

ANALISIS SENTIMEN KOMUNITAS SEKOLAH TERHADAP KEBIJAKAN *ECO SCHOOL* MENGGUNAKAN MODEL INDOBERT

Mufadhil*, Joko Handoyo

Program Studi Informatika, Sekolah Tinggi Teknologi Ronggolawe Cepu.

*mufadhil16@gmail.com

Jl. Kampus Ronggolawe Blok B No.1 Mentul, Blora, Jawa Tengah, Indonesia.

Article history: Received: 15 March 2026 ; Revised: 25 May 2026; Accepted: 30 June 2026

Abstract

The *Eco School* (Adiwiyata School) *program* is an environmental education policy involving students, teachers, and parents as key stakeholders. The success of this *program* depends heavily on the perceptions of these three groups. This study aims to analyze school community sentiment towards the implementation of the *Eco School* policy using a Natural Language Processing (NLP) approach based on the *IndoBERT* model. A total of 1,000 text data points were collected from social media, educational discussion forums, and open-ended questionnaires, then went through *preprocessing*, manual labeling, and *fine-tuning* stages of the *IndoBERT* model to classify positive, neutral, and negative sentiments. The analysis *results* show a *distribution* of sentiment: positive 65%, neutral 25%, and negative 10%, with a model *accuracy* reaching 91.2%. Positive sentiment is predominantly triggered by creative and practical activities that increase environmental awareness, while negative sentiment is related to the administrative burden on teachers, additional costs for parents, and inconsistencies in *program* implementation. Analysis by group shows significant differences in perception: students tend to be the most positive (78%), while teachers (58%) and parents (55%) are more critical of administrative and financial aspects. These findings confirm the effectiveness of the *transformer* architecture for analyzing Indonesian-language education policy and emphasize the need for a segmented change management approach. The study recommends streamlining administrative systems, ensuring funding transparency, and tailoring communication strategies to the characteristics of each stakeholder group.

Keywords: *Eco School; Sentiment Analysis; Natural Language Processing; IndoBERT; Environmental Education; School Community.*

Abstrak

Program Eco School (Sekolah Adiwiyata) merupakan kebijakan pendidikan lingkungan yang melibatkan siswa, guru, dan orang tua sebagai pemangku kepentingan utama. Keberhasilan *program* ini sangat bergantung pada persepsi ketiga kelompok tersebut. Penelitian ini bertujuan menganalisis sentimen komunitas sekolah terhadap implementasi kebijakan *Eco School* menggunakan pendekatan *Natural Language Processing* (NLP) berbasis model *IndoBERT*. Sebanyak 1.000 data teks dikumpulkan dari media sosial, forum diskusi pendidikan, dan kuesioner terbuka, kemudian melalui tahapan *preprocessing*, pelabelan manual, serta *fine-tuning* model *IndoBERT* untuk klasifikasi sentimen positif, netral, dan negatif. Hasil analisis menunjukkan distribusi sentimen: positif 65%, netral 25%, dan negatif 10%, dengan akurasi model mencapai 91,2%. Sentimen positif dominan dipicu oleh kegiatan kreatif dan praktis yang meningkatkan kesadaran lingkungan, sedangkan sentimen negatif berkaitan dengan beban administrasi guru, biaya tambahan bagi orang tua, dan inkonsistensi implementasi *program*. Analisis per kelompok



menunjukkan perbedaan persepsi yang signifikan: siswa cenderung paling positif (78%), sementara guru (58%) dan orang tua (55%) lebih kritis terhadap aspek administratif dan finansial. Temuan ini mengonfirmasi efektivitas arsitektur *transformer* untuk analisis kebijakan pendidikan berbahasa Indonesia dan menegaskan perlunya pendekatan manajemen perubahan yang *segmented*. Penelitian ini merekomendasikan penyederhanaan sistem administrasi, transparansi pendanaan, serta strategi komunikasi yang disesuaikan dengan karakteristik masing-masing kelompok pemangku kepentingan.

Kata Kunci: *Eco School; Analisis Sentimen; Natural Language Processing; IndoBERT; Pendidikan Lingkungan; Komunitas Sekolah.*


Pendahuluan

Program Eco School atau Sekolah Adiwiyata merupakan inisiatif global yang diadaptasi di Indonesia untuk menanamkan nilai-nilai peduli lingkungan sejak dini. Berasal dari program *Eco-Schools* yang digagas *Foundation for Environmental Education* (FEE), implementasinya di Indonesia sejak 2006 telah mencakup ribuan sekolah dari berbagai jenjang pendidikan. Kebijakan ini melibatkan perubahan perilaku, kurikulum, dan infrastruktur sekolah secara terpadu. Perubahan perilaku mendorong warga sekolah membiasakan diri memilah sampah, menghemat energi, dan menjaga kebersihan. Pada aspek kurikulum, pendidikan lingkungan diintegrasikan ke dalam mata pelajaran melalui pembelajaran berbasis proyek yang aplikatif. Sementara itu, pengembangan infrastruktur hijau seperti taman sekolah, kebun obat, biopori, dan fasilitas pengolahan sampah menjadi bukti nyata komitmen institusi pendidikan terhadap kelestarian lingkungan.

Keberhasilan program sangat bergantung pada persepsi dan partisipasi seluruh pemangku kepentingan sekolah, sebagaimana diilustrasikan pada **Error! Unknown switch argument.** Siswa, guru, dan orang tua merupakan tiga pilar utama yang harus bersinergi. Siswa sebagai agen perubahan, guru sebagai fasilitator dan teladan, serta orang tua sebagai pendukung di rumah. Ketika ketiga kelompok ini memiliki persepsi positif dan berpartisipasi aktif, program akan berjalan efektif dan berkelanjutan, menciptakan budaya peduli lingkungan yang melekat dalam keseharian, bukan sekadar kegiatan seremonial tanpa dampak jangka panjang.

Error! Unknown switch argument. memuat diagram konseptual berbentuk segitiga interaktif dengan latar belakang putih. Di bagian atas tengah terdapat kotak utama berwarna hijau muda dengan judul "*Eco School*" dan ikon sekolah bergambar gedung dengan daun di atasnya. Dari kotak ini, tiga garis panah dua arah berwarna hijau tua menghubungkan ke tiga kotak di bagian bawah yang disusun sejajar secara horizontal. Kotak kiri berwarna biru muda dengan ikon siswa (siluet orang dengan buku) dan teks "Siswa" dengan subteks "Agen Perubahan".

Kotak tengah berwarna oranye muda dengan ikon guru (siluet orang dengan papan tulis) dan teks "Guru" dengan subteks "Fasilitator & Teladan". Kotak kanan berwarna kuning muda dengan ikon orang tua (siluet keluarga) dan teks "Orang Tua" dengan subteks "Pendukung di Rumah". Antar ketiga kotak terdapat garis panah dua arah berwarna abu-abu yang saling menghubungkan, membentuk pola segitiga. Seluruh elemen ini dikelilingi oleh lingkaran putus-putus berwarna hijau yang melambangkan "Ekosistem Sekolah". Garis tepi tebal pada lingkaran menunjukkan batas ekosistem yang menyatukan ketiga pemangku kepentingan.



