun menjadi 75%. Hal ini mengindikasikan bahwa model cenderung kurang sensitif terhadap *tweet* bernuansa netral dan lebih sering salah mengklasifikasikannya sebagai positif atau negatif.



Gambar 9. Confusion Matrix

Sementara itu untuk *confusion matrix* pada gambar 9 di atas, model mampu mengklasifikasikan data sentimen dengan cukup baik, khususnya pada kategori Positif dan Negatif. Sebanyak 500 dari 513 data Positif berhasil diklasifikasikan dengan benar, hanya 13 data yang salah diklasifikasikan sebagai Negatif atau Netral. Untuk kategori Negatif, model berhasil mengidentifikasi 168 dari 175 data secara tepat, dengan kesalahan minimal. Namun, akurasi model menurun pada kategori Netral, di mana hanya 124 dari 198 data yang diklasifikasikan dengan benar. Sebanyak 58 data Netral salah diklasifikasikan sebagai Positif dan 16 lainnya sebagai Negatif. Hal ini menunjukkan bahwa model masih mengalami kesulitan dalam membedakan sentimen Netral, yang mungkin disebabkan karena konteks kata yang cenderung ambigu atau mirip dengan kategori lainnya.

3.5 Hasil Prediksi

Berdasarkan hasil prediksi model terhadap beberapa contoh teks pada gambar 10 dibawah ini, sistem menunjukkan kemampuan yang cukup baik dalam mengklasifikasikan sentimen. Kalimat seperti "mainnya tolol jelek banget" dan "ogak banget mainnya" berhasil dikenali sebagai sentimen negatif, mencerminkan ketidakpuasan terhadap performa tim. Kalimat seperti "permainannya lumayan bagus", "timnya masih kurang koordinasi", dan "pertahanannya kuat dan solid" dikategorikan sebagai positif, meskipun kalimat kedua mengandung kritik, namun model menilai secara keseluruhan masih dalam konteks positif atau membangun.

Teks: "mainnya tolol jelek banget"
 → Prediksi Label: Negatif
 Teks: "permainannya lumayan bagus"
 → Prediksi Label: Positif
 Teks: "timnya masih kurang koordinasi"
 → Prediksi Label: Positif
 Teks: "pertahanannya kuat dan solid"
 → Prediksi Label: Positif
 Teks: "gak jelas mainnya"
 → Prediksi Label: Netral
 Teks: "permainannya biasa aja"
 → Prediksi Label: Netral
 Teks: "ogak banget mainnya"
 → Prediksi Label: Negatif

Gambar 10. Hasil Prediksi

Untuk kalimat "gak jelas mainnya" dan "permainannya biasa aja", model memberikan label netral, menunjukkan bahwa model cukup sensitif dalam membedakan ekspresi yang tidak terlalu condong ke arah positif maupun negatif. Namun, klasifikasi "timnya masih kurang koordinasi" sebagai positif bisa menjadi indikasi bahwa model belum sepenuhnya memahami konteks implisit dari kalimat bernada kritik halus.

IV. KESIMPULAN

Penelitian ini bertujuan untuk mengklasifikasikan sentimen komentar pengguna *Twitter* terhadap klub sepak bola Persebaya Surabaya menggunakan metode *Long Short-Term Memory (LSTM)*. Model berhasil mengidentifikasi sentimen positif dan negatif dengan cukup baik, masing-masing dengan *recall* 97% untuk sentimen positif dan 96% untuk sentimen negatif, namun kesulitan pada sentimen netral dengan *recall* hanya 63%. Akurasi keseluruhan model mencapai 89%. Terjadinya *overfitting* terlihat dari meningkatnya akurasi data latih dari 92% menjadi 93,76%, sementara akurasi validasi justru menurun dari 41,99% menjadi 38,15%. Nilai *loss* validasi juga naik dari 2,60 menjadi 3,21. Hal ini menunjukkan bahwa model terlalu menyesuaikan diri dengan data latih, kemungkinan akibat ketidakseimbangan data antar kelas. Untuk penelitian selanjutnya, disarankan agar dilakukan peningkatan pada kualitas dan keseimbangan data untuk setiap label sentimen, terutama kategori netral yang sering terklasifikasi keliru.

