

## Analisis Sentimen Piala Dunia U-20 di Indonesia pada X Menggunakan Metode Deep Learning

Nadhif Zuhayri Abdillah<sup>1</sup>, Alam Rahmatulloh<sup>1</sup>

<sup>1</sup>Program Studi Informatika

Fakultas Teknik

Universitas Siliwangi

Email: [alam@unsil.ac.id](mailto:alam@unsil.ac.id) \*

### Abstrak

*Analisis sentimen publik di Indonesia terkait Piala Dunia U-20 menjadi semakin penting dalam konteks opini masyarakat yang dinamis. Penelitian ini menggunakan metode Deep Learning, khususnya Long Short-Term Memory (LSTM), untuk menganalisis sentimen yang diungkapkan di platform X (sebelumnya Twitter). Data yang dikumpulkan melalui crawling menghasilkan 484 komentar, tetapi setelah proses preprocessing, hanya 97 komentar yang layak digunakan, dengan distribusi sentimen menunjukkan 50% netral, 28% negatif, dan 22% positif. Proses penelitian meliputi pelabelan sentimen, tokenisasi, dan padding untuk menyiapkan data bagi model. Model LSTM dikembangkan dengan menggunakan layer embedding, SpatialDropout1D, LSTM layer, dan Dense layer, dioptimalkan dengan algoritma Adam. Model dilatih selama 10 epoch dengan batch size 32, mencapai akurasi pelatihan rata-rata 0.88 dan akurasi validasi rata-rata 0.86. Hasil analisis menunjukkan bahwa metode Deep Learning lebih efektif dalam menangkap sentimen dibandingkan dengan teknik tradisional, serta memberikan wawasan berharga bagi pembuat kebijakan dalam memahami dinamika opini publik selama acara besar seperti Piala Dunia.*

**Kata kunci:** analisis sentimen, deep learning, piala dunia U-20.

### Abstract

*The analysis of public sentiment in Indonesia regarding the U-20 World Cup is becoming increasingly important in the context of dynamic public opinion. This research uses Deep Learning methods, specifically Long Short-Term Memory (LSTM), to analyze sentiments expressed on platform X (formerly Twitter). The data collected through crawling resulted in 484 comments, but after preprocessing, only 97 comments were usable, with the sentiment distribution showing 50% neutral, 28% negative, and 22% positive. The research process includes sentiment labeling, tokenization, and padding to prepare the data for the model. The LSTM model was developed using embedding layer, SpatialDropout1D, LSTM layer, and Dense layer, optimized with Adam's algorithm. The model was trained for 10 epochs with a batch size of 32, achieving an average training accuracy of 0.88 and an average validation accuracy of 0.86. The analysis results show that Deep Learning methods are more effective in capturing sentiment compared to traditional techniques, and provide valuable insights for policymakers in understanding the dynamics of public opinion during major events such as the World Cup.*

**Keywords:** sentiment analysis, deep learning, U-20 world cup.

## I. Pendahuluan

Piala dunia U-20 merupakan salah satu ajang sepak bola Internasional yang dinantikan banyak orang, terutama penggemar sepak bola di seluruh dunia. Kompetensi ini diselenggarakan oleh FIFA (*Fédération Internationale de Football Association*), yang juga dikenal sebagai Federasi Sepak Bola Internasional. Pada tahun 2021, Piala Dunia U-20 dijadwalkan berlangsung di Indonesia, namun karena pandemi COVID-19, FIFA pada Desember 2020 mengumumkan pembatalan acara tersebut. Meski demikian, FIFA menetapkan Indonesia tetap tuan rumah untuk edisi 2023. Keputusan ini membuat banyak masyarakat Indonesia, baik penggemar sepak bola maupun kalangan umum, merasa antusias dan bangga atas kepercayaan yang diberikan kepada negara mereka.

