

PERBANDINGAN MODEL INDOBERT DAN INDOBERTWEET UNTUK MENDETEKSI EMOSI KOMENTAR BERITA PADA MEDIA SOSIAL

TUGAS AKHIR

Diajukan untuk melengkapi tugas-tugas dan
memenuhi syarat-syarat guna memperoleh gelar Sarjana Komputer

Oleh :

ULFIA KHAIRANI
1908107010068



**PROGRAM STUDI INFORMATIKA JURUSAN INFORMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SYIAH KUALA
DARUSSALAM, BANDA ACEH
JANUARI, 2024**

PENGESAHAN

PERBANDINGAN MODEL INDOBERT DAN INDOBERTWEET UNTUK MENDETEKSI EMOSI KOMENTAR BERITA PADA MEDIA SOSIAL

COMPARISON OF INDOBERT AND INDOBERTWEET MODELS FOR DETECTING EMOTIONS OF NEWS ON SOCIAL MEDIA

Oleh:

Nama : Ulfia Khairani
NPM : 1908107010068
Program Studi : Informatika

Menyetujui:

Pembimbing I,

Pembimbing II,



Viska Mutiawani, B.IT., M.IT.
NIP. 198008312009122003



Hendri Ahmadian, S.Si., M.IM.
NIP. 198301042014031002

Mengetahui:

Dekan Fakultas MIPA,
Universitas Syiah Kuala,



Prof. Dr. Taufik Fuadi Abidin S.Si., M.Tech
NIP. 197010081994031002

Ketua Jurusan Informatika FMIPA,
Universitas Syiah Kuala,



Viska Mutiawani, B.IT., M.IT.
NIP. 198008312009122003

Lulus Sidang Sarjana pada hari Kamis, 04 Januari 2024

PERNYATAAN BEBAS PLAGIASI

Saya yang bertanda tangan di bawah ini,

Nama lengkap : Ulfia Khairani
Tempat/tanggal lahir : Geudong/20 Juni 2001
NPM : 1908107010068
Program Studi : S1 Informatika
Fakultas : Matematika dan Ilmu Pengetahuan Alam
Judul Tugas Akhir : Perbandingan Model IndoBERT dan
IndoBERTweet untuk Mendeteksi Emosi
Komentar Berita pada Media Sosial

Menyatakan dengan sesungguhnya bahwa Laporan Tugas Akhir saya dengan judul seperti di atas adalah **hasil karya saya sendiri** bersama dosen pembimbing dan **bebas plagiasi**.

Jika ternyata dikemudian hari terbukti bahwa Laporan Tugas Akhir merupakan hasil plagiasi, saya bersedia menerima sanksi yang berlaku di Universitas Syiah Kuala.

Banda Aceh, 04 Januari 2024
Yang menyatakan,



Ulfia Khairani
NPM. 1908107010068

SURAT PERNYATAAN

Yang bertanda tangan di bawah ini,

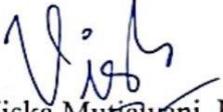
1. Nama : Ulfia Khairani
NPM : 1908107010068
Jurusan/Prodi : Informatika
Status : Mahasiswa
2. Nama : Viska Mutiawani, B.IT., M.IT.
NIP : 198008312009122003
Jurusan/Prodi : Informatika
Status : Pembimbing I
3. Nama : Hendri Ahmadian, S.Si., M.IM.
NIP : 198301042014031002
Jurusan/Prodi : Teknologi Informasi
Status : Pembimbing II

Dengan ini menyatakan hasil penelitian Tugas Akhir yang berjudul “Perbandingan Model IndoBERT dan IndoBERTtweet untuk Mendeteksi Emosi Komentar Berita pada Media Sosial” tidak dipublikasikan hingga batas waktu 5 (lima) tahun. Demikian surat pernyataan ini dibuat dengan sebenarnya untuk dapat dipergunakan seperlunya.

