

Penerapan Model Deep Neural Networks dalam Menganalisis Sentimen Aplikasi ChatGPT

Application of the Deep Neural Networks Model in Analyzing ChatGPT Application Sentiment

¹Ahmad Fauzi*, ²Indra Chaidir, ³Muhammad Iqbal, ⁴Ginabila

^{1,2,4}Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

³Teknik Informatika Kampus Kota Pontianak, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

Jalan Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, DKI Jakarta, Indonesia

*e-mail: ahmad.aau@bsi.ac.id

(*received*: 16 Agustus 2023, *revised*: 12 September 2023, *accepted*: 9 Oktober 2023)

Abstrak

AI telah mampu menirukan perilaku manusia secara cerdas dan telah diterapkan dalam berbagai konteks, termasuk kesehatan untuk perawatan pasien yang lebih efisien. Salah satu tren menonjol dalam AI adalah model bahasa canggih seperti ChatGPT yang dikembangkan oleh OpenAI. Efektivitas ChatGPT dalam menemukan dan memperbaiki bug pada kode komputer menjadi subjek perdebatan, tergantung pada tugas, data pelatihan, dan desain sistem. Kepopuleran platform media sosial, terutama Twitter, sebagai sumber data analisis teks telah meningkatkan minat dalam analisis sentimen. Penelitian ini mengeksplorasi sentimen terhadap aplikasi ChatGPT dengan menggunakan dataset 50.000 tweet. Analisis sentimen dilakukan dengan pendekatan deep neural network (DNNs) untuk mencapai akurasi yang optimal. Model deep learning dikenal memiliki prediktivitas yang tinggi dan waktu pelatihan yang efisien. Melalui eksperimen ini, kami bertujuan untuk mendapatkan wawasan tentang pandangan publik terhadap ChatGPT dalam tiga kategori sentimen: positif, negatif, dan netral. DNN (Deep Neural Network) diusulkan karena performanya yang baik serta dapat mempersingkat jumlah waktu pelatihan. Hasilnya dengan model yang digunakan pada penelitian ini yaitu CNN dan LSTM keduanya mencapai nilai akurasi lebih dari 90%: Dimana CNN memperoleh nilai akurasi sebesar 91.12% dan LSTM memperoleh akurasi sebesar 90.84%.

Kata Kunci: Artificial Intelligence, ChatGPT, analisis sentimen, deep neural network.

Abstract

AI has been able to intelligently mimic human behavior and has been applied in various contexts, including healthcare for more efficient patient care. One of the prominent trends in AI is advanced language models such as ChatGPT developed by OpenAI. The effectiveness of ChatGPT in finding and fixing bugs in computer code is a subject of debate, depending on the task, training data, and system design. The popularity of social media platforms, particularly Twitter, as a data source for text analysis has increased interest in sentiment analysis. This study explores sentiment towards the ChatGPT application using a dataset of 50,000 tweets. Sentiment analysis is performed using a deep neural network (DNNs) approach to achieve optimal accuracy. Deep learning models are known to have high predictivity and efficient training time. Through this experiment, we aim to gain insight into how the public views ChatGPT in three sentiment categories: positive, negative, and neutral. DNN (Deep Neural Network) is proposed because of its good performance and can shorten the amount of training time. The results with the model used in this study, namely CNN and LSTM both achieve an accuracy value of more than 90%: Where CNN obtains an accuracy value of 91.12% and LSTM obtains an accuracy of 90.84%.

Keywords: Artificial Intelligence, ChatGPT, sentiment analysis, deep neural network.

