

HYBRID TIME SERIES CLASSIFICATION UNTUK DETEKSI RISIKO KESEHATAN MENTAL BERBASIS INDOBERT DAN BI-LSTM

Yassa Ayu Rahmadhani^{1*}, Mustafa²

^{1,2}Universitas Islam Sultan Agung

yassaayu1@gmail.com^{1*}, cakmustafa@unissula.ac.id²

Received: 17-04-2026

Revised: 29-04-2026

Approved: 27-05-2026

ABSTRAK

Penelitian ini bertujuan untuk mengembangkan pendekatan Hybrid Time Series Classification berbasis IndoBERT dan Bidirectional Long Short-Term Memory (Bi-LSTM) dalam mendeteksi risiko kesehatan mental melalui analisis dinamika sentimen temporal pada data media sosial. Metode penelitian yang digunakan meliputi pengumpulan data Twitter (X), preprocessing teks, filtering konteks kesehatan mental menggunakan kombinasi keyword matching dan validasi kontekstual berbasis IndoBERT, penanganan data imbalance melalui teknik oversampling dan undersampling, transformasi data ke dalam bentuk deret waktu, feature engineering, serta pemodelan menggunakan Bi-LSTM. Evaluasi model dilakukan menggunakan confusion matrix, accuracy, precision, recall, dan F1-score, sedangkan hasil analisis divisualisasikan melalui dashboard interaktif berbasis Streamlit. Hasil penelitian menunjukkan bahwa proses filtering berhasil meningkatkan relevansi data dari 23.644 tweet menjadi 7.266 tweet yang sesuai dengan konteks kesehatan mental. Selain itu, penerapan teknik balancing terbukti meningkatkan performa model secara signifikan, ditunjukkan oleh peningkatan nilai accuracy dari 0,4789 menjadi 1,0000 dan F1-score dari 0,5240 menjadi 1,0000. Model juga mampu menangkap pola sentimen temporal serta mengklasifikasikan tingkat risiko kesehatan mental ke dalam kategori rendah, sedang, dan tinggi dengan tingkat akurasi yang sangat tinggi. Simpulan penelitian ini menunjukkan bahwa pendekatan hybrid berbasis IndoBERT dan Bi-LSTM efektif dalam mengintegrasikan pemahaman konteks bahasa dan dinamika temporal untuk mendeteksi risiko kesehatan mental secara adaptif, sehingga berpotensi mendukung pengembangan sistem pemantauan kesehatan mental berbasis media sosial yang lebih representatif dan informatif.

Kata Kunci: Hybrid Time Series Classification, Analisis Sentimen Temporal, Risiko Kesehatan Mental

PENDAHULUAN

Media sosial telah berkembang menjadi salah satu sarana utama bagi masyarakat dalam mengekspresikan opini, emosi, hingga kondisi psikologis secara terbuka, khususnya melalui platform Twitter (X). Aktivitas tersebut menghasilkan data teks dalam jumlah besar yang terus bertambah secara real-time dan berpotensi dimanfaatkan untuk mengidentifikasi kondisi kesehatan mental pengguna secara tidak langsung. Informasi sentimen yang terkandung dalam unggahan pengguna mampu merepresentasikan dinamika emosional individu maupun kelompok yang berubah dari waktu ke waktu. Kondisi ini membuka peluang dalam pengembangan analisis kesehatan mental berbasis data media sosial, namun pada saat yang sama menghadirkan tantangan dalam memahami pola perubahan sentimen yang bersifat dinamis dan temporal. Oleh karena itu, analisis sentimen tidak hanya dilakukan secara statis, tetapi juga perlu mempertimbangkan dimensi temporal agar pola perubahan emosi dapat dianalisis secara lebih komprehensif.

Penelitian oleh Valdez et al. [1] menunjukkan bahwa data Twitter mampu merepresentasikan perubahan kondisi kesehatan mental masyarakat secara longitudinal. Selain itu, pendekatan deep learning berbasis deret waktu juga dinilai efektif dalam menangkap pola temporal yang kompleks pada data sequential [2]. Berbagai penelitian sebelumnya telah memanfaatkan metode klasifikasi teks dan

analisis sentimen untuk mengidentifikasi kondisi emosional maupun psikologis pengguna media sosial. Pendekatan berbasis machine learning dan deep learning terus berkembang seiring meningkatnya kompleksitas data teks dan kebutuhan akan model yang mampu memahami konteks bahasa secara lebih mendalam [3], [4]. Penelitian sebelumnya juga menunjukkan bahwa pendekatan deep learning pada analisis sentimen Twitter mampu menghasilkan performa yang baik dalam memahami pola opini dan emosi pengguna pada data media sosial berskala besar [5]. Dalam konteks bahasa Indonesia, model transformer seperti IndoBERT memiliki kemampuan yang baik dalam memahami hubungan kontekstual antar kata melalui pendekatan contextual embedding [6].

IndoBERT merupakan pengembangan dari Bidirectional Encoder Representations from Transformers (BERT) yang terbukti efektif pada berbagai tugas Natural Language Processing (NLP), termasuk klasifikasi teks dan analisis sentimen [7]. Di sisi lain, model Long Short-Term Memory (LSTM) beserta variannya, seperti Bidirectional Long Short-Term Memory (Bi-LSTM), dikenal efektif dalam menangani dependensi temporal pada data sequential dan telah banyak diterapkan pada analisis kesehatan mental berbasis teks[8]. Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada klasifikasi sentimen secara statis pada satu waktu tertentu sehingga belum mampu merepresentasikan perubahan emosi pengguna secara berkelanjutan. Padahal, kondisi psikologis individu maupun masyarakat pada media sosial bersifat dinamis dan dapat berubah dari waktu ke waktu akibat pengaruh berbagai faktor eksternal. Keterbatasan tersebut menyebabkan pola fluktuasi sentimen yang berpotensi merepresentasikan tingkat risiko kesehatan mental belum dapat dianalisis secara optimal.

