

Prediksi Viralitas Tweet Berbahasa Indonesia Menggunakan IndoBERTweet, RoBERTa, dan *Multi-Layer Perceptron* untuk Optimalisasi Strategi Pemasaran Digital

Deannisa Syafira Putri*¹, Amri Muhaimin², Mohammad Idhom³

¹²³Universitas Pembangunan Nasional “Veteran” Jawa Timur

¹²³Surabaya, Indonesia

Email : ¹122083010062@student.upnjatim.ac.id, ²amri.muhamin.stat@upnjatim.ac.id,
³idhom@upnjatim.ac.id

Abstract

This study aims to predict the virality level of Indonesian-language tweets by integrating textual, sentiment, and numerical features using IndoBERTweet, RoBERTa, and a Multi-Layer Perceptron (MLP) model. IndoBERTweet is employed to generate semantic text representations, RoBERTa to analyze sentiment polarity, and the MLP serves as a classifier that combines all extracted features. The dataset consists of 1,716 promotional tweets from the X platform (27 November 2024–27 May 2025), which after preprocessing and labeling using the Gaussian Mixture Model (GMM), resulted in 1,481 clean and trainable data points. The proposed model achieved strong performance with an accuracy of 96.99%, precision of 96.97%, recall of 96.99%, and an F1-score of 96.97%, demonstrating improvements of 0.32% over Linear SVM and 1.66% over Decision Tree baselines. These findings indicate that integrating semantic representations and sentiment analysis effectively enhances prediction accuracy compared to single-feature approaches, and the model offers practical value for digital marketing practitioners in designing more targeted and potentially viral campaign strategies.

Keywords: Deep learning, IndoBERTweet, MLP, RoBERTa, Tweet Virality Prediction

Abstraksi

Penelitian ini bertujuan memprediksi tingkat viralitas tweet berbahasa Indonesia dengan menggabungkan fitur teks, sentimen, dan numerik melalui model IndoBERTweet, RoBERTa, dan Multi-Layer Perceptron (MLP). IndoBERTweet digunakan untuk menghasilkan representasi semantik, RoBERTa untuk menganalisis polaritas sentimen, dan MLP sebagai klasifikator yang menggabungkan seluruh fitur. Dataset terdiri dari 1.716 tweet promosi pada platform X (27 November 2024–27 Mei 2025), yang setelah pra-pemrosesan dan pelabelan menggunakan Gaussian Mixture Model (GMM) menghasilkan 1.481 data bersih siap latih. Model mencapai performa tinggi dengan akurasi 96,99%, precision 96,97%, recall 96,99%, dan F1-score 96,97%, mencatat peningkatan sebesar 0,32% dibandingkan Linear SVM dan 1,66% dibandingkan Decision Tree. Temuan ini menunjukkan bahwa integrasi representasi semantik dan sentimen secara efektif meningkatkan akurasi prediksi dibandingkan pendekatan tunggal, serta berpotensi membantu praktisi pemasaran digital merancang strategi kampanye yang lebih tepat sasaran dan berpotensi viral.

Kata Kunci: Deep learning, IndoBERTweet, MLP, RoBERTa, Tweet Virality Prediction

1. PENDAHULUAN

Di era digital, perkembangan teknologi informasi dan internet telah mengubah cara masyarakat berinteraksi dan mengonsumsi informasi, termasuk dalam kegiatan pemasaran. Platform digital, seperti media sosial, menjadi ruang strategis bagi perusahaan untuk menjangkau audiens secara cepat dan luas [1] [2]. Salah satu fenomena penting dalam konteks ini adalah “viral”, yaitu penyebaran konten secara masif dalam waktu singkat, yang memberikan peluang besar bagi perusahaan untuk meningkatkan eksposur merek melalui strategi pemasaran berbasis viralitas [3].

Platform X merupakan salah satu media sosial yang banyak digunakan dalam aktivitas pemasaran digital, karena memiliki karakteristik penyebaran informasi yang cepat melalui retweet dan trending topic [4]. Berdasarkan data The Global Statistic, X digunakan oleh 58,30% pengguna internet di Indonesia, menempatkannya sebagai platform keempat paling populer setelah Instagram, Facebook, dan TikTok [5]. Namun, tidak semua konten menarik dapat menjadi viral, karena viralitas dipengaruhi oleh berbagai faktor seperti jumlah pengikut, tingkat engagement (likes, retweet, komentar), serta sentimen dalam teks [6]. Sebagai contoh, sebuah tweet kampanye sosial UNICEF mengenai edukasi vaksin berhasil mencapai puluhan ribu retweet dalam 24 jam akibat pesan emosional positif yang kuat, sedangkan tweet informatif serupa dari akun institusi lain hanya memperoleh sedikit interaksi meskipun memuat topik yang sama [7]. Contoh ini menunjukkan bahwa pola penyebaran konten tidak selalu linier dan sulit diprediksi.

