

**IMPLEMENTASI METODE BERT DALAM ANALISIS
SENTIMEN PUBLIK TERHADAP KEBIJAKAN KAMPUS
BERDAMPAK DI *PLATFORM X* (TWITTER)**

LAPORAN TUGAS AKHIR

Laporan ini disusun untuk memenuhi salah satu syarat memperoleh Gelar Sarjana Strata 1 (S1) pada Program Studi Teknik Informatika Fakultas Teknologi Industri Universitas Islam Sultan Agung Semarang



Disusun Oleh :

Nama : Thadeo Miftakhul Fauzi
NIM : 32602100118
Program Studi : Teknik Informatika

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM SULTAN AGUNG SEMARANG
2025**

***IMPLEMENTATION OF THE BERT BERT METHOD IN
PUBLIC SENTIMENT ANALYSIS ON KAMPUS BERDAMPAK
POLICIES IN ON PLATFORM X (TWITTER)***

FINAL PROJECT

*This report was prepared to fulfill one of the requirements to complete the S-1
Informatics Engineering study program at the Faculty of Industrial Technology,
Sultan Agung Islamic University*



Arranged By :

Name : Thadeo Miftakhul Fauzi

NIM : 32602100118

Study Program : Informatics Engineering

***INFORMATICS ENGINEERING STUDY PROGRAM
FACULTY OF INDUSTRIAL TECHNOLOGY
SULTAN AGUNG ISLAMIC UNIVERSITY OF SEMARANG***

2025

**LEMBAR PENGESAHAN
TUGAS AKHIR**

**IMPLEMENTASI METODE BERT DALAM ANALISIS SENTIMEN
PUBLIK TERHADAP KEBIJAKAN KAMPUS BERDAMPAK DI
PLATFORM X (TWITTER)**

**Thadeo Miftakhul Fauzi
NIM. 32602100118**

Telah dipertahankan di depan tim penguji laporan tugas akhir
Program Studi Teknik Informatika
Universitas Islam Sultan Agung
Pada tanggal : 10 Desember 2025

TIM PENGUJI UJIAN SARJANA:

Moch Taufik, ST., MIT
NIDN. 210604034
(Penguji 1)

20 Januari 2026

Dedy Kurniadi, ST., M.Kom
NIDN. 210615048
(Penguji 2)


7 Januari 2026

Andi Riansyah, ST., M.Kom
NIDN. 210616053
(Pembimbing)

30 Januari 2026

Semarang, 30 Januari 2026

Mengetahui,
Kaprodi Teknik Informatika
Universitas Islam Sultan Agung



Moch Taufik, ST., MIT
NIK. 210604034

SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan dibawah ini :

Nama : Thadeo Miftakhul Fauzi

NIM : 32602100118

Judul Tugas Akhir : Implementasi Metode BERT dalam Analisis Sentimen Publik
Terhadap Kebijakan Kampus Berdampak di *Platform X*
(Twitter)

Dengan bahwa ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila dikemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 24 September 2025

Yang Menyatakan,



Thadeo Miftakhul Fauzi

PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan dibawah ini :

Nama : Thadeo Miftakhul Fauzi

NIM : 32602100118

Program Studi : Teknik Informatika

Fakultas : Teknologi industri

Dengan ini menyatakan Karya Ilmiah berupa Tugas akhir dengan Judul : Implementasi Metode BERT dalam Analisis Sentimen Publik Terhadap Kebijakan Kampus Berdampak di *Platform X* (Twitter).

Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak bebas Royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dan pangkalan data dan dipublikasikan diinternet dan media lain untuk kepentingan akademis selama tetap menyantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila dikemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan agung.

Semarang, 24 September 2025

Yang menyatakan,

A blue official stamp from Universitas Islam Sultan Agung (UNISSULA) is visible. The stamp contains the text 'UNIVERSITAS ISLAM SULTAN AGUNG' and 'UNISSULA'. A handwritten signature in black ink is written over the stamp. Below the signature, the text 'METERAN TEMPEL' and the number '1499AJX625394547' are printed.

Thadeo Miftakhul Fauzi

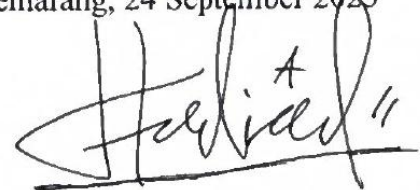
KATA PENGANTAR

Dengan mengucapkan Syukur alhamdulillah atas kehadiran Allah SWT yang telah memberikan rahmat dan karunianya kepada penulis, sehingga dapat menyelesaikan Tugas Akhir dengan judul “Implementasi Metode BERT dalam Analisis Sentimen Publik Terhadap Kebijakan Kampus Berdampak di Platform X (Twitter)” ini untuk memenuhi salah satu syarat menyelesaikan studi serta dalam rangka memperoleh gelar sarjana (S-1) pada Program Studi Teknik Informatika Fakultas Teknologi Industri Universitas Islam Sultan Agung Semarang. Tugas Akhir ini disusun dan dibuat dengan adanya bantuan dari berbagai pihak, oleh karena itu saya selaku penulis mengucapkan terimakasih kepada:

1. Rektor UNISSULA Bapak Prof. Dr. H. Gunarto, S.H., M.H yang mengizinkan penulis menimba ilmu di kampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Ir. Novi Marlyana, ST., MT., IPU., ASEAN Eng.
3. Dosen pembimbing penulis Bapak Andi Riansyah, ST, M.Kom yang telah meluangkan waktu dan memberi ilmu. Serta memberikan banyak nasehat dan saran.
4. Orang tua penulis yang telah mengizinkan untuk menyelesaikan laporan ini,
5. Dan kepada semua pihak yang tidak dapat saya sebutkan satu persatu.

Dengan segala kerendahan hati, penulis menyadari masih terdapat banyak kekurangan dari segi kualitas atau kuantitas dari ilmu pengetahuan dalam penyusunan laporan, sehingga penulis mengharapkan adanya saran dan kritikan yang bersifat membangun demi kesempurnaan laporan ini dan masa mendatang.

Semarang, 24 September 2025



Thadeo Miftakhul Fauzi

DAFTAR ISI

IMPLEMENTASI METODE BERT DALAM ANALISIS SENTIMEN PUBLIK TERHADAP KEBIJAKAN KAMPUS BERDAMPAK DI PLATFORM X (TWITTER)	i
LEMBAR PENGESAHAN TUGAS AKHIR	iii
SURAT PERNYATAAN KEASLIAN TUGAS AKHIR.....	iv
PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH	v
KATA PENGANTAR.....	vi
DAFTAR ISI.....	iii
DAFTAR GAMBAR.....	v
DAFTAR TABEL	vii
ABSTRAK	viii
BAB I.....	1
PENDAHULUAN.....	1
1.1 LATAR BELAKANG	1
1.2 PERUMUSAN MASALAH.....	4
1.3 PEMBATAAN MASALAH.....	4
1.4 TUJUAN	4
1.5 MANFAAT PENELITIAN.....	5
1.6 SISTEMATIKA PENULISAN.....	5
BAB II	7
TINJAUAN PUSTAKA DAN DASAR TEORI.....	7
2.1 Tinjauan Pustaka	7
2.2 Dasar Teori.....	11
2.2.1 Analisis Sentimen	11
2.2.2 Pendidikan Karakter	11
2.2.3 Kampus Berdampak.....	12
2.2.4 Text Mining.....	14
2.2.5 X (Twitter).....	14
2.2.6 Natural Language Processing (NLP).....	15

2.2.7	Tranformers.....	16
2.2.8	<i>Bidirectional Encoder Representations from Transformers (BERT)</i> 18	
2.2.9	IndoBERT.....	20
BAB III	23
METODE PENELITIAN	23
3.1	Alur Penelitian.....	23
3.2	Pengumpulan Data.....	25
3.3	Preprocessing.....	26
3.4	Labeling Data & Split Data.....	29
3.5	Perancangan Model.....	29
3.6	Pengujian Model.....	33
3.7	Evaluasi Model.....	33
3.8	Implementasi Model.....	35
BAB IV HASIL DAN ANALISIS PENELITIAN	37
4.1	Hasil Penelitian.....	37
4.1.1	Deskripsi Dataset.....	37
4.1.2	Data Preprocessing.....	38
4.1.3	Eksperimen Model.....	42
4.2	Hasil Perancangan Model.....	43
4.2.1	Data <i>ImBalance</i>	43
4.2.2	Data <i>Balance</i>	48
4.3	Hasil Implementasi <i>Streamlit</i>	53
BAB V	57
KESIMPULAN DAN SARAN	57
5.1	Kesimpulan.....	57
5.2	Saran.....	57
DAFTAR PUSTAKA		

DAFTAR GAMBAR

Gambar 2.1 Kampus Berdampak	13
Gambar 2.2 Natural Language Processing (NLP).....	15
Gambar 2.3 Arsitektural Bidirectional Encode Representations from Transformers (BERT).....	19
Gambar 2.4 Arsitektural IndoBERT.....	20
Gambar 3.1 Flowchart perancangan model	24
Gambar 3.2 Teknik scrapping X (Twitter) dengan tweet-harvest	25
Gambar 3.3 Flowchart Pre-Processing.....	26
Gambar 3.4 Arsitektur model.....	31
Gambar 3. 5 Flowchart alur sistem	35
Gambar 4.1 Informasi dataset	37
Gambar 4.1 Informasi dataset	37
Gambar 4. 2 Dataset sebelum pembersihan	38
Gambar 4. 3 Hasil data cleaning	40
Gambar 4. 4 Hasil Labeling dataset	40
Gambar 4. 5 Wordcloud sebelum ditambahkan stopword removal	41
Gambar 4. 6 Visualisasi Wordcloud setelah stopword removal.....	42
Gambar 4.7 Loss curve (Data ImBalance).....	44
Gambar 4.8 Classification report (Data ImBalance).....	44
Gambar 4.9 Confusion matrix (Data ImBalance)	45
Gambar 4.10 Model evaluation metrics (Data ImBalance)	46
Gambar 4.11 True labels & Classified Labels (Data ImBalance).....	47
Gambar 4.12 True labels & Classified Labels (Data Labels).....	49
Gambar 4.13 Loss curve (Data Balance)	50
Gambar 4.14 Model evaluation metrics (Data Balance).....	51
Gambar 4.15 Classification report (Data Balance)	51
Gambar 4.16 Confusion matrix (Data Balance).....	52
Gambar 4.17 Tampilan awal streamlit	53
Gambar 4.18 Inputan text komentar.....	54

Gambar 4.19 Hasil analisis sentimen negatif.....	54
Gambar 4.20 Hasil sentimen positif.....	55
Gambar 4.21 Hasil sentimen netral.....	55



DAFTAR TABEL

Tabel 2. 1 Tabel Rangkuman Tinjauan Pustaka	8
Tabel 3.2 Prediction class.....	34
Tabel 4.1 Data Cleaning.....	38



ABSTRAK

Media sosial telah menjadi ruang ekspresi publik yang aktif dan dinamis, di mana opini masyarakat terhadap berbagai isu, termasuk kebijakan pendidikan, tersebar luas dan dapat dianalisis. Salah satu kebijakan yang menjadi perhatian adalah program Kampus Berdampak yang diluncurkan sebagai kelanjutan dari Merdeka Belajar Kampus Merdeka (MBKM). Penelitian ini bertujuan untuk mengklasifikasikan sentimen publik terhadap kebijakan tersebut di Platform X (Twitter) ke dalam tiga kategori utama: positif, negatif, dan netral. Metode yang digunakan adalah analisis sentimen berbasis model IndoBERT, yang telah terbukti efektif dalam menangkap konteks bahasa Indonesia di media sosial. Data dikumpulkan dari unggahan pengguna Twitter yang membahas kebijakan Kampus Berdampak, kemudian dianalisis menggunakan model IndoBERT dan ditampilkan melalui prototipe berbasis web interaktif sederhana. Hasil penelitian ini diharapkan dapat memberikan gambaran yang lebih akurat tentang persepsi publik terhadap kebijakan pendidikan nasional serta menjadi masukan strategis bagi pengambil kebijakan dalam merespons opini masyarakat secara lebih tepat dan responsif.

Kata Kunci : analisis sentimen, BERT, IndoBERT, kebijakan, pendidikan, kampus berdampak, X (Twitter)

ABSTRACT

Social media has become an active and dynamic space for public expression, where public opinion on various issues, including education policy, is widely shared and can be analyzed. One policy of concern is the Impact Campus program, launched as a continuation of the Independent Learning Campus (MBKM). This study aims to classify public sentiment towards this policy on Platform X (Twitter) into three main categories: positive, negative, and neutral. The method used is sentiment analysis based on the IndoBERT model, which has proven effective in capturing the Indonesian language context in social media. Data were collected from Twitter user posts discussing the Impact Campus policy, then analyzed using the IndoBERT model and displayed through a simple interactive web-based prototype. The results of this study are expected to provide a more accurate and more comprehensive picture of public perception towards national education policy and provide strategic input for policymakers in responding to public opinion more appropriately and responsively.

Keywords : sentiment analysis, BERT, IndoBERT, policy, education, kampus berdampak, X (Twitter)

BAB I

PENDAHULUAN

1.1 LATAR BELAKANG

Media sosial kini telah menjadi sumber data besar (*big data*) yang sangat potensial untuk dianalisis, karena masyarakat secara aktif mengekspresikan opini, emosi, dan pandangan mereka terhadap berbagai isu di *platform* seperti Twitter, Instagram, dan lainnya. Volume besar data teks, gambar, dan simbol yang dihasilkan dari aktivitas ini membuka peluang untuk memahami dinamika opini publik. Oleh karena itu, analisis sentimen menjadi alat penting dalam mengekstraksi informasi dari opini yang tersebar di media sosial, baik dalam konteks bisnis, sosial, maupun politik (Savero *dkk*, 2024), (Pahtoni *dkk*, 2024), (Cipta *dkk*, 2024).

Twitter (sekarang dikenal sebagai X) merupakan salah satu *platform* media sosial yang memungkinkan penggunaannya berbagi informasi secara cepat dan luas, baik dalam bentuk teks, gambar, maupun tautan. *Platform* ini sering dimanfaatkan untuk menyampaikan opini pribadi, berbagi informasi aktual, hingga membentuk diskusi publik. Dengan fitur seperti *like*, *retweet*, dan *thread*, Twitter menjadi ruang interaktif yang mendorong keterlibatan pengguna dalam berbagai isu sosial dan budaya. Pengguna aktif memanfaatkannya untuk menanggapi peristiwa, menyuarakan solidaritas, dan menyebarkan informasi secara *real time* (Rhein Rahmahsya Reshany *dkk*, 2023), (Fitrianti *dkk*, 2024), (Fahira *dkk*, 2022). Informasi dan opini yang tersebar luas melalui Twitter tidak jarang memicu reaksi publik yang masif, yang pada akhirnya dapat memengaruhi perhatian media arus utama maupun para pembuat kebijakan. Ketika isu-isu sosial, politik, atau budaya menjadi viral dan menuai respons besar di *platform* ini, pemerintah maupun institusi terkait sering kali terdorong untuk merespons dengan kebijakan, klarifikasi, atau tindakan tertentu sebagai bentuk akomodasi terhadap aspirasi publik (Pahtoni *dkk*, 2024). Dengan demikian, Twitter

bukan hanya menjadi media ekspresi, tetapi juga sarana strategis dalam membentuk wacana dan mendorong perubahan kebijakan yang relevan dengan isu yang tengah diperbincangkan masyarakat (Loilatu *dkk.*, 2021).

Berdasarkan Permendikbudristek No. 53 Tahun 2023 dan pernyataan Kementerian Pendidikan Tinggi, Sains, dan Teknologi melalui rubrik Kabar DiktiSaintek (April 2025), gerakan #KampusBerdampak dinyatakan sebagai kelanjutan strategis dari program Merdeka Belajar Kampus Merdeka (MBKM) dan bagian dari infrastruktur kebijakan nasional. Kebijakan kampus berdampak merupakan bentuk konkret dari implementasi nilai-nilai pendidikan karakter dalam kehidupan. Kebijakan ini dirancang tidak hanya untuk menyelesaikan persoalan teknis, tetapi juga membawa perubahan positif yang berkelanjutan terhadap perilaku, sikap, dan kesadaran sosial masyarakat. Misalnya, penerapan kebijakan Merdeka Belajar Kampus Merdeka (MBKM) berperan penting dalam membentuk sumber daya manusia yang unggul, berkarakter, dan memiliki tanggung jawab sosial. Program ini menekankan pengembangan karakter seperti kepemimpinan, integritas, dan kemandirian melalui kegiatan nyata seperti pengabdian masyarakat dan kolaborasi lintas sektor (Maulana, 2022), (Pramudita *dkk.*, 2022).

Dalam konteks pendidikan karakter, kebijakan berdampak bukan hanya dilihat dari keberhasilan administratifnya, tetapi dari kemampuannya menciptakan perubahan perilaku positif yang mencerminkan nilai-nilai luhur seperti gotong royong, tanggung jawab, dan kepedulian terhadap sesama (Aulia *dkk.*, 2021). Dampak dari kebijakan semacam ini terlihat pada meningkatnya partisipasi aktif mahasiswa dalam kegiatan sosial dan kolaboratif yang memperkuat nilai-nilai karakter di dunia nyata. Mahasiswa tidak hanya menjadi penerima ilmu, tetapi juga agen perubahan di masyarakat, misalnya melalui program magang, proyek kemanusiaan, dan kegiatan wirausaha sosial. Hal ini turut mendorong terciptanya lulusan yang tidak hanya kompeten secara akademik, tetapi juga memiliki sensitivitas sosial dan kepedulian terhadap isu-isu kemasyarakatan. Kebijakan ini juga memperkuat keterhubungan antara dunia pendidikan dengan kebutuhan masyarakat dan dunia kerja, sehingga

proses pendidikan tidak terputus dari realitas sosial yang dihadapi sehari-hari (Maulana, 2022), (Pramudita *dkk.*, 2022).