Namun pada tahun 2023, hak tuan rumah Indonesia dicabut oleh FIFA menyusul protes terhadap keikutsertaan tim nasional Israel. Keputusan ini memicu reaksi beragam dari masyarakat, baik berupa dukungan maupun kritik, yang sebagian besar disampaikan melalui media sosial, khususnya platform X (sebelumnya dikenal sebagai *Twitter*) [1]. Di masa digital, media sosial memainkan peran penting sebagai sarana masyarakat untuk menyuarakan pandangan, opini, dan emosi mereka terkait isu-isu tertentu, termasuk olahraga [2]. Pemanfaatan media sosial, terutama X, memungkinkan pengumpulan informasi secara cepat dan efisien [3]. Dalam konteks ini, memahami reaksi masyarakat terhadap pembatalan Indonesia sebagai tuan rumah Piala Dunia U-20 menjadi penting untuk mengevaluasi dampak keputusan tersebut terhadap opini publik, khususnya dalam lingkungan yang sangat dinamis [4].

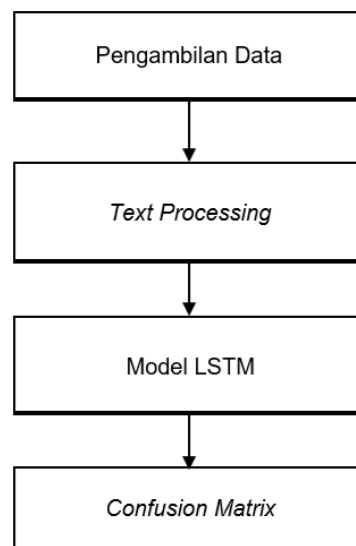
Analisis sentimen menggunakan pendekatan *machine learning* telah banyak digunakan untuk mengorganisasi data teks tidak terstruktur menjadi informasi yang bermakna [5]. Analisis sentimen adalah metode untuk mengenali dan mengekstraksi opini seseorang dari teks, mengelompokkannya ke dalam sentimen positif atau negatif, dan menyajikannya secara terstruktur [6]. Salah satu pendekatan modern yang menonjol adalah *deep learning*, khususnya metode *Long Short-Term Memory* (LSTM) [7]. Dibandingkan dengan metode tradisional seperti *Naïve Bayes* dan *Support Vector Machine* (SVM), LSTM menawarkan keunggulan dalam memahami konteks teks yang kompleks, terutama dalam menangani data media sosial yang bersifat *real-time* dan tidak terstruktur [8].

Penelitian sebelumnya telah mengeksplorasi analisis sentimen terkait pembatalan Piala Dunia U-20 menggunakan berbagai metode, seperti

*Naïve Bayes Classifier* (NBC) dengan akurasi 73,7% [9] dan *Support Vector Machine* (SVM) dengan akurasi 74,4% [10]. Namun, hasil dari metode tersebut memiliki keterbatasan dalam menangkap kompleksitas data teks media sosial [11]. Penelitian ini berkontribusi dengan menerapkan metode LSTM yang memiliki akurasi lebih tinggi dibandingkan sebelumnya [12], menunjukkan potensi signifikan dalam analisis sentimen publik [13], khususnya untuk isu-isu besar seperti pembatalan Piala Dunia U-20. Dengan pendekatan ini, diharapkan penelitian ini dapat memberikan wawasan yang lebih mendalam dan akurat mengenai opini masyarakat di media sosial dalam konteks peristiwa besar.

## II. Metode Penelitian

Proses dan tahapan penelitian melalui beberapa tahapan yang digambarkan pada diagram pada Gambar 1.



Gambar 1. Metode Penelitian

Dari Gambar 1, tahapan pertama dimulai dengan pengambilan *dataset* dari twitter atau X lalu data set tersebut dilakukan *text pre-processing*. Setelah dilakukan proses *text processing*, data yang sudah rapih membagi data menjadi pelatihan dan pengujian lalu mengkonversi ke dari label ke angka, setelah itu dibuatlah tokenizer dimasukkan kedalam model LSTM dan terakhir model dilatih untuk agar menghasilkan *output*. Hasil *output* tersebut dievaluasi melalui *confusion matrix*.

### 2.1 Data

Data yang digunakan dalam penelitian ini diperoleh melalui proses *crawling* dari platform

Twitter/X. Pengumpulan data dilakukan dengan menggunakan kata kunci "piala dunia U-20 2023". Data yang sudah dikumpulkan disimpan dengan format .csv.