Penelitian oleh Kolliakou et al. [9] menunjukkan bahwa percakapan terkait kesehatan mental di media sosial mengalami perubahan pola temporal yang signifikan dan dapat digunakan untuk merepresentasikan kondisi psikologis kolektif masyarakat. Oleh karena itu, diperlukan pendekatan yang mampu mengintegrasikan pemahaman konteks bahasa dengan pemodelan temporal secara bersamaan agar analisis sentimen terhadap risiko kesehatan mental dapat dilakukan secara lebih adaptif dan komprehensif. Selain itu, tantangan lain dalam analisis kesehatan mental berbasis media sosial adalah ketidakseimbangan distribusi data (imbalanced data) yang dapat memengaruhi performa model klasifikasi [10], [11]. Data dengan distribusi kelas yang tidak seimbang berpotensi menyebabkan model cenderung memprediksi kelas mayoritas dan menurunkan kemampuan identifikasi terhadap kelas minoritas yang justru memiliki informasi penting terkait risiko kesehatan mental. Oleh karena itu, penanganan data imbalance menjadi salah satu aspek penting dalam pengembangan model klasifikasi yang lebih robust dan representative.

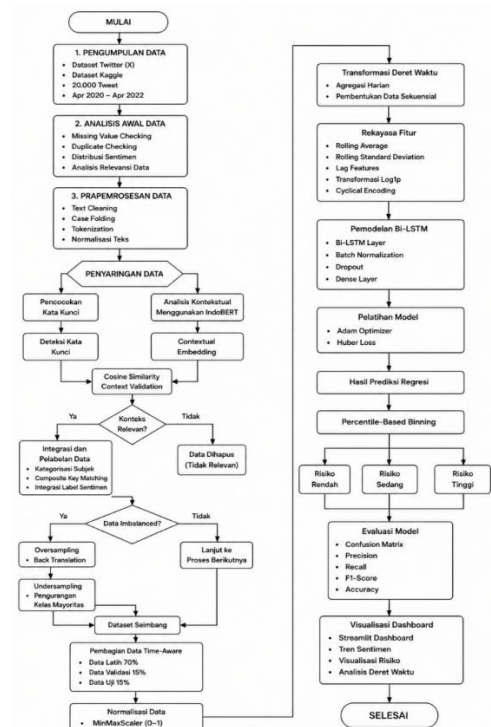
Berdasarkan latar belakang tersebut, masih terdapat kesenjangan penelitian dalam penerapan pendekatan hybrid yang mengombinasikan analisis sentimen berbasis contextual embedding dengan pemodelan deret waktu untuk mendeteksi risiko kesehatan mental dari data media sosial. Sebagian besar penelitian sebelumnya hanya berfokus pada analisis sentimen statis atau pemodelan temporal secara terpisah, sehingga belum mampu mengintegrasikan informasi kontekstual bahasa dan dinamika temporal secara optimal. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan pendekatan Hybrid Time Series Classification berbasis IndoBERT dan Bidirectional Long Short-Term Memory (Bi-LSTM) untuk menganalisis dinamika sentimen temporal serta mendeteksi tingkat risiko kesehatan mental dari data media

sosial secara lebih adaptif dan representatif. Penelitian ini mengintegrasikan proses penyaringan data melalui keyword matching, validasi kontekstual menggunakan IndoBERT, serta pemodelan temporal menggunakan Bi-LSTM. Data yang telah melalui tahap prapemrosesan kemudian ditransformasikan ke dalam bentuk deret waktu melalui proses agregasi harian dan dilanjutkan dengan feature engineering untuk meningkatkan representasi pola temporal.

Kontribusi utama penelitian ini terletak pada penerapan pendekatan hybrid yang menggabungkan analisis sentimen berbasis contextual embedding dengan pemodelan deret waktu dalam mendeteksi risiko kesehatan mental dari data media sosial. Selain itu, penelitian ini juga mengusulkan mekanisme kategorisasi tingkat risiko berdasarkan hasil prediksi model regresi yang dikonversi ke dalam kelas risiko tertentu. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan metode analisis data media sosial guna mendukung sistem pemantauan kondisi kesehatan mental secara tidak langsung yang lebih adaptif, representatif, dan berbasis dinamika temporal.

METODE PENELITIAN

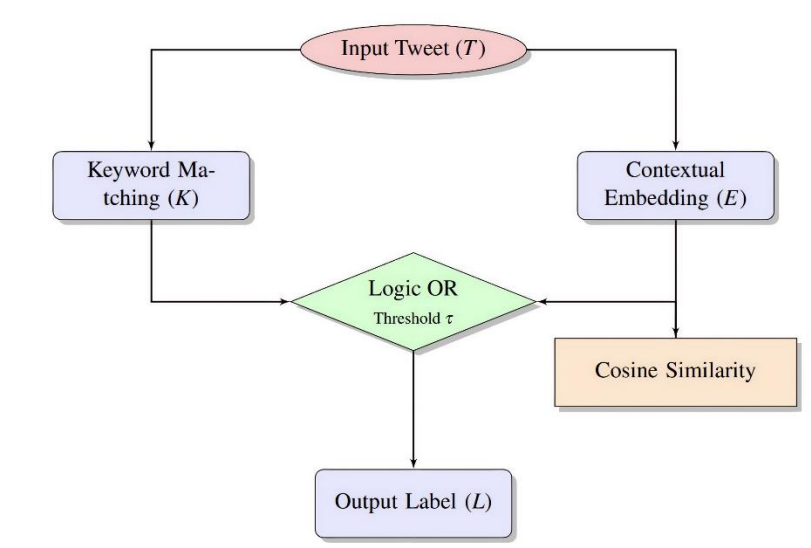
Penelitian ini mengusulkan pendekatan Hybrid Time Series Classification untuk menganalisis dinamika sentimen temporal dan mendeteksi tingkat risiko kesehatan mental berbasis data media sosial. Pendekatan yang digunakan mengintegrasikan analisis teks berbasis Natural Language Processing (NLP), contextual embedding menggunakan IndoBERT, serta pemodelan deret waktu menggunakan Bidirectional Long Short-Term Memory (Bi-LSTM) untuk menangkap dependensi temporal pada data sekuensial [2], [8]. Metodologi penelitian dirancang untuk menghasilkan sistem klasifikasi risiko kesehatan mental yang mampu merepresentasikan perubahan sentimen secara dinamis dan berkelanjutan. Pendekatan serupa telah banyak diterapkan dalam penelitian analisis sentimen, pemodelan deret waktu, dan klasifikasi kesehatan mental berbasis deep learning [2], [8]. Tahapan penelitian meliputi pengumpulan data, analisis awal data, preprocessing, filtering konteks kesehatan mental, penanganan data imbalance, transformasi data ke dalam bentuk deret waktu, feature engineering, pengembangan model Bi-LSTM, evaluasi performa model, hingga visualisasi hasil menggunakan dashboard interaktif. Sebagaimana ditunjukkan pada Gambar 1, setiap tahapan dirancang secara sistematis untuk memastikan model mampu menangkap dinamika sentimen temporal dan menghasilkan klasifikasi risiko kesehatan mental yang lebih representatif.



