

Analisis Sentimen Multimodal terhadap Opini Publik Mengenai Kesehatan Mental di Media Sosial X dengan Metode CNN BiLSTM dan Ekspansi fitur FastText

1st Nadim Rafli Hamzah
Informatika

Telkom University
Bandung, Indonesia
nadimdim@student.telkomuniversity.ac.id

2nd Erwin Budi Setiawan
Informatika

Telkom University
Bandung, Indonesia
erwinbudisetiawan@telkomuniversity.ac.id

Abstrak— Dalam hal kesehatan masyarakat global, kesehatan mental menjadi perhatian penting. Salah satu situs media sosial yang paling populer, X telah berkembang menjadi forum bagi orang-orang untuk mendiskusikan masalah kesehatan mental dan berbagi cerita pribadi. Menganalisis sentimen dalam percakapan online ini penting untuk memahami persepsi publik dan memandu intervensi kesehatan mental. Penelitian ini mengusulkan model analisis sentimen multimodal yang memanfaatkan data tekstual dan visual, dengan fitur teks yang diekstraksi melalui CNN-BiLSTM, TF-IDF, dan FastText, dan fitur gambar menggunakan VGG-16. Klasifikasi sentimen dilakukan dengan menggunakan model Hybrid CNN-BiLSTM dengan mekanisme perhatian. Model ini menggunakan fusi tingkat menengah untuk mengintegrasikan fitur teks dan gambar, diikuti dengan tingkat keputusan untuk menggabungkan output dari model teks saja, gambar saja, dan multimodal. 24.742 pasangan tweetgambar dikumpulkan dari platform X dan dianotasi melalui sistem pemungutan suara mayoritas. Untuk membangun korpus kemiripan FastText, 63.512 data dari portal berita digital CNN (Cable News Network) dan X digabungkan. Dengan akurasi 87,92%, model multimodal mengungguli model teks saja sebesar 0,09% dan model gambar saja sebesar 25,10%. Hasil ini menunjukkan keefektifan data modalitas, ekstraksi fitur yang komprehensif, dan multimodal.

Keywords— *Analisis Sentimen, FastText, Hybrid CNN-BiLSTM, TF-IDF, VGG-16*

PENDAHULUAN

Produktivitas masyarakat dan kualitas hidup individu dipengaruhi secara signifikan oleh kesehatan mental. Menurut WHO, depresi memengaruhi lebih dari 264 juta orang di seluruh dunia, angka yang terus meningkat setiap tahunnya. Sayangnya, stigma sosial masih menjadi penghalang utama untuk mencari bantuan profesional. Oleh karena itu, penelitian di bidang kesehatan mental sangat penting untuk merumuskan solusi preventif dan responsif terhadap gangguan psikologis [1]. Dengan lebih dari 450 juta pengguna aktif bulanan, X merupakan salah satu jaringan media sosial terbesar yang menyediakan data real-time dalam bentuk teks pendek dan media visual. Banyak pengguna yang secara terbuka membagikan perasaan, pengalaman pribadi, dan bahkan keinginan untuk bunuh diri melalui cuitan mereka, menjadikan X sebagai sumber data yang potensial untuk deteksi dini