Sebagai upaya untuk memahami persepsi publik terhadap kebijakan Kampus Berdampak, penggunaan metode BERT yang telah diadaptasi ke dalam bahasa Indonesia yaitu IndoBERT telah terbukti efektif dalam tugas-tugas analisis sentimen di media sosial. Dalam penelitian yang dilakukan oleh Darman (2023), model BERT berhasil mengidentifikasi kecenderungan opini masyarakat terhadap kebijakan pemerintah terkait BPJS melalui cuitan di Twitter, dengan mayoritas sentimen yang dianalisis masuk dalam kategori positif (57,7%) dan negatif (33,1%), serta hanya sebagian kecil bersifat netral (9,2%) (Mlati *dkk.*, 2025). Keberhasilan tersebut menunjukkan bahwa model BERT, khususnya IndoBERT, sangat mampu menangkap kompleksitas konteks dalam bahasa Indonesia, sehingga dapat diandalkan untuk menelaah opini publik secara akurat terhadap kebijakan sosial dan pendidikan yang sedang berkembang di masyarakat.

Berdasarkan uraian latar belakang yang telah dipaparkan, dapat disimpulkan bahwa program ini merupakan kebijakan baru dalam dunia pendidikan tinggi yang telah memunculkan beragam respons di ruang publik digital terutama di *platform X* (Twitter). Perbedaan pandangan berupa dukungan, penolakan, maupun sikap netral menunjukkan adanya dinamika opini publik yang perlu dipahami secara komprehensif dan objektif. Oleh karena itu, analisis sentimen perlu dilakukan sebagai upaya untuk mengkaji persepsi publik secara sistematis terhadap kebijakan tersebut. Hasil analisis sentimen tidak hanya memberikan gambaran nyata mengenai kecenderungan opini masyarakat, tetapi juga berperan penting dalam memahami dinamika sosial dan pola komunikasi publik di era digital. Informasi ini diharapkan dapat menjadi dasar evaluatif bagi pemangku kebijakan serta kontribusi akademik dalam pengembangan kajian analisis sentimen berbasis data media sosial.

1.2 PERUMUSAN MASALAH

Bagaimana implementasi model IndoBERT dalam sistem analisis sentimen yang dapat mengklasifikasikan sentimen kedalam 3 kategori utama, yaitu: positif, negatif, atau netral terhadap opini publik mengenai Kebijakan Kampus Berdampak di Platform X (Twitter) ?

1.3 PEMBATASAN MASALAH

Proposal Penelitian: Implementasi Metode BERT dalam Analisis Sentimen Publik terhadap Kebijakan Kampus Berdampak di *Platform X* (Twitter) memiliki beberapa batasan, antara lain:

1. Data yang digunakan dalam penelitian ini dibatasi pada opini publik yang berasal dari media sosial X (Twitter) yang membahas kebijakan kampus berdampak di Indonesia.
2. Model yang digunakan untuk analisis sentimen dibatasi pada algoritma IndoBERT (*Indonesian Bidirectional Encoder Representations from Transformers*) dan tidak dilakukan perbandingan performa dengan model NLP lainnya.
3. Sentimen yang dianalisis diklasifikasikan menjadi tiga kategori: positif, negatif, dan netral.
4. Implementasi sistem dibatasi pada prototype berbasis web yang hanya digunakan untuk menampilkan input opini, serta hasil analisis sentimen.

1.4 TUJUAN

Adapun tujuan dari tugas akhir ini adalah untuk mengklasifikasikan sentimen kedalam 3 kategori utama yaitu: positif, negatif, atau netral terhadap opini publik mengenai Kebijakan Kampus Berdampak di Platform X (Twitter) dengan menerapkan analisis sentimen berbasis model IndoBERT.

1.5 MANFAAT PENELITIAN

Penelitian ini bermanfaat untuk membantu memahami opini publik terhadap kebijakan Kampus Berdampak melalui analisis sentimen berbasis IndoBERT, yang dapat digunakan sebagai dasar evaluasi dan perumusan kebijakan yang lebih responsif.

1.6 SISTEMATIKA PENULISAN

Sistematika penulisan yang akan digunakan oleh penulis dalam pembuatan laporan tugas akhir adalah sebagai berikut:

BAB I : PENDAHULUAN

Pada BAB I menjelaskan tentang latar belakang, pemilihan judul, perumusan masalah, pebatasan masalah, tujuan penelitian, dan sistematika penulisan.

BAB II : TINJAUAN PUSTAKA DAN DASAR TEORI

Pada BAB II memuat tentang penelitian terdahulu dan landasan teori yang berkaitan untuk membantu memahami analisis sentimen pada kebijakan kampus berdampak, algoritma Natural Language Processing (NLP), Bidirectional Encoder Representations from Transformers (BERT), dan IndoBERT dalam melengkapi penelitian ini.

BAB III : METODE PENELITIAN

Pada Bab III menjelaskan tahapan-tahapan penelitian, dimulai dari pengumpulan data melalui scrapping, preprocessing data, pelabelan, pelatihan dan pengujian model IndoBERT, hingga evaluasi kinerja menggunakan metrik akurasi, presisi, *recall*, dan F1-score.

BAB IV : HASIL DAN ANALISIS PENELITIAN

Pada Bab IV berisi pemaparan hasil implementasi sistem analisis sentimen, performa model IndoBERT terhadap data uji, serta visualisasi hasil klasifikasi. Analisis dilakukan berdasarkan metrik

evaluasi untuk menilai efektivitas model dalam memahami opini publik terkait kebijakan Kampus Berdampak.

BAB V : KESIMPULAN DAN SARAN

Pada BAB V berisi rangkuman keseluruhan proses penelitian dari awal hingga akhir.



BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Analisis sentimen merupakan teknik yang digunakan untuk mengidentifikasi dan mengkategorikan opini atau emosi yang terkandung dalam data teks, biasanya dalam bentuk ulasan atau komentar, menjadi sentimen positif, negatif, atau netral. Teknik ini sangat bermanfaat untuk memahami respon publik terhadap suatu isu atau kebijakan, termasuk dalam ranah pendidikan dan kebijakan kampus (Mujahidin *dkk.*, 2022). Pada penelitian lain juga menjelaskan bahwa, analisis sentimen digunakan untuk membedakan opini masyarakat, dan hasilnya menunjukkan bagaimana sebuah opini dapat menggambarkan persepsi publik terhadap sebuah kebijakan. Pemanfaatan analisis sentimen juga diterapkan dalam berbagai bidang lain (Riyandona *dkk.*, 2025). Penelitian oleh Arista *dkk.* (2024) menunjukkan bahwa IndoBERT berhasil menganalisis sentimen publik di Twitter terkait isu pemindahan IKN dengan akurasi 94%, *F1-score* 88,4%, dan terbukti efektif untuk opini publik berbahasa Indonesia (Arista *dkk.*, 2024).

Penelitian lain oleh Olabanjo *dkk.* (2023) juga menegaskan efektivitas IndoBERT varian dari BERT dalam analisis opini publik menggunakan data Twitter, mereka berhasil mengidentifikasi preferensi pemilih dan memetakan kekuatan. Model IndoBERT yang digunakan mencapai tingkat akurasi dan *F1-score* di atas 90%, memperkuat potensi BERT dalam mendeteksi opini politik masyarakat secara masif melalui media sosial (Olabanjo *dkk.*, 2023).

Dalam konteks kebijakan, Junita dan Suryono (2024) menerapkan algoritma BERT untuk menganalisis ujaran kebencian terhadap calon wakil presiden Indonesia melalui data Twitter. Penelitian ini tidak hanya menunjukkan keandalan BERT dalam mendeteksi sentimen politik, tetapi juga kemampuannya untuk mengungkap kecenderungan opini publik terhadap

tokoh politik tertentu dengan akurasi yang sangat tinggi, bahkan mencapai 100% pada beberapa dataset kandidat (Elvika Alya Junita, 2024).

Pada Penelitian Ashraf dkk. (2023) mengembangkan model BERT khusus untuk bahasa Urdu dengan dataset *UDSA-23* (Urdu Dataset for Sentiment Analysis 2023) lebih dari 2.000 data ulasan, dan menunjukkan peningkatan akurasi hingga 26% dan *F1-score* hingga 25,87% dibanding metode sebelumnya. Studi ini menekankan efektivitas BERT bahkan dalam bahasa dengan sumber daya terbatas, sehingga sangat relevan untuk diterapkan di konteks lokal seperti opini masyarakat Indonesia (Ashraf dkk., 2023).

Keunggulan metode IndoBERT dalam menganalisis opini publik juga ditunjukkan oleh penelitian Nurfitri dkk (2024), yang menerapkan IndoBERT untuk menganalisis sentimen masyarakat Indonesia terhadap pemberitaan peningkatan kasus Covid-19. Model ini berhasil mencapai skor akurasi di atas 81% dan *F1-score* di atas 80%, menunjukkan kinerja yang konsisten dalam klasifikasi opini berbasis bahasa Indonesia, bahkan dalam topik yang bersifat sensitif dan dinamis. Hasil ini memperkuat bahwa IndoBERT layak digunakan dalam konteks analisis kebijakan sosial dan pendidikan seperti Kampus Berdampak karena kemampuannya memahami nuansa emosi dalam opini masyarakat secara kontekstual (Nurfitri dkk, 2024).

Berdasarkan penelitian sebelumnya yaitu menggunakan penerapan analisis sentimen dan metode klasifikasi BERT sehingga pada penelitian ini akan dibuat penelitian yang menggunakan teknik analisis sentimen dengan kategori positif, negatif dan netral dengan menerapkan model IndoBERT.

Tabel 2. 1 Tabel Rangkuman Tinjauan Pustaka

No.	Penulis	Judul Penelitian	Metode	Hasil Penelitian
1	Mujahidin, Hasyim, & Pratama (2022)	Analisis Sentimen untuk Mengidentifikasi dan Mengkategorikan Opini Publik	Analisis sentimen berbasis teks (ulasan/komentar)	Teknik analisis sentimen efektif mengidentifikasi opini positif, negatif, dan netral dalam memahami

No.	Penulis	Judul Penelitian	Metode	Hasil Penelitian
		dalam Ranah Pendidikan dan Kebijakan Kampus		respon publik terhadap kebijakan pendidikan dan kampus.
2	Riyandona dkk. (2025)	Analisis Sentimen sebagai Alat untuk Membedakan Opini Publik terhadap Kebijakan	Analisis sentimen pada opini masyarakat	Analisis sentimen mampu menggambarkan persepsi publik terhadap kebijakan serta diterapkan di berbagai bidang.
3	Arista dkk. (2024)	Analisis Sentimen Publik di Twitter Terkait Isu Pemindehan IKN Menggunakan IndoBERT	Model IndoBERT (varian BERT) pada data Twitter	IndoBERT berhasil mencapai akurasi 94% dan F1-score 88,4%, menunjukkan efektivitas tinggi dalam opini publik berbahasa Indonesia.
4	Olabanjo dkk. (2023)	Analisis Opini Publik Menggunakan IndoBERT untuk Mendeteksi Preferensi Politik di Media Sosial	Model IndoBERT pada data Twitter	Model mencapai akurasi dan F1-score di atas 90%, efektif memetakan preferensi pemilih dan kekuatan opini politik masyarakat.

No.	Penulis	Judul Penelitian	Metode	Hasil Penelitian
5	Junita & Suryono (2024)	Analisis Ujaran Kebencian terhadap Calon Wakil Presiden Indonesia Menggunakan BERT	Algoritma BERT pada data Twitter	BERT efektif mendeteksi sentimen politik dan mengungkap kecenderungan opini publik terhadap tokoh politik; akurasi mencapai 100% pada beberapa dataset.
6	Ashraf dkk. (2023)	Pengembangan Model BERT untuk Bahasa Urdu dengan Dataset UDSA-23	Model BERT khusus bahasa Urdu (UDSA-23, >2.000 ulasan)	Model meningkatkan akurasi hingga 26% dan F1-score hingga 25,87% dibanding metode sebelumnya; menunjukkan efektivitas BERT untuk bahasa sumber daya terbatas.
7	Nurfitri & Chowanda (2024)	Analisis Sentimen Masyarakat Indonesia terhadap Pemberitaan	Model IndoBERT untuk analisis sentimen bahasa Indonesia	Model mencapai akurasi >81% dan F1-score >80%, menunjukkan konsistensi tinggi dalam klasifikasi

No.	Penulis	Judul Penelitian	Metode	Hasil Penelitian
		Kasus Covid-19 Menggunakan IndoBERT		opini publik, relevan untuk analisis kebijakan sosial dan pendidikan.

2.2 Dasar Teori

2.2.1 Analisis Sentimen

Analisis sentimen (sentiment analysis) adalah proses otomatis untuk mengidentifikasi, mengekstrak, dan mengklasifikasikan opini atau perasaan seseorang terhadap suatu entitas seperti produk, layanan, kebijakan, atau isu sosial. Dalam konteks opini publik terhadap kebijakan pendidikan, analisis sentimen sangat berguna untuk mengetahui persepsi masyarakat dan respons emosional mereka secara massal terhadap suatu kebijakan. Teknik ini banyak digunakan dalam berbagai bidang mulai dari bisnis, politik, hingga pendidikan karena kemampuannya untuk mengolah data dalam jumlah besar secara efisien (Shaik *dkk.*, 2023); (Hariguna *dkk.*, 2020).

Beberapa studi menunjukkan bahwa analisis sentimen telah digunakan untuk menganalisis opini politik masyarakat terhadap berbagai kebijakan publik. Sebagai contoh, dalam konteks pendidikan, Shaik *dkk.* (2022) meneliti bagaimana opini siswa terhadap kurikulum dianalisis menggunakan pendekatan NLP berbasis AI untuk meningkatkan pengambilan keputusan kebijakan. Sementara itu, Hariguna *dkk.* (2020) menyoroti pentingnya analisis sentimen dalam memahami respons masyarakat terhadap isu sosial, termasuk pendidikan dan kebijakan politik (Shaik *dkk.*, 2023); (Hariguna *dkk.*, 2020).

2.2.2 Pendidikan Karakter

Pendidikan karakter merupakan proses sistematis untuk menanamkan nilai-nilai moral, etika, dan kebajikan kepada peserta didik agar mereka tumbuh menjadi individu yang berintegritas, bertanggung jawab, dan mampu

berkontribusi positif dalam masyarakat (Muslim, 2020). Di tingkat pendidikan tinggi di Indonesia, implementasi pendidikan karakter bertujuan untuk menghasilkan lulusan yang tidak hanya unggul secara akademik, tetapi juga memiliki integritas moral, tanggung jawab sosial, dan kepedulian terhadap masyarakat sekitarnya sebagai bagian dari pembentukan etika kepemimpinan dan jiwa sosial mahasiswa (Attruk *dkk.*, 2024). Pendidikan karakter di perguruan tinggi dipandang sebagai solusi terhadap berbagai krisis moral yang terjadi di kalangan generasi muda, seperti perilaku intoleran, rendahnya kejujuran akademik, dan lemahnya rasa tanggung jawab sosial (Lobud *dkk.*, 2025). Oleh karena itu, pendidikan karakter harus diintegrasikan secara holistik dalam kurikulum, budaya kampus, serta aktivitas kemahasiswaan agar nilai-nilai seperti religiusitas, nasionalisme, gotong royong, kemandirian, dan integritas dapat terinternalisasi dalam kehidupan mahasiswa sehari-hari (Muslim, 2020). Pemerintah Indonesia melalui kebijakan *Penguatan Pendidikan Karakter (PPK)* bahkan telah mewajibkan seluruh institusi pendidikan untuk melaksanakan pendidikan karakter sebagai bagian dari misi nasional membentuk manusia Indonesia yang berakhlak mulia dan berdaya saing global (Muslim, 2020).

2.2.3 Kampus Berdampak

Kampus Berdampak merupakan bentuk konkret dari pendidikan karakter di perguruan tinggi karena mendorong mahasiswa untuk mengaplikasikan nilai-nilai moral dan sosial melalui keterlibatan langsung dalam pengabdian kepada masyarakat, yang menjadi ciri utama program Merdeka Belajar Kampus Merdeka (Majdi, 2023).



Gambar 2.1 Kampus Berdampak

Kebijakan Kampus Berdampak merupakan bagian dari transformasi pendidikan tinggi melalui program Merdeka Belajar Kampus Merdeka (MBKM) yang menekankan pentingnya keterlibatan aktif mahasiswa dalam kegiatan nyata di masyarakat sebagai bentuk penguatan tridarma perguruan tinggi. Melalui kebijakan ini, mahasiswa tidak hanya dituntut untuk unggul secara akademis, tetapi juga diharapkan memiliki kesadaran sosial, kemampuan beradaptasi, serta kepedulian terhadap permasalahan riil di lingkungan sekitarnya (Pramudita *dkk.*, 2022). Kegiatan pengabdian masyarakat yang terintegrasi dalam program Kampus Berdampak menjadi media strategis dalam menanamkan nilai-nilai karakter seperti empati, tanggung jawab, dan integritas yang sejalan dengan tujuan pendidikan karakter di perguruan tinggi. Dengan demikian, kebijakan ini bukan hanya mendukung pencapaian kompetensi akademik mahasiswa, tetapi juga menjadi wahana internalisasi nilai-nilai moral dan etika sebagai bagian dari pembentukan karakter lulusan perguruan tinggi (Majdi, 2023). Dengan mengintegrasikan pendidikan karakter ke dalam kerangka kebijakan kampus berdampak, maka proses pembelajaran tidak hanya berlangsung di ruang kelas, melainkan juga melalui keterlibatan mahasiswa dalam menyelesaikan tantangan nyata yang dihadapi masyarakat (Paskarina *dkk.*, 2023).