**Tabel 1.** Contoh hasil data crawl

| No | Full_text   | username        |
|----|---|-----------------|
| 1  | Ini Buat heboh satu negara hingga dianggap menjadi salah satu alasan batalnya Piala Dunia U-20 2023 di Indonesia Ganjar mengaku tidak menyesal. GantianKitaHapus MimpiGanjar #Gnj4rHapusMimpiU20  | D4rmesta        |
| 2  | @ganjarpranowo Saya kasih tau orang Indonesia itu gila sama sepak bola kalo dipresentasikan 80%+ jadi ini alasan membuat 03 kalah telak di Pilpres 2024 Lagian Ganjar Pranowo yang menyebabkan Indonesia batal jadi tuan rumah piala dunia U-20 2023 dan membuat Indonesia di blacklist <a href="https://t.co/WmJX0cxf9h">https://t.co/WmJX0cxf9h</a> | Khoirularifinnn |
| 3  | @kangdede78 Saat piala dunia u 20 thn 2023 israel masuk final sdh pasti resiko keamanan tinggi apalagi itu melanggar konstitusi.  | CDoreri         |

Data pada tabel 1 belum terstruktur, maka dilakukan lah tahap selanjutnya yaitu *preporcessing* dimana data tersebut akan menjadi lebih terstruktur.

## 2.2. Text Preprocessing

Tahap persiapan data merupakan langkah krusial dalam proses analisis sentimen, karena data mentah yang diambil dari platform seperti Twitter/X umumnya tidak terstruktur dan memerlukan berbagai bentuk transformasi agar dapat digunakan oleh model. Tahap ini mencakup empat sub-tahapan utama yang masing-masing memiliki peran penting dalam memastikan kualitas dan kesiapan data untuk dianalisis oleh model Long Short-Term Memory (LSTM) [14].

### 1. Pembuatan Label Sentimen

Langkah awal melibatkan pengelompokan teks berdasarkan sentimen yang terkandung di dalamnya. Sentimen dikelompokkan ke dalam tiga label utama: positif, negatif, dan netral. Proses klasifikasi dilakukan dengan memanfaatkan kata kunci yang sesuai dengan konteks permasalahan. Misalnya, dalam analisis pembatalan Indonesia sebagai tuan rumah Piala Dunia U-20, kata-kata seperti "kecewa" atau "marah" dapat dilabeli sebagai negatif, sementara "senang" atau "puas" dapat dilabeli sebagai positif. Proses ini membutuhkan pemahaman mendalam tentang konteks sosial

dan budaya untuk memastikan bahwa setiap kata kunci yang dipilih mencerminkan sentimen dengan akurat. Langkah ini sangat penting karena label-label tersebut akan menjadi dasar bagi model untuk belajar mengenali pola sentimen dalam teks selama proses pelatihan [15].

### 2. Pelabelan Teks menjadi Angka

Setelah label sentimen dibuat, teks yang tidak terstruktur diubah menjadi bentuk representasi numerik agar dapat diproses dan dipahami oleh model pada tahap klasifikasi selanjutnya. Proses ini sering disebut sebagai *encoding*, di mana setiap label sentimen (positif, negatif, netral) dan kata dalam teks diberi nilai numerik unik. Misalnya, "positif" dapat diberi label 1, "negatif" diberi label 0, dan "netral" diberi label 2. Transformasi ini memastikan bahwa data yang digunakan oleh model memiliki format yang sesuai dengan algoritma *deep learning*, yang hanya dapat memproses angka, bukan teks mentah [14].

### 3. Tokenisasi

Proses tokenisasi adalah langkah penting berikutnya, proses ini memecah teks menjadi unit-unit kecil yang disebut token, yang dapat berupa kata, angka, simbol, tanda baca, atau elemen penting lainnya. Misalnya, kalimat "Indonesia batal jadi tuan rumah" dapat dipecah menjadi token-token seperti ["Indonesia", "batal", "jadi", "tuan", "rumah"]. Tokenisasi membantu model untuk menganalisis setiap elemen dalam teks secara individual, memungkinkan model untuk menangkap makna spesifik dari kata-kata atau simbol tertentu dalam konteks kalimat. Tokenisasi juga memastikan bahwa model dapat memproses teks secara konsisten dan terstruktur. Proses ini memerlukan pengaturan yang cermat, seperti menentukan apakah tokenisasi dilakukan pada tingkat kata atau karakter, serta bagaimana penanganan tanda baca atau istilah-istilah khusus yang mungkin relevan dalam analisis [15].