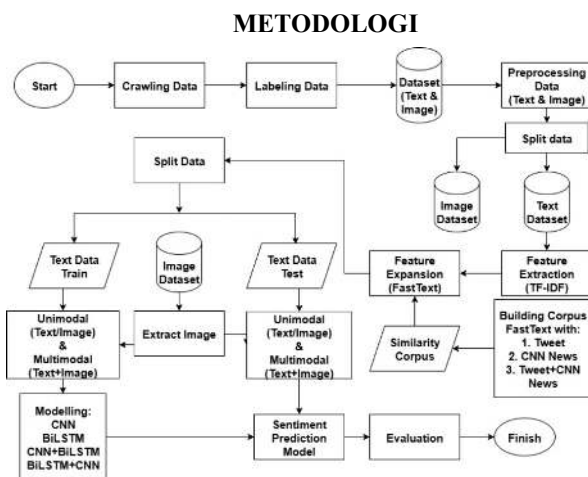
gangguan mental. Setelah pandemi COVID-19, tren penggunaan X untuk mengekspresikan masalah kesehatan mental telah meningkat, seperti yang terlihat dari tagar populer seperti #MentalHealthAwareness dan #Depression [2], [3]. Cuitan di X tidak hanya berisi informasi verbal, tetapi juga visual melalui gambar yang menyertainya. Analisis multimodal yang menggabungkan teks dan gambar telah terbukti lebih unggul daripada pendekatan unimodal karena memberikan konteks yang lebih lengkap. Sebagai contoh, teks yang netral dapat menunjukkan tanda-tanda depresi ketika digabungkan dengan gambar yang menyedihkan. Model seperti CNN-BiLSTM dan penyematan FastText telah terbukti meningkatkan akurasi prediksi kondisi mental dalam pendekatan ini [4]. Pengembangan kerangka kerja multimodal yang menggabungkan Hybrid CNN-BiLSTM dan TF-IDF adalah kontribusi utama dari penelitian ini. Kerangka kerja ini disempurnakan melalui FastText untuk perluasan fitur dalam ekstraksi fitur tekstual dan untuk prediksi sentimen pada subjek kesehatan mental, VGG-16 untuk ekstraksi fitur visual. Sementara itu, strategi fusi menengah menggabungkan karakteristik visual dan tekstual, dan output dari model teks saja dan gambar saja digabungkan pada fusi tingkat keputusan. Para penulis mengklaim bahwa belum ada penelitian sebelumnya yang meneliti analisis sentimen multimodal dengan ekstraksi TF-IDF dalam model prediksi sentimen. Oleh karena itu, tujuan dari penelitian ini adalah untuk membuat kerangka kerja seperti itu karena, menurut hasil penelitian sebelumnya, hal tersebut dapat meningkatkan akurasi.

STUDI TERKAIT

Beberapa penelitian telah meneliti penerapan teknologi pada analisis kesehatan mental di media sosial, khususnya X, yang menyediakan data yang melimpah untuk memahami opini publik tentang kesehatan mental. Pada penelitian pertama mengembangkan model CNN-BiLSTM yang didukung oleh FastText untuk mendeteksi gangguan mental dan keinginan untuk bunuh diri dari data X. Penelitian ini menunjukkan bahwa pendekatan multimodal dapat meningkatkan akurasi prediksi karena FastText memiliki kemampuan untuk menangkap representasi semantik teks dengan lebih baik.[5]

Penelitian kedua menampilkan peningkatan hasil analisis sentimen berbasis X dengan menggunakan fusi fitur pada tingkat representasi. Penelitian ini berhasil menunjukkan bahwa fusi fitur tingkat tinggi dapat memberikan hasil yang lebih akurat pada analisis data berbasis teks pendek seperti X, karena model yang digunakan menggabungkan CNN-BiLSTM dengan embedding FastText yang berfokus pada klasifikasi emosi melalui perhatian pada karakteristik data.[6]

Untuk mendeteksi depresi di media sosial, penelitian yang dilakukan oleh Ghosh dan Al Banna (2023) memperkenalkan pendekatan hybrid berbasis BiLSTM-CNN dengan arsitektur perhatian. Mereka menggunakan penyematan FastText untuk mengekstrak fitur teks yang lebih rinci, dan untuk meningkatkan interpretabilitas prediksi, mereka menerapkan anotasi pada model. Metode ini dapat digunakan untuk memahami masalah kesehatan mental dari sudut pandang pengguna media sosial.[7]



GAMBAR 1
Alur kerja sistem menggunakan arsitektur hibrida CNN-BiLSTM

Pipeline prediksi sentimen yang menggunakan model hibrida CNN-BiLSTM dengan ekspansi fitur FastText digambarkan dalam flowchart pada Gambar 1. *Crawling data*, *Pre-processing* data, ekstraksi fitur TF-IDF, perluasan fitur FastText, dan model CNN, BiLSTM, *hybrid* CNN-BiLSTM, dan *hybrid* BiLSTM-CNN adalah beberapa langkah yang membentuk sistem.

A. Crawling Data

Crawling data mengumpulkan sejumlah besar tweet tekstual dan visual untuk analisis sentimen percakapan X seputar kesehatan mental [8]. Memanfaatkan kata kunci, periode tanggal, atau akun pengguna storing, alat seperti Tweet-harvest mengekstrak tweet yang relevan, menyimpan data dalam format CSV bersama dengan stempel waktu, URL gambar, teks tweet, dan metadada untuk analisis multimodal. Sebaran data hasil dari *crawling* dapat dilihat pada tabel 1.