2.2.4 Text Mining

Text mining adalah suatu pendekatan komputasional yang digunakan untuk mengekstraksi informasi bermakna dari data teks tidak terstruktur dengan bantuan teknik Natural Language Processing (NLP), statistik, dan pembelajaran mesin. Dalam konteks analisis sentimen terhadap kebijakan kampus, text mining berperan penting dalam mengolah opini publik, terutama yang bersumber dari media sosial seperti Twitter atau ulasan daring (Siregar *dkk*, 2023).

Text mining menggunakan kumpulan teks yang berformat tidak beraturan, terstruktur atau minimal semi-terstruktur untuk mendapatkan informasi berguna dari sekumpulan data. *Text mining* melakukan dua tugas khusus yaitu mengkategorikan teks (*text categorization*) dan pengelompokan teks (*text clustering*). Proses *text mining* menggunakan konsep dan teknik data mining untuk menemukan pola dalam teks, khususnya dalam proses menganalisis teks, untuk menemukan informasi yang berguna untuk tujuan tertentu. Proses ini memerlukan beberapa langkah awal untuk mempersiapkan dasar agar teks dapat dianalisis (Apri Wenando, 2023).

2.2.5 X (Twitter)

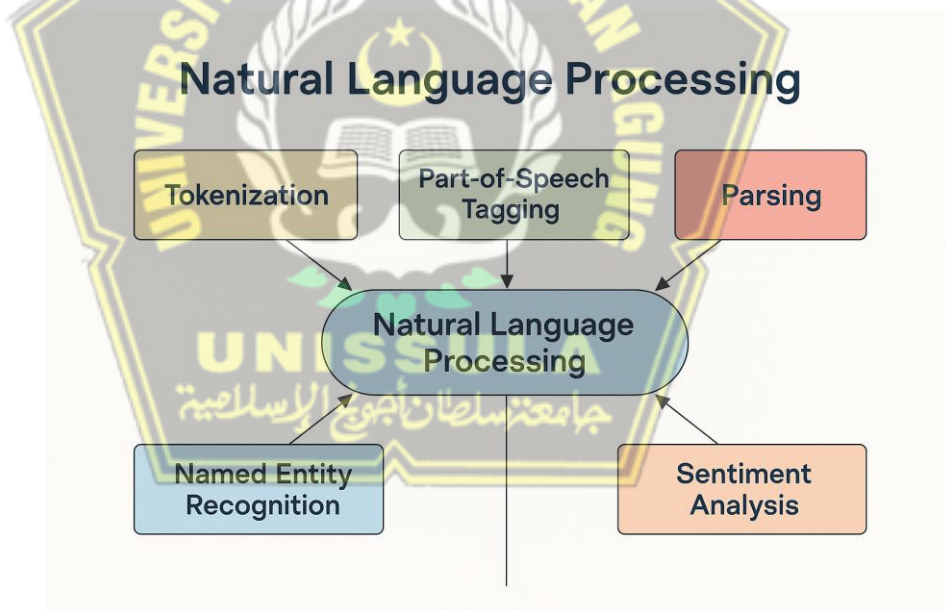
X (dahulu Twitter) adalah *platform* media sosial berbasis mikroblogging yang memungkinkan penggunaannya untuk berbagi pesan singkat (disebut “*tweet*”) secara real-time. Setelah diakuisisi oleh Elon Musk pada tahun 2022, Twitter berganti nama menjadi X, namun fungsionalitas utamanya tetap sama: menyebarkan opini publik, informasi aktual, dan diskusi daring dalam bentuk teks, gambar, atau video.

Dalam konteks penelitian ilmiah, terutama analisis sentimen dan text mining, X/Twitter memiliki peran penting karena menjadi salah satu sumber opini publik paling aktif dan terbuka. *Platform* ini digunakan secara luas oleh masyarakat Indonesia untuk mengekspresikan pendapat mereka terhadap berbagai isu, termasuk kebijakan politik dan pendidikan. Dengan fitur-fitur seperti *hashtag*, *mention*, dan *retweet*, X memungkinkan peneliti mengakses

dan mengelompokkan opini masyarakat berdasarkan tema tertentu (Mujahidin *dkk*, 2022).

2.2.6 Natural Language Processing (NLP)

Natural Language Processing (NLP) merupakan cabang dari kecerdasan buatan (Artificial Intelligence/AI) yang memungkinkan mesin untuk memahami, menginterpretasikan, dan menghasilkan bahasa manusia secara otomatis. NLP berperan penting dalam menghubungkan interaksi manusia-komputer melalui bahasa alami, sehingga memungkinkan komputer merespons dan menafsirkan informasi berbasis teks dengan cara yang menyerupai cara manusia memahami bahasa. Dalam perkembangannya, NLP menggabungkan pendekatan linguistik komputasional dengan teknik pembelajaran mesin, khususnya deep learning, untuk mencapai pemahaman semantik dan sintaksis dari data tekstual (Kosaraju, 2022).



Gambar 2.2 Natural Language Processing (NLP)

Natural Language Processing (NLP) mencakup serangkaian teknik yang dirancang untuk memungkinkan komputer memahami dan menganalisis bahasa manusia secara otomatis. Komponen utama dalam NLP meliputi *tokenization*, yaitu proses memecah teks menjadi unit-unit kecil seperti kata atau frasa; *part-of-speech tagging*, yang menandai setiap kata berdasarkan kelas gramatikalnya; serta *named entity recognition* (NER) yang berfungsi

mengidentifikasi entitas penting dalam teks seperti nama orang, tempat, atau organisasi. Selain itu, dependency parsing digunakan untuk memahami struktur sintaksis dan hubungan antar kata dalam sebuah kalimat. Tahapan-tahapan ini sangat penting sebelum menerapkan algoritma pembelajaran mesin atau deep learning dalam tugas lanjutan seperti sentiment analysis. Sentiment analysis sendiri merupakan salah satu aplikasi paling populer dari NLP, di mana sistem secara otomatis menentukan sikap emosional dari teks, apakah positif, negatif, atau netral (Vanita, 2024).

Secara matematis, proses NLP berakar pada konsep **language modeling**, yaitu memperkirakan probabilitas suatu rangkaian kata dalam teks. Rumus dasar yang digunakan adalah:

$$P(W) = \prod_{i=1}^n P(w_i | w_1, w_2, \dots, w_{i-1}) \quad 1$$

Keterangan:

- $P(W)$: Probabilitas dari suatu kalimat atau dokumen W .
- w_i : Kata ke- i dalam urutan teks.
- $P(W) = w_i | w_1, w_2, \dots, w_{i-1}$: Probabilitas kata w_i muncul berdasarkan konteks kata sebelumnya.

Rumus probabilistik ini menjelaskan bagaimana komputer memahami teks dengan menghitung kemungkinan kemunculan kata dalam konteks tertentu. Pada model tradisional, pendekatan ini sering dibatasi oleh n -gram yang hanya memperhitungkan sejumlah kata sebelumnya. Namun, perkembangan model modern seperti Transformers dan BERT memungkinkan penggunaan konteks dua arah (*bidirectional*), sehingga pemahaman teks menjadi lebih akurat (Amini *dkk.*, 2023); (Zhang *dkk.*, 2024).

2.2.7 Transformers

Transformers adalah arsitektur model pembelajaran mesin yang dirancang untuk memproses data sekuensial tanpa bergantung pada urutan waktu, seperti yang dilakukan oleh RNN atau LSTM. Keunggulan utamanya terletak pada mekanisme self-attention, yang memungkinkan model

memberikan bobot relevansi antar-kata dalam satu kalimat maupun antar-kalimat secara paralel. Ini membuat Transformer sangat efektif dalam memahami hubungan semantik dan konteks global dalam teks, yang sangat krusial dalam analisis sentimen opini publik terhadap kebijakan sosial seperti pendidikan (Nurfitri *dkk*, 2024).

Dalam konteks analisis sentimen, Transformer memiliki keunggulan dalam menangkap hubungan semantik kompleks antara kata dan kalimat. Penelitian menunjukkan bahwa Transformer melalui model BERT secara signifikan meningkatkan akurasi klasifikasi sentimen karena kemampuannya membaca teks secara dua arah (bidirectional), sehingga makna kata dipahami berdasarkan konteks penuh dari kalimat (Narayan *dkk*, 2024). Selain itu, Transformer memungkinkan fine-tuning yang fleksibel untuk berbagai tugas, termasuk klasifikasi opini publik terhadap kebijakan, sebagaimana ditunjukkan dalam studi sentiment analysis pada Twitter menggunakan BERT yang menghasilkan akurasi tinggi dalam mengelompokkan sentimen positif dan negatif terhadap isu-isu politik (Das *dkk*, 2024).

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad 2$$

Keterangan:

- Q = Query (representasi kata yang sedang diproses).
- K = Key (representasi kata dalam konteks).
- V = Value (informasi yang dibawa setiap kata).
- d_k = dimensi dari vektor Key.
- $softmax$ = fungsi aktivasi untuk mengubah skor menjadi probabilitas.

Rumus ini memungkinkan setiap kata dalam teks menilai relevansi terhadap kata lain dengan menghitung bobot perhatian (*attention weights*), sehingga hubungan semantik dan konteks global dapat dipahami lebih baik. Mekanisme ini diulang melalui *multi-head attention*, yang membuat model mampu menangkap pola semantik dari berbagai perspektif secara paralel. Pendekatan ini terbukti sangat efektif dalam berbagai tugas NLP, termasuk

analisis sentimen, karena menghasilkan representasi teks yang lebih kontekstual (Yu *dkk.*, 2023); (Thakur *dkk.*, 2021).

2.2.8 Bidirectional Encoder Representations from Transformers (BERT)

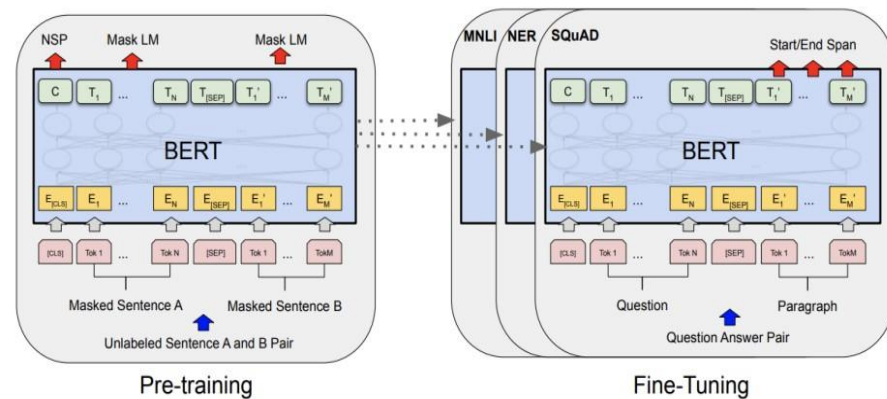
BERT adalah model representasi bahasa berbasis arsitektur Transformer yang dikembangkan oleh Google pada tahun 2018. Tidak seperti model sebelumnya yang hanya memproses teks dalam satu arah (kiri ke kanan atau kanan ke kiri), BERT mampu memahami konteks kata secara bidirectional atau dua arah, yang memungkinkan pemahaman yang lebih mendalam terhadap struktur dan makna kalimat (Gupta, 2024).

$$\tau_{MLM} = - \sum_{i \in M} \log P(w_i | w_{\setminus M}) \quad 3$$

Keterangan:

- M = himpunan posisi kata yang di-*masking* secara acak.
- w_i = kata asli yang ditutupi (*masked word*).
- $w_{\setminus M}$ = konteks kata lain yang tidak ditutupi,
- τ_{MLM} = fungsi loss yang meminimalkan perbedaan antara kata asli dengan prediksi model.

Rumus di atas menjelaskan tugas utama Masked Language Modeling (MLM) pada BERT, di mana beberapa kata dalam kalimat disembunyikan (masked), lalu model memprediksi kata yang hilang berdasarkan konteks dari kedua sisi. Selain itu, BERT juga dilatih dengan Next Sentence Prediction (NSP), yaitu klasifikasi biner untuk memprediksi apakah dua kalimat berurutan secara logis. Kombinasi dua teknik ini membuat BERT unggul dalam memahami hubungan kata dalam satu kalimat maupun antar kalimat (Zhang dan Shafiq, 2024).



Gambar 2.3 Arsitektural Bidirectional Encode Representations from Transformers (BERT)

Secara arsitektural, BERT dibangun hanya menggunakan encoder dari model Transformer, yang merupakan komponen utama dalam memproses seluruh teks secara paralel melalui mekanisme self-attention. Fungsi ini memungkinkan setiap kata dalam kalimat untuk memperhatikan kata lainnya tanpa memperhatikan urutan liniernya, sehingga sangat efisien untuk memahami hubungan antar kata dan konteks global kalimat (Kachkou, 2021).

BERT dilatih dengan dua tugas utama saat pre-training:

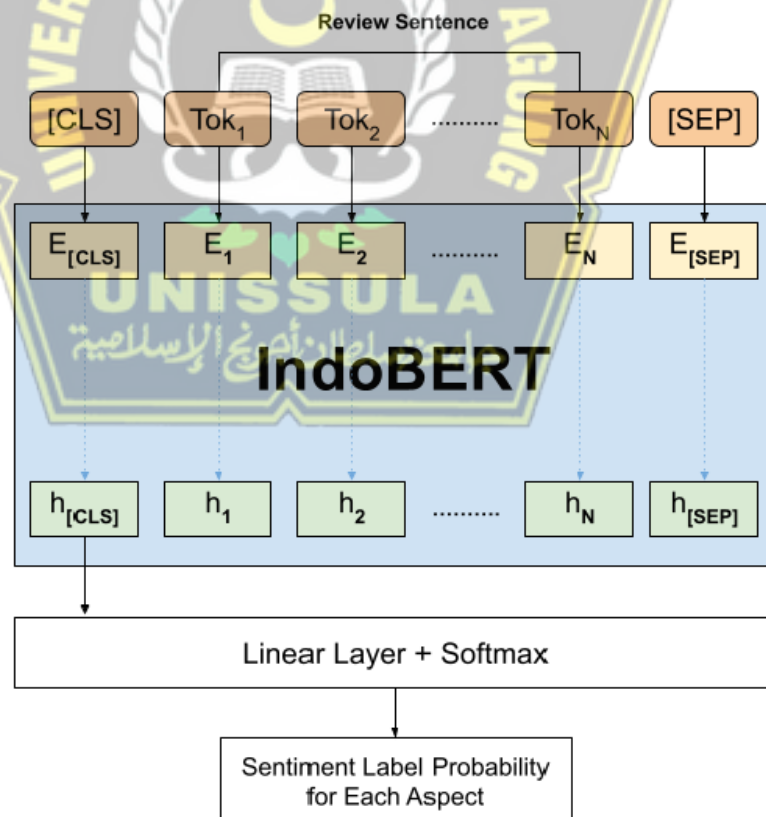
1. Masked Language Modeling (MLM): Beberapa kata dalam kalimat disembunyikan (masked) dan model harus memprediksi kata yang hilang berdasarkan konteks dari kedua sisi.
2. Next Sentence Prediction (NSP): Model memprediksi apakah dua kalimat berurutan secara logis, berguna untuk memahami hubungan antar kalimat dalam konteks seperti QA dan summarization (Gupta, 2024).

Fine-tuning pada algoritma BERT merujuk pada proses penyesuaian parameter model yang telah dilatih sebelumnya (pre-trained) agar dapat digunakan secara optimal pada tugas spesifik tertentu, seperti analisis sentimen, deteksi parafrase, atau klasifikasi teks. Berbagai strategi fine-tuning telah dikembangkan dalam beberapa tahun terakhir untuk meningkatkan performa dan efisiensi BERT. Salah satu pendekatan yang terbukti efektif adalah multitask fine-tuning dengan regularisasi adversarial

yang meningkatkan generalisasi tanpa overfitting terhadap data tugas tertentu (Stanford CS224N dkk., 2023).

2.2.9 IndoBERT

IndoBERT adalah model bahasa berbasis arsitektur BERT yang dirancang khusus untuk memahami bahasa Indonesia. IndoBERT dikembangkan untuk mengatasi keterbatasan sumber daya linguistik dalam penelitian pemrosesan bahasa alami (NLP) untuk bahasa Indonesia, yang meskipun digunakan oleh hampir 200 juta penutur, tetap kurang terwakili dalam literatur ilmiah. Model ini dilatih menggunakan korpus besar dalam bahasa Indonesia dan dievaluasi melalui benchmark IndoLEM, yang mencakup tujuh tugas NLP seperti analisis morfosintaksis, semantik, dan wacana. Hasil pengujian menunjukkan bahwa IndoBERT mencapai performa terbaik (*state of the art*) pada sebagian besar tugas NLP dibandingkan model lain yang tersedia saat ini (Koto dkk., 2020).



Gambar 2.4 Arsitektural IndoBERT

IndoBERT dibangun di atas arsitektur *Bidirectional Encoder Representations from Transformers* (BERT), namun menggunakan korpus berbahasa Indonesia yang luas dan bervariasi, sehingga mampu menangkap nuansa makna, idiom, serta ekspresi linguistik yang khas dalam opini atau komentar publik berbahasa Indonesia, termasuk yang berkaitan dengan topik sosial-politik seperti kebijakan kampus berdampak (Arifin *dkk.*, 2024). Model ini terdiri dari tiga tahap utama: pertama, teks diproses oleh *tokenizer* dan dikonversi menjadi *token* dengan *embedding* posisi dan segmen (Yulianti *dkk.*, 2024); kedua, *token embedding* ini diproses oleh 12 lapis *transformer encoder* dengan mekanisme *multi head self attention* untuk memahami konteks secara dua arah (Imaduddin *dkk.*, 2023); ketiga, vektor representasi dari *token* khusus [CLS] diproses oleh lapisan klasifikasi (*dense-softmax*) untuk menghasilkan label sentimen akhir (Arista *dkk.*, 2024).

$$y = \text{softmax}(W \cdot h_{[CLS]} + b) \quad 4$$

Keterangan:

- $h_{[CLS]}$ = hirepresentasi vektor hasil encoder IndoBERT pada token [CLS].
- W dan b = parameter bobot dan bias pada lapisan klasifikasi.
- y = probabilitas kelas sentimen (positif, negatif, netral).

di mana $h_{[CLS]}$ adalah representasi teks dari IndoBERT, sementara W dan b merupakan parameter pelatihan pada lapisan klasifikasi. Rumus ini memungkinkan model memetakan teks ke dalam probabilitas kelas sentimen (positif, negatif, atau netral) (Kartika, *dkk.*, 2023).