### 4. Padding

Setelah proses tokenisasi selesai, panjang teks yang dihasilkan sering kali bervariasi. Sebagai contoh, satu kalimat mungkin memiliki 10 kata, sementara yang lain memiliki 15 atau lebih. Untuk mengatasi variasi ini, digunakan teknik *padding*, yaitu menambahkan token tertentu (misalnya, angka nol) di akhir atau awal setiap teks sehingga semua teks memiliki panjang yang sama. Misalnya, jika panjang standar yang ditentukan adalah 20 kata, maka

teks yang lebih pendek akan diberi padding hingga mencapai panjang tersebut. Padding ini penting untuk memastikan kompatibilitas dengan input model LSTM, yang memerlukan data dengan dimensi yang seragam. Selain itu, padding memungkinkan model untuk memproses batch data secara efisien selama pelatihan [14].

Keempat sub-tahapan ini saling melengkapi dan menjadi dasar untuk menghasilkan data yang siap digunakan oleh model deep learning. Proses ini tidak hanya memastikan bahwa data mentah dari media sosial dapat dianalisis, tetapi juga meningkatkan kualitas prediksi dengan memberikan representasi data yang lebih baik untuk model. Dengan persiapan data yang matang, model memiliki peluang lebih besar untuk menghasilkan hasil analisis yang akurat dan informatif.

## 2.2 Model LSTM

Tahapan pembuatan model *Long Short-Term Memory* (LSTM) dimulai dengan penggunaan lapisan *embedding*, yang bertujuan untuk mengubah teks input yang tidak terstruktur menjadi representasi vektor berdimensi tinggi. *Embedding* ini berfungsi untuk memetakan kata-kata dalam kalimat ke dalam ruang vektor sehingga model dapat memahami hubungan semantic antara kata-kata tersebut. Vektor-vektor ini memungkinkan model memahami makna serta konteks kata-kata dalam sebuah kalimat, sehingga model dapat memproses teks dengan lebih efektif [16]. Representasi vektor yang dihasilkan oleh lapisan *embedding* berukuran 512 dimensi, memberikan ruang yang cukup luas bagi model untuk mempelajari hubungan yang kompleks dalam teks.

Setelah lapisan *embedding*, untuk mengurangi risiko *overfitting* dan meningkatkan kemampuan model untuk generalisasi, diterapkan lapisan *SpatialDropout1D* dengan tingkat dropout sebesar 20%. Teknik dropout ini membantu model untuk tidak terlalu bergantung pada fitur tertentu selama proses pelatihan, yang pada gilirannya mencegah model menjadi terlalu spesifik pada data pelatihan, model menjadi lebih efektif dan mampu melakukan generalisasi terhadap data yang belum pernah ditemui sebelumnya. Dropout bekerja dengan cara menghilangkan secara acak sejumlah neuron atau fitur pada setiap literasi pelatihan, sehingga model tidak terlalu mengandalkan pola-pola yang terlalu spesifik dari data pelatihan. Penggunaan *SpatialDropout1D* di sini lebih ditujukan untuk mengurangi ketergantungan pada fitur tertentu yang berhubungan dengan urutan data (seperti kata-kata dalam kalimat). Yang dapat

meningkatkan akurasi model pada data yang tidak terduga [17].

Langkah berikutnya adalah penggunaan lapisan *Long Short-Term Memory* (LSTM) yang terdiri 100 neuron dengan tingkat dropout 20% bertujuan untuk menangkap ketergantungan temporal dalam data teks, yaitu hubungan antara kata-kata yang muncul dalam urutan tertentu. *Long Short-Term Memory* (LSTM) memiliki kemampuan untuk mengingat informasi dari urutan kata sebelumnya dalam kalimat dan menggunakan informasi tersebut untuk memprediksi kata atau makna yang relevan di posisi berikutnya. Dengan menggunakan 100 neuron, model *Long Short-Term Memory* (LSTM) mampu memproses informasi dalam dimensi yang lebih besar, memberikan kekuatan lebih dalam memahami kompleksitas hubungan antara kata-kata dalam teks. Selain itu, dengan menambahkan dropout sebesar 20% pada lapisan *Long Short-Term Memory* (LSTM), model kembali dilindungi dari potensi *overfitting* yang dapat terjadi akibat ketergantungan terlalu besar pada neuron tertentu dalam menangkap pola data yang berulang [18].