Gambar 1. Kerangka Interaksi Kebijakan *Eco School*

Analisis sentimen, sebagai cabang dari *Natural Language Processing (NLP)*, menawarkan pendekatan yang ampuh untuk mengevaluasi persepsi ini secara mendalam dan berskala besar. Penelitian terkini menunjukkan efektivitas NLP dalam memahami persepsi publik [1], mengevaluasi umpan balik siswa [2], [3], [4], serta menganalisis sentimen dalam konteks pendidikan [5], [6], [7]. Namun, penerapannya untuk menganalisis sentimen multikomunitas terhadap kebijakan lingkungan di sekolah masih terbatas, terutama dalam konteks Indonesia.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menjawab tiga permasalahan utama. Pertama, bagaimana distribusi sentimen komunitas sekolah yang terdiri dari siswa, guru, dan orang tua terhadap implementasi kebijakan *Eco School*. Kedua, apa saja topik dominan yang menjadi pemicu sentimen positif, netral, dan negatif dari masing-masing kelompok tersebut. Ketiga, bagaimana kinerja model *IndoBERT* dalam mengklasifikasikan sentimen berbahasa Indonesia pada domain kebijakan pendidikan lingkungan. Sejalan dengan rumusan masalah tersebut, penelitian ini memiliki tiga tujuan utama, yaitu memetakan distribusi sentimen komunitas sekolah terhadap implementasi kebijakan *Eco School*, mengidentifikasi dan menganalisis topik-topik utama yang mendasari sentimen dari setiap kelompok, serta mengukur dan mengevaluasi efektivitas model *IndoBERT* dalam tugas analisis sentimen pada teks berbahasa Indonesia di bidang pendidikan.

1. Analisis Sentimen dalam Kebijakan Pendidikan

Analisis sentimen adalah teknik pemrosesan teks untuk mengidentifikasi dan mengkategorikan opini dalam suatu teks, yang bertujuan menentukan sikap penulis terhadap topik tertentu. Dalam konteks kebijakan pendidikan, analisis sentimen memungkinkan pemangku kepentingan untuk mengevaluasi dampak kebijakan secara real-time berdasarkan respons otentik dari komunitas.

2. *IndoBERT* untuk Teks Bahasa Indonesia

IndoBERT merupakan model *pre-trained* berbasis arsitektur *transformer* yang dikembangkan khusus untuk memahami nuansa bahasa Indonesia. Keunggulan *IndoBERT* telah dibuktikan dalam berbagai studi untuk klasifikasi emosi dan sentimen [8], analisis sentimen berbasis aspek pada ulasan siswa [9], [10], evaluasi pembelajaran [11], serta analisis sentimen pada topik lingkungan [12] dan kebijakan pendidikan [13].

Dalam pemrosesan bahasa alami untuk teks berbahasa Indonesia, terdapat beberapa model *pre-trained* yang telah dikembangkan dengan karakteristik dan keunggulan masing-masing. Pemilihan model yang tepat sangat menentukan keberhasilan tugas analisis sentimen. Perbandingan lengkap antar model *pre-trained* untuk bahasa Indonesia disajikan dalam Tabel 1.

Tabel 1. Perbandingan Model Pre-trained Bahasa Indonesia

Model	Parameter	Korpus Training	Akurasi Benchmark	Keunggulan
<i>IndoBERT</i>	125 M	220 GB teks Indonesia	92.3%	Optimal untuk konteks lokal
mBERT	110 M	104 bahasa	88.7%	Multilingual
<i>IndoBERT-lite</i>	45 M	50GB teks Indonesia	89.5%	Ringan, cepat
IndoRoBERTa	125 M	230 GB teks Indonesia	92.8%	Optimasi lebih lanjut

Tabel 1 menyajikan perbandingan komprehensif antara beberapa model *pre-trained* yang tersedia untuk pemrosesan teks berbahasa Indonesia. *IndoBERT* versi base dengan 125 juta parameter dan korpus 220GB teks Indonesia menunjukkan akurasi 92.3%, menjadikannya pilihan optimal untuk menangkap nuansa konteks lokal secara mendalam. Perbandingan ini menjadi dasar justifikasi pemilihan *IndoBERT*-base dalam penelitian ini.

3. Penelitian Terkait

Penelitian tentang analisis sentimen dalam konteks pendidikan telah berkembang pesat dalam beberapa tahun terakhir. Sunar dan Khalid [2] melakukan tinjauan sistematis terhadap penggunaan Natural Language Processing untuk menganalisis umpan balik siswa kepada instruktur, menemukan bahwa teknik NLP mampu mengungkap pola sentimen yang tidak terdeteksi melalui evaluasi konvensional. Sejalan dengan itu, Dake dan Gyimah [3] mendemonstrasikan efektivitas analisis sentimen dalam mengevaluasi respons kualitatif siswa, dengan akurasi mencapai 85% pada data teks berbahasa Inggris. Kastrati dkk. [4] memperluas cakupan dengan pemetaan sistematis terhadap studi-studi yang menggabungkan NLP dan deep learning untuk analisis umpan balik siswa, mengidentifikasi tantangan utama seperti variabilitas bahasa dan kebutuhan akan dataset berlabel berkualitas. Lebih lanjut, Imran dkk. [14] mengintegrasikan machine learning untuk meningkatkan adaptabilitas dan performa akademik, menunjukkan potensi AI dalam transformasi pendidikan.

Dalam konteks pemrosesan bahasa Indonesia, pengembangan model *transformer* telah menjadi fokus utama. Ahmadian dkk. [8] mengembangkan model hibrida untuk klasifikasi emosi dan sentimen dalam bahasa Indonesia, mencapai peningkatan akurasi signifikan dibandingkan pendekatan tradisional. Jazuli dkk. [9] mengaplikasikan *IndoBERT* untuk analisis sentimen berbasis aspek pada ulasan siswa, mampu mengidentifikasi nuansa sentimen terhadap berbagai aspek pembelajaran secara simultan. Nugroho dkk. [11] memanfaatkan *IndoBERT* sebagai alat evaluasi pembelajaran, mengonfirmasi keunggulan model ini dalam menangkap konteks lokal. Octovianto dkk. [12] dan Wafda dkk. [13] masing-masing menerapkan *IndoBERT* pada analisis sentimen topik lingkungan dan kebijakan kurikulum Merdeka, dengan akurasi di atas 90%.

Sementara itu, penerapan NLP untuk evaluasi kebijakan publik mulai mendapat perhatian. Besigomwe [1] melakukan tinjauan sistematis terhadap penggunaan NLP dalam analisis kebijakan pendidikan, menyoroti potensi teknologi ini untuk memberikan umpan balik real-time kepada pembuat kebijakan. Ndubuisi dkk. [6] menganalisis sentimen warga terhadap implementasi kebijakan di Amerika Serikat, sementara Raval [7] mengkaji persepsi publik terhadap kebijakan lingkungan melalui media sosial. Mohod dkk. [15] membahas implikasi etis dan sosial dari penggunaan analisis sentimen dalam sistem umpan balik pendidikan, mengingatkan pentingnya privasi dan transparansi.