Berdasarkan uraian dasar teori yang telah dipaparkan, dapat disimpulkan bahwa analisis sentimen merupakan pendekatan yang relevan untuk memahami opini publik terhadap kebijakan Kampus Berdampak sebagai bagian dari transformasi pendidikan tinggi dan penguatan pendidikan karakter. Opini publik yang diekspresikan melalui platform X (Twitter) menjadi sumber data yang kaya namun tidak terstruktur, sehingga memerlukan pendekatan *text mining* dan teknik *Natural Language Processing* (NLP) untuk dapat diolah secara sistematis. Dalam

konteks ini, arsitektur Transformer dengan mekanisme *self-attention* memungkinkan pemodelan konteks teks secara lebih mendalam, yang kemudian diimplementasikan melalui model BERT dengan kemampuan pemahaman dua arah (*bidirectional*). Selanjutnya, penggunaan IndoBERT sebagai adaptasi BERT untuk bahasa Indonesia menjadi sangat tepat karena mampu menangkap karakteristik linguistik dan nuansa bahasa Indonesia dalam opini publik. Keterpaduan konsep-konsep tersebut membentuk landasan teoritis yang kuat dalam menganalisis sentimen masyarakat terhadap kebijakan Kampus Berdampak secara akurat, objektif, dan kontekstual.



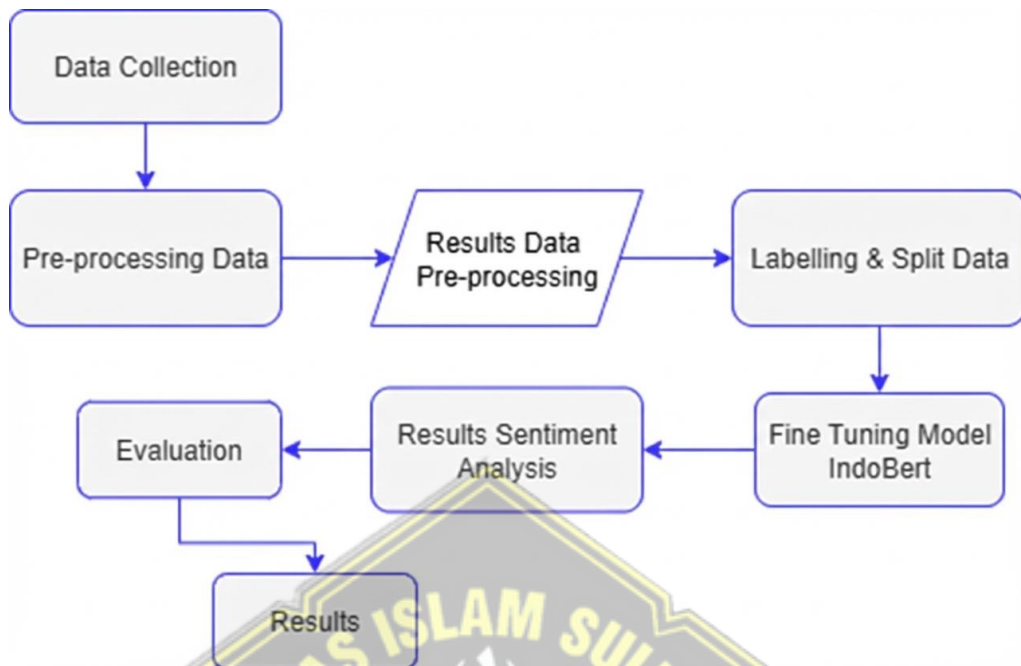
BAB III

METODE PENELITIAN

Bagian ini memberikan penjelasan tentang metodologi yang digunakan dalam penelitian. Teks opini publik tentang kebijakan kampus berdampak yang merupakan implementasi nyata dari hasil pendidikan karakter yang diambil dari scrapping melalui media sosial X (Twitter). Dataset akan dibagi menjadi data *training* dan data *testing* setelah melalui *pre-processing* teks seperti pembersihan data (*data clean*), *tokenization*, dan konversi ke format input model dengan perbandingan 80:20 atau 70:30. Setelah itu, tugas utama analisis sentimen dibuat menggunakan model IndoBERT varian dari BERT (*Bidirectional Encoder Representations from Transformers*). Kemudian, model dievaluasi menggunakan metrik akurasi, *precision*, *recall*, *F1-score*, dan terakhir hasil dievaluasi. Proses metodologi penelitian yang digunakan dalam penelitian ini adalah sebagai berikut :

3.1 Alur Penelitian

Untuk memberikan gambaran yang jelas mengenai tahapan penelitian yang dilakukan, Flowchart ini menggambarkan proses penelitian secara sistematis dan terstruktur, mulai dari tahap pengumpulan data hingga diperolehnya hasil akhir analisis sentimen yang ditunjukkan pada Gambar 3.1.



Gambar 3.1 Flowchart perancangan model

Alur penelitian pada Gambar 3.1, penelitian diawali dengan tahap *Data Collection*, yaitu proses pengumpulan data berupa teks cuitan dari *platform X* (Twitter) yang berkaitan dengan topik penelitian. Data yang telah dikumpulkan kemudian masuk ke tahap *pre-processing* data, di mana dilakukan *case folding* untuk mengubah seluruh teks menjadi huruf kecil. Selanjutnya dilakukan translasi otomatis untuk menyeragamkan bahasa pada data, kemudian dilanjutkan dengan tokenisasi guna memecah teks menjadi token kata. Setelah itu dilakukan stemming untuk mengubah kata ke bentuk dasarnya, diikuti dengan stopword removal untuk menghapus kata-kata yang tidak memiliki makna signifikan.

Selanjutnya, hasil dari tahap *pre-processing* ditampilkan pada tahap *Results Data Pre-processing* sebagai gambaran kondisi data setelah dibersihkan. Data yang telah bersih kemudian dilanjutkan ke tahap *Labelling & Split Data*, yaitu pemberian label sentimen (positif, negatif, dan netral) serta pembagian dataset menjadi *data training* dan *data testing* dengan perbandingan 70:30 atau 80:20. *Data training* digunakan untuk melatih model, sedangkan *data testing* digunakan untuk menguji kinerja model dalam proses klasifikasi sentimen.

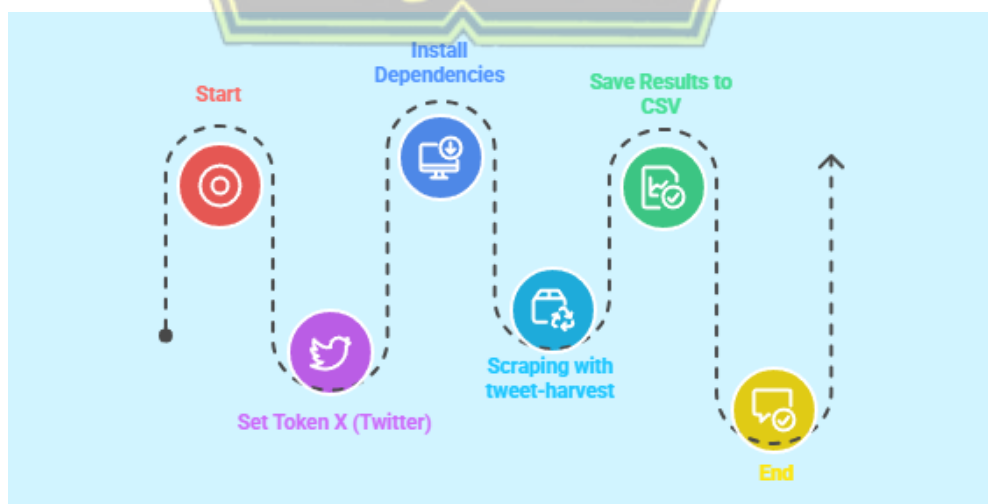
Tahap berikutnya adalah *Fine Tuning* Model IndoBERT, di mana model dilatih menggunakan *data training* untuk melakukan klasifikasi sentimen. Model yang telah dilatih kemudian digunakan untuk menghasilkan prediksi sentimen pada *data testing*, yang ditampilkan pada tahap *Results Sentiment Analysis*. Hasil prediksi tersebut selanjutnya dievaluasi pada tahap *Evaluation* dengan menggunakan metrik performa akurasi, *precision*, *recall*, dan *F1-score* untuk menilai kinerja model.

Tahap terakhir adalah *Results*, yang menyajikan keseluruhan hasil penelitian, baik dalam bentuk tabel, grafik, maupun interpretasi analisis sentimen publik terhadap kebijakan Kampus Berdampak berdasarkan hasil pemodelan yang telah dilakukan.

3.2 Pengumpulan Data

Data penelitian diperoleh melalui web scraping pada platform media sosial X (Twitter) dengan memanfaatkan kata kunci yang merepresentasikan pendapat dan respons masyarakat terhadap kebijakan Kampus Berdampak. Proses pengambilan data dilakukan dalam rentang waktu Januari 2025 hingga Agustus 2025, sehingga data yang dikumpulkan mencerminkan dinamika opini publik pada periode tersebut.

Pada tahap pengumpulan data, dilakukan proses web *scrapping* terhadap media sosial X (Twitter) untuk memperoleh opini publik terkait kebijakan kampus berdampak dapat dilihat pada Gambar 3.3.

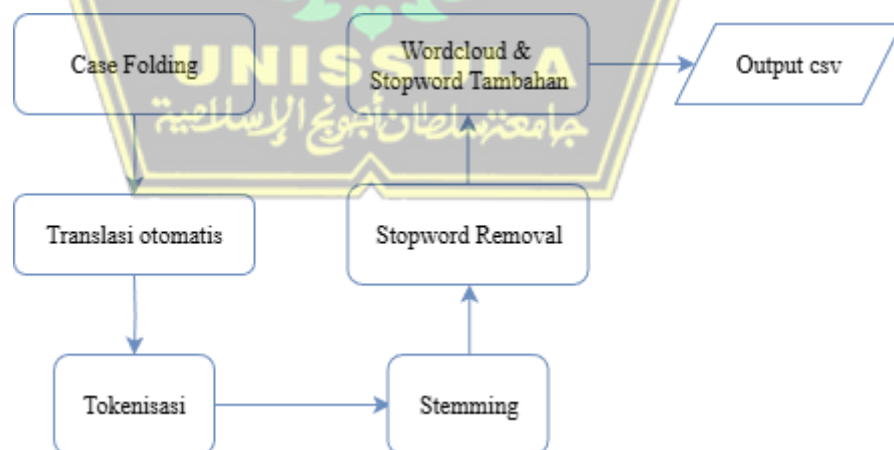


Gambar 3.2 Teknik scrapping X (Twitter) dengan *tweet-harvest*

Cuitan (tweets) atau teks komentar yang berhasil dihimpun kemudian digunakan sebagai korpus data penelitian. Sebelum dilakukan pemodelan, data akan melalui tahapan praproses teks (text preprocessing) untuk meningkatkan kualitas data. Selanjutnya, data dianalisis menggunakan model Bidirectional Encoder Representations from Transformers (BERT) guna mengklasifikasikan sentimen publik terhadap kebijakan Kampus Berdampak.

Proses ini dilakukan menggunakan tools bernama *tweet harvest*, yaitu tools berbasis *Node.js* yang memungkinkan pengambilan data langsung dari laman pencarian Twitter tanpa menggunakan *API* resmi. *Scrapping* dijalankan di *Google Colab* dengan memanfaatkan beberapa *library* dan tools pendukung seperti *Node.js*, *Pandas*, serta *token* autentikasi pengguna. Kata kunci atau label *hashtag* pencarian yang digunakan seperti “#KampusBerdampak”, “#DiktisaintekBerdampak”, dan lain-lain. Data hasil *scrapping* disimpan dalam format CSV yang berisi informasi seperti isi *tweet*, nama pengguna, tanggal, serta jumlah interaksi (*retweet*, *like*, dan *reply*). Data inilah yang nantinya digunakan dalam proses analisis sentimen menggunakan metode BERT.

3.3 Preprocessing



Gambar 3.3 Flowchart Pre-Processing

Gambar 3.3 menunjukkan tahap *preprocessing* yang dilakukan untuk mempersiapkan data agar dapat digunakan oleh model. Berikut merupakan penjelasan setiap tahap *preprocessing* yang dilakukan :

- *Case folding* merupakan langkah pengolahan data yang bertujuan untuk mengubah atau menghilangkan semua huruf kapital pada dokumen menjadi huruf kecil.
- Tahap selanjutnya melibatkan penerjemahan *tweet* yang berbahasa Inggris ke dalam Bahasa Indonesia menggunakan *library googletrans*. Hal ini bertujuan agar seluruh konten teks dapat diproses oleh model IndoBERT yang dirancang khusus untuk Bahasa Indonesia. Hasil terjemahan disimpan dalam kolom baru bernama `translated_text`.
- Setelah diterjemahkan, teks dibersihkan dari komponen-komponen yang tidak diperlukan seperti tautan (URL), tanda pagar (*hashtag*), angka, dan tanda baca. Seluruh huruf juga dikonversi menjadi huruf kecil untuk menyeragamkan format penulisan, serta dilakukan penghapusan spasi yang berlebihan.
- Langkah selanjutnya adalah memecah kalimat menjadi bagian-bagian kata yang disebut *token*. Proses tokenisasi ini memudahkan analisis kata secara individual, terutama untuk tahap stemming dan penghitungan kemunculan kata nantinya. Selain langkah-langkah pembersihan dan normalisasi, proses tokenisasi dilakukan menggunakan WordPiece Tokenizer yang memecah kata menjadi token subword. Hal ini memungkinkan model IndoBERT memahami kata baru atau jarang digunakan melalui kombinasi potongan kata. Secara formal, proses tokenisasi ini dapat dinyatakan dengan persamaan:

$$T = WP_{Tokenizer}(S) \quad 5$$

Keterangan:

- (S) = string input (teks tweet)
- $WP_{Tokenizer}$ = fungsi tokenisasi WordPiece
- T = urutan token hasil pemecahan

Penerapan rumus ini memastikan bahwa teks input diubah menjadi representasi yang sesuai untuk diproses oleh model BERT.

- Setiap *token* kemudian diproses menggunakan teknik stemming dari pustaka Sastrawi untuk mengubah kata ke bentuk dasar. Contohnya, kata seperti “menyuarakan” akan dikembalikan ke bentuk asalnya yaitu “suara”. Hal ini dilakukan agar variasi kata yang memiliki arti sama dapat diperlakukan secara konsisten.
- Meskipun huruf telah diubah menjadi huruf kecil sebelumnya, proses case folding kembali diterapkan guna memastikan seluruh teks telah sepenuhnya konsisten dalam format lowercase, termasuk hasil dari proses normalisasi dan stemming.
- Kemudian, kata-kata yang bersifat umum dan tidak memberi pengaruh signifikan pada makna kalimat seperti “yang”, “itu”, atau “dan” dihilangkan. Proses ini menggunakan daftar *stopword* bawaan dari Sastrawi dan diperkuat dengan daftar khusus yang disesuaikan dengan konteks penelitian.
- Pada tahap selanjutnya, dilakukan konversi kata-kata tidak baku menjadi bentuk baku dengan memanfaatkan kamus eksternal (*kamuskatabaku.xlsx*). Contoh konversinya adalah “gk” atau “ga” menjadi “tidak”. Proses ini juga mendokumentasikan daftar kata yang diubah dan hasil normalisasinya dalam kolom-kolom khusus.
- Setelah proses normalisasi, dilakukan kembali tokenisasi untuk menyesuaikan kata-kata baru yang terbentuk. Kemudian, dilakukan penghapusan *stopword* tambahan untuk memastikan hasil akhir teks bebas dari kata-kata yang tidak relevan.
- Guna mendapatkan gambaran umum dari konten opini yang dianalisis, digunakan visualisasi *Wordcloud* dan grafik frekuensi untuk menampilkan sepuluh kata paling dominan. Ini memberikan wawasan terhadap tema utama yang muncul dari kumpulan *tweet*.
- Sentimen dari masing-masing *tweet* dianalisis menggunakan pendekatan berbasis kamus (*lexicon-based*). Tiga kamus utama digunakan, yakni *positive.csv*, *negative.csv*, dan *neutral.csv* untuk memberikan skor berdasarkan jumlah kata yang bersentimen positif, negatif, dan netral.

Hasil analisis kemudian diklasifikasikan ke dalam tiga kategori: positif, negatif, dan netral.

3.4 Labeling Data & Split Data

Pada tahap ini, proses pelabelan dilakukan secara semi otomatis oleh peneliti berdasarkan interpretasi terhadap isi *tweet*, dengan mengklasifikasikannya ke dalam tiga kategori sentimen: positif, negatif, atau netral. Setelah pelabelan, data dibagi menjadi dua bagian: data *training* dan data *testing*, dengan rasio umum 80:20 atau 70:30. Tujuan dari pembagian ini adalah untuk mengevaluasi kemampuan model dalam melakukan generalisasi terhadap data baru dan menghindari overfitting.