Gambar 1. Alur Metodologi Penelitian Hybrid Time Series Classification

Pendekatan pemodelan yang digunakan bersifat regresi sehingga menghasilkan nilai sentimen dalam bentuk kontinu, berbeda dengan pendekatan klasifikasi konvensional yang bersifat diskrit. Nilai prediksi kemudian dikonversi ke dalam tiga tingkat risiko kesehatan mental, yaitu rendah, sedang, dan tinggi, menggunakan teknik percentile-based binning. Pendekatan ini memungkinkan representasi perubahan sentimen yang lebih adaptif terhadap dinamika temporal dibandingkan metode klasifikasi konvensional [2]. Dataset yang digunakan berasal dari platform Twitter (X) dan diperoleh melalui Kaggle dengan judul Indonesian Twitter Sentiment Analysis Dataset PPKM [4]. Dataset mencakup sekitar 20.000 tweet berbahasa Indonesia terkait kebijakan PPKM selama periode April 2020 hingga April 2022 yang merepresentasikan dinamika sosial pada masa pandemi COVID-19 [1]. Setiap entri data terdiri atas atribut waktu, teks, dan label sentimen awal berupa positif, negatif, dan netral. Tahap analisis awal dilakukan untuk mengidentifikasi distribusi sentimen, kualitas data, keberadaan missing value, data duplikat, serta kesesuaian data dengan konteks kesehatan mental. Selain itu, dilakukan penyaringan akun non-individu seperti bot, akun media, dan akun promosi guna meningkatkan relevansi data terhadap analisis kondisi psikologis pengguna media sosial [9].

Tahap preprocessing dilakukan untuk menghasilkan data yang bersih, konsisten, dan terstruktur sehingga dapat digunakan secara optimal pada proses pemodelan deep learning. Proses preprocessing sebagaimana ditunjukkan pada Gambar 2 meliputi text cleaning dengan menghilangkan URL, mention, hashtag, angka, tanda baca, emoji, dan karakter khusus lainnya. Selain itu, diterapkan case folding untuk menyeragamkan format huruf, tokenization untuk memecah teks menjadi token kata, serta normalisasi teks untuk meningkatkan konsistensi data.



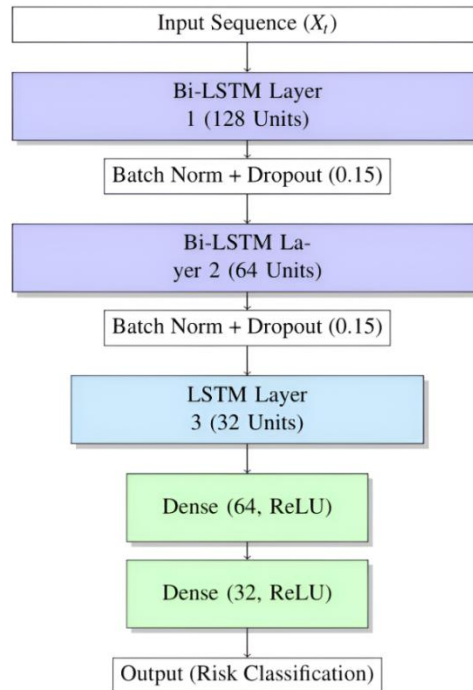
Gambar 2. Alur Data Preprocessing

Filtering konteks kesehatan mental dilakukan menggunakan pendekatan hybrid yang mengombinasikan keyword matching dan validasi kontekstual berbasis IndoBERT [6]. Keyword matching digunakan untuk menyaring tweet yang mengandung kata-kata terkait kondisi psikologis dan kesehatan mental. Selanjutnya, model IndoBERT digunakan untuk melakukan validasi kontekstual melalui pembentukan contextual embedding sehingga model mampu memahami hubungan semantik antar kata dalam teks berbahasa Indonesia. Representasi embedding kemudian dihitung tingkat kemiripannya menggunakan cosine similarity untuk memastikan kesesuaian konteks kesehatan mental pada data teks.

Data hasil filtering selanjutnya dikategorikan ke dalam beberapa kelompok subjek menggunakan pendekatan berbasis aturan (rule-based classification). Integrasi label sentimen dilakukan menggunakan metode composite key matching untuk menghasilkan dataset yang terstruktur dan siap digunakan dalam proses pemodelan deret waktu. Untuk mengatasi permasalahan ketidakseimbangan distribusi kelas (imbalanced data), penelitian ini menerapkan pendekatan hybrid sampling yang mengombinasikan oversampling dan undersampling [10], [11]. Oversampling dilakukan menggunakan metode back translation untuk menghasilkan variasi teks baru tanpa mengubah makna utama kalimat, sedangkan undersampling diterapkan secara proporsional pada kelas mayoritas. Pendekatan ini bertujuan untuk meningkatkan representasi kelas minoritas dan mengurangi bias model terhadap kelas mayoritas sehingga performa klasifikasi menjadi lebih stabil dan representatif.

