

# Analisis Sentimen dan Pemodelan Topik pada *Post* tentang Merek Teknologi di X Menggunakan *Fine-tuning* IndoBERT dan BERTopic

Muhammad Rayhan Nur<sup>1</sup>, Yudi Wibisono<sup>2</sup>, Rani Megasari<sup>3</sup>

<sup>1,2,3</sup>Fakultas Pendidikan Matematika dan Ilmu Pengetahuan Alam, Ilmu Komputer, Universitas Pendidikan Indonesia, Bandung, Indonesia

Email: <sup>1</sup>m.rayhan.nur@upi.edu, <sup>2</sup>yudi@upi.edu, <sup>3</sup>megasari@upi.edu

(\* Email Corresponding Author: m.rayhan.nur@upi.edu)

Received: July 27, 2025 | Revision: July 27, 2025 | Accepted: July 28, 2025

## Abstrak

Media sosial telah menjadi wadah bagi konsumen untuk menyampaikan persepsi dan opini. Opini yang beredar tersebut berpotensi menjadi sumber data yang berharga bagi *brand*, termasuk Xiaomi, dalam memahami persepsi publik terhadap produk mereka. Penelitian ini bertujuan untuk menganalisis sentimen dan mengidentifikasi topik diskusi pada unggahan (*post*) mengenai merek teknologi Xiaomi di platform X (sebelumnya Twitter) dengan pendekatan berbasis Transformer. Dua metode utama yang digunakan adalah *fine-tuning* IndoBERT untuk model klasifikasi sentimen dan BERTopic untuk pemodelan topik. Data yang berhasil dikumpulkan sebanyak 10.130 *post* dari bulan Mei 2023 hingga Mei 2025 yang dilanjutkan menuju tahapan pra-proses serta pelabelan. Model klasifikasi dilatih dengan berbagai kombinasi konfigurasi *hyperparameter*, dengan hasil pengujian terbaik menghasilkan nilai *accuracy* 79,8%, *precision* 73,0%, *recall* 67,7%, dan *f1-score (macro)* sebesar 0,699. Distribusi sentimen dalam data menunjukkan dominasi sentimen netral, sedangkan BERTopic berhasil menghasilkan 16 *cluster* topik dengan rata-rata nilai *coherence (C<sub>v</sub>)* sebesar 0,5437. Topik paling dominan dengan jumlah anggota *cluster* terbanyak membahas mengenai produk Xiaomi *Series* dan Poco. Sementara itu, topik dengan persentase sentimen negatif tertinggi berkaitan dengan layanan *service center* dan sentimen positif tertinggi mengenai produk komputer tablet (*tab*) Xiaomi. Penggabungan hasil analisis sentimen dan topik memberikan pemahaman yang lebih mendalam terhadap isu yang dibicarakan serta persepsi konsumen. Penelitian ini membuktikan bahwa kombinasi IndoBERT dan BERTopic efektif dalam menganalisis opini konsumen di media sosial serta memberikan wawasan strategis yang relevan bagi perusahaan untuk mengidentifikasi kekuatan dan potensi peningkatan yang dapat dilakukan.

**Kata Kunci:** Media Sosial X, Analisis Sentimen, Pemodelan Topik, IndoBERT, BERTopic

## Abstract

Social media has become a platform for consumers to express their perceptions and opinions. These circulating opinions have the potential to become valuable data sources for brands, including Xiaomi, in understanding public perception of their products. This study aims to analyze sentiment and identify discussion topics in posts about the Xiaomi technology brand on the X platform (formerly Twitter) using a Transformer-based approach. Two main methods were employed: *fine-tuning* IndoBERT for sentiment classification and BERTopic for topic modeling. A total of 10,130 posts were collected from May 2023 to May 2025, followed by preprocessing and labeling stages. The classification model was trained using various combinations of hyperparameter configurations, with the best testing results achieving an accuracy of 79.8%, precision of 73.0%, recall of 67.7%, and a macro F1-score of 0.699. The sentiment distribution in the data showed a dominance of neutral sentiment, while BERTopic successfully generated 16 topic clusters with an average coherence score (*C<sub>v</sub>*) of 0.5437. The most dominant topic discussed Xiaomi Series and Poco products. Meanwhile, the topic with the highest negative sentiment was related to service center issues, and the topic with the highest positive sentiment was about Xiaomi tablet products. The combination of sentiment and topic analysis provides deeper insights into the discussed issues and consumer perceptions. This study demonstrates that the combination of IndoBERT and BERTopic is effective in analyzing consumer opinions on social media and offers strategic insights for companies to identify strengths and areas for improvement.

**Keywords:** Social Media X, Sentiment Analysis, Topic Modeling, IndoBERT, BERTopic

## 1. PENDAHULUAN

Di era digital saat ini, media sosial menjadi wadah untuk menyuarakan pendapat, memberikan kritik, serta membagikan pengalaman [1]. Kemudahan akses dan jangkauan informasi yang luas menjadikan media sosial sebagai sarana untuk memperoleh dan menyebarkan informasi secara cepat dan efisien [2]. Salah satu platform yang populer di Indonesia adalah X (sebelumnya Twitter). X sebagai media sosial berbasis *microblogging* berfokus pada penyampaian pesan melalui konten teks singkat yang mendukung penyebaran informasi secara terbuka, independen, dan *real-time*, serta telah berkembang menjadi salah satu wadah utama dalam komunikasi opini publik [3]. Seiring meningkatnya penggunaan media sosial, konsumen juga semakin aktif menyuarakan opini secara terbuka [4]. Opini konsumen yang tersebar di media sosial tidak hanya mencerminkan pengalaman tetapi juga menjadi sumber data yang berharga bagi perusahaan untuk dapat mengetahui persepsi publik [5] dan meningkatkan kualitas produk atau layanan [6].