Pendekatan berbasis Machine Learning (ML) dan Deep Learning (DL) dapat digunakan untuk mengatasi tantangan tersebut. ML memungkinkan sistem mempelajari pola dari data historis untuk mengidentifikasi faktor-faktor yang memengaruhi viralitas tweet [8]. Sedangkan DL, sebagai cabang ML, meniru cara kerja sistem saraf manusia, mampu menghasilkan prediksi dengan tingkat akurasi lebih tinggi [9].

Twitter, yang kini dikenal sebagai X setelah diakuisisi oleh Elon Musk pada Oktober 2022, merupakan platform media sosial berbasis microblogging yang diluncurkan pada 2006 oleh Jack Dorsey dan timnya [10]. Platform ini memungkinkan pengguna berbagi opini, berita, dan berinteraksi melalui tweet, hashtag, serta retweet [11], menjadikannya sarana penting untuk penyebaran informasi real-time, promosi, dan diskusi publik.

Meskipun mengalami berbagai perubahan fitur dan kebijakan, X tetap menjadi salah satu platform paling berpengaruh dalam komunikasi digital global [10].

Dalam konteks digital, istilah “viral” merujuk pada konten seperti video, tulisan, atau berita yang menyebar cepat melalui interaksi dan berbagi ulang di media sosial [12]. Fenomena ini memengaruhi strategi komunikasi individu maupun organisasi karena memungkinkan menjangkau audiens yang lebih luas. Berasal dari kata “virus” yang awalnya bermakna negatif, sejak 1990-an istilah ini mengalami pergeseran menjadi simbol penyebaran informasi secara masif di dunia maya [13].

Bidirectional Encoder Representation from Transformers (BERT) merupakan model berbasis transformer yang dilatih menggunakan Masked Language Modeling (MLM) dan Next Sentence Prediction (NSP), lalu disesuaikan melalui proses fine-tuning untuk tugas tertentu. RoBERTa mengembangkan BERT dengan menghapus NSP, menerapkan dynamic masking, serta melakukan pelatihan menggunakan data yang lebih besar sehingga mampu memberikan pemahaman linguistik lebih baik, termasuk pada tugas analisis emosi [14] [15]. Namun, performa RoBERTa sangat dipengaruhi oleh pemilihan hyperparameter seperti learning rate, batch size, dan epoch, sehingga optimasi hyperparameter menjadi penting untuk mencegah overfitting maupun underfitting [16].

IndoBERTweet adalah model pre-trained berbasis transformer yang dirancang khusus untuk Bahasa Indonesia dan dioptimalkan menggunakan data Twitter, sehingga unggul dalam memproses teks informal seperti singkatan dan bahasa gaul [17] [18]. Model ini menggunakan arsitektur encoder BERT berisi 12 lapisan, dilatih dengan teknik Masked Language Modeling (MLM), serta memanfaatkan tokenisasi AutoTokenizer dengan kosakata yang disesuaikan untuk media sosial [19]. Dengan proses fine-tuning dan pemilihan hyperparameter yang tepat, IndoBERTweet menjadi model yang lebih andal untuk berbagai tugas NLP pada teks tidak formal di platform sosial berbahasa Indonesia [17].

Multi-Layer Perceptron (MLP) adalah salah satu metode jaringan syaraf tiruan yang banyak digunakan dalam klasifikasi karena kemampuannya menyesuaikan diri dengan data, menangani noise, memprediksi hubungan antara atribut dan kelas, serta menghitung probabilitas posterior [20]. Sebagai algoritma deep learning dalam kategori feed-forward network, MLP terdiri dari input layer, hidden layer, dan output layer, serta mampu

menyelesaikan masalah linear maupun nonlinear tanpa memerlukan pengetahuan awal. Keunggulan lainnya adalah fleksibilitas implementasi dan kemampuan optimalisasi bobot. Namun, performa MLP sangat bergantung pada elemen-elemen seperti arsitektur jaringan, algoritma pembelajaran, dan fungsi aktivasi, yang biasanya ditentukan melalui proses trial and error karena tidak ada aturan baku untuk konfigurasi ideal [21].

Beberapa penelitian sebelumnya telah dilakukan untuk memprediksi viralitas di media sosial dengan berbagai pendekatan. Ringkasan dari penelitian terdahulu yang dijadikan acuan dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu

No.	Profil Pustaka	Metode dan Temuan
1.	<i>Prediction of Social Media Virality Through Stacking Ensemble Utilising ML Algorithms</i> (2025). Penulis: Upasana Adhikari, Subir Gupta, Joyjit Patra, Bibhuti Bhusan Dash, Subrata Chowdhury, Sudhansu Shekhar Patra [22].	Penelitian ini mengusulkan model <i>stacking ensemble</i> yang menggabungkan Random Forest, XGBoost, dan Logistic Regression untuk mengatasi kompleksitas serta ketidakseimbangan data interaksi pengguna. Dengan kombinasi teknik <i>bagging</i> , <i>boosting</i> , dan <i>probabilistic calibration</i> , model ini mencapai akurasi 95%, <i>F1-score</i> 98%, serta ROC-AUC 92%, menunjukkan efektivitas pendekatan <i>ensemble</i> dalam meningkatkan akurasi dan interpretabilitas prediksi viralitas konten. Namun, model ini masih memiliki kekurangan berupa ketergantungan pada tuning hiperparameter, komputasi tinggi, dan kurangnya generalisasi lintas platform.
2.	<i>Measuring and Detecting Virality on Social Media: The Case of Twitter's Viral Tweets Topic</i> (2023). Penulis: Tuğrulcan Elmas, Stephane Selim, Célia Houssiaux [23].	Penelitian ini membahas prediksi viralitas konten di platform X dengan menggunakan 1.008 <i>tweet</i> viral dan membandingkan model DL seperti BERTBase, RoBERTa, TinyBERT, dan BERTweet. Hasilnya, BERTweet menunjukkan performa terbaik dengan <i>F1-score</i> 0.793, terutama saat ditambah fitur sentimen, media, dan verifikasi. Namun, penelitian ini terbatas pada dataset kecil, tidak membandingkan dengan metode ML tradisional, dan belum mempertimbangkan faktor emosional dalam isi <i>tweet</i> .
3.	<i>Predicting Popularity of Viral Content in Social Media through a Temporal-Spatial Cascade Convolutional Learning Framework</i> (2023). Penulis : Zhixuan Xu dan Minghui Qian [24].	Penelitian ini mengusulkan model ViralGCN berbasis <i>Graph Neural Network</i> (GNN) untuk memprediksi popularitas konten media sosial melalui analisis hubungan spasial dan temporal dalam grafik penyebaran informasi. Menggunakan dataset Sina Weibo dan metrik MSLE, model ini terbukti lebih akurat dibandingkan metode sebelumnya seperti DeepCas dan DeepHawkes. Meskipun efektif dalam mengidentifikasi pola penyebaran dan tipe pengguna,

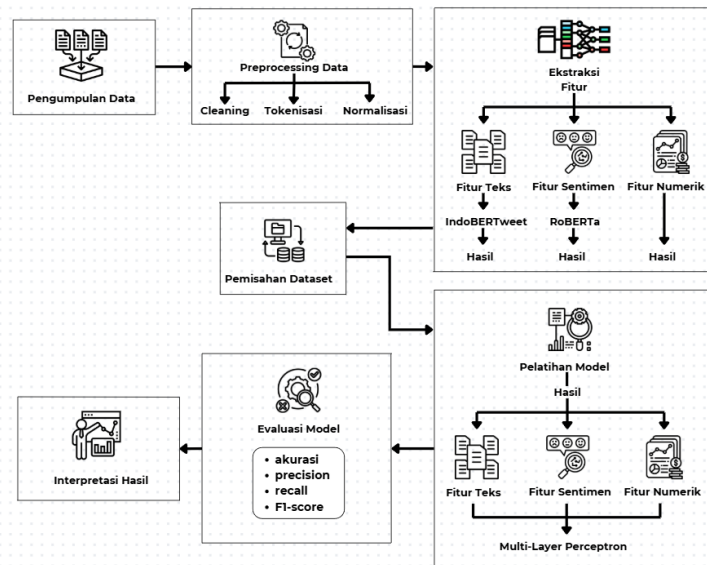
No.	Profil Pustaka	Metode dan Temuan
		penelitian ini masih terbatas pada satu platform dan belum mempertimbangkan faktor konten atau sentimen.
4.	<i>How Do Sentiments Affect Virality on Twitter</i> (2025). Penulis: Salud María Jiménez-Zafra, Antonio José Sáez-Castillo, Antonio Conde-Sánchez and María Teresa Martín Valdivia [25].	Penelitian ini menganalisis pengaruh sentimen terhadap tingkat <i>retweet</i> menggunakan model regresi <i>Generalized Waring</i> (GW) pada 46.962 <i>tweet</i> terkait referendum Catalonia 2017. Dengan membandingkan tiga kamus leksikal sentimen (iSOL, ML-SentiCon, dan NRC), hasilnya menunjukkan bahwa kata bernuansa negatif meningkatkan viralitas, sedangkan kata positif menurunkannya, dengan iSOL menjadi kamus paling akurat. Namun, penelitian ini terbatas pada konteks politik dan belum menerapkan model pembelajaran mesin modern.
5.	<i>ViralBERT: A User Focused BERT-Based Approach to Virality Prediction</i> (2022). Penulis: Rikaz Rameez, Hossein A. Rahmani, Emine Yilmaz [26].	Penelitian ini membahas prediksi viralitas <i>tweet</i> di platform X dengan menggunakan 330.000 <i>tweet</i> dan menggabungkan fitur konten, pengguna, serta sentimen dalam model berbasis BERT. Model ini meningkatkan performa hingga 13% dibanding <i>baseline</i> terbaik dengan <i>F1-score</i> 0.523, di mana sentimen dan jumlah pengikut menjadi faktor paling berpengaruh terhadap viralitas <i>tweet</i> .