Darussalam, 04 Januari 2024

Yang membuat pernyataan,

Pembimbing I


Viska Mutiawani, B.IT., M.IT.
NIP. 198008312009122003

Pembimbing II


Hendri Ahmadian, S.Si., M.IM.
NIP. 198301042014031002

Mahasiswa,


Ulfia Khairani
NPM.1908107010068

Mengetahui:

Koordinator TA,


Ketua Jurusan Informatika
Universitas Syiah Kuala,
Viska Mutiawani, B.IT., M.IT.
NIP. 198008312009122003


Alim Misbullah, S.Si., M.Si.
NIP. 198806032019031011

ABSTRAK

Platform media sosial saat ini membentuk wadah dimana berita dapat lebih mudah ditemukan dan menarik perhatian individu. Pada media sosial, masyarakat dapat memberikan komentar-komentar terhadap berita yang telah dibaca. Pemahaman terhadap emosi yang mengiringi komentar-komentar yang telah diberikan pengguna pada postingan berita dapat membantu memahami bagaimana berita tersebut diserap, diinterpretasi, dan direspons oleh publik. Penelitian ini bertujuan untuk mendeteksi emosi pada komentar berita di media sosial dengan menggunakan *pre-trained model* IndoBERT dan IndoBERTweet serta mengeksplorasi dampak penggunaan tahapan *preprocessing* khususnya *remove stopwords* dan *stemming* pada kedua model tersebut. Penelitian ini melalui tujuh tahapan yaitu pengumpulan data, pelabelan data (marah, senang, takut, dan sedih), *preprocessing*, *split dataset*, tokenisasi, *fine-tuning*, dan evaluasi model. Hasil penelitian menunjukkan bahwa model indoBERTweet menghasilkan akurasi yang lebih baik dibandingkan dengan model indoBERT yaitu sebesar 88.28% untuk data yang melalui tahapan *remove stopwords* dan *stemming* serta 92.54% untuk data yang tidak melalui tahapan *remove stopwords* dan *stemming*.

Kata Kunci: Deteksi Emosi, Media Sosial, IndoBERT, IndoBERTweet

ABSTRACT

The current social media platforms have shaped a space where news can be more easily discovered and capture individuals' attention. On social media, people can provide comments on the news they have read. Understanding the emotions that accompany the comments that users have given on news posts can help understand how the news is absorbed, interpreted, and responded to by the public. This research aims to detect emotions in news comments on social media using pre-trained models IndoBERT and IndoBERTweet and explore the impact of using preprocessing stages, especially removing stopwords and stemming on these two models. This research went through seven stages, namely data collection, data labeling (anger, happiness, fear, and sadness), preprocessing, split dataset, tokenization, fine-tuning, and model evaluation. The research results show that the IndoBERTweet model performs better accuracy compared to the indoBERT model, achieving an accuracy of 88.28% for data that underwent the remove stopwords and stemming steps and 92.54% for data that did not undergo these preprocessing steps.

Keywords: Emotion Detection, Social Media, IndoBERT, IndoBERTweet

KATA PENGANTAR

Dengan menyebut nama Allah Yang Maha Pengasih lagi Maha Penyayang. Segala Puji bagi Allah SWT yang telah memberikan rahmat dan karunia-Nya kepada penulis, sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul **“Perbandingan Model IndoBERT dan IndoBERTweet untuk Mendeteksi Emosi Komentar Berita pada Media Sosial”**. Shalawat beriringan salam tidak lupa penulis sanjungkan kepangkuan Nabi Muhammad SAW, yang telah membawa umatnya dari zaman gelap gulita yang penuh dengan kebodohan ke zaman yang terang benderang yang penuh ilmu pengetahuan seperti yang dirasakan seperti sekarang.