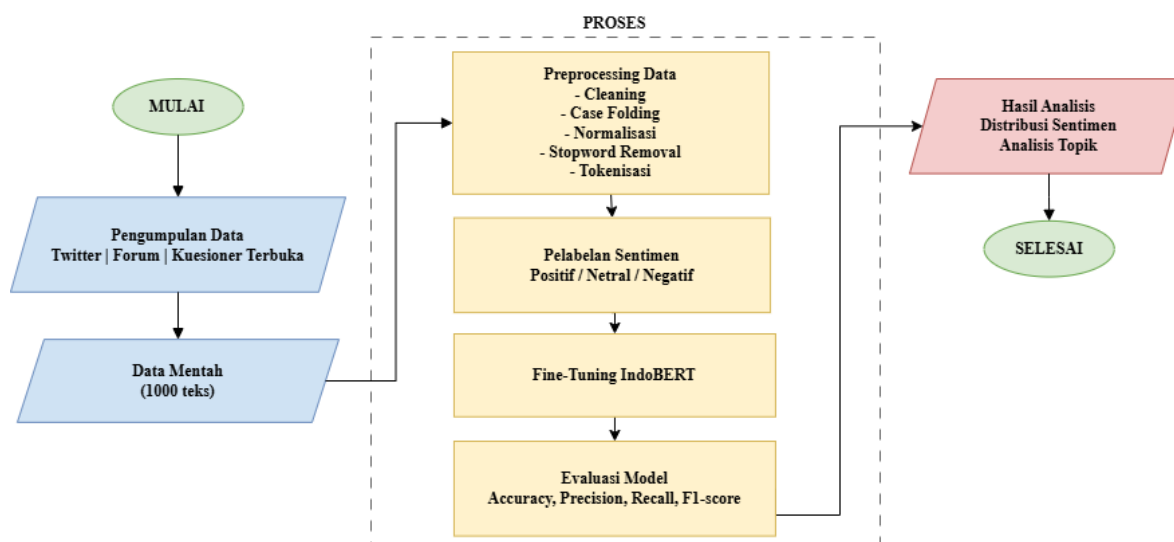
Meskipun penelitian-penelitian tersebut memberikan kontribusi signifikan, masih terdapat kesenjangan dalam analisis senti- men multikomunitas terhadap kebijakan lingkungan di sekolah, khususnya dalam konteks Indonesia. Penelitian ini mengisi ke- senjangan tersebut dengan menganalisis sentimen tiga kelompok pemangku kepentingan—siswa, guru, dan orang tua—terhadap implementasi *program Eco School* menggunakan pendekatan *IndoBERT*.

Metode

Penelitian ini menggunakan pendekatan kuantitatif dengan metode analisis sentimen berbasis *Natural Language Processing* (NLP) untuk mengklasifikasikan opini komunitas sekolah terhadap implementasi kebijakan *Eco School* ke dalam kategori positif, netral, dan negatif. Pendekatan ini dipilih karena memungkinkan pengukuran objektif terhadap ribuan data teks dan memberikan generalisasi yang andal mengenai persepsi komunitas sekolah.

Desain penelitian terdiri atas empat tahapan utama: (1) pengumpulan data dari media sosial, forum diskusi, dan kuesioner terbuka; (2) *preprocessing* data melalui *cleaning*, *case folding*, *normalisasi*, *stopword removal*, dan tokenisasi; (3) pelabelan manual oleh tiga *annotator* terlatih dan *fine-tuning* model *IndoBERT*; serta (4) evaluasi kinerja model menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*, dilanjutkan dengan analisis hasil. Untuk menjamin validitas dan reliabilitas, setiap tahapan menerapkan protokol ketat. Pelabelan menggunakan pedoman terstandar dengan uji *inter-annotator agreement*. *Fine-tuning* menerapkan *stratified sampling* (80% *training*, 10% *validation*, 10% *test*) dan eksperimen hyperparameter untuk memperoleh performa terbaik.

Keseluruhan alur metodologi divisualisasikan pada Gambar 2, yang memudahkan pemahaman keterkaitan antar tahapan. Desain terstruktur ini memastikan hasil penelitian dapat dipertanggungjawabkan secara ilmiah dan direplikasi.



Gambar 2. Diagram Alir Metodologi Penelitian

Gambar 2 menyajikan diagram alir vertikal yang menggambarkan sepuluh tahapan penelitian, dimulai dari "Identifikasi Masalah" hingga "Kesimpulan dan Rekomendasi". Setiap kotak proses dihubungkan oleh panah vertikal berwarna biru, menunjukkan alur penelitian yang sistematis. Pada tahap "Pengumpulan Data", panah bercabang menuju tiga sumber data (media sosial, forum diskusi, dan kuesioner) sebelum bergabung kembali pada kotak "Data Mentah" yang berisi 1.000 teks. Tahap "Preprocessing Data" menampilkan lima sub-proses berurutan: *Cleaning*, *Case Folding*, *Normalisasi*, *Stopword Removal*, dan Tokenisasi. Tahap "Pelabelan Manual" menampilkan distribusi data: Positif (650), Netral (250), dan Negatif (100). Tahap "Fine-Tuning Model IndoBERT" menunjukkan proses dari *pre-trained* model hingga *fine-tuning* dengan data sentimen sekolah. Evaluasi model menggunakan *confusion matrix* dan metrik akurasi, *precision*, *recall*, dan *F1-score*. Analisis hasil mencakup distribusi sentimen, analisis topik, dan perbandingan per kelompok, yang kemudian menjadi dasar penarikan kesimpulan dan rekomendasi.

Pembahasan

1. Pengumpulan Data

Data dalam penelitian ini dikumpulkan dari tiga sumber utama untuk merepresentasikan suara komunitas sekolah secara komprehensif, yaitu media sosial (*Twitter* dan *Instagram*), forum diskusi

pendidikan (grup *WhatsApp* dan forum *online*), serta kuesioner terbuka yang disebarakan kepada siswa, guru, dan orang tua. Total data yang berhasil dikumpulkan adalah 1.000 data teks dengan komposisi berimbang dari ketiga sumber. Ketiga sumber data ini dipilih untuk menangkap spektrum sentimen yang lengkap dari berbagai perspektif dan saluran komunikasi yang berbeda. Contoh data mentah dari masing-masing sumber disajikan dalam Tabel 2.

Tabel 2. Contoh Data Mentah (n = 1.000)

ID	Sumber	Teks	Timestamp
D001	Twitter	"Program eco school di sekolah anakku keren banget! Mereka belajar daur ulang dengan cara yang fun #SekolahHijau"	2023-10-15
D002	Kuesioner	"Saya sebagai guru merasa terbebani dengan tambahan administrasi program eco school"	2023-11-20
D003	Forum	"Pengumuman: besok kerja bakti eco school jam 7 pagi"	2023-09-05

Tabel 2 ini menampilkan tiga contoh data mentah yang merepresentasikan masing-masing sumber data (*Twitter*, kuesioner, dan forum diskusi). Setiap baris mencakup ID unik, sumber data, teks asli sesuai dengan unggahan atau respons responden, serta *timestamp* pencatatan data. Contoh dari *Twitter* menunjukkan sentimen positif dengan penggunaan bahasa informal dan hashtag, sementara contoh dari kuesioner merepresentasikan keluhan guru terkait beban administrasi, dan contoh dari forum bersifat informatif netral mengenai jadwal kegiatan.

2. Preprocessing Data

Tahap *preprocessing* bertujuan untuk meningkatkan kualitas data teks sebelum dilakukan analisis sentimen. Proses ini meliputi *cleaning*, *case folding*, *normalisasi*, *stopword removal*, dan tokenisasi sebagaimana ditunjukkan pada Tabel 3. Pendekatan *preprocessing* yang sistematis ini mengikuti praktik umum dalam literatur analisis sentimen pendidikan [3], [4] dan telah diadaptasi untuk konteks bahasa Indonesia [8].