Namun, tantangan utama dalam menganalisis opini tersebut adalah karakteristik bahasa yang digunakan di media sosial yang cenderung tidak baku dan sangat beragam [7]. Oleh karena itu, teknologi seperti *Natural Language Processing* (NLP) menjadi pendekatan tepat untuk memproses data teks secara otomatis. NLP merupakan bagian dari kecerdasan buatan (*artificial intelligence*) yang memungkinkan komputer memahami dan mengolah bahasa manusia [8]. Salah satu


penerapan utama NLP adalah analisis sentimen, yaitu mengelompokkan opini ke dalam kategori positif, negatif, atau netral [9], yang bermanfaat untuk mengumpulkan umpan balik dari pelanggan [10].

Selain analisis sentimen, NLP juga dapat digunakan untuk pemodelan topik, yaitu teknik untuk menemukan topik tersembunyi dalam kumpulan dokumen teks yang besar [11]. Pemodelan topik merepresentasikan topik sebagai distribusi kata-kata yang sering muncul bersama dan memungkinkan identifikasi tanpa harus memberikan label atau kategori pada teks tersebut sebelumnya [12]. Perkembangan *deep learning* semakin memperkuat kemampuan NLP dengan memanfaatkan jaringan saraf tiruan (*artificial neural networks*), salah satunya melalui arsitektur Transformer yang memungkinkan pemahaman hubungan kata secara kontekstual [13]. Model seperti BERT (*Bidirectional Encoder Representations from Transformers*) [14] dan BERTopic [15] yang memanfaatkan arsitektur Transformer semakin banyak digunakan dalam task analisis sentimen dan pemodelan topik.

Penelitian-penelitian terdahulu telah menunjukkan efektivitas penggunaan metode berbasis arsitektur Transformer untuk *task* analisis sentimen dan pemodelan topik di media sosial. Sebagai contoh, pemanfaatan BERTopic dan *fine-tuned* BERT pada komentar Reddit berhasil mengidentifikasi 36 topik dan menunjukkan mayoritas sentimen positif terhadap masa depan *artificial intelligence* [16]. Studi lain menggunakan IndoBERT, model bahasa berbasis BERT yang telah disesuaikan khusus untuk menangani teks dalam bahasa Indonesia [17], dan BERTopic untuk menganalisis *tweet* tentang layanan suatu *brand* transportasi *online* dengan akurasi model mencapai 97% dan sebanyak 6 topik berhasil ditemukan [18].

Berdasarkan hal di atas, penelitian ini menggabungkan penerapan analisis sentimen dan pemodelan topik menggunakan pendekatan berbasis arsitektur Transformer, yang diterapkan pada kumpulan *post* mengenai sebuah merek teknologi di media sosial X. Merek yang dipilih sebagai subjek penelitian adalah Xiaomi, karena merupakan salah satu *brand* populer di Indonesia, memiliki basis pengguna yang besar, serta memproduksi berbagai jenis produk. Hal ini membuat Xiaomi berpotensi menghasilkan data yang kaya dan beragam untuk dianalisis. Tujuan dari penelitian ini adalah untuk mengembangkan model klasifikasi sentimen yang akurat serta mengidentifikasi topik-topik yang terkandung, sekaligus menganalisis distribusi sentimen dalam setiap topiknya.

## 2. METODOLOGI PENELITIAN



**Gambar 1.** Alur Tahapan Penelitian

### 2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan kumpulan *post* dari media sosial X yang mengandung kata kunci “xiaomi” atau “xiaomiindonesia” dan memenuhi beberapa kriteria tambahan, seperti berbahasa Indonesia, tidak mengandung tautan, dan bukan merupakan *reply* atau *post* balasan. Proses pengumpulan data menggunakan teknik *web scraping* dengan menggunakan *custom tool* “selenium-twitter-scraper” yang dikembangkan secara *open-source* oleh akun GitHub bernama “godkingjay”. *Tool* ini memanfaatkan *library* Selenium dalam bahasa pemrograman Python. Pengumpulan data dilakukan dari rentang waktu unggah *post* sejak 1 Mei 2023 hingga 31 Mei 2025. Total data yang berhasil dikumpulkan sebanyak 10.130 *post*.

### 2.2 Praproses Data

Langkah pertama praproses data yang dilakukan yakni menghapus data duplikat. Setelah itu, pemilihan data dilakukan untuk menyaring data yang digunakan agar relevan dengan tujuan penelitian. Setelah dilakukan kedua proses tersebut, jumlah data mengalami pengurangan menjadi sebanyak 8.306 baris data yang memenuhi kriteria relevan dan dipertahankan. Kemudian, dilakukan tahapan praproses teks terhadap isi *post* yang terdiri dari beberapa tahap, yaitu mengubah seluruh teks menjadi huruf kecil (*case folding*), menghapus tanda baca dan karakter yang tidak diperlukan (*punctuation removal*), normalisasi kata tidak baku menjadi bentuk yang baku (*slang normalization*), serta menghapus kata-kata umum yang tidak memiliki makna penting (*stopwords removal*).