Penelitian-penelitian pada Tabel 1 menunjukkan hasil yang menjanjikan, tetapi masih terdapat keterbatasan studi yang sering kali menggunakan dataset tidak seimbang, mengabaikan faktor kontekstual, dan belum teroptimasi untuk Bahasa Indonesia. Oleh karena itu, penelitian ini bertujuan memprediksi viralitas tweet berbahasa Indonesia dengan mengadaptasi pendekatan ViralBERT [26], yaitu menggabungkan IndoBERTweet untuk representasi semantik, RoBERTa untuk analisis sentimen, dan fitur numerik ke dalam arsitektur Multi-Layer Perceptron (MLP). Metode ini menggunakan supervised learning untuk menangkap pola kompleks dan meningkatkan akurasi prediksi agar lebih relevan dengan dinamika pengguna lokal.

Berdasarkan urgensi tersebut, penelitian ini bertujuan mengembangkan model prediksi viralitas tweet berbahasa Indonesia dengan memanfaatkan kombinasi IndoBERTweet, RoBERTa, dan Multi-Layer Perceptron. Model ini diharapkan dapat membantu perusahaan memperkirakan potensi viral suatu konten sebelum dipublikasikan, sehingga strategi pemasaran digital dapat dirancang lebih efektif, terukur, dan sesuai dinamika perilaku audiens pada media sosial.

2. METODE PENELITIAN

Penelitian ini mengikuti delapan tahapan utama secara sistematis, yaitu pengumpulan data, pra-pemrosesan, ekstraksi fitur, pembagian dataset, pelatihan model, evaluasi model, dan interpretasi hasil, sebagaimana ditunjukkan pada Gambar 1. Berikut adalah penjelasan masing-masing dari tahapan penelitian ini.



Gambar 1. Diagram Alir Penelitian

Berdasarkan Gambar 1, penelitian ini dimulai dengan data penelitian yang dikumpulkan melalui *web scraping* menggunakan Tweet Harvest berdasarkan kata kunci “promo OR sale OR diskon OR flash sale” pada *tweet* berbahasa Indonesia dalam periode 27 November 2024–27 Mei 2025. Proses *scraping* menghasilkan 1.716 *tweet* yang memuat teks, tanggal, dan interaksi (*retweet*, *like*, balasan, kutipan). Metadata akun seperti jumlah pengikut, *following*, dan status verifikasi dilengkapi secara manual, sementara fitur tambahan seperti jumlah *hashtag*, *mention*, dan panjang karakter dihitung otomatis. Pada penelitian ini setiap *tweet* diklasifikasikan menjadi tidak viral (0) atau viral (1), dengan tiga jenis fitur utama, yaitu teks (IndoBERTweet), sentimen (RoBERTa), dan numerik (metadata pengguna dan struktur konten). Seluruh fitur digabungkan menjadi satu dataset untuk pelatihan dan evaluasi model prediksi viralitas *tweet* berbahasa Indonesia.

Tahap selanjutnya, yaitu *preprocessing* data meliputi pembersihan, persiapan, dan pelabelan data teks serta numerik agar siap diproses oleh model. Proses ini mencakup pemilihan kolom relevan, penghapusan *tweet* non-Bahasa Indonesia dan non-Inggris, penerjemahan *tweet* berbahasa Inggris, serta pembersihan teks dari URL, simbol, angka,

dan karakter non-alfabet. Selain itu, dilakukan normalisasi emoji, penambahan kolom jumlah *hashtag* dan jumlah mention, serta perhitungan panjang karakter setiap *tweet*.

Selanjutnya, dilakukan proses *labeling* menggunakan *Gaussian Mixture Model* (GMM). Metode ini dipilih untuk mengatasi keterbatasan penggunaan ambang batas (*threshold*) manual yang tidak sesuai dengan karakteristik data penelitian ini. GMM bekerja dengan menganalisis distribusi data secara menyeluruh untuk mengelompokkan *tweet* menjadi dua kelas (viral dan tidak viral) berdasarkan fitur numerik seperti jumlah *hashtag*, *mention*, *followers*, *following*, panjang *tweet*, serta status verifikasi. Setelah proses ini selesai, diperoleh total 1.481 data *tweet* bersih dan terlabel yang siap digunakan untuk tahap pelatihan model. Berikut adalah rumus matematis dari GMM.