1 Pendahuluan

Saat ini, AI terintegrasi ke dalam kehidupan kita sehari-hari dalam berbagai bentuk, seperti asisten pribadi (Siri, Alexa, asisten Google, dll.) [1] dengan cara apapun *Artificial Intelligence* dapat menirukan tingkah laku manusia yang dikategorikan cerdas [2]. AI atau ilmu kecerdasan buatan dengan menggunakan komputer digunakan untuk mensimulasikan perilaku cerdas manusia dan melatih komputer untuk mempelajari perilaku manusia seperti belajar, penilaian, dan pengambilan keputusan [3]. Pada bidang kesehatan AI juga mulai dimasukkan ke dalam pengobatan untuk meningkatkan perawatan pasien dengan mempercepat proses dan mencapai akurasi yang lebih tinggi, membuka jalan untuk menyediakan perawatan kesehatan yang lebih baik secara keseluruhan [1].

Salah satu produk *Artificial Intelligence* yang saat ini sedang *booming* adalah ChatGPT. ChatGPT adalah model bahasa canggih yang dikembangkan oleh OpenAI yang berpotensi merevolusi cara kita berinteraksi dengan teknologi [4]. Efektivitas penggunaan ChatGPT dalam menemukan dan memperbaiki bug pada kode komputer bergantung pada tugas tertentu, kualitas data pelatihan, dan desain sistem [5]. Kemunculan ChatGPT menjadi topik hangat yang diperbincangkan pada salah satu platform media sosial salah satunya *twitter*. Kepopuleran *twitter* dalam mengambil sumber data pada analisis berbentuk teks banyak digunakan karena struktur teksnya cocok digunakan untuk melakukan analisis [6].

Pada penelitian ini data tweet yang diambil sebanyak 50.000 data untuk di analisis terhadap sentiment terhadap aplikasi ChatGPT dengan tiga label yaitu positif, negatif dan netral. Metode yang diusulkan untuk melakukan analisis terhadap sentiment ChatGPT dengan pendekatan *deep neural network* untuk mendapatkan hasil akurasi terbaik. *Deep neural network* (DNNs) telah diusulkan sebagai cara menghasilkan model yang lebih prediktif [7], performa model deep learning diakui dapat mengurangi waktu pelatihan secara berkelanjutan karena prosesnya yang cepat [8]. Model *deep neural network* yang diusulkan pada penelitian ini yaitu *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) dengan tujuan untuk mendapatkan hasil yang optimal dan kinerja yang cepat pada jumlah dataset yang banyak. Hasilnya kedua model yang diusulkan memperoleh nilai akurasi yang hampir sama lebih dari 90%. CNN mendapatkan nilai akurasi sebesar 91.12% dan LSTM mendapatkan nilai akurasi sebesar 90.84%.

2 Tinjauan Literatur

Penelitian terhadap beberapa kasus sentiment analisis banyak digunakan pada penelitian sebelumnya seperti penelitian tentang sentiment analisis terhadap covid 19 yang dilakukan oleh [9] dengan menggunakan model klasifikasi *Support Vector Machine* dan *Naïve Bayes* hasilnya terhadap 214 data penelitian 98 dilabeli sebagai positif dan 116 dilabeli sebagai negatif model SVM memperoleh nilai akurasi sebesar 54,21% dan *naïve bayes* memperoleh akurasi sebesar 53,27%.