### 2.3 Pelabelan Data

Proses pelabelan data sentimen dilakukan melalui kombinasi dua pendekatan, yaitu pendekatan otomatis dan manual. Pendekatan otomatis dilakukan dengan memanfaatkan model *pre-trained* “IndoBERT-base-p1” yang telah melalui proses *fine-tuning* menggunakan *dataset* IndoNLU-SmSA [17]. Konfigurasi parameter yang digunakan dalam pelatihan model mencakup *batch size* sebesar 32, *learning rate* sebesar  $2e-5$ , jumlah *epoch* sebanyak 3, *weight decay* sebesar 0,01, serta menggunakan *optimizer* Adam [19]. Model yang telah dilatih tersebut kemudian digunakan untuk

melakukan pelabelan otomatis terhadap data *post* yang belum memiliki label sentimen. Pelabelan dilakukan ke dalam tiga kelas sentimen, yaitu negatif, netral, dan positif. Sebagai bentuk validasi, peneliti juga melakukan pemeriksaan manual terhadap seluruh hasil pelabelan otomatis guna memastikan konsistensi dan ketepatan label yang dihasilkan.

## 2.4 Fine-tuning IndoBERT

Model yang digunakan dalam penelitian ini adalah model *pre-trained* Transformer “IndoBERT-base-p1” yang diperoleh dari situs Hugging Face. Dalam pelatihan model, dilakukan eksplorasi kombinasi beberapa *hyperparameter*, yaitu *batch size*, *learning rate*, dan jumlah *epoch*, untuk mencari konfigurasi terbaik yang menghasilkan performa model paling optimal [14]. Data yang sudah melalui tahap praproses dan pelabelan dibagi menjadi beberapa bagian (subset). Pembagian data pada proses pembangunan model klasifikasi sentimen dilakukan dengan proporsi 80:10:10, yang masing-masing dialokasikan untuk data latih (*training set*), data validasi (*validation set*), dan data uji (*test set*) [18]. Pembagian data dilakukan secara acak dan proporsional menggunakan metode *stratified random sampling*.

## 2.5 Pemodelan Topik menggunakan BERTopic

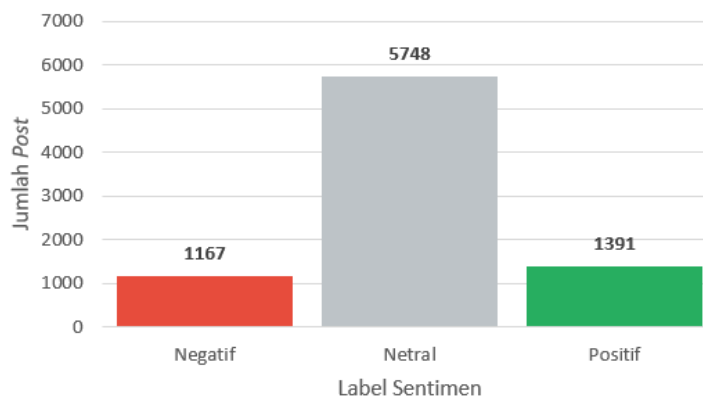
Untuk tahap pemodelan topik pada penelitian ini menggunakan BERTopic. Dalam penelitian ini, eksplorasi difokuskan pada parameter-parameter dari algoritma yang membentuk BERTopic, khususnya UMAP (*n\_neighbors*, *n\_components*, dan *min\_dist*) serta HDBSCAN (*min\_cluster\_size*), dengan tujuan untuk mengoptimalkan jumlah hasil *cluster* topik dan kualitas representasi kata kunci dari masing-masing topik [16].

## 2.6 Evaluasi dan Analisis Hasil

Evaluasi dilakukan untuk mengukur performa model dalam klasifikasi sentimen dan kualitas hasil pemodelan topik. Metrik evaluasi yang digunakan untuk model klasifikasi sentimen adalah *accuracy*, *precision*, *recall*, dan *F1-score*. Untuk *task* pemodelan topik, metrik kuantitatif yang digunakan adalah *coherence score* ( $C_v$ ) [20]. Dalam pengukuran *coherence score* ( $C_v$ ), setiap kata representatif dari suatu topik dibandingkan dengan kata-kata lain dalam topik yang sama untuk menilai sejauh mana pasangan kata tersebut muncul bersama dalam dokumen-dokumen yang sama. Semakin sering pasangan kata tersebut muncul secara bersamaan, maka semakin tinggi nilai *coherence*, yang menunjukkan bahwa topik tersebut memiliki kualitas yang baik [21]. Untuk *task* pemodelan topik, dilakukan juga evaluasi dengan pendekatan kualitatif dengan *human judgement* terhadap kata-kata kunci representatif tiap topik yang dihasilkan untuk memastikan relevansi dan kebermaknaannya. Selanjutnya, dilakukan analisis terhadap hasil yang diperoleh dengan memfokuskan pada interpretasi data serta pembahasan temuan-temuan yang muncul dari penelitian.

# 3. HASIL DAN PEMBAHASAN

## 3.1 Hasil Pelabelan Data



**Gambar 2.** Distribusi Label Sentimen pada *Dataset*

Berdasarkan hasil pelabelan, diperoleh informasi bahwa adanya ketimpangan distribusi jumlah data pada masing-masing kelas sentimen dalam *dataset*. Dari total 8.306 baris data *post*, sekitar 69% diklasifikasikan sebagai sentimen netral terhadap merek Xiaomi. Sementara itu, sekitar 17% menunjukkan sentimen positif, dan sisanya atau sekitar 14% termasuk ke dalam sentimen negatif. Dominasi kelas netral ini mengindikasikan bahwa mayoritas *post* yang dianalisis bersifat informatif atau deskriptif tanpa menyampaikan emosi, opini, atau penilaian tertentu terhadap merek.

