

maknanya sehingga menyebabkan model salah dalam melakukan prediksi. Selain itu, panjang teks dan informasi kontekstual juga berperan dalam kesalahan prediksi, teks hasil dari pre-processing menghasilkan beberapa teks pendek dan teks yang lebih pendek cenderung sulit diklasifikasikan secara akurat akibat kurangnya informasi tambahan. Kalimat pendek seperti "aku lelah" bisa menjadi pernyataan umum atau indikasi depresi tergantung pada konteks penggunaannya. Peningkatan akurasi setiap model dari baseline hingga skenario 5 ditunjukkan pada Tabel 13.

Table 12. Contoh teks ambigu

| Kata | Label Depresi (1) | Label Non-Depresi (0) |
|---------|------------------------------------|--|
| gelisah | malam gelisah pikiran tidak tenang | gelisah wawancara kerja tetap optimis |
| lelah | lelah hidup beban serah | lelah kerja senang hasil akhir |
| stress | masalah stress berat bingung | stress tugas kuliah tetap semangat selesai |

Table 13. Peningkatan total akurasi model dari baseline hingga skenario 5

| Model | Accuracy (%) |
|-----------|---------------|
| CNN | 84.13 (+1,4) |
| BiGRU | 84.37 (+1.47) |
| CNN-BiGRU | 84.27 (+1,47) |
| BiGRU-CNN | 84.40 (+1,5) |

5. Kesimpulan

Penelitian ini berfokus pada pendekripsiannya depresi di platform media sosial X menggunakan model *hybrid deep learning* dengan mekanisme *attention* yang menggabungkan CNN dan BiGRU, memanfaatkan TF-IDF untuk ekstraksi fitur dan FastText untuk perluasan fitur. Penelitian ini menggunakan dataset teks yang bersumber dari tweet berbahasa Indonesia dan hasil translate, yang terdiri dari 50.523 data, beserta terjemahannya dalam bahasa Inggris. Selanjutnya, sebuah korpus *similarity* dengan 151.117 data dibangun untuk meningkatkan kinerja model. Untuk mencapai akurasi terbaik, lima skenario eksperimental dilakukan, termasuk menentukan rasio pemisahan data yang optimal, mengidentifikasi konfigurasi n-gram yang paling efektif, mengoptimalkan jumlah fitur maksimum, menggunakan FastText untuk perluasan fitur, dan mengintegrasikan mekanisme *attention* ke dalam model. Hasil penelitian menunjukkan bahwa model CNN mencapai akurasi akhir sebesar 84,13%, BiGRU mencapai akurasi 84,37%. Untuk model hybrid dengan mekanisme *attention*, model CNN-BiGRU mencapai akurasi tertinggi senilai 84,27% dengan struktur CNN-ATT-BiGRU, sedangkan model BiGRU-CNN mencapai akurasi tertinggi senilai 84,40% dengan struktur BiGRU-ATT-CNN-ATT sekaligus menjadi model dengan nilai akurasi tertinggi. Berdasarkan hasil penelitian, penerapan mekanisme *attention* dan penggunaan ekspansi fitur dapat meningkatkan akurasi dari model deteksi depresi berbasis teks. Saran untuk penelitian selanjutnya adalah mencoba untuk melakukan perbandingan menggunakan beberapa algoritma ekspansi fitur dan optimasi lainnya.

Daftar Pustaka

- [1] H. Tufail, S. M. Cheema, M. Ali, I. M. Pires, and N. M. Garcia, “Depression Detection with Convolutional Neural Networks: A Step Towards Improved Mental Health Care,” *Procedia Comput. Sci.*, vol. 224, pp. 544–549, 2023.
- [2] Vandana, N. Marriwala, and D. Chaudhary, “A hybrid model for depression detection using deep learning,” *Meas. Sensors*, vol. 25, no. November 2022, p. 100587, 2023.
- [3] “Depressive disorder (depression).” [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/depression>.
- [4] “Survei: 17,9 Juta Remaja Indonesia Punya Masalah Mental, Ini Gangguan yang Diderita.” [Online]. Available: <https://www.detik.com/edu/detikpedia/d-7150554/survei-17-9-juta-remaja-indonesia-punya-masalah-mental-ini-gangguan-yang-diderita>.
- [5] M. Ahmad Wani, M. A. Elaffendi, K. A. Shakil, A. Shariq Imran, and A. A. Abd El-Latif, “Depression Screening in Humans With AI and Deep Learning Techniques,” *IEEE Trans. Comput. Soc. Syst.*, vol. 10, no. 4, pp. 2074–2089, 2023.
- [6] S. Bengtsson and S. Johansson, “The Meanings of Social Media Use in Everyday Life: Filling Empty Slots, Everyday Transformations, and Mood Management,” *Soc. Media Soc.*, vol. 8, no. 4, 2022.
- [7] H. Kour and M. K. Gupta, *An hybrid deep learning approach for depression prediction from user tweets*

using feature-rich CNN and bi-directional LSTM, vol. 81, no. 17. Multimedia Tools and Applications, 2022.