$$p(x|\lambda) = \sum_{k=1}^K \pi_k N(x|\mu_k, \Sigma_k) \quad (1)$$

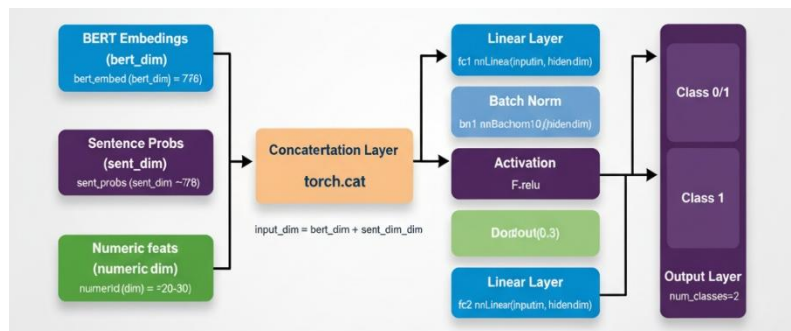
Pada persamaan (1), $p(x|\lambda)$ merepresentasikan probabilitas data x berdasarkan model GMM. Model ini terdiri dari K komponen Gaussian, di mana setiap komponen memiliki bobot π_k yang menunjukkan proporsi kontribusi komponen ke- k dalam campuran. Selain itu, setiap komponen Gaussian dimodelkan menggunakan distribusi normal multivariat $N(x|\mu_k, \Sigma_k)$ yang memiliki parameter mean μ_k dan matriks kovarians Σ_k , sehingga keseluruhan model mampu merepresentasikan distribusi data yang kompleks dan multimodal [27].

Selanjutnya, tahap ekstraksi fitur bertujuan mengambil informasi penting dari *tweet* untuk pelatihan model, mencakup tiga jenis fitur utama, yaitu teks, sentimen, dan numerik. Fitur teks diekstraksi menggunakan IndoBERTweet untuk menghasilkan representasi vektor yang mempertahankan makna semantik, sedangkan fitur sentimen diperoleh melalui RoBERTa yang mengklasifikasikan emosi *tweet* menjadi positif, negatif, atau netral. Fitur numerik meliputi metadata pengguna (*followers*, *following*, status verifikasi) serta struktur *tweet* (jumlah *hashtag*, *mention*, dan panjang karakter). Penggabungan ketiga fitur ini memberikan model pemahaman komprehensif terhadap konteks dan karakteristik *tweet* guna meningkatkan akurasi prediksi viralitas.

Setelah ekstraksi fitur, dataset dibagi menjadi tiga bagian dengan rasio 70:10:20 untuk data latih, validasi, dan uji. Data latih digunakan untuk mengenali pola, data validasi untuk penyetelan parameter dan pencegahan *overfitting*, sedangkan data uji digunakan

mengevaluasi performa model menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Pembagian ini memastikan model belajar efektif dan mampu beradaptasi dengan data baru.

Tahap pelatihan menggunakan model *Multi-Layer Perceptron* (MLP) yang menggabungkan fitur dari IndoBERTweet (teks), RoBERTa (sentimen), dan fitur numerik (jumlah pengikut, *following*, *mention*, *hashtag*, panjang karakter) untuk mempelajari hubungan dengan tingkat viralitas tweet. Pelatihan dilakukan dengan algoritma *backpropagation* dan optimasi AdamW, disertai *hyperparameter tuning* pada jumlah lapisan, neuron, *learning rate*, *batch size*, dan *dropout rate* guna mengoptimalkan akurasi prediksi pada data baru. Gambar 2 menunjukkan arsitektur model MLP yang digunakan.



Gambar 2. Arsitektur MLP yang Digunakan

Arsitektur model yang ditunjukkan pada Gambar 2 terdiri dari tiga komponen utama *input*, yaitu *embedding* teks dari IndoBERTweet, probabilitas sentimen hasil pemrosesan RoBERTa, serta fitur numerik yang merepresentasikan karakteristik pengguna dan *tweet*. Ketiga jenis fitur tersebut digabungkan melalui lapisan *concatenation* sebelum diproses oleh beberapa lapisan *fully connected* pada MLP. Setiap lapisan dilengkapi dengan fungsi aktivasi ReLU untuk memperkenalkan non-linearitas, *batch normalization* untuk menstabilkan distribusi aktivasi selama pelatihan, serta *dropout* untuk mengurangi risiko *overfitting*. Lapisan akhir menghasilkan prediksi tingkat viralitas dalam dua kelas, yaitu viral dan non-viral, berdasarkan pembelajaran pola dari kombinasi representasi teks, sentimen, dan fitur numerik tersebut.