3.5 Perancangan Model

Model yang digunakan merupakan model *pre-trained* berbasis IndoBERT, yaitu varian BERT yang secara khusus dilatih menggunakan korpus Bahasa Indonesia, seperti berita online. IndoBERT diambil dari repositori HuggingFace dan dirancang untuk memahami konteks linguistik Bahasa Indonesia secara lebih akurat dibandingkan model Multilingual BERT. Model ini kemudian di *fine-tune* untuk tugas klasifikasi sentimen, dengan menambahkan lapisan klasifikasi berupa dense layer dan fungsi aktivasi softmax di atas arsitektur IndoBERT varian dari BERT.

Pada tahap pelatihan, model menghasilkan *logit* untuk setiap kelas sentimen (positif, negatif, netral). Logit ini kemudian diubah menjadi probabilitas menggunakan fungsi Softmax, sebagaimana dirumuskan berikut:

$$P(y = c|x) = \frac{e^{z_c}}{\sum_{k=1}^K e^{z_k}} \quad 6$$

Keterangan:

- $P(y = c|x)$ = probabilitas bahwa teks x termasuk ke kelas c
- z_c = nilai output (logit) untuk kelas c
- K = jumlah kelas sentimen
- e = bilangan eksponensial

Salah satu keunggulan BERT adalah kemampuannya memahami urutan kata dalam kalimat melalui Positional Encoding. Proses ini memberikan informasi posisi token dalam sebuah urutan sehingga model dapat membedakan kata yang sama tetapi berada pada posisi berbeda. Rumus Positional Encoding dirumuskan sebagai berikut:

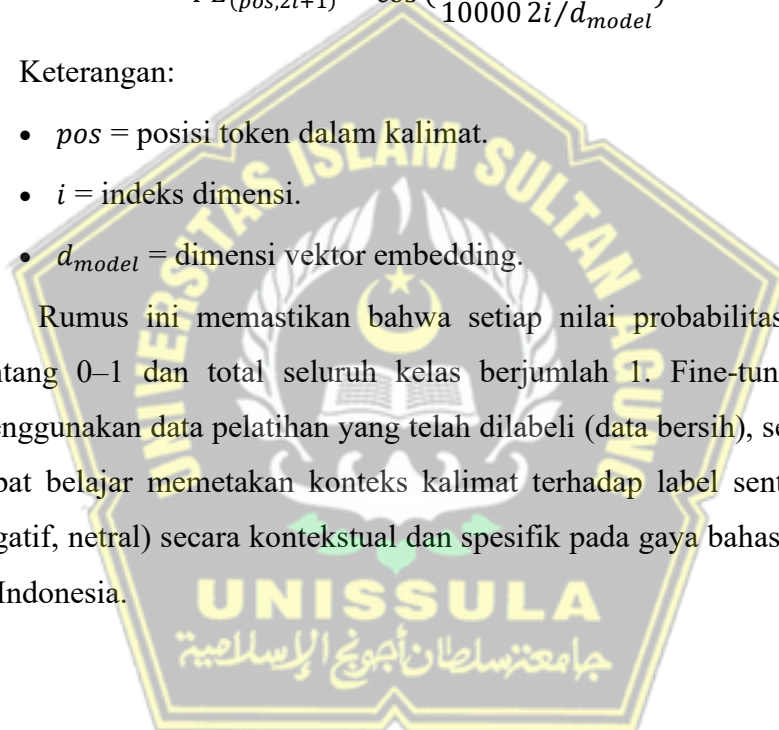
$$PE_{(pos,2i)} = \sin\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad 7$$

$$PE_{(pos,2i+1)} = \cos\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad 8$$

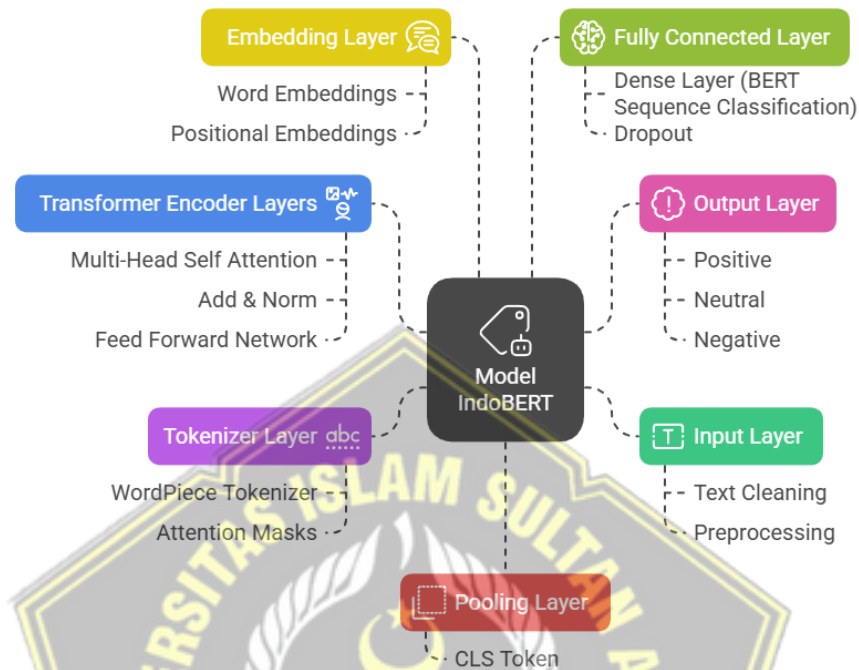
Keterangan:

- pos = posisi token dalam kalimat.
- i = indeks dimensi.
- d_{model} = dimensi vektor embedding.

Rumus ini memastikan bahwa setiap nilai probabilitas berada pada rentang 0–1 dan total seluruh kelas berjumlah 1. Fine-tuning dilakukan menggunakan data pelatihan yang telah dilabeli (data bersih), sehingga model dapat belajar memetakan konteks kalimat terhadap label sentimen (positif, negatif, netral) secara kontekstual dan spesifik pada gaya bahasa media sosial di Indonesia.



Arsitektur Model IndoBERT untuk Analisis Sentimen



Gambar 3.4 Arsitektur model

Gambar 3.4 merupakan proses dalam arsitektur model perancangan ini, secara umum memiliki 7 tahap yang akan diuraikan sebagai berikut :

- 1) **Input Layer (Text Input)** : Lapisan menerima input berupa teks yang telah melalui tahap pre-processing. Data teks berasal dari kolom `clean_text` pada dataset yang sudah diterjemahkan ke Bahasa Indonesia, dinormalisasi, dibersihkan dari tanda baca dan kata tidak baku, serta telah diberi label sentimen. Tahapan ini mencakup pembersihan teks (seperti penghapusan URL, angka, dan tanda baca), normalisasi kata berdasarkan leksikon, penghapusan *stopword*, serta pelabelan sentimen positif, negatif, atau netral. Dataset tersebut kemudian dimuat ke dalam sistem sebagai masukan utama model.
- 2) **Tokenizer Layer (WordPiece Tokenizer)** : Pada tahap ini, teks input diubah menjadi token numerik menggunakan WordPiece Tokenizer dari model IndoBERT. Tokenizer berfungsi untuk memecah kalimat menjadi unit-unit kecil (subword) yang sesuai dengan kosakata model BERT. Setiap token kemudian diberi indeks numerik sehingga dapat diproses oleh model.

Selanjutnya, data hasil tokenisasi dikemas dalam kelas `IndoSentimentDataset` untuk memastikan kompatibilitas dengan format input PyTorch.

3) **Embedding Layer (BERT Embedding)** : Lapisan embedding bertanggung jawab untuk mengonversi token yang telah ditransformasikan menjadi vektor representasi kontekstual menggunakan model `IndoBERT` yang telah dilatih sebelumnya. Pada tahap ini, setiap token mendapatkan embedding yang merepresentasikan makna semantik kata berdasarkan konteksnya dalam kalimat. Representasi ini menjadi dasar bagi pemahaman konteks oleh lapisan-lapisan transformer berikutnya.

4) **Transformer Encoder Layers (IndoBERT Base)** : Lapisan inti model `IndoBERT Base` terdiri dari beberapa encoder berbasis mekanisme self-attention. Setiap encoder mempelajari hubungan antar-token dalam sebuah kalimat sehingga model dapat memahami makna kata secara kontekstual. Proses ini memungkinkan model menangkap nuansa semantik antar kata dan frasa. Lapisan ini bekerja secara otomatis di dalam arsitektur BERT ketika proses forward pass dijalankan.

5) **Pooling Layer (CLS Token Extraction)** : Lapisan pooling bertugas untuk mengambil representasi dari token khusus [CLS] (Classification Token) yang dihasilkan oleh model BERT. Token [CLS] ini dianggap sebagai ringkasan dari seluruh kalimat dan digunakan sebagai input utama bagi lapisan klasifikasi selanjutnya. Proses ekstraksi ini dilakukan secara internal dalam arsitektur `AutoModelForSequenceClassification` yang digunakan oleh `IndoBERT`.

6) **Fully Connected Layer (Dense)** : Lapisan fully connected atau dense menerima vektor hasil ekstraksi token [CLS] dan memprosesnya menjadi representasi fitur yang lebih padat untuk klasifikasi. Lapisan ini berperan dalam memetakan fitur kontekstual ke ruang label sentimen (positif, negatif, atau netral). Selama pelatihan, parameter pada lapisan ini dioptimalkan melalui proses backpropagation dengan mempertimbangkan metrik evaluasi seperti akurasi, presisi, recall, dan F1-score.

7) **Output Layer (Softmax Classifier)** : Lapisan output menggunakan fungsi aktivasi Softmax untuk menghasilkan probabilitas prediksi terhadap setiap

kelas sentimen. Nilai probabilitas tertinggi menunjukkan label sentimen akhir yang diprediksi oleh model. Hasil akhir dari lapisan ini kemudian dievaluasi menggunakan metrik performa seperti akurasi, presisi, recall, F1-score, serta divisualisasikan dalam bentuk confusion matrix dan grafik performa model.

3.6 Pengujian Model

Pengujian dilakukan menggunakan data *testing* yang sebelumnya telah dipisahkan dan tidak pernah dilibatkan dalam proses *training*. Hal ini bertujuan untuk mengevaluasi kemampuan model IndoBERT varian dari BERT, dalam mengklasifikasikan opini publik terhadap kebijakan kampus berdampak secara objektif. Input berupa teks opini baru akan dianalisis oleh model IndoBERT, yang telah di *fine-tune* khusus untuk memahami bahasa informal dan struktur kalimat dalam Bahasa Indonesia. Hasil klasifikasi sentimen dari model kemudian dikategorikan ke dalam sentimen positif, negatif atau netral. Dengan menggunakan IndoBERT, proses pengujian ini lebih mampu menangkap makna kontekstual dan ekspresi khas publik di media sosial X (Twitter), sehingga mendukung generalisasi model terhadap data dunia nyata.

3.7 Evaluasi Model

Evaluasi dilakukan dengan mengukur kinerja model IndoBERT menggunakan metrik akurasi, precision, *recall*, dan *F1-score*. Selain itu, *confusion matrix* digunakan untuk memvisualisasikan distribusi prediksi terhadap kelas sebenarnya, sehingga membantu dalam mengidentifikasi pola kesalahan klasifikasi, khususnya dalam membedakan sentimen positif, negatif, dan netral. Evaluasi dilakukan dengan menggunakan metrik Akurasi, Presisi, *Recall*, dan *F1-score* yang dihitung berdasarkan nilai *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*. Rumus perhitungannya adalah sebagai berikut:

Tabel 3.1 Prediction class

		<i>Prediction Class</i>		
		Positif	Negatif	Netral
<i>Class</i> Sebenarnya	Positif	True Positif (TP)	False Negatif (FN)	False Netral (FNt)
	Negatif	False Positif (FP)	True Negatif (TN)	False Netral (FNt)
	Netral	False Positif (FP)	False Negatif (TN)	True Positif (TNt)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad 9$$

$$Precision = \frac{TP}{TP + FP} \quad 10$$

$$Recall = \frac{TP}{TP + FN} \quad 11$$

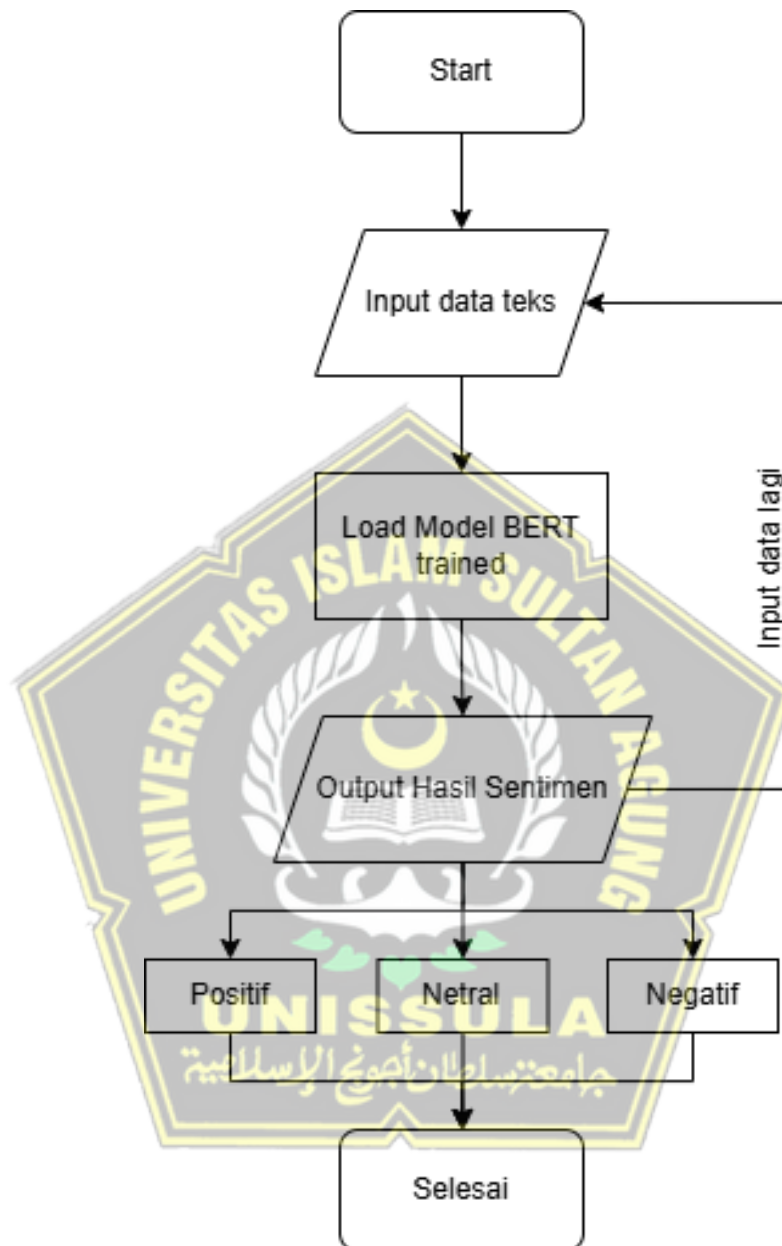
$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad 12$$

Keterangan:

- TP (*True Positive*) = jumlah prediksi positif yang benar.
- TN (*True Negative*) = jumlah prediksi negatif yang benar.
- FP (*False Positive*) = jumlah prediksi positif yang salah.
- FN (*False Negative*) = jumlah prediksi negatif yang salah.

Evaluasi ini dilakukan secara spesifik terhadap model IndoBERT yang telah di-*fine-tune* menggunakan opini masyarakat dalam Bahasa Indonesia, sehingga hasil pengukuran mencerminkan efektivitas model dalam memahami konteks lokal pada media sosial.

3.8 Implementasi Model



Gambar 3. 5 Flowchart alur sistem

Model IndoBERT yang telah melalui proses *fine-tuning* diimplementasikan dalam bentuk aplikasi *web* lokal menggunakan *streamlit*. Model IndoBERT dipilih karena telah dilatih secara khusus pada korpus Bahasa Indonesia, sehingga lebih akurat dalam memahami opini publik yang ditulis dalam konteks bahasa informal di *platform X* (Twitter). Pengguna dapat memasukkan opini secara langsung atau mengunggah dokumen teks yang berisi opini publik tentang “Kampus Berdampak”. Sistem secara otomatis akan

melakukan preprocessing, kemudian memanfaatkan model IndoBERT untuk melakukan klasifikasi sentimen ke dalam kategori positif, negatif, atau netral. Hasil klasifikasi ditampilkan dalam bentuk visualisasi interaktif seperti grafik dan tabel, untuk mempermudah pemahaman, analisis, dan pengambilan keputusan.

Penelitian ini menerapkan metodologi analisis sentimen menggunakan model IndoBERT untuk mengkaji opini publik pada X (Twitter) terkait kebijakan "Kampus Berdampak". Tahapan penelitian diawali dengan pengumpulan data melalui teknik *web scraping* dengan instrumen *tweet-harvest*, di mana proses pengambilan data dilakukan dalam rentang waktu Januari 2025 hingga Agustus 2025 guna memperoleh data yang relevan terhadap dinamika opini pada periode tersebut. Data yang dihimpun kemudian melalui tahapan *preprocessing* secara komprehensif, meliputi *case folding*, translasi, pembersihan teks, normalisasi kata baku, hingga tokenisasi menggunakan *wordpiece tokenizer*. Dataset tersebut selanjutnya digunakan untuk melakukan proses *fine-tuning* pada arsitektur IndoBERT guna mengklasifikasikan sentimen ke dalam kategori positif, negatif, dan netral. Efektivitas model diukur berdasarkan metrik akurasi, *precision*, *recall*, dan *F1-score*, yang pada tahap akhir diimplementasikan ke dalam aplikasi berbasis web menggunakan Streamlit untuk menyajikan visualisasi hasil analisis secara sistematis.