## 3.2 Evaluasi dan Analisis Fine-tuning IndoBERT

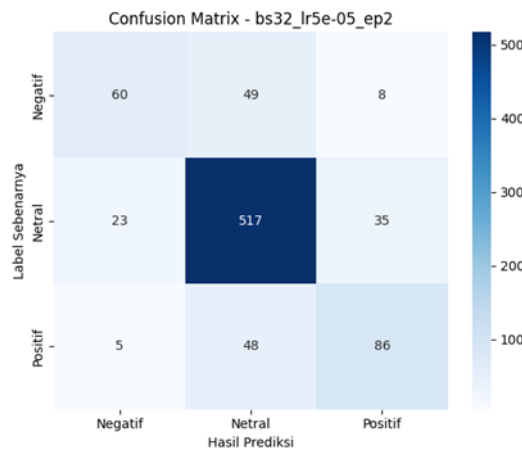
Dalam proses *fine-tuning* model IndoBERT, dilakukan pengujian untuk mencari konfigurasi *hyperparameter* yang paling optimal dengan menggunakan data *test* sebagai dasar evaluasi. Pengujian ini mencakup berbagai kombinasi dari tiga jenis *hyperparameter* utama, yaitu *batch size* dengan nilai 16 dan 32, *learning rate* sebesar  $5e-5$ ,  $3e-5$ , dan  $2e-5$ ,

serta jumlah *epoch* sebanyak 2, 3, dan 4 [14]. Hasil dari pengujian tersebut disajikan secara rinci pada Tabel 1 di bawah ini.

**Tabel 1.** Hasil Evaluasi *Fine-tuning* IndoBERT untuk Klasifikasi Sentimen

<i>Batch Size</i>	<i>Learning Rate</i>	<i>Epoch</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	
16	5e-5	2	0,769	0,689	0,658	0,672	
		3	0,753	0,660	0,646	0,652	
		4	0,768	0,684	0,652	0,667	
	3e-5	2	0,783	0,717	0,664	0,687	
		3	0,758	0,668	0,663	0,665	
		4	0,755	0,660	0,646	0,653	
	2e-5	2	2	0,771	0,698	0,655	0,673
			3	0,773	0,688	0,685	0,687
		3	2	0,771	0,685	0,694	0,689
4			<b>0,798</b>	<b>0,730</b>	<b>0,677</b>	<b>0,699</b>	
4		3	0,759	0,670	0,673	0,671	
		4	0,759	0,668	0,677	0,672	
32	3e-5	2	0,792	0,729	0,673	0,695	
		3	0,770	0,686	0,689	0,687	
		4	0,769	0,686	0,663	0,674	
	2e-5	2	0,779	0,706	0,662	0,681	
		3	0,775	0,693	0,693	0,693	
		4	0,770	0,683	0,677	0,679	

Berdasarkan hasil evaluasi pada data *test* terhadap berbagai skenario kombinasi *hyperparameter* yang ditampilkan pada Tabel 1, model dengan performa terbaik diperoleh pada konfigurasi *batch size* 32, *learning rate* 5e-5, dan jumlah *epoch* sebanyak 2. Pada konfigurasi ini, model berhasil mencapai nilai akurasi sebesar 79,8%, *precision* 73%, *recall* 67,7%, serta *f1-score (macro)* sebesar 0,699.



**Gambar 3.** Hasil *Confusion Matrix* Model Klasifikasi Sentimen Konfigurasi Terbaik

Berdasarkan Gambar 4, model menunjukkan performa terbaik dalam mengklasifikasikan kelas netral, dengan jumlah prediksi benar sebesar 517 dari total data dengan kelas tersebut. Sementara itu, kelas negatif memiliki tingkat kesalahan prediksi yang cukup tinggi, di mana hanya 60 prediksi yang benar dari total 117. Hal serupa juga terjadi pada kelas positif, di mana hanya 86 data yang terklasifikasi dengan benar. Pola ini menunjukkan bahwa model cenderung bias terhadap kelas netral, yang kemungkinan disebabkan karena distribusi label data yang tidak seimbang dalam *dataset*.

### 3.3 Evaluasi dan Analisis Hasil Pemodelan Topik BERTopic

Setelah dilakukan eksplorasi terhadap sejumlah *hyperparameter*, khususnya yang berkaitan dengan UMAP(*n\_neighbors*, *n\_components*, dan *min\_dist*) serta HDBSCAN(*min\_cluster\_size*), diperoleh konfigurasi *hyperparameter* yang dianggap optimal berdasarkan beberapa indikator. Penilaian dilakukan dengan mempertimbangkan jumlah *cluster* topik yang dihasilkan, nilai rata-rata *coherence (C<sub>v</sub>)*, serta kualitas kata-kata kunci representatif dari masing-masing *cluster* berdasarkan pendekatan kualitatif. Konfigurasi *hyperparameter* yang dianggap menghasilkan hasil pemodelan topik paling optimal dalam penelitian ini meliputi *embedding model* menggunakan “all-MiniLM-L6-v2”


(default),  $n\_neighbors$  sebesar 5,  $n\_components$  sebesar 10,  $min\_dist$  sebesar 0,1, dan  $min\_cluster\_size$  sebesar 50 atau sekitar 0.6% dari total jumlah data *post* yang berjumlah 8.306 baris.