- [8] A. Amalia, O. S. Sitompul, E. B. Nababan, and T. Mantoro, “An Efficient Text Classification Using fastText for Bahasa Indonesia Documents Classification,” *2020 Int. Conf. Data Sci. Artif. Intell. Bus. Anal. DATABIA 2020 - Proc.*, pp. 69–75, 2020.
- [9] J. Teng, W. Kong, Y. Chang, Q. Tian, C. Shi, and L. Li, “Text Classification Method Based on BiGRU-Attention and CNN Hybrid Model,” *ACM Int. Conf. Proceeding Ser.*, pp. 614–622, 2021.
- [10] “Sentiment Analysis of Student Texts Using the CNN-BiGRU-AT Model.” .
- [11] N. H. Yahya and H. Abdul Rahim, “Linguistic markers of depression: Insights from english-language tweets before and during the COVID-19 pandemic,” *Lang. Heal.*, vol. 1, no. 2, pp. 36–50, 2023.
- [12] S. Khan and S. Alqahtani, “Hybrid machine learning models to detect signs of depression,” *Multimed. Tools Appl.*, vol. 83, no. 13, pp. 38819–38837, 2024.
- [13] L. Bendebane, Z. Laboudi, A. Saighi, H. Al-Tarawneh, A. Ouannas, and G. Grassi, “A Multi-Class Deep Learning Approach for Early Detection of Depressive and Anxiety Disorders Using Twitter Data,” *Algorithms*, vol. 16, no. 12, 2023.
- [14] M. Rhanoui, M. Mikram, S. Yousfi, and S. Barzali, “A CNN-BiLSTM Model for Document-Level Sentiment Analysis,” *Mach. Learn. Knowl. Extr.*, vol. 1, no. 3, pp. 832–847, 2019.
- [15] O. Papadimitriou, “A Comparative Study of Sentiment Analysis on Twitter and Reddit Using Deep Learning Techniques,” pp. 50–55, 2024.
- [16] M. Hina, M. Ali, A. R. Javed, F. Ghabban, L. A. Khan, and Z. Jalil, “SeFACED: Semantic-Based Forensic Analysis and Classification of E-Mail Data Using Deep Learning,” *IEEE Access*, vol. 9, pp. 98398–98411, 2021.
- [17] R. H. K. Emanuel, P. D. Docherty, H. Lunt, and K. Möller, “The effect of activation functions on accuracy, convergence speed, and misclassification confidence in CNN text classification: a comprehensive exploration,” *J. Supercomput.*, vol. 80, no. 1, pp. 292–312, 2024.
- [18] D. Alsaleh and S. Larabi-Marie-Sainte, “Arabic Text Classification Using Convolutional Neural Network and Genetic Algorithms,” *IEEE Access*, vol. 9, pp. 91670–91685, 2021.
- [19] D. Yohanes, J. S. Putra, K. Filbert, K. M. Suryaningrum, and H. A. Saputri, “Emotion Detection in Textual Data using Deep Learning,” *Procedia Comput. Sci.*, vol. 227, pp. 464–473, 2023.
- [20] L. Zhou and X. Bian, “Improved text sentiment classification method based on BiGRU-Attention,” *J. Phys. Conf. Ser.*, vol. 1345, no. 3, 2019.
- [21] G. Brauwers and F. Frasincar, “A General Survey on Attention Mechanisms in Deep Learning,” *IEEE Trans. Knowl. Data Eng.*, vol. 35, no. 4, pp. 3279–3298, 2023.
- [22] G. Alfattni, N. Peek, and G. Nenadic, “Attention-based bidirectional long short-term memory networks for extracting temporal relationships from clinical discharge summaries,” *J. Biomed. Inform.*, vol. 123, no. August, p. 103915, 2021.
- [23] T. Rehman, S. Das, D. K. Sanyal, and S. Chattopadhyay, “Abstractive Text Summarization Using Attentive GRU Based Encoder-Decoder,” *Lect. Notes Electr. Eng.*, vol. 925, pp. 687–695, 2022.
- [24] S. Visa, B. Ramsay, A. Ralescu, and E. van deer Knaap, “Confusion Matrix-based Feature Selection Sofia Visa,” *ConfusionMatrix-based Featur. Sel. Sofia*, vol. 710, no. January, p. 8, 2011.