TABEL 1

JUMLAH DATASET BERDASARKAN KATA KUNCI

Keyword	Quantity
<i>broken</i>	2,078
<i>burnout</i>	3,000
<i>frustration</i>	2,500
<i>unloved</i>	3,000
<i>anxiety</i>	2,800
<i>selflove</i>	3,570
<i>mentalhealthmatters</i>	2,500
<i>wellbeing</i>	2,794
<i>toxic</i>	2,500
Total	24,742

B. Labeling Data

Dalam analisis sentimen multimodal, pelabelan data sangat penting, terutama untuk cuitan X yang berkaitan dengan kesehatan mental [8]. Setelah pengumpulan data, setiap tweet yang mencakup teks dan gambar diklasifikasikan sebagai negatif atau positif dengan melibatkan 5 anotator dengan prinsip *majority vote* yang ditampilkan pada tabel 2. Kedua modalitas tersebut diberi label, dan nada emosionalnya bisa jadi sama atau berbeda. Para anotator bekerja sama dan menyelesaikan perbedaan pendapat melalui dialog untuk menjaga konsistensi. Prosedur metode ini menghasilkan kumpulan data yang dapat dipercaya yang diperlukan untuk evaluasi dan pelatihan model hibrida CNN-BiLSTM, meningkatkan kapasitas model untuk menguraikan berbagai ekspresi emosional.

TABEL 2

DISTRIBUSI LABEL SENTIMEN DARI DATASET

Category	Label	Quantity
<i>Text</i>	<i>Positive</i>	12,429
	<i>Negative</i>	12,313
<i>Image</i>	<i>Positive</i>	12,429
	<i>Negative</i>	12,313
Total		24,742

C. Pre-Processing Data

Untuk meningkatkan kualitas data *input* dan kinerja klasifikasi, *pre-processing* sangat penting untuk analisis sentimen multimodal. *Pre-processing* data untuk ekstraksi TF-IDF melibatkan beberapa langkah *Pre-processing* menggunakan pustaka NLTK. Setelah tokenisasi, lemmatization, dan penghilangan stopword, data teks diubah menjadi vektor kata dan menjalani analisis CNN untuk mengekstrak fitur lokal dan analisis BiLSTM untuk memahami

konteks sekuensial. Sementara itu, data gambar mengalami augmentasi (rotasi, flipping), konversi warna, dan normalisasi ukuran [9].

- 1) *Pre-Processing* Teks menjamin data yang jelas dan konsisten.
 - a) *Cleaning*: Gunakan ekspresi reguler untuk menghilangkan referensi, tagar, URL, angka, dan simbol.
 - b) *Case Folding*: Untuk memastikan konsistensi, ubah teks menjadi huruf kecil.
 - c) *Normalization*: Membakukan bahasa gaul dan menggunakan ejaan yang tepat.
 - d) *Stopword Removal*: Menghilangkan istilah umum seperti “dan” dan “yang.”
 - e) *Stemming*: Memecah kata menjadi bagian-bagian yang paling dasar.
 - f) *Tokenization*: Gunakan NLTK untuk penyematan untuk membagi teks menjadi token.
- 2) *Pre-processing* gambar dilakukan dengan menggunakan *Python Imaging Library* untuk memastikan semua gambar kompatibel dengan model VGG 16 sebelum ekstraksi fitur. Langkah-langkah *pre-processing* meliputi:
 - a) *Image Resizing*: Mengubah ukuran semua gambar ke ukuran tetap 224x224 piksel.
 - b) *Format Conversion*: Gambar dalam format non-RGB dikonversi ke RGB untuk memastikan konsistensi.
 - c) *Channel Reordering*: Fungsi input *Pre-processing* modul VGG-16 digunakan untuk mengubah gambar dari RGB ke BGR.

E. Ekstraksi Fitur TF-IDF

Ekstraksi fitur dilakukan setelah tahap persiapan *Pre-processing* data. Tahap pertama dari klasifikasi teks adalah ekstraksi fitur. Tujuannya adalah untuk mengubah teks menjadi representasi vektor di mana setiap kata diberi bobot [10]. Langkah awal dalam representasi X adalah pemodelan fitur N-gram, yang meliputi unigram, bigram, dan trigram. Ekstraksi fitur yang digunakan dalam penelitian kali ini *Term Frequency-Inverse Document Frequency* (TF-IDF). Pendekatan ini banyak digunakan oleh banyak peneliti karena dianggap efisien, mudah digunakan, dan memberikan hasil yang dapat dipercaya [11]. TF-IDF merupakan kombinasi dari *Term Frequency* (TF), yang menghitung frekuensi term dalam sebuah dokumen, dan *Inverse Document Frequency* (IDF), yang membobotkan term dalam sebuah dokumen. Akibatnya, kata-kata yang sering digunakan dalam berbagai dokumen akan memiliki nilai yang lebih rendah daripada kata-kata yang lebih jarang digunakan. Rumus TF-IDF diberikan oleh persamaan 1 dan 2.

$$W_{dt} = TF_{dt} \times IDF_{dt} \quad (1)$$

$$IDF_{dt} = \left(\log \left(\frac{N}{df} \right) \right) \quad (2)$$

W adalah bobot kata d relatif terhadap kata t dalam Persamaan (1) dan (2), df adalah jumlah dokumen yang menyertakan kata yang terdeteksi, dan N adalah jumlah total dokumen dalam set data.