**Tabel 2.** Hasil Pemodelan Topik Menggunakan BERTopic dengan Label Interpretasi

ID Cluster	Kata Kunci Representatif	Label Interpretasi	Jumlah Post	Nilai $C_v$
-1	['samsung', 'pro', 'redmi', 'iphone', 'android', 'vivo', 'harga', '12']	- ( <i>outlier</i> )	1211	0,6346
0	['13t', '14', '14t', 'poco', 'ultra', 'bagus', '15', 'harga']	Kualitas dan Harga Produk Xiaomi Series dan Poco	3640	0,4802
1	['pad', 'tab', 'ipad', 'tablet', 'huawei', 'gen', 'matepad', '6s']	Produk Komputer Tablet dan Perbandingan dengan Merek Lain (Apple iPad dan Huawei)	921	0,8013
2	['samsung', 'oppo', 'bagus', 'ui', 'vivo', 'iklan', 'guys', 'a55']	Perbandingan Tampilan UI dengan Merek Lain	344	0,3887
3	['band', 'watch', 'smartwatch', 'huawei', 'smart', 'active', 'smartband', 'strap']	Perbandingan Produk <i>Smartband</i> dengan Merek Huawei	344	0,8285
4	['foto', 'video', 'camera', 'kamera', 'fotografi', 'hilang', 'ultra', 'iklan']	Kualitas Kamera Produk Xiaomi	307	0,2847
5	['note', 'redmi', 'pro', '13', '5g', '12', '10', '11']	Produk Redmi Note & Note Pro	307	0,8629
6	['iphone', 'samsung', 'apple', 'nokia', 'oppo', 'android', 'phone', '15']	Perbandingan dengan Merek Lain	270	0,6657
7	['charger', 'charging', 'fast', 'orisinal', 'kabel', 'charge', 'powerbank', 'battery']	Kemampuan Pengisian Baterai	213	0,5561
8	['vacuum', 'robot', 'earphone', 'headset', 'buds', 'lagu', 'earbuds', 'sound']	Produk Audio dan Vacuum Xiaomi	158	0,3487
9	['tv', 'remote', 'lcd', 'ac', 'instagram', 'tcl', 'smart', '4k']	Perbandingan Produk TV dan AC dengan Merek Lain (TCL)	149	0,3469
10	['service', 'center', 'baterai', 'servis', 'wifi', 'batre', 'centernya', 'data']	Pelayanan <i>Service Center</i> dan Keluhan	145	0,4685
11	['hyperos', 'hyper', 'update', 'os', 'miui', '20', 'boros', 'habis']	Sistem Operasi HyperOS dan Keluhan	99	0,6194
12	['smartphone', 'poco', 'phone', 'harga', 'persaingan', 'penggemar', 'dapatkan', 'salah']	Diskusi Harga Pasar Produk Poco	76	0,4096
13	['samsung', 's23', 's24', 'iphone', 'galaxy', 'ultra', 'fe', '14t']	Perbandingan Produk 14t dengan <i>Flagship</i> Merek Lain	66	0,7836
14	['monitor', 'fancam', 'aoc', 'bagus', 'kacamata', '100hz', 'html', 'konser']	Produk Monitor dan Aksesoris	56	0,2229
<b>Rata-Rata</b>				<b>0,5437</b>

Berdasarkan Tabel 2, diperoleh informasi bahwa pemodelan topik menggunakan BERTopic dengan konfigurasi *hyperparameter* yang telah disebutkan sebelumnya berhasil mengelompokkan data ke dalam 16 *cluster* topik yang berbeda (termasuk *outlier*). Setiap *cluster* mewakili kumpulan *post* dengan kemiripan topik yang terkandung melalui kata kunci representatifnya, yang kemudian dianalisis dan diinterpretasikan oleh peneliti. Proses interpretasi dilakukan dengan mengkaji kata-kata kunci representatif yang muncul pada masing-masing *cluster*, sehingga diperoleh label interpretasi yang bersifat deskriptif agar analisis dan pembahasan lebih mudah dipahami. Rata-rata nilai *coherence* ( $C_v$ ) yang diperoleh dari seluruh *cluster* mencapai 0,5437, yang menunjukkan bahwa kualitas topik yang terbentuk secara keseluruhan cukup baik. Adapun *cluster* yang paling dominan atau dengan jumlah *post* terbanyak, adalah *cluster* dengan ID 1 yang diberi label interpretasi “Kualitas dan Harga Produk Xiaomi Series dan Poco”. Sementara itu, *cluster* dengan nilai koherensi tertinggi berada pada *cluster* ID 5, dengan nilai  $C_v$  sebesar 0,8629, yang mewakili topik terkait “Produk Redmi Note & Note Pro”. Namun, perlu menjadi catatan bahwa masih terdapat sejumlah besar *post* yang dikategorikan

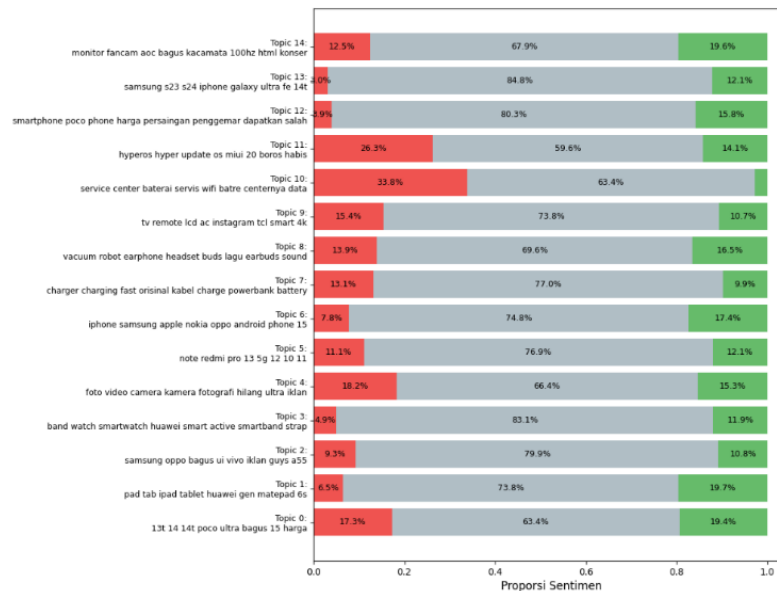
sebagai *outlier*, yaitu sebanyak 1.211 data *post* atau sekitar 14,58% dari total keseluruhan data. Kondisi ini berpotensi menyebabkan hilangnya informasi yang berharga, mengingat *post* yang tidak termasuk dalam *cluster* mana pun dapat memuat topik-topik yang sebenarnya relevan tetapi tidak teridentifikasi oleh model.