Setelah lapisan LSTM, model diakhiri dengan lapisan *Dense* yang memiliki jumlah neuron yang disesuaikan dengan jumlah kelas dalam data label, yaitu tiga kelas: positif, negatif, dan netral. Lapisan *dense* ini bertanggung jawab untuk membuat keputusan akhir mengenai klasifikasi sentimen dari teks yang telah diproses. Fungsi aktivasi yang digunakan pada lapisan *dense* adalah *softmax*, yang memungkinkan model untuk mengeluarkan probabilitas untuk setiap kelas yang ada [16]. Fungsi *softmax* mengubah output model menjadi distribusi probabilitas, di mana setiap nilai output untuk setiap kelas akan berada di antara 0 dan 1, dan totalnya akan menjadi 1. Dengan menggunakan *softmax*, model memberikan gambaran tentang seberapa besar kemungkinan sebuah teks termasuk dalam setiap kelas sentimen. Sebagai contoh, model akan mengeluarkan probabilitas seperti 0.7 untuk kelas positif, 0.2 untuk kelas netral, dan 0.1 untuk kelas negatif, yang menunjukkan keyakinan model terhadap setiap kelas tersebut [17].

Secara keseluruhan, model *Long Short-Term Memory* (LSTM) ini mengintegrasikan berbagai elemen penting dalam arsitektur *deep learning* untuk memastikan kemampuan model dapat mengelola data teks secara efektif, mencegah *overfitting*, serta menghasilkan prediksi yang lebih tepat. Lapisan *embedding* menyediakan representasi yang kaya untuk teks, sementara lapisan *Long Short-Term*

Memory (LSTM) menangkap dependensi temporal dan hubungan antar kata dalam kalimat. Dropout diterapkan untuk meningkatkan generalisasi model, dan lapisan dense dengan fungsi aktivasi softmax mengeluarkan probabilitas untuk masing-masing kelas, memungkinkan model untuk membuat prediksi berbasis data yang lebih lengkap dan informatif [18].

**2.3 Confusion matrix**

Dalam penelitian ini, kami menggunakan *confusion matrix* untuk menilai kinerja model dalam mengklasifikasikan sentimen terkait Piala Dunia U-20. *Confusion matrix* adalah alat yang membantu kita melihat seberapa baik model melakukan prediksi dibandingkan dengan hasil yang sebenarnya[19]. 4 *metrics* yang digunakan di hitung yaitu *accuracy*, *precision*, *recall*, dan *F1 Score*. *Accuracy* adalah rasio yang membandingkan jumlah prediksi benar terhadap total jumlah data, yang dapat dihitung menggunakan rumus dengan persamaan 1.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (1)$$

*Precision* merupakan rasio antara jumlah kalimat positif yang benar-benar terdeteksi sebagai kalimat positif dengan total kalimat positif yang terdeteksi. Perhitungannya dapat menggunakan persamaan 2.

$$precision = \frac{TP}{TP+FP} \dots\dots\dots (2)$$

*Recall* adalah rasio antara jumlah kalimat positif yang benar terdeteksi sebagai kalimat positif dengan total jumlah kalimat dalam data. Perhitungannya dapat menggunakan persamaan 3.

$$recall = \frac{TP}{TP+FN} \dots\dots\dots (3)$$

*F1 Score* merupakan *metric* yang menggabungkan *precision* dan *recall* untuk mengukur kinerja keseluruhan dari suatu klasifikasi. Perhitungannya dapat menggunakan persamaan 4.

$$F1\ score = \frac{TP}{TP+FP} \dots\dots\dots (4)$$

**III. HASIL DAN PEMBAHASAN**


Pada tahapan pertama yaitu tahapan *crawling data*, proses dimulai dengan mengumpulkan data dari *platform* media sosial *Twitter*, yang kini dikenal dengan X. Dari hasil *crawling*, diperoleh 484 data komentar, namun