F. Ekspansi Fitur FastText

Paradigma representasi kata yang disebut FastText diciptakan untuk mengatasi kelemahan penyematan konvensional seperti Word2Vec. Tidak seperti Word2Vec, yang hanya menggunakan vektor kata penuh, FastText membuat representasi kata berdasarkan subkata atau n-gram, yang memungkinkan FastText untuk mendapatkan lebih banyak informasi dari kata-kata yang tidak ada di dalam kosakata. Untuk bahasa dengan morfologi yang kompleks, seperti bahasa Indonesia, pendekatan berbasis subkata menjadi sangat penting [12]. Hal ini dikarenakan awalan, akhiran, dan imbuhan sering kali mengubah arti kata secara signifikan [13].

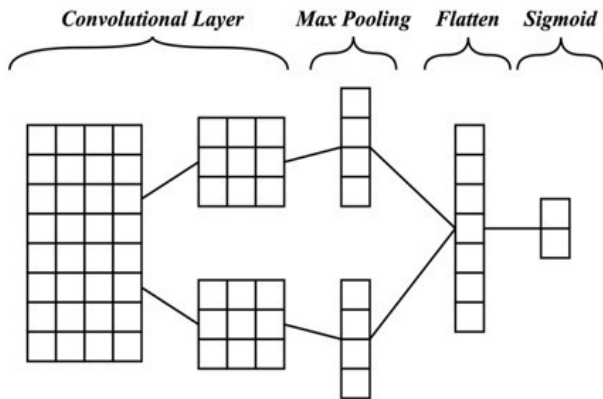
TABEL 3
KORPUS SIMILARITY FASTTEXT

	Corpus	CNN News	Tweets	Tweets + CNN News
Total	63,512	24,742	88,254	

G. Algoritma Klasifikasi


Seperti yang diilustrasikan pada Gambar 1, vektor yang dihasilkan akan digunakan sebagai input untuk pengembangan model *Hybrid Deep Learning* yang menggunakan *Convolutional Neural Networks* (CNN) dan *Bidirectional Long Short-Term Memory* (BiLSTM) untuk mendeteksi dengan melakukan kategorisasi setelah prosedur perluasan fitur selesai.

Salah satu jenis jaringan saraf yang menggunakan struktur konvolusi untuk mengekstrak vektor fitur lokal disebut *Convolutional Neural Network* (CNN) [14]. Input dari lapisan berikutnya dari jaringan *multilayer CNN* adalah output dari lapisan sebelumnya. Hasilnya, jaringan ini terdiri dari beberapa lapisan tersembunyi, *input*, dan *output* [15]. Arsitektur CNN [16] yang digunakan pada penelitian ini ditampilkan pada Gambar 2.



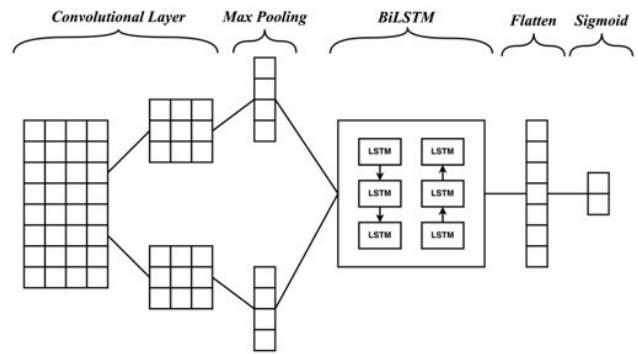
GAMBAR 2. Arsitektur CNN

Bi-directional Long Short-Term Memory (BiLSTM) adalah kombinasi dari LSTM maju dan mundur. Untuk mengekspresikan sebuah kalimat, model LSTM belajar melalui pelatihan tentang apa yang harus diingat dan apa yang harus dilupakan. Namun demikian, informasi tidak dapat dikodekan dari belakang ke depan menggunakan model LSTM. Oleh karena itu, ketergantungan semantik dua arah harus ditangkap oleh BiLSTM [14]. Arsitektur BiLSTM[16] yang digunakan pada penelitian ini ditampilkan pada Gambar 3.