Dalam penyelesaian tugas akhir, penulis banyak mendapatkan pengetahuan dan wawasan baru yang sangat berharga baik berupa dorongan maupun bantuan dari berbagai pihak secara langsung atau tidak langsung. Oleh karena itu, penulis ingin menyampaikan terima kasih kepada :

1. Bapak Prof. Dr. Taufik Fuadi Abidin, S.Si., M.Tech. selaku Dekan Fakultas MIPA Universitas Syiah Kuala.
2. Ibu Viska Mutiawani, B.IT, M.IT selaku Ketua Jurusan Informatika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Syiah Kuala.
3. Ibu Viska Mutiawani, B.IT, M.IT selaku Pembimbing I dan Bapak Hendri Ahmadian, S.Si., M.IM. selaku Pembimbing II yang telah membimbing dan memberikan arahan dalam menyelesaikan Tugas Akhir ini.
4. Bapak Prof. Dr. Taufik Fuadi Abidin, S.Si., M.Tech. selaku Dosen Wali yang telah memberikan banyak sekali dukungan serta bantuan dari awal studi hingga penulisan Tugas Akhir ini selesai.
5. Bapak Alim Misbullah, S.Si., M.Sc. selaku Koordinator Tugas Akhir Jurusan Informatika yang telah banyak memberikan arahan sehingga tugas akhir ini selesai.
6. Bapak dan Ibu Dosen di Jurusan Informatika Fakultas Matematika dan Ilmu Pengetahuan Alam yang telah memberikan ilmu dari awal studi.
7. Orang tua tercinta yaitu Bapak Muhammad Fudhil, S.H., M.H. (Alm) dan Ibu Nurhafni Hanafiah yang selalu mendukung dengan memberikan doa, semangat, nasihat dan selalu menguatkan serta memberikan kepercayaan

kepada penulis sehingga penulis mampu menyelesaikan studi. Terima kasih karena telah menjadi orang tua yang suportif dan telah mengorbankan banyak materi, waktu, tenaga, dan upaya untuk mendukung penulis meraih impian.

8. Raudhatul Nadia selaku adik dari penulis yang tak kalah penting kehadirannya karena selalu kebersamai, mendukung, menyemangati, dan setia menemani juga mendengar keluh kesah penulis. Terima kasih karena telah membuat penulis yakin jika penulis mampu menyelesaikan studi. Terima kasih karena selalu menguatkan dalam momen – momen tersulit bagi penulis dan selalu menjadi support system terbaik sehingga penulis dapat menyelesaikan tugas akhir dan juga studi.
9. Sahabat serta teman terbaik, Puan Izzati, Jessica, dan Yunza Jauhari, yang bersedia memberi dukungan dan bantuannya.
10. Terakhir, terima kasih untuk diri sendiri karena telah bertanggung jawab untuk menyelesaikan apa yang telah dimulai. Terima kasih karena telah berusaha dan berjuang hingga sampai di titik ini.

Penulis menyadari dalam proses penelitian masih terdapat banyak kesalahan dan jauh dari sempurna. Oleh karena itu, penulis sangat mengharapkan masukan, saran serta kritik demi perbaikan laporan kedepannya.

Banda Aceh, 10 Desember 2023

Penulis,



Ulfia Khairani
1908107010068

DAFTAR ISI

	Halaman
PENGESAHAN.....	ii
PERNYATAAN BEBAS PLAGIASI	iii
SURAT PERNYATAAN	iv
ABSTRAK.....	v
<i>ABSTRACT</i>	vi
KATA PENGANTAR	vii
DAFTAR ISI.....	ix
DAFTAR GAMBAR.....	xi
DAFTAR TABEL.....	xii
DAFTAR LAMPIRAN.....	xiii
BAB I PENDAHULUAN.....	1
1.1 LATAR BELAKANG	1
1.2 RUMUSAN MASALAH	3
1.3 MAKSUD DAN TUJUAN PENELITIAN	3
1.4 MANFAAT PENELITIAN	4
BAB II TINJAUAN KEPUSTAKAAN.....	5
2.1 EMOSI.....	5
2.2 BERITA.....	5
2.3 <i>NATURAL LANGUAGE PROCESSING</i>	6
2.4 BERT	7
2.5 INDOBERT	11
2.6 INDOBERTWEET	12
2.7 <i>TRANSFER LEARNING</i>	12
2.8 <i>CONFUSION MATRIX</i>	14
2.9 PENELITIAN TERKAIT	15
BAB III METODOLOGI PENELITIAN	17
3.1 WAKTU DAN LOKASI PENELITIAN.....	17
3.2 ALAT DAN BAHAN.....	17
3.3 CARA KERJA.....	17
3.3.1 Studi Literatur	18
3.3.2 Pengumpulan Data	19
3.3.3 Pelabelan Data.....	19
3.3.4 <i>Data Preprocessing</i>	19
3.3.5 <i>Split Dataset</i>	20
3.3.6 Tokenisasi	21