setelah dilakukan *preprocessing*, hanya 97 data yang memenuhi persyaratan dan dapat dimanfaatkan untuk analisis lanjutan. Proses *preprocessing* ini bertujuan untuk mempersiapkan data agar sesuai dengan kebutuhan model analisis sentimen. Proses *preprocessing* diawali dengan pelabelan terhadap kata kunci yang ada dalam kalimat yang diperoleh. Pelabelan ini penting untuk mengategorikan kalimat-kalimat berdasarkan sentimennya, yaitu positif, negative, atau netral. Proses pelabelan ini dilakukan secara manual dengan mempertimbangkan konteks dan makna setiap kalimat. Setelah tahap pelabelan, data teks kemudian melalui proses tokenisasi, di mana setiap kalimat dipecah menjadi unit terkecil, yakni token, yang dapat dianalisis lebih lanjut oleh model. Tahap tokenisasi ini penting untuk mengonversi teks ke dalam format yang dapat diproses oleh model *machine learning*. Langkah terakhir dalam *preprocessing* adalah *padding*, yang digunakan untuk menstandarkan panjang teks agar sesuai dengan input yang dibutuhkan oleh model. *Padding* memastikan bahwa setiap data teks memiliki Panjang yang seragam, sehingga dapat diproses dalam satu *batch* tanpa terjadi kesalahan

Setelah tahapan *preprocessing* selesai, tahapan selanjutnya adalah *modelling*, di mana model yang digunakan adalah *Long Short-Term Memory (LSTM)*. Model LSTM dipilih karena kemampuannya dalam menangkap dependensi temporal dalam data teks, yang sangat penting dalam analisis sentiment untuk memahami hubungan antar kata dalam kalimat yang memiliki konteks waktu atau urutan. Pada model ini digunakan beberapa layer penting. Pertama, terdapat *Layer embedding* yang berfungsi untuk mengubah teks input menjadi representasi vektor berdimensi 512, yang memetakan kata-kata dalam kalimat ke dalam ruang vektor berdimensi tinggi. Kemudian, digunakan *SpatialDropout1D* untuk mencegah overfitting, yang merupakan teknik regulasi untuk mengurangi ketergantungan model terhadap fitur-fitur tertentu yang dapat menurunkan generalisasi model. Selanjutnya LSTM *Layer* digunakan untuk menangkap pola temporal dalam urutan kata, yang memungkinkan model untuk memahami hubungan antara kata-kata yang berada dalam urutan tertentu dalam kalimat. Terakhir *Dense Layer* digunakan dengan jumlah neuron yang disesuaikan dengan jumlah kelas yang ada, yaitu tiga kelas: positif, negatif, dan netral. Model dikompilasi menggunakan *optimizer* Adam, yang terkenal dengan kemampuannya untuk mengoptimalkan kinerja model secara efisien. *Loss function* yang

digunakan adalah *loss* untuk klasifikasi, dan *metrics* digunakan untuk mengevaluasi kinerja model secara keseluruhan.

Model kemudian dilatih selama 10 *epoch*, dengan *batch size* 32, pada tahap ini data pelatihan digunakan untuk melatih model, sementara data validasi digunakan untuk mengevaluasi kinerja model setelah setiap *epoch*. Selama pelatihan, model berusaha mengurangi kesalahan prediksi berdasarkan umpan balik yang diperoleh dari data validasi. Hasil evaluasi model ditampilkan melalui *confusion matrix* yang dapat dilihat pada Gambar 2.




Gambar 2. *Confusion Matrix*

Pada Gambar 2 *confusion matrix* menunjukkan distribusi hasil prediksi model berdasarkan kategorisasi sentimen. Baris pertama menggambarkan hasil prediksi untuk kategori negatif, dimana negatif – negatif menunjukkan 1 prediksi yang benar, negatif – netral menunjukkan 3 prediksi yang salah, dan tidak ada prediksi yang salah untuk kategori negatif – positif. Baris kedua menunjukkan hasil kategori netral, di mana netral – negatif menunjukkan 2 prediksi yang salah, netral – netral menunjukkan 68 prediksi yang benar, dan netral – positif menunjukkan 3 prediksi yang salah. Baris ketiga menunjukkan hasil untuk kategori positif, dengan positif – negatif menunjukkan 0 prediksi yang salah, positif – netral menunjukkan 2 prediksi yang salah, dan positif – positif menunjukkan 18 prediksi yang benar. Hasil ini menggambarkan seberapa baik model dapat mengklasifikasikan sentimen yang ada pada data, dengan sebagian besar prediksi yang benar terjadi pada kategori netral, dan kesalahan prediksi terjadi lebih sering pada kalimat yang memiliki sentimen positif atau negatif.