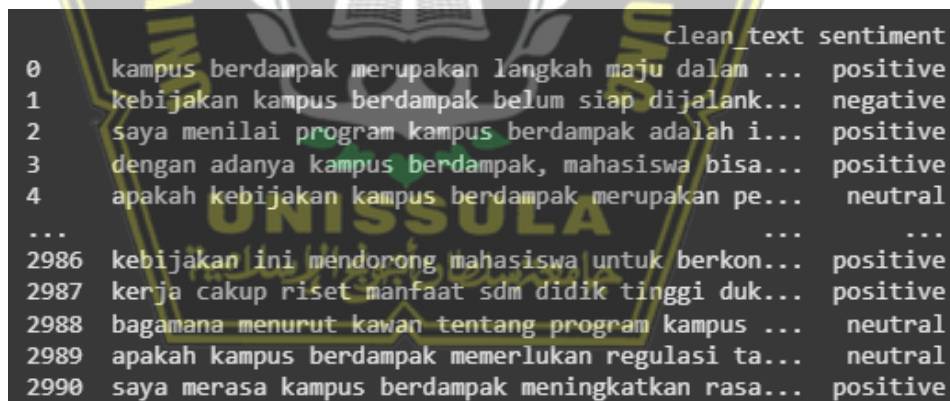
BAB IV

HASIL DAN ANALISIS PENELITIAN

4.1 Hasil Penelitian

4.1.1 Deskripsi Dataset

Pada penelitian ini, data diperoleh melalui proses *web scraping* dari platform media sosial X (Twitter) dengan menggunakan kata kunci yang terkait dengan opini publik mengenai kebijakan Kampus Berdampak. Data hasil scraping disimpan dalam format csv atau xlsx agar lebih mudah diproses pada tahap selanjutnya. Secara keseluruhan, jumlah data mentah yang terkumpul mencapai 4.034 tweet dengan rentang waktu pengumpulan data dari Januari 2025 hingga Agustus 2025. Setelah melalui *pre-processing* dan *filtering*, dataset dibagi menjadi dua bagian: data latih (*training set*) dan data uji (*testing set*). Distribusi kelas sentimen setelah proses pelabelan (*labeling*) adalah positif 2991, negatif 831, dan netral 220.



	clean_text	sentiment
0	kampus berdampak merupakan langkah maju dalam ...	positive
1	kebijakan kampus berdampak belum siap dijalank...	negative
2	saya menilai program kampus berdampak adalah i...	positive
3	dengan adanya kampus berdampak, mahasiswa bisa...	positive
4	apakah kebijakan kampus berdampak merupakan pe...	neutral
...
2986	kebijakan ini mendorong mahasiswa untuk berkon...	positive
2987	kerja cakup riset manfaat sdm didik tinggi duk...	positive
2988	bagaimana menurut kawan tentang program kampus ...	neutral
2989	apakah kampus berdampak memerlukan regulasi ta...	neutral
2990	saya merasa kampus berdampak meningkatkan rasa...	positive

Gambar 4.1 Informasi dataset

Gambar 4.1 memperlihatkan sampel dataset setelah melalui tahap *pre-processing*, sehingga dapat memberikan gambaran mengenai struktur data yang digunakan dalam pelatihan model IndoBERT.

4.1.2 Data Preprocessing

4.1.2.1 Data Cleaning

Pada proses *pre-processing*, salah satu tahapan yang dilakukan adalah pembersihan data (*data cleaning*). Langkah ini bertujuan menghilangkan komponen yang tidak relevan dari dataset. Sebelum pembersihan, data masih memuat tanda baca yang tidak diperlukan seperti hashtag terkait kampus berdampak, mbkm serta hashtag lain, penggunaan huruf kapital yang tidak seragam, serta adanya spasi berlebih. Setelah melalui proses *data cleaning*, seluruh tanda baca dihapus kecuali tanda tanya (?), huruf diubah seluruhnya menjadi huruf kecil, dan spasi ganda dihilangkan. Perbandingan kondisi dataset sebelum dan sesudah pembersihan ditampilkan pada Tabel 4.1, dan gambar 4.2 menampilkan dataset sebelum pembersihan.

```

0 Kampus berdampak merupakan langkah maju dalam meningkatkan kualitas pendidikan tinggi #kampusberdampak #mbkm #kampusmerdeka
1 Kebijakan kampus berdampak belum siap dijalankan karena fasilitas kampus tidak mendukung #kampusberdampak #mbkm #kampusmerdeka
2 Saya menilai program kampus berdampak adalah inovasi positif dari pemerintah dan kampus #kampusberdampak #mbkm #kampusmerdeka
3 Dengan adanya kampus berdampak, mahasiswa bisa lebih peduli terhadap lingkungan sekitar #kampusberdampak #mbkm #kampusmerdeka
4 Apakah kebijakan kampus berdampak merupakan pengembangan dari program kampus merdeka? #kampusberdampak #mbkm #kampusmerdeka
  
```

Gambar 4. 2 Dataset sebelum pembersihan

Tabel 4.1 *Data Cleaning*

Sebelum <i>Cleaning Data</i>	Sesudah <i>Cleaning Data</i>
Sudah baik	sudah baik
Kampus berdampak merupakan langkah maju dalam meningkatkan kualitas pendidikan tinggi. #kampusberdampak #mbkm #kampusmerdeka	kampus berdampak merupakan langkah maju dalam meningkatkan kualitas pendidikan tinggi
Bagus	Bagus
Kebijakan kampus berdampak belum siap dijalankan karena fasilitas kampus tidak mendukung. #kampusberdampak #mbkm #kampusmerdeka	baik cuman kurang nya fasilitas kipas angin dalam satu kamar sehingga membuat kamar jadi panas
Saya menilai program kampus berdampak adalah inovasi positif dari pemerintah dan kampus #kampusberdampak #mbkm	saya menilai program kampus berdampak adalah inovasi positif dari pemerintah dan kampus

#kampusmerdeka	
Dengan adanya kampus berdampak, mahasiswa bisa lebih peduli terhadap lingkungan sekitar #kampusberdampak #mbkm #kampusmerdeka	dengan adanya kampus berdampak, mahasiswa bisa lebih peduli terhadap lingkungan sekitar
Apakah kebijakan kampus berdampak merupakan pengembangan dari program kampus merdeka? #kampusberdampak #mbkm #kampusmerdeka	apakah kebijakan kampus berdampak merupakan pengembangan dari program kampus merdeka?
Kebijakan ini mendorong mahasiswa untuk berkontribusi nyata dalam pembangunan lokal. #kampusberdampak #mbkm #kampusmerdeka	kebijakan ini mendorong mahasiswa untuk berkontribusi nyata dalam pembangunan lokal
Kerja cakup riset manfaat sdm didik tinggi dukung bijak strategis dirut pt pindad sinergi tingkat ilmu tahu teknologi kualitas sdm indonesia #kampusberdampak #mbkm #kampusmerdeka	kerja cakup riset manfaat sdm didik tinggi dukung bijak strategis dirut pt pindad sinergi tingkat ilmu tahu teknologi kualitas sdm indonesia
Bagaimana menurut kawan tentang program kampus berdampak ? #kampusberdampak #mbkm #kampusmerdeka	Bagaimana menurut kawan tentang program kampus berdampak ?

Proses *data cleaning* dilakukan pada teks komentar hasil *scraping* dari platform X (Twitter) yang berhubungan dengan kebijakan Kampus Berdampak. Tahap ini berfokus pada kolom *clean_text* yang digunakan sebagai input bagi model BERT. Pembersihan data dilakukan untuk menghilangkan komponen yang tidak relevan seperti tanda baca berlebih, emoji, URL, mention (@), serta hashtag (#) yang sering muncul pada unggahan Twitter namun tidak memberikan kontribusi langsung terhadap analisis sentimen. Selain itu, seluruh karakter selain huruf, angka, dan spasi dihapus, kemudian teks diubah menjadi huruf kecil (*lowercase*) agar memiliki format yang seragam. Spasi ganda juga dihilangkan untuk merapikan struktur teks.

```

                                clean_text sentiment
0      kampus berdampak merupakan langkah maju dalam ... positive
1      kebijakan kampus berdampak belum siap dijalank... negative
2      saya menilai program kampus berdampak adalah i... positive
3      dengan adanya kampus berdampak, mahasiswa bisa... positive
4      apakah kebijakan kampus berdampak merupakan pe... neutral

```

Gambar 4. 3 Hasil data cleaning

Perbandingan kondisi data sebelum dan sesudah proses *data cleaning* dapat dilihat pada Gambar 4.2 dan 4.3. Untuk memberikan gambaran yang lebih jelas, dua contoh hasilnya disajikan pada Tabel 4.1.

4.1.2.2 Labeling & Split Data

Pada proses *labeling*, dilakukan secara semi otomatis dengan membaca kalimat atau komentar satu persatu untuk melihat apakah masih ada duplikat beserta hasil sentimen positif, negatif, atau netral sudah sesuai atau belum. Kategori pelabelan meliputi kalimat positif, negatif dan netral berdasarkan kata di kolom “clean_text”.

```

                                clean_text sentiment
0      kampus berdampak merupakan langkah maju dalam ... positive
1      kebijakan kampus berdampak belum siap dijalank... negative
2      saya menilai program kampus berdampak adalah i... positive
3      dengan adanya kampus berdampak, mahasiswa bisa... positive
4      apakah kebijakan kampus berdampak merupakan pe... neutral
...
2986  kebijakan ini mendorong mahasiswa untuk berkon... positive
2987  kerja cakup riset manfaat sdm didik tinggi duk... positive
2988  bagaimana menurut kawan tentang program kampus ... neutral
2989  apakah kampus berdampak memerlukan regulasi ta... neutral
2990  saya merasa kampus berdampak meningkatkan rasa... positive

```

Gambar 4. 4 Hasil Labeling dataset

Gambar 4.4 merupakan hasil dari *labelling* data pada kolom “sentiment”, tahap labelling data dilakukan dengan semi-otomatis menggunakan menggunakan *library* pandas untuk memproses dan menganalisis data, dengan tujuan utama memberikan label sentimen (positif, negatif, atau netral) pada teks yang sudah dibersihkan (clean_text) dalam DataFrame. Proses dimulai dengan fungsi `load_lexicon` yang membaca dua file CSV (*positive.csv* dan *negative.csv*) pada file base dataset utama, berisi daftar kata-kata positif dan negatif beserta skornya, kemudian mengubahnya menjadi kamus Python untuk memudahkan pencarian skor sentimen. Setelah dilakukan labelling secara otomatis, masih banyak kata yang belum sesuai

4.1.2.4 Visualisasi Akhir *Wordcloud*

Proses visualisasi *Wordcloud* diawali dengan tahap tokenisasi, yaitu memecah teks hasil normalisasi menjadi potongan kata agar lebih mudah dianalisis. Selanjutnya dilakukan *stopword removal* dengan memanfaatkan daftar *stopword* bawaan dari *library Wordcloud* yang diperluas menggunakan custom *stopword* sesuai kebutuhan penelitian, sehingga kata-kata yang tidak memiliki makna penting dapat dihapus. Setelah itu, seluruh kata hasil pembersihan digabungkan menjadi satu korpus besar untuk merepresentasikan keseluruhan data. Tahap terakhir adalah pembuatan dan visualisasi *Wordcloud* dengan pengaturan tertentu seperti latar belakang putih, jumlah maksimum kata, serta ukuran visualisasi, kemudian ditampilkan menggunakan *matplotlib*, di mana ukuran kata mencerminkan frekuensi kemunculannya dalam dataset.



Gambar 4. 6 Visualisasi Wordcloud setelah stopword removal

Hasil *Wordcloud* menunjukkan kata-kata dominan seperti “kampus berdampak”, “pendidikan”, “tinggi”, “indonesia”, “mahasiswa”, dan “masa depan”. Hal ini menegaskan bahwa topik utama diskusi publik di media sosial berfokus pada kebijakan Kampus Berdampak serta kaitannya dengan pendidikan tinggi dan masa depan mahasiswa.

4.1.3 Eksperimen Model

Dalam proses pelatihan model IndoBERT pada penelitian ini, dilakukan tahap *Hyperparameter tuning* untuk menentukan konfigurasi

parameter terbaik yang dapat meningkatkan kinerja model dalam klasifikasi sentimen. *Hyperparameter tuning* sangat penting karena setiap parameter berpengaruh langsung terhadap hasil akhir pelatihan, baik dari segi akurasi, efisiensi, maupun generalisasi model. Adapun hasil pengaturan *hyperparameter* yang digunakan dalam eksperimen ditunjukkan pada tabel berikut:

Tabel 4.2 *Hyperparameter tuning*


No	<i>Hyperparameter</i>	Ukuran
1.	Batch Size	32
2.	Learning Rate	5e-05
3.	<i>Epoch</i>	5
4.	Max_length	256

Kombinasi hyperparameter di atas dipilih berdasarkan hasil eksperimen yang menunjukkan performa optimal pada data *imBalance* maupun setelah dilakukan balancing. Dengan batch size 32, proses pelatihan berjalan stabil; learning rate 5e-05 memungkinkan pembaruan bobot secara bertahap dan lebih akurat; jumlah *epoch* 5 sudah cukup untuk mencapai konvergensi; serta max length 256 menjaga konteks ulasan agar tetap terwakili secara utuh. Oleh karena itu, konfigurasi ini dinilai paling sesuai untuk menghasilkan model IndoBERT yang efektif dalam menganalisis sentimen publik terkait kebijakan Kampus Berdampak.

4.2 Hasil Perancangan Model

4.2.1 Data *ImBalance*

Hasil eksperimen pada dataset *ImBalance* yang telah dilakukan dengan menggunakan *hyperparameter batch size 32, learning rate 5e-05, epoch 5, serta max length 256* dapat dilihat pada gambar 4.7.



Gambar 4.7 Loss curve (Data ImBalance)

Gambar 4.7 memperlihatkan grafik *Training Loss*, *Validation Accuracy*, dan *Test Accuracy* pada model yang dilatih dengan data tidak seimbang. Kurva *Training Loss* menunjukkan penurunan signifikan dari *epoch* pertama hingga *epoch* kelima, menandakan bahwa model mampu mempelajari pola dari data dengan baik. Sementara itu, *Validation Accuracy* meningkat secara stabil hingga mendekati 0.85. Garis hijau yang merepresentasikan *Test Accuracy* menunjukkan nilai sebesar 0.878, yang menandakan performa model tergolong baik. Namun, perlu dicatat bahwa nilai akurasi ini masih bisa menutupi ketidakseimbangan prediksi antar kelas, karena data yang dominan (kelas positif dan negatif) lebih mudah dipelajari oleh model dibandingkan kelas netral yang jumlah datanya lebih sedikit.

```

=== Classification Report (Validation Set) ===
      precision    recall  f1-score   support

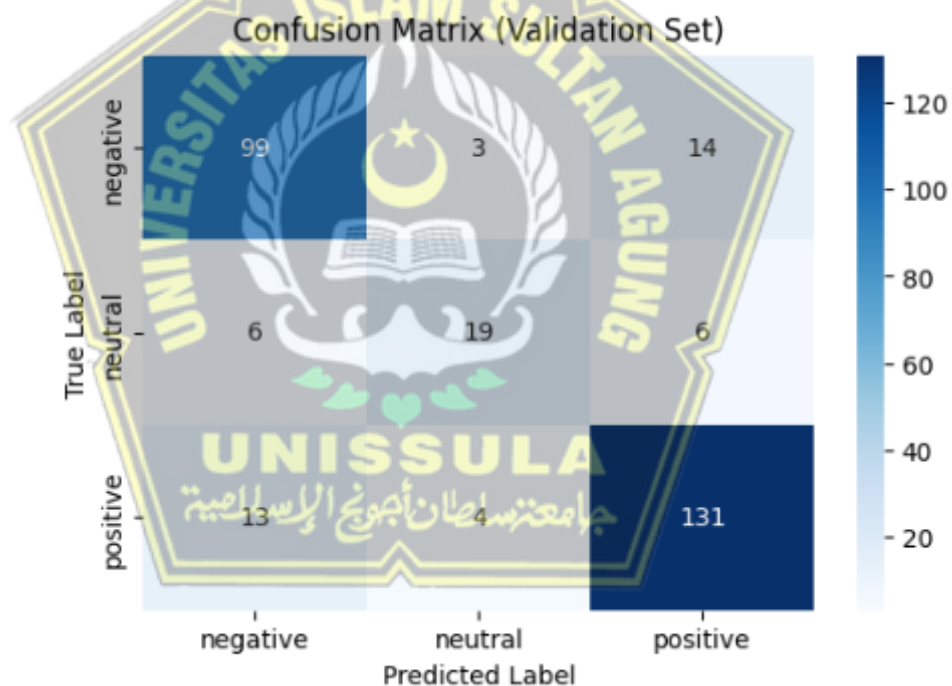
 negative         0.84         0.85         0.85         116
  neutral         0.73         0.61         0.67          31
 positive         0.87         0.89         0.88         148

 accuracy                   0.84         295
 macro avg         0.81         0.78         0.80         295
 weighted avg         0.84         0.84         0.84         295

```

Gambar 4.8 Classification report (Data ImBalance)


Gambar 4.8 merupakan *Classification report* yang menampilkan metrik evaluasi berupa *precision*, *recall*, dan *f1-score* untuk masing-masing kelas. Hasilnya memperlihatkan bahwa kelas *negative* dan *positive* memiliki nilai *precision* dan *recall* yang tinggi (sekitar 0.84–0.89), sehingga kinerja model pada kedua kelas tersebut dapat dikatakan sangat baik. Sebaliknya, kelas *neutral* memiliki performa jauh lebih rendah dengan nilai *recall* hanya 0.61 dan *f1-score* 0.67. Hal ini menunjukkan bahwa model kesulitan mengenali tweet dengan sentimen netral akibat jumlah data yang jauh lebih sedikit dibandingkan dua kelas lainnya. Rata-rata keseluruhan (*accuracy* 0.84) memang terlihat tinggi, namun terjadi ketidakseimbangan performa antar kelas, yang menjadi indikasi utama adanya dampak *data imbalance*.