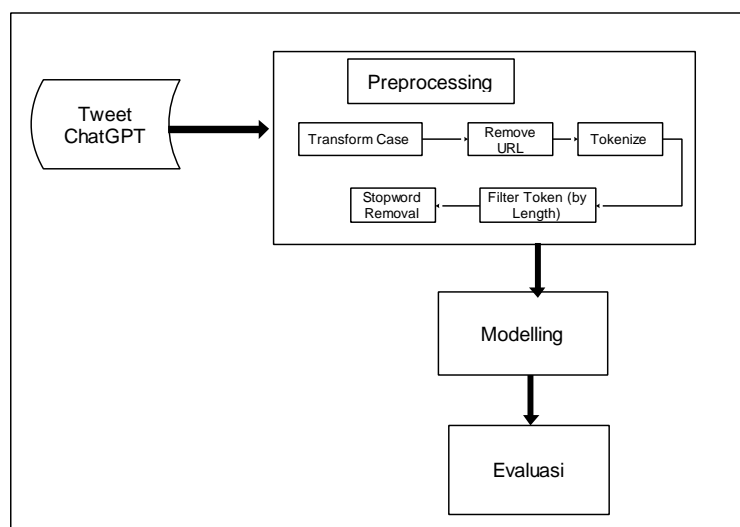
Penelitian dengan metode klasifikasi terhadap sentiment analisis hastag #omnibuslaw menyimpulkan dari 1,133 dataset dimana kelas yang dibentuk dari penelitian ini terdiri dari dua kelas yaitu positif dan negatif dengan perbandingan 60:40 untuk perbandingan label negatif dan positifnya, penelitian ini mengusulkan parameter *sample bootstrapping* untuk mengatasi ketidak seimbangan sampel pada label kelas sehingga dapat meningkatkan nilai akurasi terhadap tiga model klasifikasi yang digunakan pada penelitian ini yaitu SVM sebesar 85,88%, *Naïve Bayes* 85,08% dan *K-Nearest Neighbour* sebesar 78,64% [10].

Selanjutnya model deep neural network digunakan pada kasus sentiment analisis untuk mencari kata yang disematkan dalam sebuah tweet, representasi terhadap kata yang disematkan (*embedded words*) terhadap ulasan produk diuji dengan menyajikan konfigurasi LSTM Model dan CNN model pada 50,000 dataset kata tersemat. Jaringan syaraf LSTM dan CNN memiliki nilai akurasi yang sama baiknya yaitu sebesar 65% [11].

Sentimen analisis terhadap kata berbahasa Indonesia berdasarkan sumber data dari *twitter* berjumlah pada 10 tagar yang sedang trending topik dimana total ada 2023 data dengan tiga kelas kategori yaitu positif, negatif dan netral mengkomparasikan tiga model yang diusulkan pada penelitian ini yaitu *naïve bayes* (NB), *Support Vector Machine* (SVM) dan *Deep Belief Network* (DBN) yang merupakan bagian dari *deep neural network* menyimpulkan hasil akurasi DBN adalah yang terbaik dengan tingkat akurasi sebesar 93% dibandingkan dengan dua model lainnya SVM memperoleh akurasi sebesar 92%, sedangkan NB paling kecil akurasinya hanya 79% [12].

3 Metode Penelitian

Metode penelitian text mining adalah pendekatan yang digunakan untuk menganalisis dan mengekstraksi informasi berharga dari teks dalam jumlah besar untuk mengetahui pola-pola atau urutan yang terkait antara satu kata dengan kata lainnya [10]. Metodologi yang diusulkan pada penelitian ini dijelaskan pada Gambar 1.



Gambar 1. Metode Penelitian

Pada gambar 1 diuraikan metodologi atau tahapan penelitian dimana penelitian ini diawali dengan pengumpulan tweet yang bersumber dari tweeter dengan hashtag #ChatGPT.

3.1 Dataset Penelitian

Untuk mendapatkan data yang relevan dengan penelitian, pada tahap pengambilan dataset dari twitter penting melakukan penarikan pada saat trend atau isu yang akan diteliti sedang *booming* atau menjadi topik pembahasan tujuannya supaya sentiment tweet yang diambil banyak. Pada penelitian ini jumlah dataset total yang didapatkan 50.000 dataset.

3.2 Preprocessing

Pada tahap *preprocessing* dataset dilakukan beberapa proses untuk mendapatkan hasil tweet dengan kalimat aslinya tanpa menyertakan url, taggar atau symbol-simbol yang tidak digunakan pada saat dilakukan modeling.