Selanjutnya, hasil akurasi model ditunjukkan pada Gambar 3 dalam bentuk diagram batang yang menggambarkan perbandingan rata-rata

akurasi untuk data pelatihan dan data validasi. Proses pelatihan model *deep learning* menunjukkan bahwa model ini tidak mengalami *overfitting*, yang berarti model memiliki kemampuan yang efektif untuk melakukan generalisasi pada data yang belum pernah ditemui sebelumnya. Hasil dari *mean training accuracy* mencapai 0,88, sedangkan *mean validation accuracy* mencapai 0,86. Perbedaan antara keduanya menunjukkan bahwa model mampu memprediksi dengan akurasi yang cukup baik, baik pada data pelatihan maupun data validasi. Namun, perbedaan nilai ini juga memberikan indikasi bahwa ada ruang untuk perbaikan, terutama dalam hal ini meningkatkan akurasi pada data validasi, yang bisa dioptimalkan lebih lanjut melalui *fine-tuning* model atau penambahan data pelatihan



Gambar 3. Akurasi

Secara keseluruhan, temuan penelitian ini mengindikasikan bahwa model *Long Short-Term Memory* (LSTM) yang digunakan dalam analisis sentiment pada data *Twitter/X* mampu memberikan hasil yang cukup memadai, meskipun masih ada beberapa area yang perlu ditingkatkan untuk mencapai akurasi yang lebih baik, khususnya pada kategori sentimen positif dan negatif.

#### IV. Kesimpulan

Berdasarkan penelitian ini, dapat disimpulkan bahwa penerapan metode *Deep Learning*, khususnya *Long Short-Term Memory* (LSTM), sangat efektif dalam analisis sentimen terkait pembatalan Indonesia sebagai tuan rumah Piala Dunia U-20, dengan tingkat akurasi sebesar 88%, yang lebih unggul dibandingkan dengan metode pembelajaran mesin tradisional. LSTM terbukti mampu menangani data teks yang tidak terstruktur, seperti yang sering ditemui pada media sosial, dan memberikan analisis cepat serta akurat dalam situasi real-time yang dinamis. Namun, meski hasilnya memuaskan, penelitian ini menyarankan eksplorasi model lain seperti Transformer atau BERT, serta pengoptimalan parameter dan

teknik pengolahan data untuk meningkatkan akurasi, terutama dalam kategori tertentu. Secara keseluruhan, LSTM memiliki potensi besar untuk diaplikasikan dalam analisis sentiment berbasis teks pada berbagai konteks yang lebih luas di masa depan.