Gambar 4.9 *Confusion matrix* (Data *ImBalance*)


Gambar 4.9 menunjukkan *confusion matrix* pada data validasi. Dari visualisasi tersebut terlihat jelas bahwa kelas *negative* (116 data) dan *positive* (148 data) mampu diprediksi dengan cukup akurat, masing-masing dengan 99 dan 131 prediksi benar. Namun pada kelas *neutral* (31 data), jumlah prediksi benar hanya 19, sementara sisanya banyak salah terklasifikasi menjadi *negative* maupun *positive*. Kondisi ini memperkuat hasil pada

classification report, yaitu bahwa kelas dengan jumlah data lebih sedikit (*neutral*) menjadi paling rentan salah prediksi, sehingga menunjukkan kelemahan model akibat distribusi data yang tidak seimbang.



Gambar 4.10 Model *evaluation metrics* (Data ImBalance)

Gambar 4.10 memperlihatkan Model *Evaluation Metrics (Validation Set)* berupa *accuracy*, *precision*, *recall*, dan *f1-score*. Keempat metrik tersebut menunjukkan nilai yang relatif seimbang, berada pada kisaran 0.842–0.844. Secara sekilas, hal ini mengindikasikan bahwa model memiliki kinerja yang stabil dan konsisten dalam melakukan klasifikasi. Namun, sama seperti temuan pada Gambar 4.9 dan 4.10, nilai rata-rata yang tinggi ini tetap belum mampu menggambarkan kelemahan mendasar model terhadap kelas minoritas (*neutral*). Dengan kata lain, meskipun metrik makro (keseluruhan) terlihat baik, adanya perbedaan signifikan antar kelas masih tersembunyi di balik nilai agregat tersebut.



Gambar 4.11 True labels & Classified Labels (Data ImBalance)

Gambar 4.11 menunjukkan distribusi label sebenarnya (*True Labels*) dibandingkan dengan label hasil prediksi model (*Classified Labels*) pada data validasi. Pada kelas *negative* dan *positive*, terlihat bahwa jumlah prediksi model hampir mendekati distribusi sebenarnya, menandakan model mampu mempelajari pola dari kedua kelas tersebut dengan baik. Akan tetapi, pada kelas *neutral* perbedaan cukup jelas terlihat: jumlah prediksi yang dihasilkan lebih sedikit dibandingkan dengan label sebenarnya. Hal ini memperkuat analisis sebelumnya bahwa model masih kesulitan mengenali sentimen *neutral* sehingga cenderung salah mengklasifikasikannya menjadi *negative* atau *positive*.

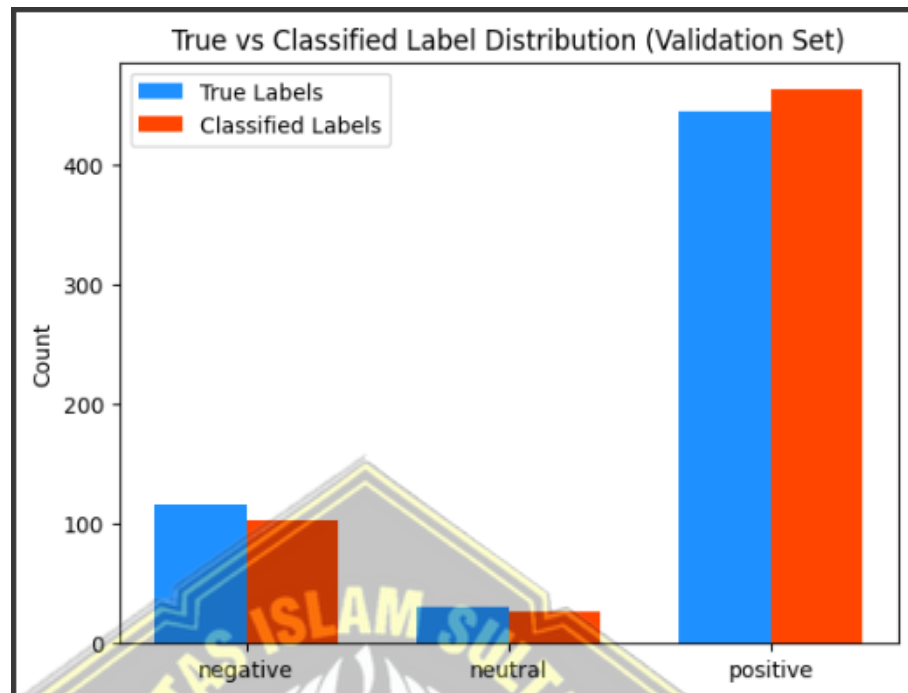
Kelemahan model dalam mengenali kelas *neutral* dapat menimbulkan bias analisis, karena sentimen ragu atau ambivalen mahasiswa justru salah terbaca sebagai dukungan atau penolakan. Akibatnya, kebijakan kampus berpotensi diambil tanpa mempertimbangkan kelompok mahasiswa yang sebenarnya bersikap netral. Untuk mengatasinya, oversampling data dilakukan dengan memperbanyak sentimen positif, sehingga distribusi data lebih condong ke arah sentimen positif dibandingkan negatif maupun netral.

Dengan ini, model diharapkan lebih peka dalam mengenali komentar yang mendukung kebijakan kampus berdampak.

Hal ini dapat terjadi karena model lebih banyak belajar dari kelas dengan jumlah data dominan, sementara kelas dengan jumlah data yang lebih sedikit tidak cukup memberikan representasi yang memadai untuk ditangkap oleh model.

4.2.2 Data Balance

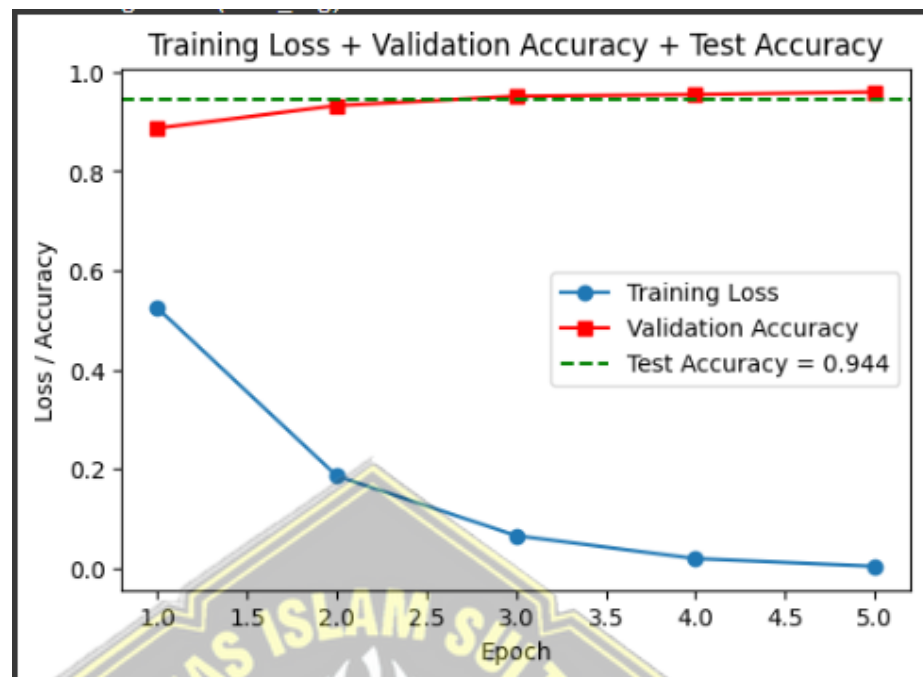
Dikarenakan terdapat ketidakseimbangan distribusi data untuk setiap kelas pada dataset, dapat berpengaruh pada kinerja model. Model yang dilatih dengan data yang tidak seimbang akan cenderung mengklasifikasikan kelas mayoritas secara berlebihan dan mengabaikan kelas minoritas, sehingga akan mengakibatkan banyak kesalahan klasifikasi. Selain itu, distribusi data yang tidak seimbang juga dapat mengakibatkan *overfitting*. *Overfitting* merupakan kondisi dimana model memiliki kinerja yang baik terhadap data *training*, namun tidak pada data *testing*. Oleh karena itu, pada penelitian ini dilakukan penyeimbangan data *training* menggunakan *Random Over Sampler* sebelum data digunakan untuk pelatihan model. *Random Over Sampler* melakukan oversampling pada kelas minoritas dengan cara menggandakan data yang sudah ada agar jumlah datanya menjadi seimbang dengan kelas mayoritas. Hasil dari proses *balancing* ini ditunjukkan pada Gambar 4.12.



Gambar 4.12 True labels & *Classified Labels* (Data Labels)


Gambar 4.12 menunjukkan distribusi *true Labels* dan *Classified Labels* pada data validasi menunjukkan kesesuaian yang cukup tinggi. Untuk kelas *negative* dan *neutral*, jumlah prediksi mendekati distribusi label sebenarnya meskipun terdapat sedikit perbedaan. Pada kelas *positive*, jumlah prediksi sedikit lebih banyak dibandingkan distribusi sebenarnya, namun tetap sejalan dengan proporsi mayoritas. Hasil ini menunjukkan bahwa balancing data berhasil membuat model lebih adil dalam mempelajari pola dari tiap kelas, sehingga distribusi prediksi lebih proporsional dibandingkan pada kondisi data *ImBalance*.

Hasil eksperimen pada dataset yang sudah melalui proses balancing dapat dilihat pada gambar 4.13.



Gambar 4.13 Loss curve (Data Balance)

Gambar 4.13 menunjukkan grafik *Training Loss*, *Validation Accuracy*, dan *Test Accuracy* pada model yang dilatih dengan data yang sudah di-Balance. Terlihat bahwa *Training Loss* mengalami penurunan tajam sejak *epoch* pertama hingga *epoch* kelima, mendekati angka 0 yang menandakan model semakin baik dalam mempelajari pola data. *Validation Accuracy* juga meningkat stabil dari sekitar 0.89 hingga hampir 0.96. Garis hijau yang mewakili *Test Accuracy* menunjukkan nilai sebesar 0.944, lebih tinggi dibandingkan pada kondisi data ImBalance sebelumnya. Hal ini mengindikasikan bahwa proses balancing data berdampak signifikan terhadap peningkatan performa model.



Gambar 4.14 Model evaluation metrics (Data Balance)

Evaluasi metrik model pada data validasi memperlihatkan nilai yang hampir seimbang antara accuracy, precision, *recall*, dan f1-score, masing-masing berada pada kisaran 0.958–0.959. Keseragaman nilai ini menandakan model bekerja konsisten dan tidak bias terhadap kelas tertentu. Hal ini berbeda dengan kondisi *ImBalance* sebelumnya, di mana terjadi kesenjangan kinerja antar kelas, khususnya pada kelas *neutral*.

Setelah proses pelatihan dilakukan, tahap selanjutnya yaitu proses menguji performa model. Hasil dari implementasi model terhadap data training dan data testing menunjukkan hasil *accuracy*, *precision*, *recall* dan *f1-score* dari dataset *ImBalance* yang diperoleh ditunjukkan pada gambar 4.9.

```

=== Classification Report ===
              precision    recall  f1-score   support

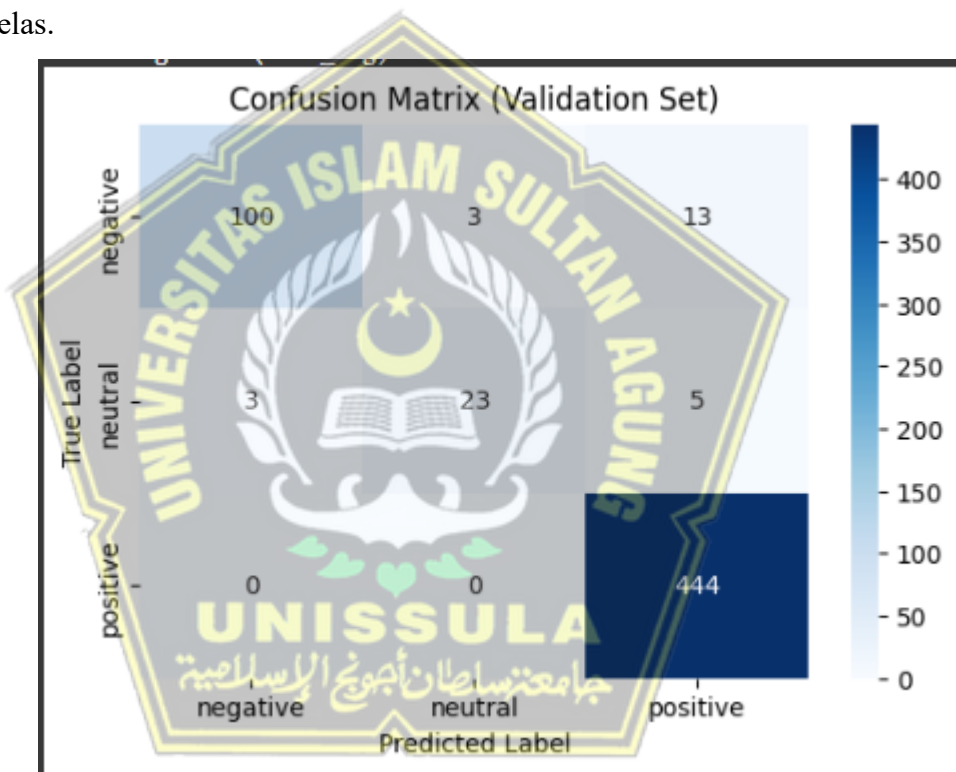
negative     0.96      0.89      0.92       116
neutral      0.92      0.74      0.82        31
positive     0.97      1.00      0.98       444

accuracy                0.96       591
macro avg              0.95      0.88      0.91       591
weighted avg           0.96      0.96      0.96       591

```

Gambar 4.15 Classification report (Data Balance)

Pada gambar 4.9 *Classification report* memperlihatkan hasil evaluasi model pada data validasi. Kelas *positive* memiliki performa sangat tinggi dengan *precision* 0.96, *recall* 1.00, dan *f1-score* 0.98. Kelas *negative* juga cukup baik dengan *precision* 0.97 dan *f1-score* 0.91 meskipun *recall* lebih rendah (0.86). Sedangkan kelas *neutral* mengalami peningkatan performa signifikan dibandingkan kondisi data *ImBalance*, dengan *recall* 0.74 dan *f1-score* 0.81. Secara keseluruhan, model mencapai *accuracy* 0.96 dengan *macro average f1-score* 0.90, yang menandakan performa model merata di seluruh kelas.



Gambar 4.16 Confusion matrix (Data Balance)

Pada gambar 4.10 menunjukkan bahwa confusion matrix memberikan gambaran detail prediksi pada masing-masing kelas. Dari total 116 data kelas *negative*, sebanyak 100 diprediksi benar, sementara 13 salah diklasifikasikan sebagai *positive*. Untuk kelas *neutral*, dari 31 data terdapat 23 prediksi benar, sisanya salah diprediksi sebagai *negative* maupun *positive*. Pada kelas *positive*, semua 444 data berhasil diprediksi dengan benar tanpa kesalahan. Hal ini menegaskan bahwa balancing data membantu meningkatkan

ketepatan klasifikasi, terutama pada kelas *neutral* yang sebelumnya sering salah prediksi.

Balancing data berhasil meningkatkan performa model dibandingkan kondisi *ImBalance*, terutama dalam mengenali kelas *neutral*. Selain itu, distribusi prediksi menjadi lebih proporsional meskipun kelas positif tetap dominan sesuai tujuan penelitian.

4.3 Hasil Implementasi *Streamlit*

Hasil dari pemodelan yang telah dilakukan sebelumnya menggunakan model IndoBERT kemudian diimplementasikan ke dalam sebuah sistem berbasis web dengan framework *streamlit*. Sistem ini dibuat agar pengguna dapat secara langsung melakukan analisis sentimen dengan memasukkan komentar terkait kebijakan Kampus Berdampak. Implementasi sistem ini ditampilkan melalui beberapa tampilan antarmuka yang dapat dilihat pada gambar berikut.



Gambar 4.17 Tampilan awal *streamlit*

Gambar 4.17 menunjukkan tampilan awal dari aplikasi web berbasis *Streamlit* yang dibuat untuk menganalisis sentimen publik terhadap kebijakan Kampus Berdampak. Pada halaman utama terdapat kolom input teks di mana pengguna dapat menuliskan komentar terkait kebijakan kampus. Selain itu, pada bagian sebelah kiri tersedia menu navigasi yang berisi beberapa pilihan, yaitu *Analisis Sentimen*, *Wordclouds*, *Grafik*, dan *More Information*. Menu ini memudahkan pengguna untuk berpindah antar fitur sesuai kebutuhan.



Gambar 4.18 Inputan text komentar

Gambar 4.18 memperlihatkan proses ketika pengguna memasukkan komentar ke dalam kolom input. Pada contoh ini, pengguna menuliskan komentar positif: “kampus berdampak merupakan langkah maju dalam meningkatkan kualitas pendidikan tinggi”. Setelah itu, pengguna dapat menekan tombol *Analisis Sentimen Terhadap Komentar* untuk memproses input. Hasil dari analisis sentimen akan ditampilkan secara otomatis oleh sistem.



Gambar 4.19 Hasil analisis sentimen negatif

Gambar 4.19 menunjukkan hasil dari analisis sentimen terhadap komentar yang bersifat negatif. Pada contoh ini, komentar yang dimasukkan adalah: “kampus berdampak hanya menambah birokrasi tanpa manfaat yang nyata”. Kemudian sistem berhasil mendeteksi komentar tersebut sebagai *negative*.