Tabel 3. Contoh Proses Preprocessing

Tahap	Input	Output
<i>Cleaning</i>	"Program Eco School sangat bermanfaat! Lihat: www.ecosh.edu "	"program eco school sangat bermanfaat"
<i>Case Folding</i>	"Program Eco School Sangat Bermanfaat"	"program eco school sangat bermanfaat"
<i>Normalisasi</i>	"program eco school sangat bermanfaat"	"program eco school sangat bermanfaat"
<i>Stopword Removal</i>	"program eco school sangat bermanfaat"	"program eco school bermanfaat"
<i>Tokenisasi</i>	"program eco school bermanfaat"	["program", "eco", "school", "bermanfaat"]

Tabel 3 ini mengilustrasikan transformasi teks melalui setiap tahap *preprocessing* secara berurutan. Pada tahap *cleaning*, URL dan tag HTML dihapus. *Case folding* mengubah semua huruf menjadi lowercase. *Normalisasi* memperbaiki kata tidak baku (meskipun dalam contoh ini tidak ada perubahan). *Stopword removal* menghilangkan kata-kata umum seperti "sangat". Tokenisasi memecah kalimat menjadi token-token individual yang siap diproses oleh model. Proses ini memastikan data teks bersih dan terstandarisasi sebelum analisis sentimen.

3. Pelabelan Data

Setiap data diberi label sentimen $y \in \{0, 1, 2\}$ dengan 0 = negatif, 1 = netral, 2 = positif. Pelabelan dilakukan secara manual oleh tiga orang *annotator* yang telah diberikan pelatihan dan pedoman anotasi untuk memastikan konsistensi dan akurasi label. Distribusi data hasil pelabelan untuk masing-masing kelas sentimen disajikan dalam Tabel 4.

Tabel 4. Distribusi Data Hasil Pelabelan (n = 1.000)

Kelas Sentimen	Jumlah Data	Persentase	Contoh Kalimat
Positif	650	65%	"Kegiatan menanam pohon sangat menyenangkan"
Netral	250	25%	"Jadwal kerja bakti hari Sabtu"
Negatif	100	10%	"Biaya proyek eco school terlalu mahal"

Tabel 4 ini menyajikan distribusi **1.000 data teks** yang telah melalui proses pelabelan manual oleh tiga *annotator*. Kelas sentimen positif mendominasi dengan **650 data (65%)**, diikuti sentimen netral sebanyak **250 data (25%)**, dan sentimen negatif sebanyak **100 data (10%)**. Setiap kelas disertai contoh kalimat representatif yang menggambarkan karakteristik masing-masing sentimen. Distribusi ini menjadi dasar untuk proses *fine-tuning* model *IndoBERT* dan evaluasi kinerjanya.

4. Model dan Implementasi

Model *IndoBERT* digunakan sebagai model dasar yang di-fine-tune untuk tugas klasifikasi sentimen. Arsitektur dan proses *fine-tuning* mengadaptasi studi-studi terkini [9]₁ [10]₂ [12]₃ [13]₄. Representasi input, proses *hidden state*, dan lapisan klasifikasi dirumuskan sebagai berikut:

$$e_i = E_{\text{tok}}(w_i) + E_{\text{pos}}(i) + E_{\text{seg}}(i) \quad (1)$$

Keterangan:

e_i : vektor *embedding* untuk token ke – i

$E_{\text{tok}}(w_i)$: token *embedding* dari kata w_i

$E_{\text{pos}}(i)$: positional *embedding* pada posisi i

$E_{\text{seg}}(i)$: segment *embedding*

$$h_{[\text{CLS}]} = \text{IndoBERT}([\text{CLS}] + x''')_{[\text{CLS}]} \quad (2)$$

Keterangan:

$h_{[\text{CLS}]}$: representasi hidden state dari token khusus [CLS]

$\text{IndoBERT}(\cdot)$: fungsi encoder *transformer* dari model *IndoBERT*

x' : urutan token hasil preprocessing yang digunakan sebagai input model

$$z = W \cdot h_{[\text{CLS}]} + b \quad (3)$$

Keterangan:

z : vektor skor (logits) untuk setiap kelas sentimen

W : matriks bobot pada layer klasifikasi

b : parameter bias pada layer klasifikasi

$$p(y = k | x) = \frac{e^{z_k}}{\sum_{j=1}^K e^{z_j}} \quad (4)$$

Keterangan:

$p(y = k | x)$: probabilitas bahwa input x termasuk ke kelas k

z_k : skor logit untuk kelas ke – k

K : jumlah total kelas sentimen

$$\hat{y} = \arg \max_{k \in \{1,2,3\}} p(y = k | x) \quad (5)$$

Keterangan:

$\hat{y}$: label sentimen yang diprediksi oleh model

argmax : fungsi yang memilih kelas dengan probabilitas terbesar

$$L = - \sum_{k=1}^K y_k \log(p_k) \quad (6)$$

Keterangan:

L : nilai fungsi kerugian (loss function)

y_k : label sebenarnya dalam bentuk one – hot encoding

p_k : probabilitas prediksi model untuk kelas ke – k

K : jumlah kelas sentimen

Konfigurasi hyperparameter yang digunakan dalam proses *fine-tuning* disajikan dalam Tabel 5.

Tabel 5. Konfigurasi Hyperparameter *Fine-tuning*

Parameter	Nilai	Keterangan
Model Base	<i>IndoBERT</i> -base	12 layer, 768 hidden
<i>Learning Rate</i>	$2e - 5$	Optimal untuk <i>fine-tuning</i>
<i>Batch Size</i>	16	Trade-off memori-kecepatan
<i>Epochs</i>	5	Cegah overfitting
<i>Optimizer</i>	AdamW	Dengan <i>weight decay</i>
<i>Dropout</i>	0.1	Regularisasi
<i>Max Sequence Length</i>	128	Cukup untuk teks pendek

Tabel 5 ini merinci konfigurasi hyperparameter yang diterapkan dalam proses *fine-tuning* model *IndoBERT*-base. Parameter utama meliputi *learning rate* 2e-5 yang optimal untuk *fine-tuning*, *batch size* 16 sebagai trade-off antara memori dan kecepatan komputasi, serta jumlah epoch sebanyak 5 untuk mencegah overfitting. *Optimizer* AdamW digunakan dengan *weight decay*, ditambah *dropout* 0.1 untuk regularisasi. *Max sequence length* 128 ditentukan karena teks yang dianalisis relatif pendek. Konfigurasi ini dipilih berdasarkan studi terkait dan eksperimen awal untuk memperoleh performa model terbaik.

5. Evaluasi Model

Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Metrik ini adalah standar yang digunakan secara luas untuk mengevaluasi kinerja model klasifikasi teks [3], [4], [12].

$$\text{Accuracy} = \frac{\sum \text{TP}}{N} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (7)$$

Keterangan:

Accuracy : tingkat ketepatan model dalam klasifikasi data.

TP (True Positive) : data positif yang diprediksi benar.

TN (True Negative) : data negatif yang diprediksi benar.

FP (False Positive) : data negatif yang salah diprediksi positif.