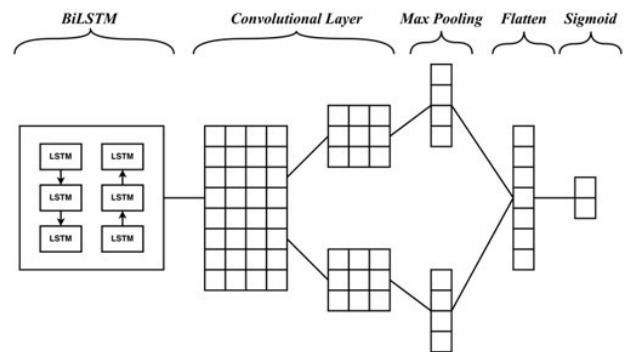


GAMBAR 3. Arsitektur BiLSTM

Oleh karena itu, dengan menggunakan keunggulan dari kedua model tersebut, proyek ini akan bereksperimen dengan menggabungkan CNN dan BiLSTM untuk menghasilkan model *Hybrid* CNN-BiLSTM dan *Hybrid* BiLSTM-CNN. BiLSTM dapat menangkap ketergantungan jarak jauh dan konteks masa lalu dan masa depan, sedangkan CNN dapat menangkap pola lokal [16]. Gambaran rinci tentang arsitektur *Hybrid* CNN-BiLSTM[16] dan *Hybrid* BiLSTM-CNN[16] dapat dilihat pada Gambar 4 dan 5.



GAMBAR 4. Arsitektur CNN-BiLSTM



GAMBAR 5. Arsitektur BiLSTM-CNN

Evaluasi

CNN, BiLSTM, CNN-BiLSTM, dan BiLSTM-CNN adalah empat model algoritma klasifikasi yang akan menjadi subjek dari beberapa pengujian dalam penelitian ini. Di sini, temuan-temuan tersebut akan dijelaskan dan diuraikan ke dalam beberapa skenario berikut.

A. Skenario 1

Rasio pembagian data pada skenario pertama 90:10, 80:20, dan 70:30. Diuji untuk menemukan rasio data *training* optimal yang akan diterapkan pada skenario berikutnya. Selain mengevaluasi rasio data, skenario ini juga menguji fitur maksimum optimal yang akan digunakan pada skenario berikutnya. Skala fitur maksimum berkisar antara 5.000 hingga 15.000 fitur.

Nilai akurasi dari kedua model, dengan menggunakan fitur maksimum 10.000 untuk semua proporsi data yang dibagi, ditampilkan pada Tabel 5. *Baseline* yang digunakan untuk skenario berikut ini adalah TF-IDF dengan split 80:20. Karena, jika dibandingkan dengan split yang lain, temuan pada Tabel 5 data split 80:20 memperoleh nilai akurasi terbaik.

TABEL 4
NILAI AKURASI DENGAN SPLIT RASIO

<i>Split Ratio</i>	<i>Accuracy (%)</i>
--------------------	---------------------

	<i>CNN</i>	<i>BiLSTM</i>
90:10	85.97	87.38
80:20	86.21	87.79
70:30	85.72	87.55

TABEL 5
NILAI AKURASI DENGAN FITUR MAKSIMAL

<i>Data Ratio</i>	<i>Max Feature</i>	<i>Accuracy (%)</i>	
		<i>CNN</i>	<i>BiLSTM</i>
80:20	5000	85.11	83.32
	10000	86.21	87.79
	15000	86.24	85.61

B. Skenario 2

Skenario kedua akan membandingkan TF-IDF n-gram seperti Unigram, Bigram, Trigram, Unigram+Bigram, atau Allgram. Karena split data 80:20 memiliki tingkat akurasi tertinggi di antara split data pada skenario sebelumnya, maka kedua model yang akan diuji pada skenario ini menggunakan split data 80:20 dan fitur maksimum 10.000.

Nilai akurasi kedua model dari perbandingan n-gram dengan split 80:20 dan fitur maksimum 10.000 ditampilkan pada Tabel 6. Model CNN dengan n-gram Unigram + Bigram dan model BiLSTM dengan n-gram Unigram adalah *baseline* yang digunakan untuk skenario berikutnya.