1. *Transform Case*
Transforms case dapat membantu dalam membuat teks lebih konsisten, sehingga model analisis sentimen tidak akan bingung oleh variasi kapitalisasi misalnya mengubah semua huruf menjadi huruf kecil (*lower case*) semua atau huruf kapital semua (*upper case*) [10].
2. *Remove URL*
Remove URL digunakan untuk menghilangkan alamat URL atau tautan yang terdapat pada text atau komentar [13].
3. *Tokenize*
Tokenize digunakan untuk memecah setiap kalimat menjadi kata-kata individu, sambil menghilangkan karakter yang tidak relevan [13].
4. *Filter Token (by length)*
Pada tahap ini *Filter Token (by length)* dilakukan untuk menghapus kata-kata yang memiliki jumlah karakter kurang dari ambang nilai yang telah ditetapkan misalnya kata-kata yang kurang dari 3 atau 4 karakter [10].


5. Stopword Removal

Proses penghapusan "stop words" membantu dalam mengurangi dimensi data dan meningkatkan kualitas analisis, karena kata-kata ini sering kali tidak membawa makna khusus dalam konteks tertentu dan dapat mengganggu pemahaman lebih lanjut tentang teks, misalnya kata sambung –kan, -an, pada, ked an kata-kata lainnya yang tidak memiliki artian secara khusus [12].

3.3 Modelling

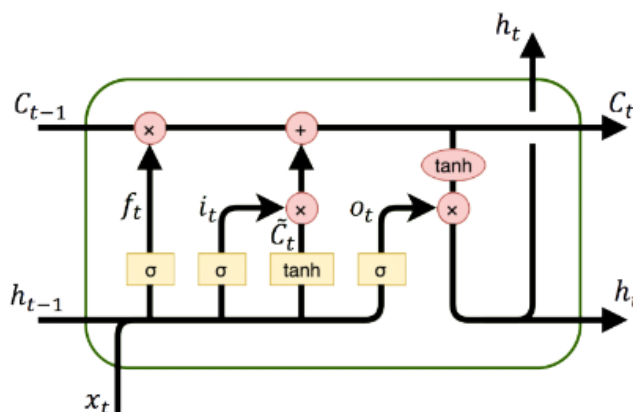
Pada tahap pemodelan dataset diuji dengan model algoritma model *deep learning*. *model deep learning* dapat melibatkan banyak eksperimen dan iterasi untuk mencapai hasil yang optimal . penelitian ini melakukan pengujian dengan model *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM).

Arsitektur CNN Model digambarkan pada Gambar 2



Gambar 2. Arsitektur CNN Model [11]

Arsitektur Model LSTM network



Gambar 3. Arsitektur LSTM Model [13]

3.4 Evaluasi

Pada tahap evaluasi digunakan subset pengujian untuk mengevaluasi kinerja model. Ini melibatkan mengukur akurasi, presisi, recall, F1-score, dan metrik evaluasi lainnya yang sesuai dengan jenis analisis yang dilakukan [14]. Untuk mendapatkan hasil yang ingin dicapai pada penelitian ini evaluasi model yang dilakukan dalam menentukan model terbaik dilakukan dengan beberapa evaluasi diantaranya:

1. Akurasi

Akurasi merupakan total data uji yang diprediksi benar dalam bentuk persentase berdasarkan hasil pengujian [15]. Persamaan akurasi dijelaskan pada rumus (1):

$$Accuracy = \frac{(a + d)}{Totalsample} \times 100\% \tag{1}$$

2. AUC/ROC

Receiver Operating Characteristics (ROC) adalah semacam alat ukur *performance* untuk *classification* problem dalam menentukan *threshold* dari suatu model [16]. Rumus menghitung AUC/ROC dijelaskan pada point (2):

$$AUC = 1/2 \sum_{ki=1}^n (xi + 1 - xi)(yi + 1 - yi) \quad (2)$$

3. Presisi

Presisi adalah bagian dari data yang diambil sesuai dengan informasi yang diperlukan [15]. Rumus presisi dijelaskan pada point (3) sebagai berikut:

$$Precision = \frac{(d)}{(b+d)} \times 100\% \quad (3)$$

Dalam klasifikasi biner, presisi dapat dianggap setara dengan nilai prediksi positif.