Gambar 4.20 Hasil sentimen positif

Gambar 4.20 menampilkan hasil analisis terhadap komentar yang bersifat positif. Komentar yang digunakan adalah: “kampus berdampak merupakan langkah maju dalam meningkatkan kualitas pendidikan tinggi” sistem kemudian mengklasifikasikan sentimen tersebut sebagai *positive*.



Gambar 4.21 Hasil sentimen netral

Gambar 4.21 memperlihatkan hasil analisis terhadap komentar yang bersifat netral. Pada contoh ini, komentar yang dimasukkan adalah: “apakah kebijakan kampus berdampak merupakan pengembangan dari program kampus merdeka?”. Kemudian sistem mengidentifikasi komentar tersebut sebagai *neutral*.

Berdasarkan hasil penelitian dan implementasi yang telah dipaparkan, dapat disimpulkan bahwa analisis sentimen terhadap kebijakan Kampus Berdampak sebagai kelanjutan dari kebijakan Merdeka Belajar Kampus Merdeka (MBKM) berhasil dilaksanakan secara komprehensif. Data penelitian diperoleh melalui web scraping platform X (Twitter) pada periode

Januari hingga Agustus 2025, dengan total 4.034 tweet yang setelah melalui proses preprocessing dan pelabelan menghasilkan distribusi sentimen positif sebanyak 2.991 data, sentimen negatif 831 data, dan sentimen netral 220 data. Distribusi ini menunjukkan bahwa opini publik cenderung memberikan respons positif terhadap kebijakan Kampus Berdampak. Hasil eksperimen menggunakan model IndoBERT menunjukkan bahwa ketidakseimbangan data berpengaruh terhadap performa model, khususnya pada kelas netral, namun setelah dilakukan penyeimbangan data menggunakan Random Over Sampler, kinerja model meningkat secara signifikan dan lebih merata pada seluruh kelas sentimen. Model terbaik selanjutnya berhasil diimplementasikan ke dalam aplikasi berbasis web berbasis Streamlit, sehingga sistem mampu melakukan analisis sentimen secara interaktif dengan tingkat akurasi yang tinggi.



BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa komentar publik terhadap kebijakan Kampus Berdampak menunjukkan kecenderungan respons yang dominan positif, yang dapat diartikan bahwa kebijakan Kampus Berdampak secara umum dipersepsikan sebagai kebijakan yang baik. Distribusi ini menunjukkan bahwa opini publik cenderung memberikan respons positif terhadap kebijakan Kampus Berdampak. Namun, distribusi data yang tidak seimbang tetap memengaruhi kinerja model, khususnya dalam mengenali kelas netral yang memiliki jumlah data paling sedikit, sehingga pada kondisi *ImBalance* model cenderung salah mengklasifikasikan sentimen netral. Setelah dilakukan proses penyeimbangan data menggunakan metode Random Over Sampler, performa model mengalami peningkatan yang signifikan dan lebih merata pada seluruh kelas sentimen, dengan nilai akurasi sebesar 96%, *precision* 96%, *recall* 96%, dan *f1-score* 96%. Model IndoBERT yang digunakan terbukti mampu bekerja dengan baik dalam mengklasifikasikan komentar ke dalam kategori positif, negatif, dan netral. Selain itu, implementasi model ke dalam sistem berbasis web menggunakan Streamlit berhasil dilakukan sehingga dapat memudahkan pengguna dalam melakukan analisis sentimen secara interaktif.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan saran untuk penelitian selanjutnya yaitu :

1. Meskipun sistem yang dikembangkan pada penelitian ini telah menunjukkan kinerja yang sangat baik dengan nilai akurasi, precision, recall, dan f1-score masing-masing sebesar 96%, ruang lingkup analisis masih terbatas pada komentar publik terkait kebijakan Kampus Berdampak. Oleh karena itu, penelitian selanjutnya

disarankan untuk mengembangkan sistem agar mampu menganalisis komentar dari topik kebijakan lain yang lebih beragam, sehingga hasil analisis sentimen menjadi lebih luas dan komprehensif.

2. Penelitian selanjutnya disarankan untuk menggunakan dataset dengan jumlah yang lebih besar dan variasi yang lebih beragam guna meningkatkan kemampuan generalisasi model, sehingga model menjadi lebih robust dalam mengenali pola sentimen pada berbagai konteks dan gaya bahasa.
3. Untuk meningkatkan kualitas model, penelitian berikutnya diharapkan dapat menerapkan strategi tambahan dalam mengatasi potensi overfitting, seperti penggunaan teknik regularisasi, early stopping, atau penyesuaian arsitektur dan parameter model.
4. Mengingat model pada penelitian ini dilatih dengan jumlah epoch yang relatif terbatas, penelitian selanjutnya disarankan untuk melakukan eksplorasi jumlah epoch yang lebih optimal guna memperoleh keseimbangan terbaik antara performa model dan kemampuan generalisasi terhadap data baru. karena keterbatasan spesifikasi perangkat, sehingga penelitian berikutnya diharapkan dapat menggunakan perangkat dengan spesifikasi yang lebih tinggi agar pelatihan model dapat dilakukan secara optimal.

DAFTAR PUSTAKA

- Amini, A. *dkk.* (2023) "Generating Text from Language Models," *Proceedings of the Annual Meeting of the Association for Computational Linguistics*, 6, hal. 27–31. Tersedia pada: <https://doi.org/10.18653/v1/2023.acl-tutorials.4>.
- Analisis, S. dan Kuantitatif, R. (tanpa tanggal) "Pengaruh Penggunaan Akun X @drhaltekehalte Terhadap Pemenuhan Kebutuhan Tempat Kuliner Followers," (X), hal. 195–216.
- Apri Wenando, F. (2023) "Analisis Opini Publik Terhadap Undang-Undang KUHP Tahun 2022 Menggunakan Algoritma Naïve Bayes Classifier," *Jurnal Fasilkom*, 13(02), hal. 334–339. Tersedia pada: <https://doi.org/10.37859/jf.v13i02.5670>.
- Arifin, M.Z. *dkk.* (2024) "Analyzing the Indonesian sentiment to rohingya refugees using IndoBERT model," 8(2), hal. 180–191.
- Arista, D., Sibaroni, Y. dan Prasetyo, S.S. (2024) "Sentiment Analysis on Twitter(X) Related to Relocating the National Capital using the IndoBERT Method using Extraction Features of Chi-Square," *Jurnal Media Informatika Budidarma*, 8(1), hal. 403. Tersedia pada: <https://doi.org/10.30865/mib.v8i1.7198>.
- Ashraf, M.R. *dkk.* (2023) "BERT-Based Sentiment Analysis for Low-Resourced Languages: A Case Study of Urdu Language," *IEEE Access*, 11(September), hal. 110245–110259. Tersedia pada: <https://doi.org/10.1109/ACCESS.2023.3322101>.
- Aulia, S.N. dan Dewi, D.A. (2021) "Pengaruh Pendidikan Kewarganegaraan Dalam Membangun Karakter Generasi Muda," *Jurnal Kewarganegaraan*, 5(1), hal. 268–275. Tersedia pada: <https://doi.org/10.31316/jk.v5i1.1354>.
- Cahyaningsih, D.S., Taufiqurrahman, T. dan Sulaksono, A.G. (2021) "Using of the Learning Management System on motivation and learning outcomes in the 'Merdeka Belajar Kampus Merdeka' Program," *Jurnal Penelitian*, 18(2), hal. 1–11. Tersedia pada: <https://doi.org/10.26905/jp.v18i2.7047>.
- Cipta, S.P. dan Adini, M.H. (2024) "Analisis Sentimen pada Aplikasi Pinjaman

- Online Easycash Menggunakan Algoritma Naïve Bayes di Media Sosial Twitter,” 7(4), hal. 981–988.
- Das, R.K. dan Pedersen, D.T. (2024) “SemEval-2017 Task 4: Sentiment Analysis in Twitter using BERT.” Tersedia pada: <http://arxiv.org/abs/2401.07944>.
- Elvika Alya Junita, R.R.S. (2019) “Analisis Sentimen Hate Speech Mengenai Calon WakilPresiden Indonesia Menggunakan Algoritma Bert,” *JIPi (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 8(3), hal. 1–13.
- Fahira, D. dan Yulianita, N. (2022) “Hubungan antara Penggunaan Media Sosial Twitter dengan Keterbukaan Diri Mahasiswa,” *Bandung Conference Series: Public Relations*, 2(1), hal. 166–173. Tersedia pada: <https://doi.org/10.29313/bcspr.v2i1.505>.
- Fariq, M., Attruk, H. dan Mujahidah, N.U. (tanpa tanggal) “IMPLEMENTATION OF CHARACTER EDUCATION IN HIGHER EDUCATION: STRATEGIES, CHALLENGES, AND IMPACT,” hal. 2–7.
- Gupta, R. (2024) “Bidirectional encoders to state-of-the-art: a review of BERT and its transformative impact on natural language processing,” *Информатика. Экономика. Управление - Informatics. Economics. Management*, 3(1), hal. 0311–0320. Tersedia pada: <https://doi.org/10.47813/2782-5280-2024-3-1-0311-0320>.
- Hariguna, T., Sukmana, H.T. dan Kim, J. Il (2020) “Survey Opinion using Sentiment Analysis,” *Journal of Applied Data Sciences*, 1(1), hal. 35–40. Tersedia pada: <https://doi.org/10.47738/jads.v1i1.10>.
- Imaduddin, H., A’la, F.Y. dan Nugroho, Y.S. (2023) “Sentiment Analysis in Indonesian Healthcare Applications using IndoBERT Approach,” *International Journal of Advanced Computer Science and Applications*, 14(8), hal. 113–117. Tersedia pada: <https://doi.org/10.14569/IJACSA.2023.0140813>.
- Kachkou, D.I. (2021) “Language modeling and bidirectional coders representations: an overview of key technologies,” *Informatics*, 17(4), hal. 61–72. Tersedia pada: <https://doi.org/10.37661/1816-0301-2020-17-4-61-72>.

- Kartika, B.V., Alfredo, M.J. dan Kusuma, G.P. (2023) "Fine-Tuned IndoBERT based model and data augmentation for Indonesian language paraphrase identification," *Revue d'Intelligence Artificielle*, 37(3), hal. 733–743. Tersedia pada: <https://doi.org/10.18280/ria.370322>.
- Kosaraju, D. (2022) "The Progression of Natural Language Processing : A Journey from Syntax Parsing to Deep Sentiment Analysis," 6(September), hal. 172–178.
- Koto, F. *dkk.* (2020) "IndoLEM and IndoBERT: A Benchmark Dataset and Pre-trained Language Model for Indonesian NLP," *COLING 2020 - 28th International Conference on Computational Linguistics, Proceedings of the Conference*, hal. 757–770. Tersedia pada: <https://doi.org/10.18653/v1/2020.coling-main.66>.
- Lobud, S., Khairil, M. dan Natsir, N. (2025) "Implementation of Character Education Policy at State Islamic University of Datokarama Palu , Indonesia," 08(01), hal. 1–9. Tersedia pada: <https://doi.org/10.47191/ijmra/v8-i01-01>.
- Loilatu, M.J. *dkk.* (2021) "Analisis Fungsi Twitter Sebagai Media Komunikasi Transportasi Publik," *Jurnal Komunikasi*, 13(1), hal. 54.
- Maulana, A. (2022) "Implementasi Kebijakan Merdeka Belajar Kampus Merdeka (MBKM) Dalam Mewujudkan SDM Unggul dan Kompetitif di Perguruan Tinggi (Berdasarkan Survey SPADA di Universitas Muhammadiyah Jakarta Tahun 2022)," *Al-Qisth Law Review*, 6(1), hal. 1. Tersedia pada: <https://doi.org/10.24853/al-qisth.6.1.1-21>.
- Mlati, K., Sleman Sugiasih, K. dan 2025 (2025) "Jurnal Widya Bhumi," *Widya Bhumi*, 5(1), hal. 87.
- Mujahidin, S., Hasyim, M.N. dan Pratama, B.M. (2022) "Implementasi Analisis Sentimen Opini Publik Mengenai Sirkuit Internasional Mandalika Pada Twitter Menggunakan Metode Multinomial Naïve Bayes Classifier," *Bianglala Informatika*, 10(2), hal. 129–136. Tersedia pada: <https://doi.org/10.31294/bi.v10i2.13544>.
- Muslim, A.B. (2020) "Character Education Curriculum in the Government of

- Indonesia Strengthening Character Education Program,” *JIEBAR : Journal of Islamic Education: Basic and Applied Research*, 01, hal. 2.
- Narayan, U. dan Kumar, D. (2024) “Sentiment Analysis Using Transformer Based Model,” 8106, hal. 264–269. Tersedia pada: <https://doi.org/10.55524/csistw.2024.12.1.46>.
- Nurfitri, W. dan Chowanda, A. (2024) “Analisis Sentimen Pada Kasus Positif Covid-19 Berdasarkan Pemberitaan Media Di Indonesia Menggunakan Indobert,” *Progresif: Jurnal Ilmiah Komputer*, 20(1), hal. 580. Tersedia pada: <https://doi.org/10.35889/progresif.v20i1.1897>.
- Olabanjo, O. dkk. (2023) “Twitter Sentiment Analysis of Lagos State 2023 Gubernatorial Election Using BERT,” *Journal of Advanced Research in Social Sciences*, 6(2), hal. 59–75. Tersedia pada: <https://doi.org/10.33422/jarss.v6i2.1027>.
- Pahtoni, T.Y. dan Jati, H. (2024) “Analisis Sentimen Data Twitter Terkait Chatgpt Menggunakan Orange Data Mining,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(2), hal. 329–336. Tersedia pada: <https://doi.org/10.25126/jtiik.20241127276>.
- Paskarina, C., Rahmatunnisa, M. dan Herdiansah, A.G. (2023) “Pengembangan Desain Kurikulum Ilmu Politik Dalam Konteks Merdeka Belajar-Kampus Merdeka,” *Dharmakarya*, 11(4), hal. 361. Tersedia pada: <https://doi.org/10.24198/dharmakarya.v11i4.36717>.
- Pramudita, R. dkk. (2022) “Evaluation of Merdeka Belajar Kampus Merdeka to Improve The Quality of Tridharma at Bina Insani University,” *INFORMATION SYSTEM FOR EDUCATORS AND PROFESSIONALS : Journal of Information System*, 6(1), hal. 13. Tersedia pada: <https://doi.org/10.51211/isbi.v6i1.1709>.
- Rhein Rahmahsya Reshany dan Santi Indra Astuti (2023) “Media Sosial Twitter sebagai Sarana Mendiskusikan Kasus Kekerasan Seksual,” *Bandung Conference Series: Journalism*, 3(1), hal. 34–43. Tersedia pada: <https://doi.org/10.29313/bcsj.v3i1.6224>.
- Riyandona, S.A. dkk. (2025) “MODEL,” 13(1).

- Savero, J.E., Pranatawijaya, V.H. dan Christian, E. (2024) “Analisis Sentimen Pengguna Media Sosial X terhadap Perubahan Harga Bitcoin: Pendekatan Machine Learning,” *KONSTELASI: Konvergensi Teknologi dan Sistem Informasi*, 4(1), hal. 196–208. Tersedia pada: <https://doi.org/10.24002/konstelasi.v4i1.9043>.
- Shaik, T. *dkk.* (2023) “Sentiment analysis and opinion mining on educational data: A survey,” *Natural Language Processing Journal*, 2(Yan Li), hal. 100003. Tersedia pada: <https://doi.org/10.1016/j.nlp.2022.100003>.
- Simposium, P., Multidisiplin, N. dan Tangerang, U.M. (2022) “Analisis Sentimen Kinerja Pemerintahan Menggunakan Algoritma,” 4, hal. 114–121.
- Siregar, R.A., Sari, Y.A. dan Indriati, I. (2023) “Analisis Sentimen Kebijakan New Normal dengan Menggunakan Automated Lexicon Senti N-Gram,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(1), hal. 29–34. Tersedia pada: <https://doi.org/10.25126/jtiik.20231015006>.
- Thakur, N. *dkk.* (2021) “BEIR: A Heterogeneous Benchmark for Zero-shot Evaluation of Information Retrieval Models,” *Advances in Neural Information Processing Systems* [Preprint].
- Trujillo, C. (tanpa tanggal) “Multi Task Fine Tuning of BERT Using Adversarial Regularization and Priority Sampling.”
- Vanita (2024) “An Extant of Natural Language Processing,” *International Journal For Multidisciplinary Research*, 6(2), hal. 62–69. Tersedia pada: <https://www.ijfmr.com/research-paper.php?id=18326>.
- Yu, Y. dan Shahabi, L. (2023) “Optimal infrastructure in microgrids with diverse uncertainties based on demand response, renewable energy sources and two-stage parallel optimization algorithm,” *Engineering Applications of Artificial Intelligence*, 123, hal. 106233. Tersedia pada: <https://doi.org/10.1016/j.engappai.2023.106233>.
- Yulianti, E. dan Nissa, N.K. (2024) “ABSA of Indonesian customer reviews using IndoBERT: single-sentence and sentence-pair classification approaches,” *Bulletin of Electrical Engineering and Informatics*, 13(5), hal. 3579–3589. Tersedia pada: <https://doi.org/10.11591/eei.v13i5.8032>.

- Zhang, H. dan Shafiq, M.O. (2024) “Survey of transformers and towards ensemble learning using transformers for natural language processing,” *Journal of Big Data*, 11(1). Tersedia pada: <https://doi.org/10.1186/s40537-023-00842-0>.
- Zhang, S. *dkk.* (2024) “Language Rectified Flow: Advancing Diffusion Language Generation with Probabilistic Flows,” *Proceedings of the 2024 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL 2024*, 1, hal. 3893–3905. Tersedia pada: <https://doi.org/10.18653/v1/2024.naacl-long.215>.