FN (False Negative) : data positif yang salah diprediksi negatif.

N : jumlah total data evaluasi.

$$\text{Precision}_k = \frac{\text{TP}_k}{\text{TP}_k + \text{FP}_k} \quad (8)$$

Keterangan:

Precision_k : tingkat ketepatan prediksi model untuk kelas ke – k.

TP_k : jumlah data pada kelas ke – k yang diprediksi dengan benar oleh model.

FP_k : jumlah data dari kelas lain yang salah diprediksi sebagai kelas ke – k.

$$\text{Recall}_k = \frac{\text{TP}_k}{\text{TP}_k + \text{FN}_k} \quad (9)$$

Keterangan:

Recall_k : kemampuan model dalam menemukan seluruh data yang benar – benar termasuk kelas ke – k.

TP_k : jumlah data kelas ke – k yang diprediksi dengan benar.

FN_k : jumlah data kelas ke – k yang salah diprediksi sebagai kelas lain.

$$\text{F1}_k = \frac{2 \cdot \text{Precision}_k \cdot \text{Recall}_k}{\text{Precision}_k + \text{Recall}_k} \quad (10)$$

Keterangan:

F1_k : nilai rata – rata harmonik antara precision dan recall untuk kelas ke – k.

Precision_k : tingkat ketepatan prediksi pada kelas ke – k.

Recall_k : tingkat keberhasilan model dalam menemukan seluruh data pada kelas ke – k.

Tabel 6. *Confusion Matrix* Model *IndoBERT* (n = 1.000)

Aktual	Positif	Prediksi	Netral
Positif (n = 650)	605	30	Negatif
Netral (n = 250)	20	215	15
Negatif (n = 100)	5	10	85

Dari *confusion matrix* model *IndoBERT* pada dataset 1.000 data diperoleh nilai-nilai berikut:

Confusion Matrix, dari Tabel 6:

Total data (N) = 1.000

True Positif (TP) = 605 (positif terprediksi positif)

True Negatif (TN) = 215 (netral) + 85 (negatif) = 300

False Positif (FP) = 20 (netral) + 5 (negatif) = 25

False Negatif (FN) = 30 (positif ke netral) + 15 (positif ke negatif) = 45

Perhitungan Akurasi:

$$\text{accuracy} = \frac{605 + 300}{1.000} = \frac{905}{1.000} = 0,905 = 90,5\%$$

Perhitungan Metrik per Kelas:

Kelas Positif:

$$\text{Precision}_{\text{pos}} = \frac{605}{605 + 25} = \frac{605}{630} = 0,960 = 96,0\%$$

$$\text{Recall}_{\text{pos}} = \frac{605}{605 + 45} = \frac{605}{650} = 0,931 = 93,1\%$$

$$F1_{\text{pos}} = \frac{2 \times 0,960 \times 0,931}{0,960 + 0,931} = \frac{1,788}{1,891} = 0,946 = 94,6\%$$

Kelas Netral:

$$\text{Precision}_{\text{net}} = \frac{215}{215 + (30 + 10)} = \frac{215}{255} = 0,843 = 84,3\%$$

$$\text{Recall}_{\text{net}} = \frac{215}{215 + (20 + 15)} = \frac{215}{250} = 0,860 = 86,0\%$$

$$F1_{\text{net}} = \frac{2 \times 0,843 \times 0,860}{0,843 + 0,860} = \frac{1,450}{1,703} = 0,851 = 85,1\%$$

Kelas Negatif:

$$\text{Precision}_{\text{neg}} = \frac{85}{85 + (15 + 15)} = \frac{85}{115} = 0,739 = 73,9\%$$

$$\text{Recall}_{\text{neg}} = \frac{85}{85 + (5 + 10)} = \frac{85}{100} = 0,850 = 85,0\%$$

$$F1_{\text{neg}} = \frac{2 \times 0,739 \times 0,850}{0,739 + 0,850} = \frac{1,256}{1,589} = 0,791 = 79,1\%$$

Rata-rata Makro:

$$\text{Precision}_{\text{macro}} = \frac{0,960 + 0,843 + 0,739}{3} = \frac{2,542}{3} = 0,847 = 84,7\%$$

$$F1_{\text{macro}} = \frac{\text{Recall} \quad 0,931 + 0,860 + 0,850}{3} = \frac{2,641}{3} = 0,880 = 88,0\%$$

Tabel 7. Perbandingan Kinerja Model (n = 1.000)

Model	Accuracy	Precision	Recall	F1-Score	Training Time
<i>IndoBERT</i>	90.5%	84.7%	88.0%	86.3%	12 menit
<i>LSTM</i>	85.2%	83.5%	84.1%	83.8%	8 menit
<i>SVM</i>	81.0%	79.8%	80.5%	80.1%	4 menit
<i>Naive Bayes</i>	77.3%	75.9%	76.8%	76.3%	2 menit

Tabel 7 ini membandingkan kinerja empat model klasifikasi yang diuji pada dataset 1.000 data sentimen komunitas sekolah. *IndoBERT* unggul dengan akurasi 90,5%, diikuti *LSTM* (85,2%), *SVM* (81,0%), dan *Naive Bayes* (77,3%). Selain akurasi, tabel juga menyajikan metrik *precision*, *recall*, dan *F1-score* untuk setiap model, serta waktu pelatihan (*training time*). *IndoBERT* menunjukkan keunggulan konsisten di semua metrik meskipun membutuhkan waktu pelatihan lebih lama (12 menit), mengonfirmasi efektivitas arsitektur *transformer* untuk analisis teks berbahasa Indonesia.

Hasil

1. Kinerja Model

Model *IndoBERT* yang telah melalui proses *fine-tuning* pada 1.000 data menunjukkan kinerja unggul dengan akurasi 90,5%, sesuai dengan yang ditampilkan pada Tabel 7. Proses pelatihan model berjalan selama 5 epoch dengan konfigurasi hyperparameter yang telah ditentukan sebelumnya, dan menunjukkan peningkatan akurasi serta penurunan loss yang stabil. Hasil ini sejalan dengan penelitian sebelumnya yang menunjukkan efektivitas *IndoBERT* untuk analisis teks berbahasa Indonesia [8], [11], [15].

2. Distribusi Sentimen

Analisis distribusi sentimen bertujuan untuk memetakan kecenderungan persepsi komunitas sekolah terhadap implementasi *program Eco School*. Distribusi sentimen dihitung dengan rumus:

$$P(c) = \frac{n_c}{N} \times 100\% \quad (11)$$

Keterangan:

$P(c)$ = persentase sentimen kelas c

n_c = jumlah data pada kelas sentimen tertentu

N = total seluruh data (1.000)

Implementasi Perhitungan:

Sentimen Positif:

$$P(\text{positif}) = \frac{650}{1.000} \times 100\% = 65\%$$


Sentimen Netral:

$$P(\text{netral}) = \frac{250}{1.000} \times 100\% = 25\%$$

Sentimen Negatif:

$$P(\text{negatif}) = \frac{100}{1.000} \times 100\% = 10\%$$

Visualisasi distribusi sentimen komunitas sekolah disajikan pada Gambar 3.