Tahap evaluasi dilakukan untuk mengukur kinerja model prediksi viralitas *tweet* menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. *Precision* menilai ketepatan prediksi *tweet* viral, *recall* mengukur keberhasilan mendeteksi seluruh *tweet* viral yang ada,

dan *F1-score* memberikan keseimbangan antara keduanya. Selain pengukuran metrik, validitas model juga diuji melalui analisis komparatif dengan membandingkan performanya terhadap model *baseline*, yaitu *Linear Support Vector Machine* (Linear SVM) dan *Decision Tree*, guna memastikan efektivitas arsitektur yang diusulkan dibandingkan metode klasifikasi tradisional.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Labeling

Tahap awal penelitian ini diawali dengan hasil proses *labeling data* untuk menentukan tingkat viralitas setiap *tweet*. Proses ini dilakukan menggunakan metode *Gaussian Mixture Model* (GMM) berdasarkan distribusi beberapa fitur numerik, seperti jumlah pengikut, jumlah pengguna yang diikuti, jumlah *retweet*, jumlah *like*, jumlah *hashtag*, jumlah *mention*, dan panjang karakter *tweet*. Melalui pendekatan ini, data berhasil diklasifikasikan ke dalam dua kelompok utama, yaitu *tweet* viral dan non-viral, yang kemudian digunakan sebagai label dasar dalam tahap pelatihan model prediksi. Tabel 1 menunjukkan hasil *labeling data* yang telah dilakukan.


Tabel 1. Rata-rata Fitur dan Jumlah Data Hasil Labeling

Label	Jumlah Data	Rata-rata Followers	Rata-rata Following	Rata-rata Like	Rata-rata Retweet	Rata-rata Verified status	Rata-rata Reply	Rata-rata Quote
Tidak Viral	755	79962	504	1	0	0	0	0
Viral	726	824663	8	1046	432	1	3800	22

Tabel 2 menunjukkan keberhasilan metode *Gaussian Mixture Model* (GMM) dalam memisahkan data *tweet* menjadi dua kelompok (viral dan tidak viral) dengan karakteristik yang sangat kontras, di mana kelompok viral memiliki nilai rata-rata fitur interaksi yang jauh lebih tinggi. Validitas pengelompokan ini diperkuat secara matematis dengan perolehan *Silhouette Score* sebesar 0.6101 dan *Davies-Bouldin Index* sebesar 0.5873, yang mengindikasikan bahwa struktur klaster terbentuk dengan baik dan memiliki separasi yang tegas. Kombinasi bukti statistik dari perbedaan nilai fitur dan metrik evaluasi internal tersebut menegaskan bahwa hasil *labeling* ini valid dan akurat, ditambah dengan distribusi data yang seimbang (755 *tweet* tidak viral dan 726 *tweet* viral) yang ideal untuk proses pelatihan model selanjutnya.

3.2. Hasil *Training* dan Evaluasi Model

Pada tahap ini akan membahas hasil pelatihan dan evaluasi model prediksi viralitas *tweet* yang dibangun menggunakan arsitektur *Multi-Layer Perceptron* (MLP). Proses pelatihan dilakukan dengan menggabungkan fitur teks dari IndoBERTweet, hasil analisis sentimen dari RoBERTa, serta fitur numerik terkait aktivitas pengguna di platform X. Evaluasi dilakukan untuk menilai kemampuan model dalam membedakan *tweet* viral dan tidak viral menggunakan metrik evaluasi (*akurasi*, *precision*, *recall*, dan *F1-score*) dan *comparasion* dengan *baseline model*. Gambar 3 menunjukkan hasil *training model* yang telah dilakukan.



Gambar 3. Grafik Hasil Training Mode


Gambar 3 menunjukkan grafik *training loss* dan *validation loss* selama proses pelatihan model MLP. Terlihat bahwa nilai *loss* pada data pelatihan (*garis biru*) dan data validasi (*garis oranye*) keduanya mengalami penurunan yang konsisten seiring bertambahnya *epoch*, menandakan bahwa model berhasil belajar secara stabil. Perbedaan antara *training loss* dan *validation loss* relatif kecil setelah beberapa *epoch*, yang menunjukkan bahwa model memiliki generalisasi yang baik dan tidak mengalami *overfitting* secara signifikan. Dengan kata lain, model mampu mempelajari pola data dengan efektif tanpa kehilangan kemampuan untuk memprediksi data baru dengan akurat.

Tabel 2. Hasil Evaluasi Model

Model	F1-Score	Precision	Recall	Akurasi
Linear SVM	0.9663	0.9668	0.9667	0.9667
Decision Tree	0.9529	0.9538	0.9533	0.9533
Model Utama	0.9697	0.9697	0.9699	0.9699

Hasil evaluasi pada Tabel 3 menunjukkan bahwa model usulan (Model Utama) berhasil mencatatkan kinerja terbaik dibandingkan seluruh model *baseline*, dengan capaian *F1-score* sebesar 0,9697, *precision* 0,9697, *recall* 0,9699, dan akurasi 0,9699. Performa ini

terbukti lebih unggul dengan peningkatan performa sebesar 0,32% dibandingkan Linear SVM yang memiliki akurasi 0,9667, serta unggul lebih signifikan sebesar 1,66% dibandingkan *Decision Tree* yang tertinggal di angka 0,9533. Keunggulan model utama terhadap metode klasifikasi tradisional ini menegaskan efektivitas arsitektur gabungan IndoBERTweet dan RoBERTa berbasis MLP dalam menangkap pola kompleks pada data. Selain itu, tingginya nilai pada seluruh metrik model utama mengindikasikan stabilitas dan keseimbangan yang optimal antara kemampuan deteksi (*recall*) dan ketepatan prediksi (*precision*) dalam mengklasifikasikan viralitas *tweet*.