**Gambar 4.** Grafik Jumlah *Post* per Bulan untuk 5 *Cluster* Topik Terdominan

Berdasarkan grafik jumlah *post* per bulan dari Mei 2023 hingga Mei 2025 untuk lima *cluster* topik terdominan (berdasarkan jumlah anggota *cluster* terbanyak) pada Gambar 4, terlihat bahwa topik dengan *Cluster ID* 0, yaitu mengenai “Kualitas dan Harga Produk Xiaomi Series dan Poco”, secara konsisten mendominasi jumlah *post* dibandingkan *cluster* lainnya. Lonjakan signifikan dalam jumlah *post* untuk topik ini terjadi pada bulan Maret dan Oktober, yang kemungkinan besar disebabkan oleh jadwal perilisn produk baru dari “Xiaomi Series” pada periode tersebut, sehingga menarik perhatian dan tanggapan dari pengguna di media sosial X. Sebaliknya, penurunan aktivitas terlihat pada bulan Februari, yang dapat diinterpretasikan sebagai masa jeda sebelum peluncuran produk berikutnya yang berdampak pada berkurangnya jumlah *post* terkait topik tersebut. Pola ini menunjukkan bahwa antusiasme publik terhadap topik ini bersifat musiman dan berkorelasi dengan agenda peluncuran produk. Sementara itu, topik dengan *Cluster ID* 1 yang membahas mengenai “Produk Komputer Tablet dan Perbandingan dengan Merek Lain (Apple iPad dan Huawei)” konsisten berada di posisi kedua tertinggi, meskipun perbedaan jumlah *post* yang jauh dengan *Cluster ID* 0.

### 3.4 Analisis Distribusi Sentimen Setiap *Cluster* Topik



**Gambar 5.** Distribusi Persentase Sentimen per *Cluster* Topik

Berdasarkan hasil visualisasi distribusi persentase sentimen pada setiap *cluster* topik hasil pemodelan pada Gambar 5, dapat dilihat persentase tiap sentimen untuk setiap *cluster* topiknya. Topik dengan persentase sentimen netral tertinggi ditemukan pada topik dengan *Cluster ID* 13, yaitu sebesar 84,8% dari total dokumen (*post*) pada *cluster* tersebut. Topik ini membahas perbandingan produk *flagship* Xiaomi dengan merek lain, khususnya Samsung dan Apple. Tabel 3 di bawah ini menyajikan contoh *post* pada *cluster* tersebut.

**Tabel 3.** Contoh *Post* pada *Cluster* Topik dengan Persentase Sentimen Netral Tertinggi

Isi Post	Label Sentimen	Cluster ID
Guysss saran dong, hp ku xiaomi 13t, pngn upgrade mending ke samsung s23 ultra atau ip 15 basic?	Netral	13
help lebih worth it samsung a55 apa xiaomi 14t	Netral	13
Beli Xiaomi 14 atau Samsung Galaxy S23 bekas ya? Bingung soalnya duitnya belum ada	Netral	13

Selanjutnya, topik dengan persentase sentimen negatif tertinggi ditemukan pada topik dengan *Cluster* ID 10, dengan nilai sebesar 33,8% dari total *post* di *cluster* tersebut. Topik ini berisi diskusi mengenai layanan *service center* Xiaomi, termasuk berbagai keluhan pengguna. Dominasi sentimen negatif dalam topik ini menunjukkan adanya persepsi negatif yang cukup kuat dari konsumen terkait kualitas layanan purna jual, yang dapat menjadi perhatian penting bagi perusahaan dalam meningkatkan kepuasan pelanggan. Tabel 4 di bawah ini menyajikan contoh *post* pada *cluster* tersebut.

**Tabel 4.** Contoh *Post* pada *Cluster* Topik dengan Persentase Sentimen Negatif Tertinggi

Isi Post	Label Sentimen	Cluster ID
Service center xiaomi kenapa jelek banget ya sumpah butut bikin orang kesel terus, pelayanan super burukk	Negatif	10
setelah banyak baca komplain service resmi xiaomi yang waw waw waw, jadi ragu deh pengen beli lagi	Negatif	10
Bobrok banget Informasi dari service center Bekasi awalnya hanya 4-5 hari tapi udah 2 minggu statusnya masih "menunggu suku cadang dari pusat". YANG BENER AJA 2 MINGGU? Kecewa banget. Gak profesional, merugikan waktu saya dan nanti harus bayar sesuai harga awal? @XiaomiIndonesia	Negatif	10

Sementara itu, proporsi persentase sentimen positif tertinggi terdapat pada topik dengan *Cluster* ID 1, yakni sebesar 19,7% dari total *post* di *cluster* tersebut. Topik ini berfokus pada diskusi terkait produk komputer tablet Xiaomi termasuk perbandingannya dengan merek kompetitor lain, seperti Apple dan Huawei. Kehadiran sentimen positif yang lebih dominan dibandingkan sentimen negatif pada topik ini menunjukkan bahwa konsumen memiliki pandangan yang cenderung apresiatif terhadap produk Xiaomi dalam kategori komputer tablet. Tabel 5 di bawah ini menyajikan contoh *post* pada *cluster* tersebut.