4. Recall

Recall merupakan bagian data yang relevan dengan *query* yang berhasil diambil dari dataset [15]. Secara umum rumus *recall* dijelaskan pada point (4).

$$Recall = \frac{(d)}{(c+d)} \times 100\% \quad (4)$$

Keterangan :

a = Prediksi benar, hasil benar

b = Prediksi benar, hasil salah

c = Prediksi salah, hasil benar

d = Prediksi salah, hasil salah

5. F1-Score

F1 score adalah salah satu metrik evaluasi kinerja yang umum digunakan dalam tugas klasifikasi, terutama ketika dataset tidak seimbang [16]. Rumus untuk menghitung *F1 score* secara detail dijelaskan pada point (5):

$$F1 \text{ score} = 2 * \frac{precision*recall}{precision+recall} \quad (5)$$

4 Hasil dan Pembahasan

Dalam penelitian ini, kami melakukan analisis mendalam terhadap sentiment tentang #ChatGPT dengan tujuan untuk melihat seberapa besar model yang diusulkan dalam melakukan evaluasi. Dalam rangka mencapai tujuan tersebut, kami mengumpulkan dan menganalisis data.

1. Dataset penelitian

Dataset yang digunakan pada penelitian ini sebanyak 50.000 tweet yang bersumber dari dataset publik kaggle.com yang mengumpulkan sejumlah komentar dari aplikasi sosial media *tweeter* dengan hashtag #ChatGPT, #OpenAI dari tanggal 21 Januari 2023 sampai dengan tanggal 24 Januari 2023.

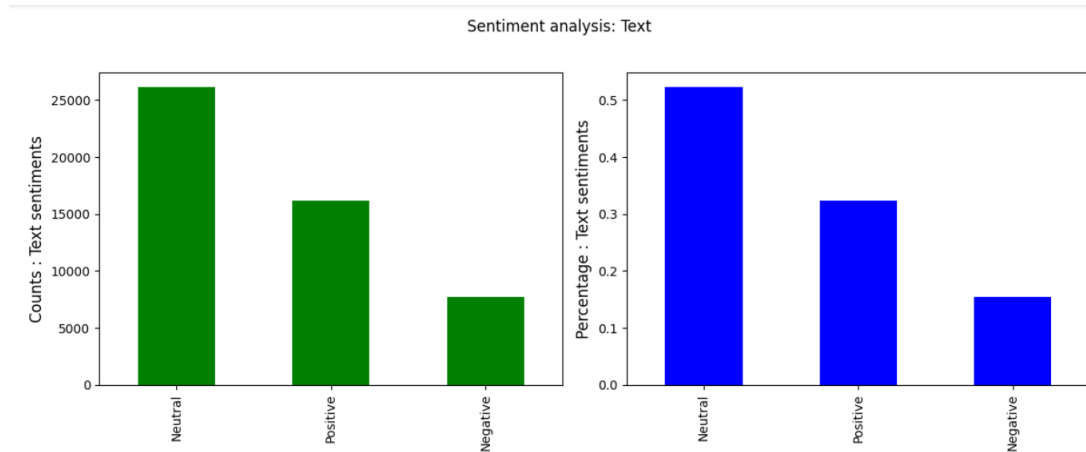
Tabel 1. Contoh Komentar

No	Kalimat	Kategori
1	AI will initiate a new era of entrepreneurship. a thesis. #chatgpt #visionary #artificialintelligence #future https://t.co/yxpj9w7qcy .	Positif
2	Soon, we will see a scenario where we will discover that a bestseller was written using #ChatGPT It is just a matter of time.	Positif