3.3.7	<i>Load Model</i>	21
3.3.8	<i>Fine-tuning</i>	21
3.3.9	Evaluasi Model	22
BAB IV HASIL DAN PEMBAHASAN		23
4.1	PENGUMPULAN DATA	23
4.2	PELABELAN DATA	23
4.3	<i>DATA PREPROCESSING</i>	25
4.3.1	<i>Case folding</i>	25
4.3.2	<i>Data cleaning</i>	25
4.3.3	Normalisasi	26
4.3.4	<i>Remove Stopwords</i>	26
4.3.5	<i>Stemming</i>	27
4.4	VISUALISASI DATA	27
4.5	<i>SPLIT DATASET</i>	29
4.6	TOKENISASI	30
4.7	<i>FINE-TUNING</i>	31
4.8	EVALUASI MODEL	31
4.8.1	IndoBERT	32
4.8.2	IndoBERTweet	35
4.8.3	Perbandingan model IndoBERT dan IndoBERTweet	39
BAB V KESIMPULAN DAN SARAN		41
5.1	KESIMPULAN	41
5.2	SARAN	41
DAFTAR KEPUSTAKAAN		42
LAMPIRAN		46

DAFTAR GAMBAR

Gambar 2.1 Ilustrasi arsitektur BERT	8
Gambar 2.2 Representasi <i>input</i> pada BERT (Devlin et al., 2019).....	9
Gambar 2.3 Ilustrasi <i>pre-training</i> dan <i>fine-tuning</i> BERT (Devlin et al., 2019)	10
Gambar 2.4 <i>Hyperparameter pre-trained model</i> IndoBERT (Wilie et al., 2020)	12
Gambar 2.5 Ilustrasi perbedaan <i>traditional machine learning</i> dan <i>transfer learning</i> (Hosna et al., 2022).....	13
Gambar 3.1 Alur Kerja Penelitian	18
Gambar 4.1 Distribusi label emosi pada data	24
Gambar 4.2 <i>Wordcloud</i> label marah	28
Gambar 4.3 <i>Wordcloud</i> label senang	28
Gambar 4.4 <i>Wordcloud</i> label takut	28
Gambar 4.5 <i>Wordcloud</i> label sedih.....	29
Gambar 4.6 Grafik akurasi model IndoBERT pada skenario pertama	32
Gambar 4.7 Grafik <i>loss</i> model IndoBERT pada skenario pertama	33
Gambar 4.8 Grafik akurasi model IndoBERT pada skenario kedua	34
Gambar 4.9 Grafik <i>loss</i> model IndoBERT pada skenario kedua.....	34
Gambar 4.10 Grafik akurasi model IndoBERTtweet pada skenario pertama	36
Gambar 4.11 Grafik <i>loss</i> model IndoBERTtweet pada skenario pertama.....	36
Gambar 4.12 Grafik akurasi model IndoBERTtweet pada skenario kedua.....	37
Gambar 4.13 Grafik <i>loss</i> model IndoBERTtweet pada skenario kedua	38