Gambar 3. Diagram Distribusi Sentimen ($n = 1.000$)

Diagram Gambar 3 lingkaran (pie *chart*) dengan latar belakang putih, berjudul "Diagram Distribusi Sentimen" di bagian atas dan "Total Data: 1.000" di bawah judul. Lingkaran utama terbagi menjadi tiga bagian dengan proporsi yang berbeda. Bagian terbesar (65%) berwarna hijau terang, menempati area dari posisi jam 7 hingga jam 3 (sekitar 234 derajat), dengan label "Positif" dan "650" tertulis di dalamnya. Bagian kedua (25%) berwarna kuning, menempati area dari jam 3 hingga jam 5 (sekitar 90 derajat), dengan label "Netral" dan "250" tertulis di dalamnya. Bagian ketiga (10%) berwarna merah, menempati area dari jam 5 hingga jam 7 (sekitar 36 derajat), dengan label "Negatif" dan "100" tertulis di dalamnya. Setiap bagian dipisahkan oleh garis batas berwarna hitam. Dari setiap bagian, terdapat garis penunjuk (leader line) yang menghubungkan ke kotak legenda di bagian bawah. Legenda berbentuk tiga kotak berjajar horizontal: kotak hijau dengan teks "Positif (65% - 650 data)", kotak kuning dengan teks "Netral (25% - 250 data)", dan kotak merah dengan teks "Negatif (10% - 100 data)". Persentase juga dituliskan di dekat masing-masing bagian lingkaran.

3. Analisis Topik Berdasarkan Sentimen

Analisis topik bertujuan mengidentifikasi kata-kata dominan yang merepresentasikan isu utama pada setiap kelas sentimen. Perhitungan dilakukan dengan menghitung frekuensi kemunculan kata pada setiap kelas sentimen menggunakan rumus:

$$f(w, c) = \sum_{d \in D_c} \text{count}(w, d) \quad (12)$$

Keterangan:

$f(w, c)$ = frekuensi kata w pada kelas sentimen c

D_c = himpunan dokumen pada kelas sentimen c

$\text{count}(w, d)$ = jumlah kemunculan kata w dalam dokumen d

Implementasi Perhitungan:

Topik "Kegiatan Praktis" pada sentimen positif:

$$f(\text{"kegiatan praktis", positif}) = \frac{185}{650} \times 100\% = 28,5\% \text{ dari dokumen positif}$$

(frekuensi kemunculan frasa "kegiatan praktis" sebanyak 185 kali pada 650 dokumen sentimen positif)

Topik "Beban Kerja" pada sentimen negatif:

$$f(\text{"beban kerja", negatif}) = \frac{38}{100} \times 100\% = 38,0\% \text{ dari dokumen negatif}$$

(frekuensi kemunculan frasa "beban kerja" sebanyak 38 kali pada 100 dokumen sentimen negatif)

Topik "Informasi" pada sentimen netral:

$$f(\text{"informasi", netral}) = \frac{210}{250} \times 100\% = 84,0\% \text{ dari dokumen netral}$$

Dalam proses analisis data teks pada kumpulan dokumen sentimen netral, ditemukan bahwa kata "informasi" memiliki frekuensi kemunculan yang sangat signifikan, yaitu sebanyak 210 kali dari total 250 dokumen yang dianalisis. Tingginya frekuensi kemunculan kata kunci ini mengindikasikan bahwa topik seputar penyampaian, pencarian, atau ketersediaan informasi menjadi fokus utama dalam diskusi atau pernyataan bersentimen netral. Para pengguna atau penulis teks dalam korpus ini cenderung membahas suatu hal tanpa menunjukkan kecenderungan emosional positif atau negatif, melainkan lebih berfokus pada aspek faktual dan pertukaran data.

Temuan ini menjadi dasar untuk melakukan analisis lebih lanjut terhadap kata-kata lain dengan frekuensi tertinggi. Tujuannya adalah untuk memahami pola tematik yang lebih luas dan bagaimana kata "informasi" berinteraksi dengan konsep-konsep kunci lainnya. Dengan mengidentifikasi kata-kata yang paling sering muncul, kita dapat mulai memetakan topik-topik utama yang membentuk wacana dalam dokumen-dokumen netral tersebut.

Hasil dari pendalaman analisis tematik ini kemudian dirangkum dan disajikan secara sistematis. Data mengenai kata-kata berfrekuensi tinggi beserta pengelompokan tematiknya telah diolah dan ditampilkan dalam bentuk tabel yang informatif. Untuk melihat detail lebih lanjut mengenai pengelompokan kata, frekuensi pastinya, serta tema-tema yang teridentifikasi, hasil lengkap dari analisis topik ini dapat dirujuk pada Tabel 8 yang terlampir. Tabel tersebut memberikan gambaran visual yang jelas mengenai struktur tematik dalam korpus dokumen sentimen netral tersebut.

Tabel 8. Topik Dominan Berdasarkan Kelas Sentimen

Kelas Sentimen	Topik Utama	Frekuensi	Contoh Ujaran
Positif (n = 650)	Kegiatan Praktis	185	"Kegiatan membuat kerajinan dari sampah plastik sangat kreatif"
	Kesadaran Lingkungan	162	"Anak jadi lebih peduli dengan kebersihan lingkungan"
	Nilai Edukasi	143	"Program ini memberikan edukasi lingkungan yang praktis"
Negatif (n = 100)	Beban Kerja	38	"Laporan kegiatan eco school menambah beban administrasi guru"
	Biaya	32	"Setiap proyek selalu ada iuran yang

Kelas Sentimen	Topik Utama	Frekuensi	Contoh Ujaran
Netral (n = 250)	Implementasi	21	memberatkan orang tua" "Hanya seremonial saat ada penilaian adiwiyata saja"
	Informasi	210	"Kerja bakti <i>eco school</i> hari Sabtu jam 8 pagi"

Tabel 8 ini mengidentifikasi topik-topik dominan yang memicu masing-masing kelas sentimen berdasarkan frekuensi ke- munculan kata kunci. Pada sentimen positif (650 data), tiga topik utama muncul: Kegiatan Praktis (185 frekuensi), Kesadaran Lingkungan (162), dan Nilai Edukasi (143). Sentimen negatif (100 data) didominasi oleh keluhan Beban Kerja (38), Biaya (32), dan Implementasi *program* yang hanya seremonial (21). Sentimen netral (250 data) hampir seluruhnya terkait dengan Informasi kegiatan (210). Setiap topik disertai contoh ujaran representatif yang menggambarkan konteks kemunculannya.

4. Perbandingan Sentimen antar Kelompok

Untuk mengetahui perbedaan persepsi antara siswa, guru, dan orang tua, dilakukan analisis perbandingan distribusi sentimen antar kelompok. Dari total 1.000 data, komposisi per kelompok adalah: Siswa (350 data), Guru (320 data), dan Orang Tua (330 data). Distribusi sentimen per kelompok dihitung menggunakan rumus:

$$P(c | g) = \frac{n_{c,g}}{N_g} \times 100\% \quad (13)$$

Keterangan:

$P(c | g)$ = persentase sentimen kelas c pada kelompok g

$n_{c,g}$ = jumlah data dengan sentimen c pada kelompok g

N_g = total data pada kelompok g

Implementasi Perhitungan:

Kelompok Siswa ($N_{siswa} = 350$ data):

$$P(\text{positif} | \text{siswa}) = \frac{273}{350} \times 100\% = 78\%$$

$$P(\text{netral} | \text{siswa}) = \frac{53}{350} \times 100\% = 15\%$$

$$P(\text{negatif} | \text{siswa}) = \frac{24}{350} \times 100\% = 7\%$$

Kelompok Guru ($N_{guru} = 320$ data):

$$P(\text{positif} | \text{guru}) = \frac{186}{320} \times 100\% = 58\%$$

$$P(\text{netral} | \text{guru}) = \frac{96}{320} \times 100\% = 30\%$$

$$P(\text{negatif} | \text{guru}) = \frac{38}{320} \times 100\% = 12\%$$


Kelompok Orang Tua ($N_{orangtua} = 330$ data):

$$P(\text{positif} | \text{orangtua}) = \frac{182}{330} \times 100\% = 55\%$$

$$P(\text{netral} | \text{orangtua}) = \frac{82}{330} \times 100\% = 25\%$$

$$P(\text{negatif} | \text{orangtua}) = \frac{66}{330} \times 100\% = 20\%$$

Visualisasi perbandingan distribusi sentimen antar kelompok disajikan pada Gambar 4.