<http://sistemasi.ftik.unisi.ac.id>

3	Why do I feel hurt being ghosted by ChatGPT? https://t.co/3aG1wI0YjC	Netral
...
50000	Stop using ChatGPT, Jasper or any generic AI to write articles. I built an AI editor that trains itself on your published articles. The result? An immediate upgrade over these generic tools. Don't believe me? Try it for free	Negatif

Pada Tabel 1 setiap komentar diberikan label untuk mengkategorikan setiap tweet supaya dievaluasi kinerjanya. Secara detail jumlah perbandingan antaran label positif, negatif dan netral pada Gambar 4



Gambar 4. Grafik Sentiment Analysis

Dari Gambar 4 berdasarkan hasil penelitian jumlah sentiment analisis dengan hashtag #ChatGPT, 25.000 data atau 50% dikategorikan sebagai sentiment yang netral, 15.000 atau 30% data dikategorikan sebagai sentiment positif dan 10.000 data atau 10% dikategorikan sebagai sentiment yang negatif.

Selanjutnya adalah melakukan *preprocessing* dengan beberapa teknik terhadap sentiment/komentar sehingga menjadi kalimat dalam bentuk baku yang akan diproses dengan model yang diusulkan.



Gambar 5. Hasil *Preprocessing Text Mining*

Pada Gambar 5 proses dalam melakukan klasifikasi sentiment analisis terhadap aplikasi ChatGPT melalui beberapa proses/*preprocessing* sebelum dikategorikan apakah sentiment yang ditulis cenderung bersifat positif, negatif atau netral. Untuk mendapatkan kalimat baku atau kata asli dari kalimat yang dituliskan pada kasus ini data yang digunakan adalah komentar berbahasa Inggris dengan melalui tahapan-tahapan sebagaimana dijelaskan pada gambar 5 dimulai dari pengambilan kalimat aslinya kemudian melakukan *transform case* dengan membuat semua tulisan menjadi huruf

kecil semua supaya data inputan terlihat konsisten. Selanjutnya menghapus URL atau link yang ada pada kalimat supaya dapat diketahui bahwa inputan berupa kata-kata tanpa ada tautan atau sumber dari halaman web lainnya. Tahap berikutnya adalah melakukan tokenize untuk mendapatkan kata asli yang tidak diberi kata imbuhan baik awalan atau akhiran, selanjutnya menghapus kata-kata yang kurang dari 2 huruf untuk menghindari kata sambung atau kata yang tidak memiliki arti sehingga pada tahap akhir didapatkan kalimat yang terdiri dari kata asalnya untuk dilakukan evaluasi dan penilaian terhadap suatu sentiment/komentar.


2. Evaluasi Convolutional Neural Network Model

Evaluasi yang dilakukan pada dataset penelitian dengan menggunakan CNN Model. Dalam konteks CNN *epoch* mengacu pada satu putaran lengkap dari seluruh dataset pelatihan melalui jaringan CNN. Setiap *epoch* terdiri dari beberapa iterasi, di mana model memproses setiap batch data untuk memperbarui bobot dan bias berdasarkan hasil pelatihan. Hasil yang didapatkan dijelaskan pada Tabel 2.

Tabel 2. Evaluasi Model CNN

<i>Epoch</i>	Akurasi	Loss
1/10	0.9023	0.2956
2/10	0.9112	0.2711
3/10	0.9098	0.3054
4/10	0.9061	0.3586
5/10	0.9054	0.4023
6/10	0.9049	0.4470
7/10	0.9034	0.5106
8/10	0.8958	0.6024
9/10	0.8992	0.6223
10/10	0.8939	0.6321

Pada Tabel 2 berdasarkan hasil penelitian terhadap objek penelitian dengan model CNN nilai akurasi paling besar terjadi pada *epoch* ke 2/10 dengan nilai sebesar 0,91 atau 91% dan *Loss* terkecil dengan nilai 0,27 atau 27%. Visualisasi dari hasil perbandingan nilai akurasi dan *loss* terhadap *epoch*nya pada gambar 5



Gambar 6. Visualisasi Nilai Akurasi Model CNN

Pada Gambar 6 hubungan antara sumbu X (akurasi) dan sumbu Y (*epoch*) menggambarkan nilai model akurasi yang disimbolkan dengan garis berwarna biru sebagai data *training* dan garis berwarna orange sebagai data *testing* nilai-nilai yang dihasilkan secara detail sudah dijelaskan pada Tabel 2.