DAFTAR TABEL

Tabel 2.1 Tabel <i>confusion matrix</i>	14
Tabel 4.1 Contoh data yang telah dikumpulkan	23
Tabel 4.2 Contoh hasil pelabelan data	24
Tabel 4.3 Contoh hasil <i>case folding</i>	25
Tabel 4.4 Contoh hasil <i>data cleaning</i>	25
Tabel 4.5 Contoh hasil normalisasi data	26
Tabel 4.6 Contoh hasil <i>remove stopwords</i>	27
Tabel 4.7 Contoh hasil <i>stemming</i>	27
Tabel 4.8 Distribusi label setelah <i>split dataset</i>	29
Tabel 4.9 Hasil <i>tokenizer</i> IndoBERT.....	30
Tabel 4.10 Hasil <i>tokenizer</i> IndoBERTweet	31
Tabel 4.11 <i>Hyperparameter</i> IndoBERT dan IndoBERTweet	31
Tabel 4.12 <i>Confusion matrix</i> model IndoBERT skenario pertama	33
Tabel 4.13 <i>Confusion matrix</i> model IndoBERT skenario kedua.....	35
Tabel 4.14 <i>Confusion matrix</i> model IndoBERTweet skenario pertama.....	37
Tabel 4.15 <i>Confusion matrix</i> model IndoBERTweet skenario kedua	38
Tabel 4.16 Perbandingan model IndoBERT dan IndoBERTweet.....	39
Tabel 4.17 Hasil prediksi model IndoBERT dan IndoBERTweet.....	39

DAFTAR LAMPIRAN

Lampiran 1. <i>Fine-tuning batch size 16, dropout 0.5, 70:15:15, maximum sequence length 98</i>	46
Lampiran 2. <i>Fine-tuning batch size 16, dropout 0.5, 80:10:10, maximum sequence length 98</i>	47
Lampiran 3. <i>Fine-tuning batch size 32, dropout 0.5, 75:15:15, maximum sequence length 98</i>	48
Lampiran 4. <i>Fine-tuning batch size 16, dropout 0.5, 75:15:15, maximum sequence length 30</i>	49
Lampiran 5. <i>Bukti submission artikel</i>	50
Lampiran 6. <i>Artikel ilmiah</i>	51
Lampiran 7. <i>Biodata Penulis</i>	52

BAB I

PENDAHULUAN

1.1 LATAR BELAKANG

Di era saat ini, kemajuan teknologi informasi mengalami perkembangan yang sangat pesat. Salah satu dampak signifikan dari perkembangan teknologi adalah munculnya media sosial sebagai ruang baru bagi masyarakat untuk mengekspresikan diri. Media sosial saat ini tidak lagi terbatas oleh batasan ruang dan waktu seperti halnya komunikasi konvensional (Agustina, 2018). Saat ini, lingkungan jaringan media sosial juga membentuk wadah dimana berita dapat lebih mudah ditemukan dan menarik perhatian individu (Realita & Setiadi, 2022). Tidak hanya berita besar yang mendapat sorotan, tetapi juga berita lokal dan topik khusus yang dapat dengan mudah diakses dan disebarluaskan. Kini, masyarakat tidak hanya mengandalkan media tradisional seperti televisi dan surat kabar lagi tetapi juga berpaling kepada platform-platform media sosial untuk mendapatkan informasi terkini seperti facebook, instagram, dan platform lain yang menyediakan informasi berita dalam era digital.

Pada media sosial, masyarakat tidak hanya dapat membaca berita saja namun juga dapat memberikan komentar dan opini terhadap berita yang telah dibaca. Komentar-komentar tersebut mencerminkan keragaman sudut pandang dan tanggapan publik terhadap berbagai isu aktual. Komentar-komentar yang muncul tidak hanya berisi kata-kata biasa tetapi juga merupakan cara bagi masyarakat mengungkapkan pikiran dan perasaannya tentang berita-berita tersebut. Komentar-komentar yang diberikan memiliki potensi untuk mencerminkan reaksi dan emosi mereka terhadap berita tersebut.