Dataset kemudian dibagi menggunakan pendekatan time-aware splitting dengan proporsi 70% data latih, 15% data validasi, dan 15% data uji untuk menghindari data leakage serta mempertahankan urutan temporal data [2]. Selanjutnya, dilakukan normalisasi menggunakan MinMaxScaler dalam rentang 0–1 guna menjaga stabilitas proses pelatihan dan mempercepat konvergensi model. Data teks yang telah diproses kemudian ditransformasikan menjadi sinyal deret waktu melalui proses agregasi harian berdasarkan timestamp data. Untuk meningkatkan kualitas representasi temporal, dilakukan feature engineering yang mencakup pembentukan rolling average, rolling standard deviation, lag features, transformasi logaritmik (\log_{1p}), serta cyclical encoding menggunakan fungsi sinus dan cosinus untuk menangkap pola periodik pada

data temporal [2]. Model Deep Bidirectional Long Short-Term Memory (Bi-LSTM) digunakan sebagai inti pemodelan temporal untuk menangkap dependensi sekuensial dua arah pada data deret waktu [8]. Struktur arsitektur model ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur Model Bi-LSTM

Arsitektur model terdiri atas beberapa lapisan Bidirectional LSTM bertingkat yang diikuti oleh lapisan dense dengan fungsi aktivasi linear. Untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting, diterapkan teknik regularisasi berupa batch normalization dan dropout layer. Pelatihan model dilakukan menggunakan fungsi Huber Loss yang lebih robust terhadap outlier dibandingkan Mean Squared Error (MSE), sedangkan optimasi model dilakukan menggunakan Adam optimizer dengan learning rate sebesar 0,001 untuk memastikan proses konvergensi berlangsung secara stabil [12].

Evaluasi model dilakukan dengan mengonversi hasil prediksi regresi ke dalam kategori risiko kesehatan mental menggunakan teknik percentile-based binning dengan pembagian persentil sebesar 33% dan 67%. Pendekatan ini menghasilkan tiga kategori risiko kesehatan mental, yaitu rendah, sedang, dan tinggi. Kinerja model dievaluasi menggunakan confusion matrix, precision, recall, dan F1-score untuk mengukur kemampuan model dalam mengklasifikasikan tingkat risiko kesehatan mental secara akurat [13], [14]. Selain itu, dilakukan analisis terhadap kurva training loss dan validation loss untuk mengidentifikasi potensi overfitting maupun underfitting selama proses pelatihan model.

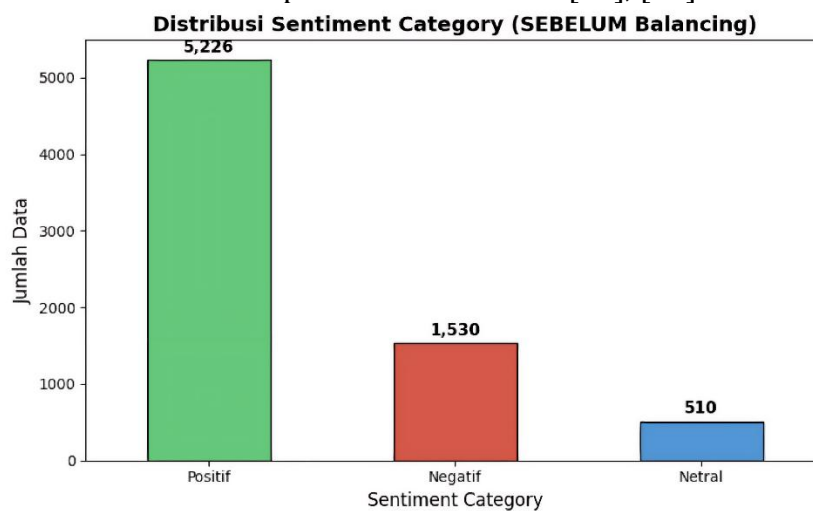
Sebagai bagian dari implementasi sistem, dikembangkan dashboard interaktif berbasis Streamlit untuk menyajikan hasil analisis secara visual dan dinamis. Dashboard menyediakan fitur eksplorasi data melalui penyaringan berdasarkan rentang waktu, kategori kesehatan mental, dan kategori subjek, serta menampilkan visualisasi berupa distribusi sentimen, tren deret waktu, distribusi subjek, dan kategori

kesehatan mental. Pendekatan ini dirancang untuk meningkatkan interpretabilitas hasil analisis serta mendukung proses pengambilan keputusan berbasis data secara lebih efektif dan informatif.

HASIL PENELITIAN DAN PEMBAHASAN

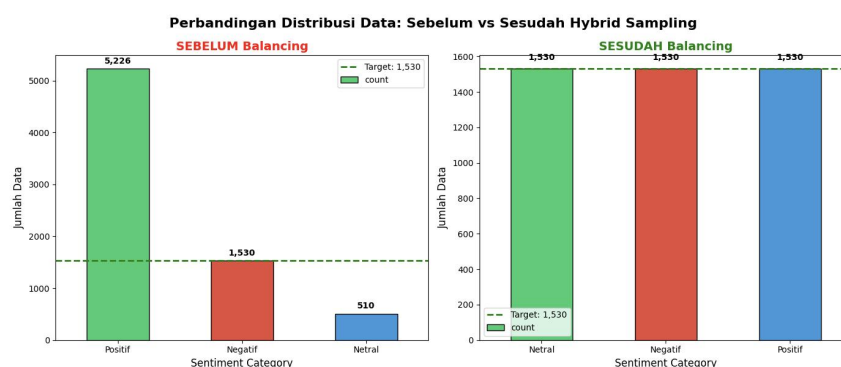
Bagian ini membahas hasil eksperimen serta analisis kinerja model *Hybrid Time Series Classification* berbasis *Bidirectional Long Short-Term Memory* (Bi-LSTM) dalam mengidentifikasi tingkat risiko kesehatan mental berdasarkan dinamika sentimen temporal pada data media sosial. Evaluasi dilakukan untuk menilai kemampuan model dalam menangani data sentimen yang tidak seimbang sekaligus menganalisis pola temporal yang terbentuk selama proses pemodelan. Penyajian hasil dilakukan secara bertahap sesuai tahapan metodologi penelitian, dimulai dari analisis kualitas dataset setelah preprocessing, distribusi sentimen sebelum dan sesudah proses balancing, transformasi data ke dalam bentuk *time series*, proses *feature engineering*, evaluasi performa model, hingga implementasi dashboard visualisasi hasil klasifikasi risiko kesehatan mental.