DAFTAR PUSTAKA

- [1] P. Widiyantoro and Y. D. Prasetyo, "Deteksi Cyberbullying pada Pemain Sepak Bola di Platform Media Sosial 'X' Menggunakan Metode Long Short-Term Memory (LSTM)," 2025.
- [2] D. P. Ardiansyah, M. Arief, and N. Andrianto, "Strategi komunikasi green nord'27 tribune dalam merubah image bonek di masyarakat," pp. 355–362, 2023.
- [3] N. E. Destianti, M. Fridha, T. Palupi, and I. Danadharta, "Interaksi Fanatisme Suporter Sepakbola (Studi Etnografi Virtual Pada Akun Instagram @Officialpersebaya Pasca Tragedi Kanjuruhan)," *Semakom Semin. Nas. Mhs. Komun.*, vol. 1, no. 01, pp. 865–869, 2023, [Online]. Available: <https://conference.untag-sby.ac.id/index.php/semakom/article/view/1923>
- [4] M RIZQI ARIEL GIFFARI, "Analisis Sentimen Berbasis Aspek Pada," vol. 3, no. September, pp. 67–77, 2021.
- [5] R. Cahyadi *et al.*, "Recurrent Neural Network (Rnn) Dengan Long Short Term

- Memory (Lstm) Untuk Analisis Sentimen Data Instagram,” *J. Inform. dan Komput.*, vol. 5, no. 1, pp. 1–9, 2020.
- [6] X. Liu, D. Cao, and K. Yu, “Binarized LSTM language model,” *NAACL HLT 2018 - 2018 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. - Proc. Conf.*, vol. 1, pp. 2113–2121, 2018, doi: 10.18653/v1/n18-1192.
- [7] M. Abdul-Mageed and L. Ungar, “EmoNet: Fine-grained emotion detection with gated recurrent neural networks,” *ACL 2017 - 55th Annu. Meet. Assoc. Comput. Linguist. Proc. Conf. (Long Pap.)*, vol. 1, pp. 718–728, 2017, doi: 10.18653/v1/P17-1067.
- [8] J. Homepage *et al.*, “MALCOM: Indonesian Journal of Machine Learning and Computer Science Sentiment Analysis of Online Services at the Engineering and Vocational Faculty of Ganesha Education University Using Naïve Bayes and LSTM Algorithms Analisis Sentimen Pelayanan Daring di,” vol. 4, no. 3, pp. 1120–1129, 2024.
- [9] T. Pemilu, M. Khadapi, and V. M. Pakpahan, “Analisis Sentimen Berbasis Jaringan LSTM dan BERT terhadap Diskusi,” vol. 6, pp. 130–137, 2024.
- [10] N. Nur Azizah, I. Purnamasari, and S. Prangga, “Pengelompokan Judul Laporan Skripsi Berbasis Text Mining dengan Metode Fuzzy K-Means,” *Metik J.*, vol. 8, no. 1, pp. 18–23, 2024, doi: 10.47002/metik.v8i1.808.
- [11] A. A. Syam, G. H. M, A. Salim, D. F. Surianto, and M. F. B, “Analisis teknik preprocessing pada sentimen masyarakat terkait konflik israel-palestina menggunakan support vector machine,” vol. 9, no. 3, pp. 1464–1472, 2024.
- [12] M. Febima, L. Magdalena, M. Asfi, M. Hatta, and R. Fahrudin, “Implementasi Optimasi NLP dan KNN untuk User Review Aplikasi SAMPEAN Cirebon,” pp. 162–168.
- [13] U. Khairani, V. Mutiawani, and H. Ahmadian, “Pengaruh Tahapan Preprocessing Terhadap Model Indobert Dan Indobertweet Untuk Mendeteksi Emosi Pada Komentar Akun Berita Instagram,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 4, pp. 887–894, 2024, doi: 10.25126/jtiik.1148315.
- [14] D. A. N. Arifin, S. Pada, D. Teks, B. Indonesia, J. Pardede, and D. Darmawan, “PERBANDINGAN ALGORITMA STEMMING PORTER , SASTRAWI , IDRIS , COMPARISON OF STEMMING ALGORITHMS PORTER , SASTRAWI , IDRIS , AND ARIFIN SETIONO ON INDONESIAN TEXT DOCUMENTS,” vol. 12, no. 1, 2025, doi: 10.25126/jtiik.2025128860.
- [15] P. Made, R. C. Dinatha, and N. A. Rakhmawati, “Komparasi Term Weighting dan Word Embedding pada Klasifikasi Tweet Pemerintah Daerah (Comparison of Term Weighting and Word Embedding on Local Government Tweet Classification),” *J. Nas. Tek. Elektro dan Teknol. Inf.* |, vol. 9, no. 2, 2020.
- [16] Y. Ardian Pradana, I. Cholissodin, and D. Kurnianingtyas, “Analisis Sentimen Pemindahan Ibu Kota Indonesia pada Media Sosial Twitter menggunakan Metode LSTM dan Word2Vec,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 5, pp. 2389–2397, 2023, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [17] A. Rolangon, A. Weku, and G. A. Sandag, “Perbandingan Algoritma LSTM Untuk Analisis Sentimen Pengguna Twitter Terhadap Layanan Rumah Sakit Saat Pandemi Covid-19,” *TeKa*, vol. 13, no. 01, pp. 31–40, 2023, doi: 10.36342/teika.v13i01.3063.