Emosi memiliki pengaruh yang kuat terhadap bagaimana manusia membuat keputusan dan juga berfungsi sebagai alat bantu yang mendorong komunikasi efektif dengan dunia. Deteksi emosi menjadi sebuah proses yang melibatkan pengenalan dan identifikasi beragam jenis perasaan atau emosi yang dirasakan oleh seseorang, contohnya kebahagiaan, kesedihan, atau kemarahan (Nandwani & Verma, 2021). Ekspresi emosi dapat terwujud secara lisan melalui penggunaan kata dan nuansa suara, ataupun non lisan seperti ekspresi wajah atau gerakan tubuh. Namun,

pendeteksiian emosi dari teks lebih menantang. Hal ini disebabkan oleh teks yang dalam banyak kasus mungkin kurang memadai untuk mengenali emosi. Varian gaya penulisan, perbedaan antara gaya bahasa formal dan informal, serta penggunaan bahasa kiasan seperti sindiran dapat memperumit pendeteksiian emosi dalam teks (Mirzaee et al., 2022).

Deteksi emosi pada tulisan, khususnya yang tersebar dalam platform media sosial memiliki potensi sebagai sumber data berharga yang bisa dijadikan pembelajaran tentang beragam cara individu menanggapi situasi dan peristiwa. Deteksi emosi memiliki dampak dalam mendukung pengambilan keputusan di beragam ranah, seperti manajemen dan pemasaran, interaksi pengguna, aspek keuangan, politik, kesehatan, serta pendidikan (Nisa et al., 2021). Dalam konteks berita, pemahaman terhadap emosi yang mengiringi komentar-komentar tersebut dapat membantu memahami bagaimana informasi diserap, diinterpretasi, dan direspons oleh publik. Oleh karena itu, analisis emosi yang terkandung dalam komentar-komentar ini menjadi penting dalam mengurai dinamika respons publik terhadap berita.

Belakangan ini, Natural Language Processing (NLP) telah menarik perhatian besar dalam usahanya untuk menggambarkan dan menganalisis bahasa manusia melalui pendekatan komputasi (Khurana et al., 2023). Di Indonesia, model bahasa seperti IndoBERT dan IndoBERTtweet dapat dimanfaatkan untuk melakukan tugas mendeteksi emosi. IndoBERT merupakan model yang telah dilatih sebelumnya (*pre-trained*) menggunakan algoritma BERT untuk bahasa Indonesia (Wilie et al., 2020). Sementara itu, IndoBERTtweet adalah *pre-trained model* yang dilatih dengan memperluas model BERT berbahasa Indonesia (Koto et al., 2021).

Dalam memproses data teks khususnya yang berasal dari media sosial memiliki tantangan tersendiri pada tahapan *preprocessing*. Peran *preprocessing data* sangat penting dan tidak dapat diabaikan karena dapat mempengaruhi keakuratan pada model yang akan digunakan. Salah satu tahapan yang sering digunakan pada *preprocessing* adalah *remove stopwords* dan *stemming*. *Remove stopwords* adalah proses menghilangkan kata-kata umum yang sering muncul dalam teks dan dianggap hanya memiliki sedikit kontribusi terhadap makna dari teks (Miyajiwala et al., 2022),

sedangkan *stemming* adalah proses mengubah bentuk sebuah kata menjadi bentuk kata dasarnya (Rosid et al., 2020).

Berdasarkan paparan di atas, penulis berinisiatif melakukan penelitian tentang deteksi emosi komentar berita pada media sosial menggunakan IndoBERT dan IndoBERTweet serta mengeksplorasi dampak penggunaan tahapan *remove stopwords* dan *stemming* pada kedua model tersebut. Harapannya, penelitian ini dapat memberikan wawasan yang lebih mendalam terkait penggunaan model IndoBERT dan IndoBERTweet untuk mendeteksi emosi serta pengaruh dari tahapan *remove stopwords* dan *stemming* pada kedua model tersebut.

1.2 RUMUSAN MASALAH

Berdasarkan latar belakang yang telah disampaikan diatas, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana penerapan model IndoBERT dalam mendeteksi emosi pada komentar berita di media sosial?
2. Bagaimana penerapan model IndoBERTweet dalam mendeteksi emosi pada komentar berita di media sosial?
3. Bagaimana perbandingan kinerja model IndoBERT dan IndoBERTweet dalam mendeteksi emosi pada komentar berita di media sosial?
4. Bagaimana pengaruh tahapan *remove stopwords* dan *stemming* pada model IndoBERT dan IndoBERTweet?