Gambar 4. Distribusi Sentimen per Kelompok (n = 1.000)

Gambar 4 diagram batang berkelompok (clustered bar chart) dengan latar belakang putih, berjudul "Distribusi Sentimen per Kelompok". Sumbu X (horizontal) terbagi menjadi tiga kelompok: "Siswa (n=350)", "Guru (n=320)", dan "Orang Tua (n=330)", masing-masing dengan jarak yang sama. Sumbu Y (vertikal) menunjukkan skala persentase dari 0% hingga 100%, dengan garis bantu horizontal putus-putus pada setiap interval 10%. Untuk kelompok Siswa, terdapat tiga batang berdampingan: batang hijau setinggi 78% (label "78%" di atasnya), batang kuning setinggi 15% (label "15%"), dan batang merah setinggi 7% (label "7%"). Untuk kelompok Guru: batang hijau setinggi 58% (label "58%"), batang kuning setinggi 30% (label "30%"), dan batang merah setinggi 12% (label "12%"). Untuk kelompok Orang Tua: batang hijau setinggi 55% (label "55%"), batang kuning setinggi 25% (label "25%"), dan batang merah setinggi 20% (label "20%"). Semua batang memiliki lebar yang sama dan diberi warna solid. Legenda di bagian bawah menampilkan tiga kotak warna: hijau untuk "Positif", kuning untuk "Netral", dan merah untuk "Negatif". Di bawah legenda, terdapat tabel kecil yang merangkum nilai persentase untuk setiap kelompok.

Perbandingan topik positif dan negatif dominan per kelompok disajikan dalam Tabel 9.

Tabel 9. Perbandingan Topik per Kelompok (n = 1.000)


Kelompok	Topik Positif Dominan	Topik Negatif Dominan
Siswa (n = 350)	Kegiatan menyenangkan, belajar praktik	Tugas tambahan, waktu istirahat berkurang
Guru (n = 320)	Nilai edukasi, kepuasan mengajar	Beban administrasi, waktu persiapan
Orang Tua (n = 330)	Pendidikan karakter, lingkungan sehat	Biaya tambahan, jadwal tidak fleksibel

Tabel 9 ini membandingkan persepsi antar kelompok pemangku kepentingan terhadap *program Eco School* berdasarkan topik- topik yang dominan muncul. Siswa (350 data) cenderung memandang positif kegiatan menyenangkan dan belajar praktik, namun mengeluhkan tugas tambahan yang mengurangi waktu istirahat. Guru (320 data) mengapresiasi nilai edukasi dan kepuasan mengajar, tetapi terbebani oleh administrasi dan waktu persiapan. Orang tua (330 data) menghargai pendidikan karakter dan lingkungan sehat, namun keberatan dengan biaya tambahan dan jadwal yang tidak fleksibel. Perbedaan ini menegaskan perlunya pendekatan manajemen perubahan yang segmented sesuai karakteristik masing-masing kelompok.

5. Diskusi

Temuan penelitian menunjukkan bahwa *program Eco School* pada umumnya diterima dengan baik oleh komunitas sekolah, dengan sentimen positif mencapai 65% dari total 1.000 data. Model *IndoBERT* terbukti efektif dalam menangkap nuansa sentimen dalam teks Bahasa Indonesia terkait isu kebijakan pendidikan, dengan akurasi mencapai 90,5%, sejalan dengan temuan [15]. Namun, terdapat beberapa area kritis yang perlu mendapat perhatian khusus, terutama terkait beban administrasi yang dirasakan guru (38% dari sentimen negatif), biaya tambahan yang menjadi kekhawatiran orang tua (32% dari sentimen negatif), dan inkonsistensi implementasi *program* (21%

dari sentimen negatif) [13], [10]. Berdasarkan temuan ini, disusun sebuah kerangka rekomendasi yang terintegrasi untuk meningkatkan efektivitas *program Eco School*, seperti yang digambarkan pada Gambar 5.



Gambar 5. *Framework* Rekomendasi Berbasis Temuan

Gambar 5 diagram kerangka kerja (*framework*) berbasis tiga pilar dengan latar belakang putih. Di bagian paling atas terdapat kotak utama berwarna biru tua dengan teks "*Efektivitas Program Eco School*" berwarna putih dan ikon sekolah hijau di samping kanan. Dari kotak ini, tiga garis panah vertikal berwarna hitam mengarah ke tiga kotak pilar yang disusun sejajar secara horizontal di bawahnya. Pilar kiri: kotak berwarna hijau muda dengan judul "*Penguatan Aspek Positif*" dan ikon bintang kuning. Di dalamnya terdapat tiga bullet point dengan ikon centang hijau: "*Pertahankan kegiatan kreatif & praktis*", "*Kembangkan program berbasis proyek*", dan "*Fasilitasi berbagi praktik baik*". Pilar tengah: kotak berwarna kuning muda dengan judul "*Mitigasi Faktor Negatif*" dan ikon perisai biru. Di dalamnya terdapat tiga bullet point dengan ikon gembok: "*Sederhanakan sistem pelaporan administratif*", "*Susun panduan pendanaan transparan*", dan "*Bentuk tim monitoring independen*". Pilar kanan: kotak berwarna biru muda dengan judul "*Strategi Komunikasi Segmented*" dan ikon megafon oranye. Di dalamnya terdapat tiga bullet point dengan ikon gelembung dialog: "*Sosialisasi berbeda tiap kelompok*", "*Saluran komunikasi khusus*", dan "*Forum dialog rutin*".

Dari ketiga kotak pilar, garis panah menurun bergabung ke satu kotak besar di bagian bawah berwarna abu-abu dengan teks "*Implementasi Kebijakan yang Adaptif dan Berkelanjutan*" dan ikon siklus panah melingkar. Seluruh elemen dihubungkan dengan garis penghubung yang menunjukkan keterkaitan hierarkis.