Gambar 4. Hasil *Confusion Matrix*

Gambar 4 menunjukkan hasil *confusion matrix* untuk semakin memvalidasi model yang diusulkan, di mana hasilnya menunjukkan bahwa model mampu membedakan *tweet* viral dan tidak viral dengan sangat baik. Dari total data uji, model hanya membuat sedikit kesalahan, 6 prediksi salah pada kelas tidak viral dan 3 pada kelas viral, yang mencerminkan performa klasifikasi yang seimbang dan akurat. Secara keseluruhan, rendahnya jumlah kesalahan ini mendukung tingginya nilai akurasi, *precision*, *recall*, dan *F1-score* pada model.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model prediksi viralitas tweet berbahasa Indonesia melalui integrasi IndoBERTweet, RoBERTa, dan MLP dengan performa tinggi, yaitu akurasi 96,99%, *precision* 96,97%, *recall* 96,99%, dan *F1-score* 96,97%, sehingga secara teoretis menguatkan bahwa kombinasi fitur semantik, sentimen, dan numerik mampu meningkatkan akurasi prediksi. Hasil *confusion matrix* juga menunjukkan stabilitas model dengan hanya 6 kesalahan pada kelas tidak viral dan 3 pada kelas viral. Secara

praktis, model ini dapat digunakan oleh praktisi pemasaran digital untuk mengestimasi potensi viral sebuah tweet sebelum dipublikasikan. Namun, metode labeling menggunakan GMM tanpa ground truth manual menjadi keterbatasan metodologis, dan arsitektur model yang kompleks menimbulkan trade-off berupa interpretabilitas rendah dan kebutuhan komputasi yang tinggi.

5. SARAN

Saran untuk penelitian selanjutnya adalah melakukan validasi labeling berbasis Gaussian Mixture Model dengan melibatkan anotasi manual oleh manusia guna meningkatkan keakuratan dan keandalan label data. Selain itu, penelitian mendatang disarankan untuk mengintegrasikan teknik explainable artificial intelligence, seperti SHAP atau LIME, guna meningkatkan interpretabilitas model tanpa mengorbankan performa prediksi..

DAFTAR PUSTAKA

- [1] C. E. Sitanggang, D. A. Firda, R. Ramadhini, J. M. Panjaitan, Sofwan and M. Sholeh, " Studi Literatur: Penggunaan Media Sosial Sebagai Alat Promosi Usaha," Jurnal Ilmiah Ekonomi Dan Bisnis Universitas Multi Data Palembang, vol. 14, pp. 23-29, 2024.
- [2] A. D. Ade, M. Rizan and I. Febrilia, "PENGARUH AKTIVITAS PEMASARAN MEDIA SOSIAL TERHADAP CITRA MEREK, LOYALITAS MEREK, DAN NIAT BELI ULANG PADA SOCIAL COMMERCE TIKTOK SHOP," Jurnal Masharif al-Syariah: Jurnal Ekonomi dan Perbankan Syariah, vol. 9, no. 4, pp. 2399-2416, 2024.
- [3] L. Agustina, "VIRALITAS KONTEN DI MEDIA SOSIAL," MAJALAH SEMI ILMIAH POPULER KOMUNIKASI MASSA , vol. 1, no. 2, pp. 149-160, 2020.
- [4] M. Febiansyah, Jondri and Indwiarti, "Prediksi Retweet Berdasarkan Konten Dan Pengguna Dengan Metode Classifier Selection," Smart Comp: Jurnalnya Orang Pintar Komputer, vol. 14, no. 1, pp. 123-129, 2025.
- [5] The Global Statistics, "The Global Statistics," The Data Expert, 12 Maret 2025. [Online]. Available: <https://www.theglobalstatistics.com/indonesia-socialmedia-statistics>. [Accessed 3 April 2025].
- [6] M. I. Alfandi, P. Adytia and Wahyuni, "Analisis Sentimen Masyarakat Terhadap Tapera Pada Media Sosial X Menggunakan Metode K-Nearest Neighbor," Sebatik, vol. 28, no. 2, pp. 1-8, 2024.
- [7] D. K. Kowalczyk and L. K. Hansen, "The Complexity of Social Media Response: Statistical Evidence For One-Dimensional Engagement Signal in Twitter," in 12th International Conference on Agents and Artificial Intelligence, Valletta, 2020.
- [8] I. D. Sulistyowati, S. Sunarno and D. Djuniadi, "PENERAPAN MACHINE LEARNING DENGAN ALGORITMA SUPPORT VECTOR MACHINE UNTUK PREDIKSI KELEMBAPAN UDARA RATA-RATA," Just IT : Jurnal Sistem Informasi, Teknologi Informasi dan Komputer, vol. 15, no. 1, pp. 234-324, 2024.