#### Daftar Pustaka

- [1] H. Setiawan and I. Zufria, "Analisis Sentimen Pembatalan Indonesia Sebagai Tuan Rumah Piala Dunia FIFA U-20 Menggunakan Naïve Bayes," *J. Media Inform. Budidarma*, vol. 7, no. 3, pp. 1003–1012, 2023, doi: 10.30865/mib.v7i3.6144.
- [2] I. R. Afandi, N. Pratiwi, A. A. Rizki, M. Irva, and M. F. Aulia, "Perancangan Sistem Informasi Pelayanan Pembuatan Surat Online Di Desa Ciangsana Bebas Website," *JATI (Jurnal Mhs. Tek. Inform., vol. 6, no. 2, pp. 571–577, 2022, doi: 10.36040/jati.v6i2.5318.*
- [3] S. Fathurrohman, I. R. Afandi, and F. N. Hasan, "Sentiment Analysis of TIMNAS Indonesia's Participation in the Asian Cup U23 2024 on X Using Naive Bayes and SVM," *IJID Int. J. Informatics Dev., vol. 13, no. 1, pp. 434–447, 2024, doi: 10.14421/ijid.2024.4504.*
- [4] R. H. Nufus and U. Surapati, "Analisis Sentimen Persepsi Masyarakat Terhadap Timnas Indonesia U-23 dalam AFC-23 Asian Cup 2024 Pada Media Sosial X Menggunakan Metode Naïve Bayes Classifier," vol. 5, no. 3, pp. 2647–2657, 2024.
- [5] Y. Akbar and A. N. Ihsan, "Analisis Sentimen Twitter Terhadap Opini Masyarakat Pada Sea Games Kamboja 2023 Menggunakan Algoritma Support Vector Machine," *INTECOMS J. Inf. Technol. Comput. Sci., vol. 6, no. 2, pp. 814–821, 2023, doi: 10.31539/intecom.v6i2.7670.*
- [6] F. Matheos Sarimole and K. Kudrat, "Analisis Sentimen Terhadap Aplikasi Satu Sehat Pada Twitter Menggunakan Algoritma Naive Bayes Dan Support Vector Machine," *J. Sains dan Teknol., vol. 5, no. 3, pp. 783–790, 2024, doi: 10.55338/saintek.v5i3.2702.*
- [7] I. Verawati and B. S. Audit, "Algoritma Naïve Bayes Classifier Untuk Analisis Sentiment Pengguna Twitter Terhadap Provider By.u," *J. Media Inform. Budidarma*, vol. 6, no. 3, p. 1411, 2022, doi: 10.30865/mib.v6i3.4132.
- [8] A. Noviriandini, H. Hermanto, and Y. Yudhistira, "Klasifikasi Support Vector Machine Berbasis Particle Swarm Optimization Untuk Analisa Sentimen Pengguna Aplikasi Pedulilindungi," *JIKA (Jurnal Inform., vol. 6, no. 1, p. 50, 2022, doi: 10.31000/jika.v6i1.5681.*
- [9] A. Aliyudin, "Analisis Sentimen Terhadap Piala Dunia U-20 Yang Batal Diselenggarakan Di Indonesia Pada Media Youtube Dengan Menggunakan Metode Naïve Bayes," *Inf. Interaktif J. Inform. dan Teknol. Inf., vol. 8, no. 2, pp. 71–78, 2023.*
- [10] S. F. Handayani, R. W. Pratiwi, D. Dairoh, and D. I. Afidah, "Analisis Sentimen pada Data Ulasan Twitter dengan Long-Short Term Memory," *JTERA (Jurnal Teknol. Rekayasa), vol. 7, no. 1, p. 39, 2022, doi: 10.31544/jtera.v7.i1.2022.39-46.*
- [11] S. B. Adi, "Analisis Sentimen Terhadap Pro Dan Kontra Batalnya Indonesia Menjadi Tuan Rumah Piala Dunia U20 Pada Media Sosial Twitter Dengan Menggunakan Metode Naive Bayes Classifier (NBC)," *Inov. J. Ilm. Inov. Teknol. Inf., vol. VIII, no. 1, pp. 1–9, 2023.*
- [12] A. Damayanti and A. Khairina Maulidiyah, "Analisa Sentimen Pada Pembatalan Piala Dunia U20 di Indonesia Menggunakan Metode Support Vector Machine," *JITSI J. Ilm. Terap., vol. 1, no. 2, pp. 97–103, 2023, doi: 10.25139/jitsi.v1i2.6607.*
- [13] E. L. Rara and E. Mailoa, "Implementasi Algoritma Naive Bayes Terhadap Analisis Sentimen Perubahan Piala Dunia U-20," *Progresif J. Ilm. Komput., vol. 20, no. 1, p. 259, 2024, doi: 10.35889/progresif.v20i1.1550.*
- [14] F. Chollet, *Deep Learning with Python*. Manning Publications, 2018.
- [15] Y. Goldberg, *Neural Network Methods for Natural Language Processing*. Morgan & Claypool, 2017.
- [16] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions.," *SN Comput. Sci., vol. 2, no. 3, pp. 1–21, 2021.*
- [17] A. Goodfellow, I., Bengio, Y., & Courville, *Deep Learning*. MIT Press, 2016.
- [18] C. D. Pennington, J., Socher, R., & Manning, "GloVe: Global Vectors for Word Representation.," *Proc. 2014 Conf. Empir. Methods Nat. Lang. Process., pp. 1532–1543, 2014.*
- [19] S. Syihabuddin Azmil Umri, "Analisis Dan Komparasi Algoritma Klasifikasi Dalam Indeks Pencemaran Udara Di Dki Jakarta," *JIKO (Jurnal Inform. dan Komputer), vol. 4, no. 2, pp. 98–104, 2021, doi: 10.33387/jiko.v4i2.2871.*