Hasil tahap preprocessing menunjukkan adanya peningkatan kualitas dataset yang signifikan setelah dilakukan proses pembersihan dan filtering berbasis konteks. Jumlah data awal sebanyak 23.644 tweet berkurang menjadi 7.266 tweet yang dinilai relevan dengan isu kesehatan mental. Hasil tersebut menunjukkan bahwa sebagian besar data awal tidak secara langsung merepresentasikan kondisi psikologis pengguna. Oleh karena itu, penerapan filtering berbasis kombinasi *keyword matching* dan validasi kontekstual menggunakan IndoBERT menjadi penting untuk meningkatkan relevansi data yang digunakan dalam proses pemodelan. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa model berbasis BERT efektif dalam memahami konteks semantik pada teks media sosial [7], [6]. Distribusi sentimen awal menunjukkan adanya ketidakseimbangan kelas yang cukup signifikan, dengan dominasi sentimen positif sebesar 71,9%, diikuti sentimen negatif sebesar 21,1%, dan sentimen netral sebesar 7,0%. Karakteristik data yang tidak seimbang berpotensi menyebabkan bias model terhadap kelas mayoritas, sebagaimana dibahas dalam penelitian terkait *class imbalance* pada data klasifikasi [10], [11].



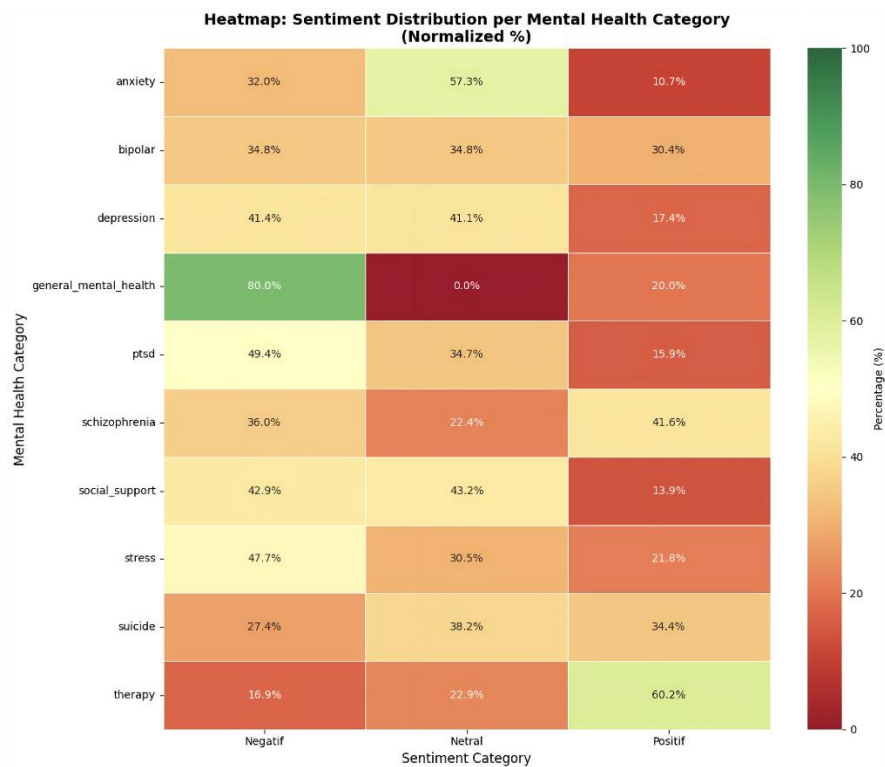
Gambar 4. Initial Sentiment Distribution

Gambar 4 menunjukkan bahwa sebagian besar percakapan didominasi oleh sentimen positif, yang dapat merepresentasikan adanya dukungan sosial selama periode pengamatan. Pola serupa juga dilaporkan pada penelitian sebelumnya terkait diskusi kesehatan mental di media sosial selama pandemi [15], [1]. Meskipun demikian, kondisi tersebut perlu ditangani agar model tidak cenderung menghasilkan prediksi yang bias terhadap kelas mayoritas. Untuk mengatasi ketidakseimbangan distribusi data, dilakukan proses balancing menggunakan kombinasi teknik *oversampling* berbasis *back translation* dan *undersampling*. Pendekatan ini digunakan untuk menghasilkan distribusi data yang lebih seimbang sehingga proses pembelajaran model dapat berlangsung secara lebih optimal. Pendekatan serupa juga telah banyak digunakan dalam penelitian sebelumnya untuk menangani permasalahan data tidak seimbang pada klasifikasi teks [16], [10].



Gambar 5. Balanced Sentiment Distribution

Hasil balancing pada Gambar 5 memperlihatkan bahwa distribusi data menjadi lebih merata dibandingkan kondisi awal. Distribusi yang lebih seimbang diharapkan mampu meningkatkan stabilitas model selama proses pelatihan dan mengurangi kecenderungan bias terhadap kelas mayoritas. Selain itu, analisis hubungan antara kategori kesehatan mental dan sentimen menunjukkan pola yang relatif konsisten. Kategori seperti depresi dan stres cenderung didominasi oleh sentimen negatif, sedangkan kategori terapi dan dukungan sosial lebih banyak didominasi oleh sentimen positif. Pola tersebut menunjukkan bahwa dataset memiliki representasi yang cukup baik dalam menggambarkan kondisi emosional pengguna. Temuan ini sejalan dengan penelitian sebelumnya yang mengkaji hubungan antara ekspresi emosi dan kondisi kesehatan mental di media sosial [17].



Gambar 6. Heatmap of Mental Health Category and Sentiment Distribution

Setelah proses balancing, data sentimen kemudian ditransformasikan ke dalam bentuk deret waktu melalui proses agregasi harian berdasarkan *timestamp* tweet. Transformasi ini bertujuan untuk merepresentasikan dinamika perubahan sentimen dari waktu ke waktu sehingga pola temporal dapat dipelajari oleh model Bi-LSTM secara lebih optimal. Selain agregasi harian, dilakukan pula proses *feature engineering* untuk memperkaya representasi temporal data. Fitur yang dihasilkan meliputi *rolling average*, *rolling standard deviation*, *lag features*, transformasi logaritmik (\log_{1p}), serta *cyclical encoding* berbasis fungsi sinus dan cosinus untuk menangkap pola periodik pada data *time series*. Pendekatan ini membantu model dalam mengenali tren sentimen serta fluktuasi emosional yang bersifat temporal sebagaimana diterapkan pada penelitian *time series* berbasis *deep learning* [2], [18], [19]. Dataset hasil preprocessing dan balancing kemudian dibagi menggunakan pendekatan *time-aware splitting* dengan proporsi 70% data latih, 15% data validasi, dan 15% data uji. Pendekatan ini digunakan untuk mempertahankan urutan temporal data dan menghindari *data leakage* selama proses pelatihan model. Dengan mempertahankan urutan waktu, model dapat mempelajari pola perubahan sentimen secara lebih realistis sesuai karakteristik data deret waktu [18].