- [9] L. Syafa'ah and M. Lestandy, "Penerapan Deep Learning untuk Prediksi Kasus Aktif Covid-19," *Jurnal Sains Komputer & Informatika (J-SAKTI)*, vol. 5, no. 1, pp. 453-457, 2021.
- [10] K. S. Kinasih and R. P. Mustikasari, "Rebranding "X" dan Brand Loyalty Pengguna," *JIP (Jurnal Ilmiah Ilmu Pendidikan)*, vol. 7, no. 9, pp. 9695-9703, 2024.
- [11] G. Corsi, "Evaluating Twitter's algorithmic amplification of low-credibility content: an observational study," *EPJ Data Science*, vol. 13, no. 18, pp. 1-15, 2024.
- [12] P. Suciati, "FAKTOR PEMBENTUK VIRALITAS PROMOSI MUSISI INDEPENDEN DI MEDIA SOSIAL," *Jurnal Vokasi Indonesia*, vol. 8, no. 1, pp. 12-26, 2020.
- [13] N. Y. Sari and A. R. Kusumawijayanti, "Peran Media Sosial dalam Fenomena Viralitas (Studi Pada Akun Tik Tok @Bundacorlaofficials)," *Perspektif Administrasi Publik dan hukum*, vol. 1, no. 3, pp. 49-58, 2024.
- [14] N. A. R. Putri and Ardiansyah, "Analisis Sentimen Terhadap Kemajuan Kecerdasan Buatan di Indonesia Menggunakan BERT dan RoBERTa," *Jurnal Sains dan Informatika*, vol. 9, no. 2, pp. 137-146, 2023.
- [15] F. Basbeth and D. H. Fudholi, "Klasifikasi Emosi Pada Data Text Bahasa Indonesia Menggunakan Algoritma BERT, RoBERTa, dan Distil-BERT," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 8, no. 2, pp. 1160-1170, 2024.
- [16] E. M. Pusung and I. N. Dewi, "Optimasi RoBERTa dengan Hyperparameter Tuning untuk Deteksi Emosi berbasis Teks," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 10, no. 3, pp. 240-248, 2024.
- [17] J. C. Setiawan, K. M. Lhaksana and Bunyamin, "SENTIMENT ANALYSIS OF INDONESIAN TIKTOK REVIEW USING LSTM AND INDOBERTWEET ALGORITHM," *JIP (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 8, no. 3, pp. 774-780, 2023.
- [18] F. Indriani, R. A. Nugroho, M. R. Faisal and D. Kartini, "Comparative Evaluation of IndoBERT, IndoBERTweet, and mBERT for Multilabel Student Feedback Classification," *JURNAL RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 8, no. 6, pp. 748-757, 2024.
- [19] F. Koto, J. H. Lau and T. Baldwin, "IndoBERTweet: A Pretrained Language Model for Indonesian Twitter with Effective Domain-Specific Vocabulary Initialization," in *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, Punta Cana, 2021.
- [20] D. Pardede, B. H. Hayadi and Iskandar, "KAJIAN LITERATUR MULTI LAYER PERCEPTRON: SEBERAPA BAIK PERFORMA ALGORITMA INI," *Journal of ICT Application and System*, vol. 1, no. 1, pp. 23-34, 2022.
- [21] A. P. Wibawa, W. Lestari, A. B. P. Utama, I. T. Saputra and Z. N. Izdihar, "Multilayer Perceptron untuk Prediksi Sessions pada Sebuah Website Journal Elektronik," *Indonesian Journal of Data and Science (IJODAS)*, vol. 1, no. 3, pp. 57-67, 2020.
- [22] U. Adhikari, S. Gupta, J. Patra, B. B. Dash, S. Chowdhury and S. S. Patra, "Prediction of Social Media Virality Through Stacking Ensemble utilising ML Algorithms," in *2025 6th International Conference for Emerging Technology (INCET)*, Karnataka, 2025.
- [23] T. Elmas, S. Selim and C. Houssiaux, "Measuring and Detecting Virality on Social Media: The Case of Twitter's Viral Tweets Topic," *WWW '23 Companion: Companion Proceedings of the ACM Web Conference 2023*, pp. 314-317, 2023.

- [24] Z. Xu and M. Qian, "Predicting Popularity of Viral Content in Social Media through a Temporal-Spatial Cascade Convolutional Learning Framework," *MDPI mathematics*, vol. 11, no. 14, pp. 1-29, 2023.
- [25] S. M. Jiménez-Zafra, A. J. Sáez-Castillo, A. Conde-Sánchez and M. T. M. Valdivia, "How do sentiments affect virality on Twitter?," *Royal Society Open Science*, vol. 8, no. 4, pp. 1-11, 2021.
- [26] R. Ramees, H. A. Rahmani and E. Yilmaz, "ViralBERT: A User Focused BERT-Based Approach to Virality Prediction," in *UMAP'22 Adjunct*, Barcelona, 2022.