3. Evaluasi LSTM Model

Evaluasi selanjutnya dengan model LSTM, hal yang sama dilakukan dengan melakukan perulangan/*epoch* pada setiap data training terhadap data testing. Hasilnya pada Tabel 3.

Tabel 3. Evaluasi Model LSTM

<i>Epoch</i>	Akurasi	Loss
1/10	0.9023	0.2994
2/10	0.9084	0.2820
3/10	0.9014	0.3357
4/10	0.9018	0.3521
5/10	0.8968	0.3981
6/10	0.9037	0.4897
7/10	0.8984	0.5262
8/10	0.9034	0.5687
9/10	0.8947	0.8947
10/10	0.9017	0.6422

Hasil penelitian menunjukkan bahwa evaluasi dengan model LSTM pada Tabel 3 dengan *Epoch* 10 iterasi nilai akurasi paling tinggi pada *epoch* ke 2/10 yaitu 0.9084 atau 90.84% sedangkan nilai lossnya sebesar 0.2820 atau 28.20%. Visualisasi dari hasil perbandingan nilai akurasi dan *loss* terhadap *epoch*nya pada Gambar 7.



Gambar 7. Visualisasi Nilai Akurasi Model LSTM

Gambar 7 merupakan visualisasi dari Tabel 3 dimana sumbu X atau *epoch* berhubungan dengan sumbu Y nilai akurasi terhadap data *training* dengan data *testing*.

4. Confusion Matriks

Hasil evaluasi dengan confusion matriks dari objek penelitian dengan menggunakan dua model *deep learning* yaitu CNN dan LSTM di jelaskan pada Tabel 4.

Tabel 4. Confusion Matriks

Model	Accuracy	Precision	Recall	F1-Score	Support
CNN	0.9112	0.97	0.91	0.94	6515
LSTM	0.9084	0.95	0.94	0.95	6515

Pada tabel 4 berdasarkan evaluasi dengan confusion matriks kedua model memiliki kinerja yang cukup baik dengan akurasi yang hampir serupa. Model LSTM sedikit lebih tinggi dalam recall, menunjukkan kemampuannya dalam mendeteksi lebih banyak kasus positif secara keseluruhan. Namun, model CNN memiliki presisi yang sedikit lebih tinggi, menunjukkan kemampuannya dalam memprediksi kelas positif dengan benar. Nilai F1-Score yang hampir setara menunjukkan keseimbangan antara kedua metrik tersebut.

5 Kesimpulan

Eksperimen ini bertujuan untuk memberikan wawasan tentang pandangan publik terhadap aplikasi ChatGPT dalam tiga kategori sentiment yaitu positif, negatif dan netral. Dalam upaya untuk meningkatkan kinerja, model-model yang diusulkan yaitu CNN dan LSTM, dipilih karena performanya yang baik dan kemampuan untuk mengurangi waktu pelatihan. Hasil eksperimen menunjukkan bahwa keduanya mencapai tingkat akurasi lebih dari 90% dimana CNN dengan nilai akurasi 91.12% dan LSTM dengan nilai akurasi 90.84%. Hal ini menunjukkan potensi model-model yang diusulkan dapat diandalkan dalam menganalisis sentimen secara efektif.