Pada tahap evaluasi, dilakukan analisis performa model sebelum dan sesudah proses augmentasi untuk mengukur pengaruh penyeimbangan distribusi data terhadap kemampuan pembelajaran model. Sebelum dilakukan augmentasi, performa model masih tergolong rendah akibat ketidakseimbangan distribusi kelas yang menyebabkan model lebih dominan mempelajari pola dari kelas mayoritas.

Evaluasi performa model dilakukan menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengukur kemampuan model dalam mengklasifikasikan tingkat risiko kesehatan mental pada setiap kategori secara akurat.

Tabel 1. Evaluasi Sebelum Augmentation

Metric	Score
Accuracy	0.4789
Precision	0.6958
Recall	0.4789
F1-score	0.5240

Hasil evaluasi sebelum augmentasi menunjukkan bahwa meskipun nilai *precision* relatif tinggi, nilai *recall* dan *accuracy* masih rendah. Kondisi ini mengindikasikan bahwa model belum mampu mengenali variasi data secara menyeluruh dan masih mengalami kesulitan dalam mengidentifikasi kelas minoritas secara optimal. Setelah dilakukan proses augmentasi dan balancing, performa model mengalami peningkatan yang sangat signifikan. Hasil ini menunjukkan bahwa distribusi data yang lebih seimbang memberikan pengaruh besar terhadap kemampuan model dalam mempelajari pola data secara lebih representatif.

Tabel 2. Evaluasi Setelah Augmentation

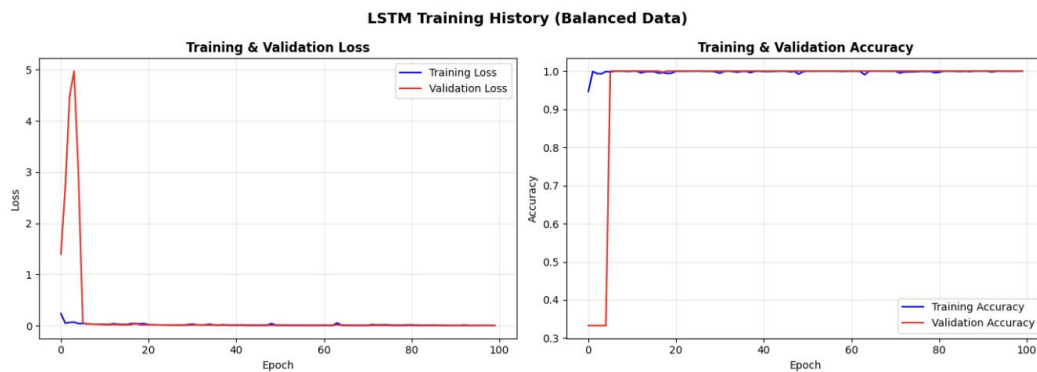
Metric	Score
Accuracy	1.0000
Precision	1.0000
Recall	1.0000
F1-score	1.0000

Hasil evaluasi setelah augmentasi menunjukkan bahwa model mampu melakukan klasifikasi dengan sangat baik pada seluruh kategori risiko kesehatan mental. Meskipun model menghasilkan nilai evaluasi yang sangat tinggi, analisis tambahan tetap dilakukan melalui pengamatan *training loss* dan *validation loss* untuk memastikan bahwa model tidak mengalami *overfitting* maupun *data leakage* selama proses pelatihan. Stabilitas kurva pelatihan menunjukkan bahwa model masih mampu melakukan generalisasi terhadap data validasi secara konsisten.

Tabel 3. Perbandingan Performa Model

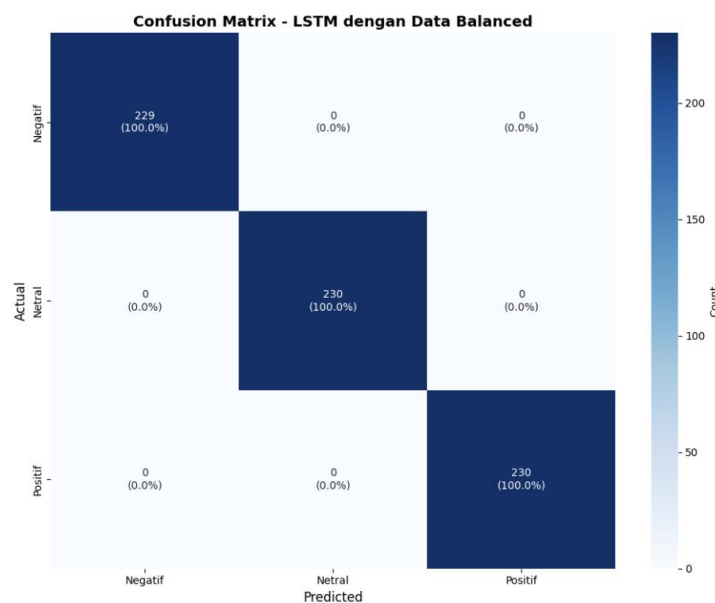
Metric	Before	After
Accuracy	0.4789	1.0000
Precision	0.6958	1.0000
Recall	0.4789	1.0000
F1-score	0.5240	1.0000

Perbandingan tersebut menunjukkan adanya peningkatan yang sangat signifikan pada seluruh metrik evaluasi setelah diterapkannya proses balancing. Hasil ini menegaskan bahwa penyeimbangan distribusi data memiliki peran penting dalam meningkatkan kualitas pembelajaran model, khususnya dalam menangani permasalahan *class imbalance* pada data teks [16], [11]. Selain menggunakan metrik evaluasi, performa model juga dianalisis melalui kurva *training loss* dan *validation loss* untuk mengevaluasi stabilitas proses pelatihan model.