**Tabel 5.** Contoh *Post* pada *Cluster* Topik dengan Persentase Sentimen Positif Tertinggi

Isi Post	Label Sentimen	Cluster ID
pngen beli xiaomi pad se deh	Positif	1
Xiaomi pad 7 menggoda banget	Positif	1
tab xiaomi pad 6 oke buat jangka panjang ga ya kira-kira, kok banyak yang bilang bagus huawei matepad 11.5, tapi dari speknya oke xiaomi	Positif	1

## 4. KESIMPULAN

Penelitian ini menunjukkan bahwa mayoritas sentimen dalam data *post* berbahasa Indonesia mengenai merek Xiaomi di platform X dalam kurun waktu unggahan Mei 2023 hingga Mei 2025 bersifat netral (69%), dengan model klasifikasi sentimen terbaik menggunakan *fine-tuning* IndoBERT mencapai akurasi 79,8% serta *f1-score (macro)* sebesar 0,699. Sementara itu, pemodelan topik menggunakan BERTopic berhasil mengidentifikasi 16 *cluster* topik (termasuk *outlier*) dengan nilai rata-rata *coherence (C<sub>v</sub>)* sebesar 0,5437. Ditemukan informasi bahwa *cluster* topik paling dominan (dengan jumlah *post* terbanyak) mengenai “Produk Xiaomi *Series* dan *Poco*”, serta *cluster* topik dengan nilai *coherence (C<sub>v</sub>)* tertinggi membahas mengenai “Produk Seri *Redmi Note* dan *Pro*”. Hal ini menunjukkan bahwa model mampu menghasilkan kata kunci representatif yang relevan untuk *cluster* tersebut serta menangkap keterkaitan antar kata yang sering muncul bersamaan dalam dokumen yang sama. Penggabungan analisis sentimen dan topik mengungkap bahwa isu layanan purna jual Xiaomi memiliki persepsi negatif yang signifikan, sementara produk komputer tablet (*tab*) menunjukkan persentase sentimen positif tertinggi. Pendekatan gabungan ini efektif untuk menggali persepsi konsumen dan dapat dimanfaatkan sebagai dasar pengambilan keputusan oleh *brand* untuk mengidentifikasi lini yang menjadi kekuatan serta kelemahan yang perlu untuk ditingkatkan. Untuk pengembangan penelitian di masa mendatang, disarankan untuk meningkatkan jumlah data pelatihan. Selain itu, apabila distribusi label dalam data tidak seimbang, perlu diterapkan teknik penyeimbangan data (*data balancing*) agar model tidak bias terhadap kelas mayoritas. Penelitian selanjutnya juga dapat melakukan perbandingan kinerja dengan beberapa model *pre-trained* Transformer lainnya guna menambah variasi skenario penelitian dan memperoleh model yang lebih optimal. Di sisi lain, pendekatan alternatif dalam pemodelan topik juga patut dipertimbangkan, seperti menerapkan pemodelan topik secara terpisah pada masing-masing kelompok

sentimen (positif, netral, dan negatif). Pendekatan ini dapat memberikan hasil topik yang lebih fokus untuk setiap kelompok sentimen, sehingga dapat memperkaya pemahaman terhadap persepsi konsumen.