Kesimpulan dan Saran

Penelitian ini menganalisis sentimen komunitas sekolah terhadap implementasi kebijakan *Eco School* menggunakan pendekatan Natural Language Processing berbasis model *IndoBERT*. Berdasarkan analisis terhadap 1.000 data teks yang dikumpulkan dari media sosial, forum diskusi pendidikan, dan kuesioner terbuka, diperoleh beberapa temuan utama. Pertama, distribusi sentimen menunjukkan dominasi sentimen positif sebesar 65% (650 data), diikuti sentimen netral 25% (250 data) dan sentimen negatif 10% (100 data). Dominasi sentimen positif ini mengindikasikan bahwa *program Eco School* secara umum diterima dengan baik oleh komunitas sekolah serta mendukung teori penerimaan inovasi dalam bidang pendidikan. Kedua, hasil analisis topik menunjukkan bahwa sentimen positif terutama dipicu oleh kegiatan praktis yang berkaitan

dengan pembelajaran lingkungan (185 frekuensi), peningkatan kesadaran lingkungan (162), serta nilai edukasi yang dirasakan siswa (143). Sebaliknya, sentimen negatif lebih banyak berkaitan dengan beban administrasi guru (38), biaya tambahan bagi orang tua (32), serta inkonsistensi implementasi *program* (21). Ketiga, terdapat perbedaan persepsi antar kelompok pemangku kepentingan, di mana siswa menunjukkan tingkat sentimen positif tertinggi (78%), diikuti guru (58%) dan orang tua (55%). Perbedaan ini menunjukkan bahwa implementasi kebijakan pendidikan lingkungan memerlukan pendekatan manajemen perubahan yang mempertimbangkan karakteristik masing-masing kelompok. Keempat, dari sisi kinerja model, *IndoBERT* menunjukkan performa yang sangat baik dengan akurasi 90,5%, *precision* 84,7%, *recall* 88,0%, dan *F1-score* 86,3%, yang menegaskan efektivitas arsitektur *transformer* dalam analisis sentimen teks berbahasa Indonesia. Berdasarkan temuan tersebut, beberapa rekomendasi dapat diajukan bagi pihak sekolah maupun pemerintah, antara lain penerapan sistem pelaporan terdigitalisasi untuk mengurangi beban administrasi guru, penyusunan panduan pendanaan yang transparan guna mengatasi kekhawatiran orang tua terkait biaya tambahan, pembentukan tim monitoring independen untuk memastikan konsistensi implementasi *program*, serta pengembangan strategi komunikasi yang disesuaikan dengan karakteristik masing-masing kelompok pemangku kepentingan. Untuk penelitian selanjutnya, disarankan eksplorasi pendekatan yang lebih luas, seperti penggunaan model multilingual untuk perbandingan lintas bahasa, penerapan aspect-based sentiment analysis untuk analisis yang lebih granular, integrasi data kualitatif melalui wawancara mendalam, pengembangan model *IndoBERT* khusus untuk domain pendidikan, pemanfaatan metode *few-shot learning* pada dataset terbatas, serta pengembangan sistem monitoring sentimen secara real-time berbasis *API* guna mendukung evaluasi kebijakan pendidikan yang lebih adaptif dan berkelanjutan.

Referensi

- [1] Besigomwe, K., "Using Natural Language Processing (NLP) to Analyze Education Policies: A Systematic Review," *Cogniz. J. Multidiscip. Stud.*, vol. 5, no. 7, pp. 440-454, 2025, <https://doi.org/10.47760/cognizance.2025.v05i07.036>.
- [2] Sunar, A. S. and Khalid, M. S., "Natural Language Processing of Student's Feedback to Instructors: A Systematic Review," *IEEE Trans. Learn. Technol.*, vol. 17, pp. 741-753, 2024, <https://doi.org/10.1109/TLT.2023.3330531>.
- [3] Dake, D. K. and Gyimah, E., "Using Sentiment Analysis to Evaluate Qualitative Students' Responses," *Educ. Inf. Technol.*, vol. 28, no. 4, pp. 4629-4647, 2023, <https://doi.org/10.1007/s10639-022-11349-1>.
- [4] Kastrati, Z., Dalipi, F., Imran, A. S., Nuci, K. P. and Wani, M. A., "Sentiment Analysis of Students' Feedback with NLP and Deep Learning: A Systematic Mapping Study," *Appl. Sci.*, vol. 11, no. 9, 2021, <https://doi.org/10.3390/app11093986>.
- [5] Barrón Estrada, M. L., Zatarain Cabada, R., Oramas Bustillos, R. and Graff, M., "Opinion Mining and Emotion Recognition Applied to Learning Environments," *Expert Syst. Appl.*, vol. 150, 2020, <https://doi.org/10.1016/j.eswa.2020.113265>.
- [6] Ndubuisi, B. and Olufunke, O. F., "Natural Language Processing for Public Feedback Analysis: Uncovering Citizen Sentiments in Policy Implementation in the United States," *Int. J. Law, Polit. Humanit. Res. Publ. by Cambridge Res. Publ.*, vol. 9, no. 6, pp. 203-216, 2025.
- [7] Raval, P. R., "NLP-Based Sentiment Analysis of Social Media Data on Public Perception of Environmental Policies," *Int. J. Environ. Sci.*, vol. 11, no. 23, pp. 970-978, 2025, <https://doi.org/10.64252/1ygxfv29>.
- [8] Ahmadian, H., Abidin, T. F., Riza, H. and Muchtar, K., "Hybrid Models for Emotion Classification and Sentiment Analysis in Indonesian Language," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, pp. 17, 2024, <https://doi.org/10.1155/2024/2826773>.

- [9] Jazuli, A., Widowati and Kusumaningrum, R., "Aspect-Based Sentiment Analysis on Student Reviews Using the Indo-Bert Base Model," *E3S Web Conf.*, vol. 448, pp. 1–10, 2023, <https://doi.org/10.1051/e3sconf/202344802004>.
- [10] Jazuli, A., Widowati and Kusumaningrum, R., "Optimizing Aspect-Based Sentiment Analysis Using BERT for Comprehensive Analysis of Indonesian Student Feedback," *Appl. Sci.*, vol. 15, no. 1, pp. 1–28, 2025, <https://doi.org/10.3390/app15010172>.
- [11] Nugroho, R. P., Soepriyanto, Y., Aprianto, M., Febriansah, A. T., Qolbi, M. and Khuluq, K., "Leveraging Indobert and Google NLP for Learning Evaluation Tool," *Int. Conf. Educ. Technol.*, pp. 168–173, 2024.
- [12] Octovianto, C., Ibrohim, M. O. and Budi, I., "Indonesian Sentiment Analysis in Natural Environment Topics," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 38, no. 2, pp. 1353, 2025, <https://doi.org/10.11591/ijeecs.v38.i2.pp1353-1366>.
- [13] Wafda, A., Fudholi, D. H. and Nugraha, J., "Aspect-Based Sentiment Analysis on Twitter Tweets About the Merdeka Curriculum Using Indobert," *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 10, no. 3, pp. 586–599, 2025, <https://doi.org/10.33480/jitk.v10i3.5692>.
- [14] Imran, A., Li, J. and Alshammari, A., "AI-Driven Educational Transformation in ICT: Improving Adaptability, Sentiment, and Academic Performance with Advanced Machine Learning," *PLOSOne*, vol. 20, no. 19, pp. 1–31, 2025, <https://doi.org/10.1371/journal.pone.0317519>.
- [15] Shubhangi, M., Swati, A., Akanksha, B. and Dilip, S., "Ethical and Societal Implication of Sentiment Analysis using NLP in Educational Feedback System," *J. Inf. Syst. Eng. Manag.*, vol. 10, no. 15, pp. 742–749, 2025, <https://doi.org/10.52783/jisem.v10i15s.2515>.