TABEL 6
NILAI AKURASI DENGAN PERBANDINGAN N-GRAM

<i>N-Gram</i>	<i>Accuracy (%)</i>	
	<i>CNN</i>	<i>BiLSTM</i>
Unigram (<i>Baseline</i>)	86.21	87.79
Bigram	75.80	77.82
Trigram	63.46	63.67
Unigram + Bigram	86.57	87.30
Allgram	86.36	87.20

C. Skenario 3

Pada skenario berikutnya, model CNN dan BiLSTM diuji dengan menggunakan fitur perluasan yang diperoleh dari korpus kemiripan FastText. Dalam proses ini, fitur perluasan membantu meningkatkan representasi teks dengan menangkap lebih banyak hubungan semantik antar kata. Kami juga memeriksa beberapa peringkat “N” teratas dari istilah yang paling mirip dalam korpus untuk menentukan metrik kemiripan optimal yang akan menghasilkan presisi maksimum. Top 1, Top

5, Top 10, Top 15, Top 20, dan Top 25 adalah beberapa peringkat teratas yang diperiksa dalam investigasi ini.

Model CNN memiliki akurasi yang meningkat dengan kurasi hingga 0,23%, menurut hasil pengujian model tunggal pada Tabel 7. Representasi semantik berhasil ditingkatkan oleh FastText. Namun, akurasi model BiLSTM tidak meningkat.

TABEL 7
NILAI AKURASI MODEL CNN & BiLSTM DENGAN FASTTEXT

<i>Model</i>	<i>Rank</i>	<i>Accuracy (%)</i>			
		<i>Baseline</i>	<i>Tweet</i>	<i>News</i>	<i>Tweet+News</i>
CNN	Top 1	86.57	85.74	85.81	86.29
	Top 5		86.72	86.22	86.77
	Top 10		85.88	86.84	86.29
	Top 15		86.24	84.85	86.24
	Top 20		-	-	-
	Top 25		-	-	-
BiLSTM	Top 1	87.79	85.55	86.24	85.91
	Top 5		85.95	86.03	86.22
	Top 10		85.81	86.43	86.58
	Top 15		86.48	85.68	86.89
	Top 20		-	-	-
	Top 25		-	-	-

D. Skenario 4

Pada skenario berikutnya, fitur-fitur yang diperluas yang diambil dari korpus kemiripan FastText juga digunakan untuk menguji model BiLSTM-CNN dan *Hybrid* CNN-BiLSTM. Dalam proses ini, fitur-fitur yang diperluas membantu meningkatkan representasi teks dengan menangkap lebih banyak hubungan semantik antar kata. Kami juga memeriksa beberapa peringkat “N” teratas dari istilah yang paling mirip dalam korpus untuk menentukan metrik kemiripan optimal yang akan menghasilkan presisi maksimum. Top 1, Top 5, Top

10, Top 15, Top 20, dan Top 25 adalah beberapa peringkat teratas yang diperiksa dalam investigasi ini.

Berdasarkan temuan pengujian pada Tabel 8, akurasi model hibrida untuk CNN-BiLSTM dan BiLSTM-CNN masing-masing adalah 87,66% dan 87,84%, yang mengindikasikan bahwa kedua model tersebut telah meningkat jika dibandingkan dengan model tunggal.

TABEL 8

NILAI AKURASI MODEL CNN-BILSTM & BILSTM-CNN DENGAN FASTTEXT

Model	Rank	Accuracy (%)		
		Tweet	News	Tweet+News
CNN-BiLSTM	Top 1	86.99	85.16	86.74
	Top 5	86.99	84.72	86.53
	Top 10	87.24	85.19	86.32
	Top 15	87.66	85.59	86.67
	Top 20	87.57	-	-
	Top 25	-	-	-
BiLSTM-CNN	Top 1	87.38	87.41	87.95
	Top 5	87.36	87.06	87.65
	Top 10	87.44	86.81	87.32
	Top 15	87.75	86.74	87.21
	Top 20	87.84	-	-
	Top 25	87.75	-	-

E. Skenario 5

Pada skenario terakhir, efektivitas pemodelan multimodal dievaluasi dengan membandingkan kinerja model teks dan gambar independent (unimodal) yang menggabungkan prediksi dari teks dan gambar.

Hasil Tabel 9 menunjukkan bahwa, dengan akurasi 87,92%, pendekatan multimodal-yang memadukan teks dan gambar-memberikan hasil yang paling baik secara keseluruhan. Hasil ini menunjukkan peningkatan sebesar +0.09% dibandingkan model berbasis teks dan +25.10% dibandingkan model berbasis gambar, yang menyoroti keefektifan penggabungan tingkat keputusan dalam meningkatkan kinerja klasifikasi sentimen.