Gambar 7. Training Loss and Validation Loss

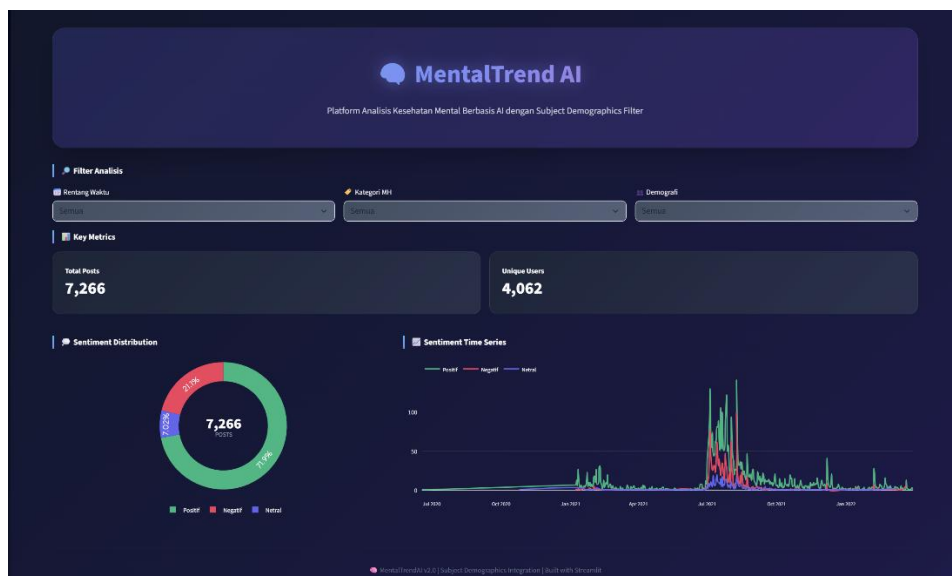
Hasil pada Gambar 7 menunjukkan bahwa proses pelatihan berlangsung stabil dan mampu mencapai konvergensi dengan baik. Pola *training loss* dan *validation loss* yang relatif konsisten menunjukkan bahwa model mampu mempelajari pola data secara efektif tanpa mengalami fluktuasi pelatihan yang signifikan, sejalan dengan penelitian terkait pelatihan model *deep learning* [12]. Nilai keluaran model regresi kemudian dikonversi ke dalam tiga kategori tingkat risiko kesehatan mental menggunakan pendekatan *percentile-based binning* dengan batas persentil 33% dan 67%. Pendekatan ini memungkinkan pembentukan kategori risiko rendah, sedang, dan tinggi secara lebih adaptif terhadap distribusi data sentimen temporal yang dihasilkan model. Evaluasi performa model juga dilakukan menggunakan *confusion matrix* untuk menganalisis distribusi hasil prediksi pada setiap kategori risiko kesehatan mental.



Gambar 8. Confusion Matrix of Risk Classification

Hasil *confusion matrix* pada Gambar 8 menunjukkan bahwa sebagian besar prediksi model berada pada diagonal utama, yang mengindikasikan tingkat akurasi klasifikasi yang tinggi. Kesalahan klasifikasi umumnya terjadi pada kategori risiko yang berdekatan, seperti antara kategori sedang dan tinggi, yang menunjukkan adanya kemiripan karakteristik pada kedua kategori tersebut. Sebagai bagian dari

implementasi sistem, dikembangkan dashboard interaktif berbasis Streamlit untuk memvisualisasikan hasil analisis sentimen dan klasifikasi risiko kesehatan mental secara dinamis. Dashboard dirancang untuk memudahkan proses eksplorasi data berdasarkan rentang waktu, kategori sentimen, kategori kesehatan mental, dan kategori demografi pengguna. Visualisasi yang ditampilkan meliputi distribusi sentimen, tren sentimen temporal, jumlah pengguna unik, serta hasil klasifikasi tingkat risiko kesehatan mental. Selain meningkatkan interpretabilitas hasil model, dashboard juga mendukung proses monitoring kondisi sentimen masyarakat secara lebih interaktif dan informatif.



Gambar 9. Dashboard Visualisasi Analisis Risiko Kesehatan Mental

Pada dashboard terlihat bahwa distribusi sentimen masih didominasi oleh sentimen positif dengan persentase sebesar 71,9%, sedangkan visualisasi *time series* menunjukkan adanya lonjakan aktivitas sentimen pada periode tertentu selama pandemi COVID-19. Dashboard juga menyediakan fitur filter berdasarkan rentang waktu, kategori kesehatan mental, dan demografi sehingga proses analisis dapat dilakukan secara lebih fleksibel dan adaptif. Model Bi-LSTM mampu menangkap dinamika sentimen temporal dan pola risiko kesehatan mental dengan baik. Model tidak hanya menunjukkan performa klasifikasi yang tinggi, tetapi juga mampu merepresentasikan pola emosional yang kompleks pada data media sosial. Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan efektivitas pendekatan *deep learning* dalam analisis sentimen berbasis *time series* [2], [19], [20]. Meskipun demikian, masih terdapat beberapa keterbatasan pada pendekatan yang digunakan. Data yang digunakan hanya berasal dari satu platform media sosial sehingga belum sepenuhnya merepresentasikan kondisi pengguna secara umum. Selain itu, pendekatan kategorisasi berbasis aturan masih memiliki keterbatasan dalam menggambarkan karakteristik psikologis pengguna secara menyeluruh. Oleh karena itu, pengembangan selanjutnya dapat dilakukan dengan memanfaatkan data dari berbagai platform media sosial, menerapkan pendekatan klasifikasi langsung sebagai pembanding, serta mengintegrasikan data multimodal guna meningkatkan akurasi dan kemampuan generalisasi model.

KESIMPULAN

Berdasarkan hasil penelitian, pendekatan Hybrid Time Series Classification berbasis IndoBERT dan Bidirectional Long Short-Term Memory (Bi-LSTM) terbukti mampu mendeteksi risiko kesehatan mental melalui analisis dinamika sentimen temporal pada data media sosial secara efektif. Proses filtering menggunakan kombinasi keyword matching dan validasi kontekstual berbasis IndoBERT berhasil meningkatkan relevansi data dari 23.644 tweet menjadi 7.266 tweet yang sesuai dengan konteks kesehatan mental. Penerapan teknik balancing melalui kombinasi oversampling dan undersampling juga terbukti meningkatkan kualitas pembelajaran model, yang ditunjukkan oleh peningkatan performa dari accuracy 0,4789 dan F1-score 0,5240 sebelum augmentasi menjadi accuracy, precision, recall, dan F1-score sebesar 1,0000 setelah augmentasi. Selain itu, transformasi data ke dalam bentuk deret waktu yang didukung feature engineering memungkinkan model Bi-LSTM menangkap pola perubahan sentimen secara temporal dan mengklasifikasikan tingkat risiko kesehatan mental ke dalam kategori rendah, sedang, dan tinggi dengan tingkat akurasi yang sangat tinggi. Hasil visualisasi melalui dashboard interaktif juga menunjukkan bahwa model mampu menyajikan informasi risiko kesehatan mental secara dinamis dan informatif. Dengan demikian, integrasi IndoBERT dan Bi-LSTM dalam pendekatan hybrid memberikan kemampuan yang baik dalam memahami konteks bahasa sekaligus dinamika temporal sentimen, sehingga berpotensi mendukung pengembangan sistem pemantauan kesehatan mental berbasis media sosial yang lebih adaptif, representatif, dan berbasis data.