Referensi

- [1] Y. Mintz and R. Brodie, "Introduction to artificial intelligence in medicine," *Minim. Invasive Ther. & Allied Technol.*, vol. 28, no. 2, pp. 73–81, 2019.
- [2] F. Y. Tember, I. Najiyah, T. Informatika, F. T. Informasi, and J. Barat, "Klasifikasi Motif Batik Jawa Barat menggunakan Convolutional Neural Network Classification of West Java Batik Motifs Using Convolutional Neural Network," vol. 12, pp. 282–292, 2023.
- [3] C. Zhang and Y. Lu, "Study on artificial intelligence: The state of the art and future prospects," *J. Ind. Inf. Integr.*, vol. 23, no. April, p. 100224, 2021.
- [4] M. Aljanabi, M. Ghazi, A. H. Ali, S. A. Abed, and ChatGpt, "ChatGpt: Open Possibilities," *Iraqi J. Comput. Sci. Math.*, vol. 4, no. 1, pp. 62–64, 2023.
- [5] N. M. S. Surameery and M. Y. Shakor, "Use Chat GPT to Solve Programming Bugs," *Int. J. Inf. Technol. Comput. Eng.*, no. 31, pp. 17–22, 2023.
- [6] R. Ferdiana, F. Jatmiko, D. D. Purwanti, A. S. T. Ayu, and W. F. Dicka, "Dataset Indonesia untuk Analisis Sentimen," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 8, no. 4, p. 334, 2019.
- [7] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders, and K. R. Müller, "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications," *Proc. IEEE*, vol. 109, no. 3, pp. 247–278, 2021.
- [8] S. Basodi, C. Ji, H. Zhang, and Y. Pan, "Gradient amplification: An efficient way to train deep neural networks," *Big Data Min. Anal.*, vol. 3, no. 3, pp. 196–207, 2020.
- [9] S. Hadiani *et al.*, "Analisis Sentiment Covid-19 Di Twitter Menggunakan Metode Naive Bayes Dan Svm," *J. Teknol. Inf.*, vol. 6, no. 1, pp. 58–63, 2022.
- [10] W. Gata, S. Surohman, and H. M. Nawawi, "Twitter in analysis of policy sentiments of the omnibus law work creative design," *AIP Conf. Proc.*, vol. 2714, no. September 2011, 2023.
- [11] S. Kamiş and D. Goularas, "Evaluation of Deep Learning Techniques in Sentiment Analysis from Twitter Data," *Proc. - 2019 Int. Conf. Deep Learn. Mach. Learn. Emerg. Appl. Deep. 2019*, pp. 12–17, 2019.
- [12] I. Zulfa and E. Winarko, "Sentimen Analisis Tweet Berbahasa Indonesia Dengan Deep Belief Network," *IJCCS (Indonesian J. Comput. Cybern. Syst.)*, vol. 11, no. 2, p. 187, 2017.
- [13] A. P. Giovani, A. Ardiansyah, T. Haryanti, L. Kurniawati, and W. Gata, "Analisis Sentimen Aplikasi Ruang Guru Di Twitter Menggunakan Algoritma Klasifikasi," *J. Teknoinfo*, vol. 14, no. 2, p. 115, 2020.
- [14] H. M. Nawawi, H. Sutisna, and N. Ichsan, "Sistem Pendukung Keputusan Pemberian Kredit Kendaraan Roda Dua Menggunakan Metode TOPSIS (Studi Kasus PT. Central Sentosa Finance Ciamis)," *J. Infokar*, vol. 1, no. 23, pp. 301–316, 2019.
- [15] H. M. Nawawi, S. Rahayu, J. J. Purnama, and S. I. Komputer, "Algoritma c4.5 untuk memprediksi pengambilan keputusan memilih deposito berjangka," *J. Techno Nuasa Mandiri*, vol. 16, no. 1, pp. 65–72, 2019.

- [16] Hermanto, A. Mustopa, and A. Y. Kuntoro, "Algoritma Klasifikasi Naive Bayes dan Support Vector Machine Dalam Layanan Komplain Mahasiswa," *J. ILMU Pengetah. DAN Teknol. Komput.*, vol. 5, no. 2, pp. 211–220, 2020.