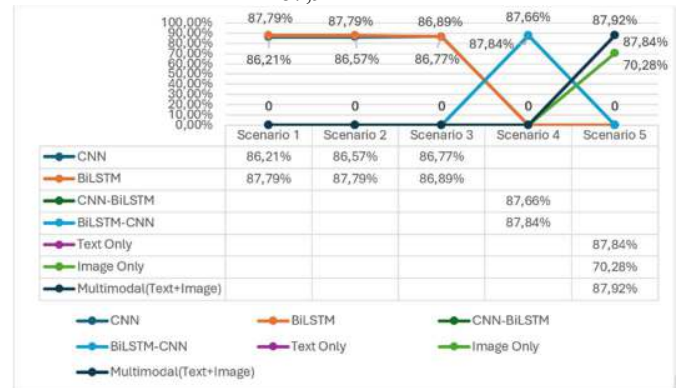
TABEL 9

EVALUASI UNIMODAL DAN MULTIMODAL

Feature	Accuracy (%)
Text-based	87,84
Image-based	70,28
Multimodal (Text+Image)	87,92

F. Diskusi

Untuk menemukan model terbaik, sejumlah skenario pengujian dilakukan dalam investigasi ini. Akurasi model berbasis teks, berbasis gambar, dan multimodal di masing-masing dari lima skenario yang diteliti ditunjukkan pada Gambar 6. Skenario pertama berfungsi sebagai *baseline*, dengan akurasi awal masing-masing model sebesar 86,21% untuk CNN dan 87,79% untuk BiLSTM. Pada skenario kedua, terdapat sedikit peningkatan yang signifikan untuk model CNN yang meningkat menjadi 86,57% dan BiLSTM tetap pada 87,79%. Tingkat akurasi model CNN kemudian meningkat menjadi 0,23% pada kasus ketiga, sedangkan model BiLSTM tidak. Pada 87,66% untuk CNN-BiLSTM dan 87,84% untuk BiLSTM-CNN, model hibrida CNN-BiLSTM dan BiLSTM-CNN mengungguli model tunggal pada kasus keempat. Pada skenario kelima, kinerja model teks dan gambar diuji secara terpisah untuk membandingkan kemampuan model multimodal. Hasilnya, tingkat akurasi untuk gambar Adalah 70,28%, sedangkan tingkat akurasi untuk multimodal adalah 87,92%.



GAMBAR 6.

Performa Akurasi Varian Model pada seluruh skenario

KESIMPULAN

Pada penelitian ini dikembangkan analisis sentimen multimodal dengan model hybrid CNN-BiLSTM dan ekspansi fitur FastText. Penelitian ini menggunakan 24.742 pasangan tweet-gambar berbahasa Inggris dari media sosial X setelah preprocessing dan hanya menggunakan label positif dan negatif. Untuk membangun korpus kemiripan FastText, 63.512 entri dari portal berita digital CNN (*Cable News Network*) dan kumpulan data X digabungkan. Semua skenario dievaluasi menggunakan model BiLSTM-CNN yang diintegrasikan

dengan mekanisme perhatian dan dinilai menggunakan rasio pembagian 80:20. Konfigurasi ekstraksi fitur teks yang optimal adalah konfigurasi yang dicapai dengan menggabungkan TF-IDF menggunakan Allgram dengan maksimum 10.000 fitur, perluasan menggunakan 15 kata yang mirip dari korpus FastText. Untuk ekstraksi fitur visual menggunakan VGG-16. Hasil terbaik secara keseluruhan adalah hasil yang dicapai dengan menggunakan pendekatan multimodal, yang menggabungkan teks dan gambar, dengan akurasi 87,92%. Hasil ini menunjukkan peningkatan sebesar 0,09% dibandingkan dengan model berbasis *text unimodal* dan 25,10% dibandingkan dengan model berbasis *image unimodal*. Kekuatan dari penelitian ini terletak pada pendekatan komprehensif untuk ekstraksi fitur, memanfaatkan keunggulan yang saling melengkapi dari setiap modalitas dan tingkat fusi untuk memahami dan mengklasifikasikan sentimen dalam wacana kesehatan mental secara lebih efektif.