## REFERENCES

- [1] F. W. Umbara, "User Generated Content di Media Sosial Sebagai Strategi Promosi Bisnis," *J. Manaj. Strateg. dan Apl. Bisnis*, vol. 4, no. 2, hal. 572–581, 2021, [Daring]. Tersedia pada: <http://ejournal.imperiuminstitute.org/index.php/JMSAB/article/view/366>.
- [2] A. Zaini, R. Patrajaya, W. Noor, dan M. Iksannudin, "Optimalisasi Penggunaan Media Sosial dalam Meningkatkan Efektivitas dan Aksesibilitas Penyebaran Informasi di KUA Kecamatan Jekan Raya," *J. Ilm. Pengabd. Kpd. Masy.*, vol. 4, no. 2, hal. 86–95, 2024, [Daring]. Tersedia pada: <https://ejournal.iain-manado.ac.id/index.php/nyiuur/article/view/1165>.
- [3] J. Zhao, H. He, X. Zhao, dan J. Lin, "Modeling and simulation of microblog-based public health emergency-associated public opinion communication," *Inf. Process. Manag.*, vol. 59, no. 2, hal. 102846, 2022, [Daring]. Tersedia pada: <https://www.sciencedirect.com/science/article/pii/S0306457321003186>.
- [4] N. Kusumawati, A. T. Suhandi, dan M. S. Purwanegara, "Why do customers decide to complain on social media? And how to produce customer forgiveness," *Rev. Integr. Bus. Econ. Res.*, vol. 13, no. 3, hal. 235–254, 2024, [Daring]. Tersedia pada: [http://gmp-riber.com/uploads/3/4/9/8/34980536/riber\\_13-3\\_17\\_s23-084\\_235-254.pdf](http://gmp-riber.com/uploads/3/4/9/8/34980536/riber_13-3_17_s23-084_235-254.pdf).
- [5] A. Giachanou dan F. Crestani, "Opinion retrieval in Twitter using stylistic variations," in *Proceedings of the 31st Annual ACM Symposium on Applied Computing*, 2016, hal. 1077–1079, [Daring]. Tersedia pada: <https://dl.acm.org/doi/abs/10.1145/2851613.2851922>.
- [6] J. Qi, Z. Zhang, S. Jeon, dan Y. Zhou, "Mining customer requirements from online reviews: A product improvement perspective," *Inf. Manag.*, vol. 53, no. 8, hal. 951–963, 2016, [Daring]. Tersedia pada: <https://www.sciencedirect.com/science/article/pii/S0378720616300581>.
- [7] M. Arsanti dan L. N. Setiana, "Pudarnya Pesona Bahasa Indonesia di Media Sosial (Sebuah Kajian Sociolinguistik Penggunaan Bahasa Indonesia)," *Ling. Fr. J. Bahasa, Sastra, dan Pengajarannya*, vol. 4, no. 1, hal. 1–12, 2020, [Daring]. Tersedia pada: <https://journal.um-surabaya.ac.id/lingua/article/view/4314>.
- [8] D. Sulistyono, F. Ahda, dan V. A. Fitria, "Epistemologi dalam Natural Language Processing," *J. Inov. Teknol. dan Edukasi Tek.*, vol. 1, no. 9, hal. 652–664, 2021, doi: 10.17977/um068v1i92021p652-664.
- [9] M. F. Çelikutü, "Twitter sentiment analysis, 3-way classification: positive, negative or neutral?," in *2018 IEEE international conference on big data (big data)*, 2018, hal. 2098–2103, [Daring]. Tersedia pada: <https://ieeexplore.ieee.org/abstract/document/8621970>.
- [10] K. P. Gunasekaran, "Exploring sentiment analysis techniques in natural language processing: A comprehensive review," *arXiv Prepr. arXiv2305.14842*, 2023, [Daring]. Tersedia pada: <https://arxiv.org/abs/2305.14842>.
- [11] B. V. Barde dan A. M. Bainwad, "An overview of topic modeling methods and tools," in *2017 International Conference on Intelligent Computing and Control Systems (ICICCS)*, 2017, hal. 745–750, [Daring]. Tersedia pada: <https://ieeexplore.ieee.org/abstract/document/8250563/>.
- [12] R. A. Wayasti dan I. Surjandari, "Mining Customer Opinion for Topic Modeling Purpose: Case Study of Ride-Hailing Service Provider," in *2018 6th International Conference on Information and Communication Technology (ICOICT)*, 2018, hal. 305–309, [Daring]. Tersedia pada: <https://ieeexplore.ieee.org/abstract/document/8528751>.
- [13] A. Vaswani et al., "Attention is all you need," *Adv. Neural Inf. Process. Syst.*, vol. 30, 2017, [Daring]. Tersedia pada: <https://proceedings.neurips.cc/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html>.
- [14] J. Devlin, M. W. Chang, K. Lee, dan K. Toutanova, "BERT: Pre-training of deep bidirectional transformers for language understanding," *NAACL HLT 2019 - 2019 Conf. North Am. Chapter Assoc. Comput. Linguist. Hum. Lang. Technol. - Proc. Conf.*, vol. 1, no. Mlm, hal. 4171–4186, 2019, [Daring]. Tersedia pada: <https://aclanthology.org/N19-1423/>.
- [15] M. Grootendorst, "BERTopic: Neural topic modeling with a class-based TF-IDF procedure," 2022, [Daring]. Tersedia pada: <http://arxiv.org/abs/2203.05794>.
- [16] A. Ocal, "Perceptions of the Future of AI on Social Media: A Topic Modeling and Sentiment Analysis Approach," *IEEE Access*, vol. 12, no. December, 2024, doi: 10.1109/ACCESS.2024.3510526.
- [17] B. Wilie et al., "IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding," in *Proceedings of the 1st Conference of the Asia-Pacific Chapter of the Association for Computational Linguistics and the 10th International Joint Conference on Natural Language Processing*, Des 2020, hal. 843–857, [Daring]. Tersedia pada: <https://aclanthology.org/2020.aacl-main.85>.
- [18] N. Mahfudiyah dan A. Alamsyah, "Understanding User Perception of Ride-Hailing Services Sentiment Analysis and Topic Modelling using IndoBERT and BERTopic," *2023 Int. Conf. Digit. Bus. Technol. ICONDBTM 2023*, no. July, hal. 1–6, 2023, doi: 10.1109/ICONDBTM59210.2023.10327320.
- [19] H. Jayadianti, W. Kaswidjanti, A. T. Utomo, S. Saifullah, F. A. Dwiyanto, dan R. Drezewski, "Sentiment analysis of Indonesian reviews using fine-tuning IndoBERT and R-CNN," *Ilk. J. Ilm.*, vol. 14, no. 3, hal. 348–354, 2022, doi: 10.33096/ilkom.v14i3.1505.348-354.
- [20] M. Röder, A. Both, dan A. Hinneburg, "Exploring the space of topic coherence measures," in *Proceedings of the eighth ACM international conference on Web search and data mining*, 2015, hal. 399–408, [Daring]. Tersedia pada: <https://dl.acm.org/doi/abs/10.1145/2684822.2685324>.
- [21] E. Rijcken, "C<sub>v</sub> Topic Coherence Explained," 2023. <https://towardsdatascience.com/cv-topic-coherence-explained-fe70e2a85227/>.