DAFTAR PUSTAKA

- [1] D. Valdez, M. ten Thij, K. Bathina, L. A. Rutter, and J. Bollen, "Social media insights into US mental health during the COVID-19 pandemic: Longitudinal analysis of twitter data," *J. Med. Internet Res.*, vol. 22, no. 12, 2020, doi: 10.2196/21418.
- [2] B. Lim, S. Zohren, and B. Lim, "Time-series forecasting with deep learning: a survey Subject Areas: Author for correspondence ;," no. April, 2026, doi: 10.1098/rsta.2020.0209/248905/rsta.2020.0209.pdf.
- [3] J. Cui, Z. Wang, S. Ho, and E. Cambria, *Survey on sentiment analysis: evolution of research methods and topics*, vol. 56, no. 8. Springer Netherlands, 2023. doi: 10.1007/s10462-022-10386-z.
- [4] M. C. C. Utomo, M. Tauhid, and S. Mujahidin, "Analisis Sentimen Media Sosial Twitter pada Kasus Pemberlakuan Pembatasan Kegiatan Masyarakat dengan menggunakan Metode Naïve Bayes Classifier," *EQUIVA J. J. Math. Inf. Technol.*, vol. 1, pp. 41–48, 2023, doi: 10.35718/equiva.v1i1.815.
- [5] H. Kaur, S. U. Ahsaan, B. Alankar, and V. Chang, "A Proposed Sentiment Analysis Deep Learning Algorithm for Analyzing COVID-19 Tweets," pp. 1417–1429, 2021, doi: 10.1007/s10796-021-10135-7.
- [6] F. Koto and T. Baldwin, "IndoLEM and IndoBERT : A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP," pp. 757–770, 2020, doi: 10.18653/v1/2020.coling-main.66.
- [7] M. C. Kenton, L. Kristina, and J. Devlin, "BERT : Pre-training of Deep Bidirectional Transformers for Language Understanding," pp. 4171–4186, 2019, doi: 10.48550/arXiv.1810.04805.
- [8] P. Haryoko, A. Syukur, and N. Rijati, "Development of a Mental Health Classifier Using LSTM and Text Preprocessing Techniques," vol. 12, no. 1, pp. 77–86, 2025,

- doi: 10.15294/sji.v12i1.21216.
- [9] A. Kolliakou *et al.*, “Mental health-related conversations on social media and crisis episodes : a time-series regression analysis,” pp. 1–7, 2020, doi: 10.1038/s41598-020-57835-9.
- [10] A. P. Ratnasari and R. Nur, “Performance of Random Oversampling , Random Undersampling , and SMOTE-NC Methods in Handling Imbalanced Class in Classification Models,” vol. 12, no. 04, pp. 494–501, 2024, doi: 10.18535/ijsrm/v12i04.m03.
- [11] M. Altalhan, A. Algarni, and M. T. Alouane, “Imbalanced Data Problem in Machine Learning : A Review,” *IEEE Access*, vol. 13, no. December 2024, pp. 13686–13699, 2025, doi: 10.1109/ACCESS.2025.3531662.
- [12] C. Li, K. Liu, and S. Liu, “A Survey of Loss Functions in Deep Learning,” vol. 1, no. 1, pp. 1–50, 2025, doi: 10.3390/math13152417.
- [13] A. Tharwat, “Classification assessment methods,” vol. 17, no. 1, pp. 168–192, 2026, doi: 10.1016/j.aci.2018.08.003.
- [14] D. Chicco and G. Jurman, “The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation,” pp. 1–13, 2020, doi: 10.1186/s12864-019-6413-7.
- [15] A. Kolliakou *et al.*, “Mental health-related conversations on social media and crisis episodes: a time-series regression analysis,” *Sci. Rep.*, vol. 10, no. 1, pp. 1–7, 2020, doi: 10.1038/s41598-020-57835-9.
- [16] A. Agung, G. Wahyu, S. Erlangga, I. G. A. Gunadi, and I. M. G. Sunarya, “Kombinasi Oversampling dan Undersampling dalam Menangani Class Imbalanced dan Overlapping pada Klasifikasi Data Bank Marketing,” vol. 3, no. 1, pp. 32–42, 2024, doi: 10.31598/jurnalresistor.v7i1.1515.
- [17] A. A. Jamali, C. Berger, and R. J. Spiteri, “Momentary Depressive Feeling Detection Using X (Formerly Twitter) Data : Contextual Language Approach Corresponding Author :,” vol. 2, pp. 1–12, 2023, doi: 10.2196/49531.
- [18] V. Cerqueira, L. Torgo, and I. Mozetič, *Evaluating time series forecasting models : an empirical study on performance estimation methods*, vol. 109, no. 11. Springer US, 2020. doi: 10.1007/s10994-020-05910-7.
- [19] Y. Ensafi, S. Hassanzadeh, G. Zhang, and B. Shah, “International Journal of Information Management Data Insights Time-series forecasting of seasonal items sales using machine learning – A comparative analysis,” *Int. J. Inf. Manag. Data Insights*, vol. 2, no. 1, p. 100058, 2022, doi: 10.1016/j.jjime.2022.100058.
- [20] A. Bashar, R. Nayak, and T. Balasubramaniam, “Deep learning based topic and sentiment analysis : COVID19 information seeking on social media,” *Soc. Netw. Anal. Min.*, vol. 12, no. 1, pp. 1–15, 2022, doi: 10.1007/s13278-022-00917-5.