REFERENSI

- [1] A. Abdurrahim and D. H. F. Fudholi, "Mental Health Prediction Model on Social Media Data Using CNN-BiLSTM," *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, vol. 4, no. 1, 2024, doi: 10.22219/kinetik.v9i1.1849.
- [2] Y. Cao, J. Dai, Z. Wang, Y. Zhang, X. Shen, and Y. Liu, "Systematic Review: Text Processing Algorithms in Machine Learning and Deep Learning for Mental Health Detection on Social Media," pp. 1–48.
- [3] E. Lee, H. Kim, Y. Esener, and T. McCall, "Online Social Connections of Black American College Students Pre- and Peri-COVID-19 Pandemic: Network Science Approach (Preprint)," *J Med Internet Res*, vol. 26, 2023, doi: 10.2196/55531.
- [4] S. A. Sazan, M. H. Miraz, and A. B. M. Muntasir Rahman, "Enhancing Depressive Post Detection in Bangla: A Comparative Study of TF-IDF, BERT and FastText Embeddings," *Annals of Emerging Technologies in Computing*, vol. 8, no. 3, pp. 34–49, 2024, doi: 10.33166/AETiC.2024.03.003.
- [5] Ö. Ezerceci and R. Dehkharghani, *Mental disorder and suicidal ideation detection from social media using deep neural networks*, vol. 7, no. 3. Springer Nature Singapore, 2024. doi: 10.1007/s42001-024-00307-1.
- [6] H. Elfaik and E. H. Nfaoui, "Leveraging feature-level fusion representations and attentional bidirectional RNN-CNN deep models for Arabic affect analysis on Twitter," *Journal of King Saud University - Computer and Information Sciences*, vol. 35, no. 1, pp. 462–482, 2023, doi: 10.1016/j.jksuci.2022.12.015.
- [7] T. Ghosh, M. H. Al Banna, M. J. Al Nahian, M. N. Uddin, M. S. Kaiser, and M. Mahmud, "An attention-based hybrid architecture with explainability for depressive social media text detection in Bangla," *Expert Syst Appl*, vol. 213, no. PC, p. 119007, 2023, doi: 10.1016/j.eswa.2022.119007.
- [8] N. H. Di Cara, V. Maggio, O. S. P. Davis, and C. M. A. Haworth, "Methodologies for Monitoring Mental Health on Twitter: Systematic Review," 2023, JMIR Publications Inc. doi: 10.2196/42734.
- [9] S. W. Jannah, "Analisis Sentimen Multimodal Berbasis Aspek untuk Ulasan Wisatawan Menggunakan Metode Deep Learning," *Skripsi Sarjana*, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 2025. [Online]. Available: <https://repository.its.ac.id/11746/1/>
- [10] Febiana Anistya and Erwin Budi Setiawan, "Hate Speech Detection on Twitter in Indonesia with Feature Expansion Using GloVe," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, pp. 1044–1051, Dec. 2021, doi: 10.29207/resti.v5i6.3521.
- [11] A. Zeyer, P. Doetsch, P. Voigtlaender, R. Schluter, and H. Ney, "A comprehensive study of deep bidirectional LSTM RNNs for acoustic modeling in speech recognition," *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, pp. 2462–2466, 2017, doi: 10.1109/ICASSP.2017.7952599.
- [12] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov, "Enriching Word Vectors with Subword Information," *Trans Assoc Comput Linguist*, vol. 5, pp. 135–146, 2017, doi: 10.1162/tacl_a_00051.
- [13] Yue, W., Li, L. (2020). Sentiment analysis using Word2vec-CNN-BiLSTM classification. In 2020 Seventh International Conference on Social Networks Analysis, Management and Security (SNAMS), Paris, France, pp. 1–5. <https://doi.org/10.1109/SNAMS52053.2020.9336549>
- [14] Rhanoui, M., Mikram, M., Yousfi, S., Barzali, S. (2019). A CNN-BiLSTM model for document-level sentiment analysis. *Machine Learning and Knowledge Extraction*, 1(3): 832–847. <https://doi.org/10.3390/make1030048>
- [15] Toktarova, A., Syrlybay, D., Myrzakhmetova, B., Anuarbekova, G., Rakhimbayeva, G., Zhylanbaeva, B., Suieuoova, N., Kerimbekov, M. (2023). Hate speech detection in social networks using machine learning and deep learning methods. *International Journal of Advanced Computer Science and Applications*, 14(5): 396–406. <https://doi.org/10.14569/IJACSA.2023.0140542>
- [16] M. A. S. Nasution and E. B. Setiawan, "Enhancing Cyberbullying Detection on Indonesian Twitter: Leveraging FastText for Feature Expansion and Hybrid Approach Applying CNN and BiLSTM," *Revue d'Intelligence Artificielle*, vol. 37, no. 4, pp. 929–936, 2023, doi: 10.18280/ria.370413.