1.3 MAKSUD DAN TUJUAN PENELITIAN

Berdasarkan rumusan masalah yang telah diuraikan diatas, maksud dan tujuan dari penelitian ini adalah sebagai berikut :

1. Menerapkan model IndoBERT dalam mendeteksi emosi pada komentar berita di media sosial.
2. Menerapkan model IndoBERTweet dalam mendeteksi emosi pada komentar berita di media sosial.
3. Membandingkan dan menganalisis hasil kinerja antara model IndoBERT dan IndoBERTweet dalam mendeteksi emosi pada komentar berita di media sosial.

4. Menganalisis pengaruh tahapan *remove stopwords* dan *stemming* pada model IndoBERT dan IndoBERTtweet

1.4 MANFAAT PENELITIAN

Adapun manfaat yang diperoleh dari penelitian ini adalah dapat memberikan informasi tentang kinerja dan perbandingan antara model IndoBERT dan IndoBERTtweet untuk mendeteksi emosi komentar berita pada media sosial serta pengaruh tahapan *remove stopwords* dan *stemming* pada kedua model tersebut. Temuan penelitian ini juga dapat digunakan sebagai referensi untuk menghadirkan konten yang lebih relevan secara emosional, serta dapat membantu memahami bagaimana cara masyarakat merespons berita tertentu.

BAB II

TINJAUAN KEPUSTAKAAN

2.1 EMOSI

Emosi adalah karakteristik yang sangat kompleks dan memiliki banyak dimensi yang mencerminkan kepribadian dan sifat perilaku manusia. Dalam kehidupan sehari-hari, orang mengekspresikan emosi terhadap berbagai isu, peristiwa, individu, lingkungan, bahkan hal-hal kecil disekitarnya (Sailunaz & Alhadj, 2019). Hal ini menunjukkan betapa pentingnya emosi dalam membentuk respons dan interaksi manusia terhadap dunia sekitarnya. Emosi tidak hanya mempengaruhi kehidupan sehari-hari manusia secara umum, tetapi juga memiliki dampak yang signifikan pada kondisi kesehatan mental seperti gangguan psikiatri (Gu et al., 2019).

Terdapat empat emosi dasar yaitu *joy* (kebahagiaan), *sadness* (kesedihan), *fear* (ketakutan), dan *anger* (kemarahan) (Gaus, 2011). Bahagia atau senang adalah emosi yang dapat diartikan sebagai perasaan positif atau menyenangkan mulai dari rasa puas hingga kegembiraan yang sangat mendalam (Saldanha et al., 2021). Sedih merupakan emosi yang umumnya dikaitkan dengan kegagalan, kekalahan, dan kehilangan (Tsikandilakis et al., 2023). Takut adalah emosi yang muncul ketika terjadi situasi yang berpotensi membahayakan keselamatan diri sendiri atau orang lain. Emosi takut dipicu oleh persepsi bahwa situasi tersebut membawa risiko (Garcia, 2017). Marah adalah respons emosional alami terhadap situasi atau kondisi yang menghalangi atau mengganggu pemenuhan kebutuhan dasar manusia (Ulya, 2020).

2.2 BERITA

Berita adalah kumpulan informasi dalam bentuk teks, ucapan, atau gambar, yang diperlukan oleh manusia untuk meningkatkan dan memperbarui pengetahuan atau informasi yang dimilikinya (Rahardja et al., 2018). Berita merupakan pemberitahuan mengenai kejadian terbaru. Tidak semua kejadian pantas untuk dilaporkan. Berita yang patut untuk dilaporkan adalah kejadian yang memenuhi

standar nilai berita. Oleh karena itu, suatu berita harus memuat setidaknya satu dari kriteria nilai berita. Nilai-nilai berita diuraikan sebagai berikut (Romli, 2018):

1. *Impact*: Semakin banyak orang yang terpengaruh oleh suatu peristiwa, semakin besar pengaruh berita tersebut.
2. *Proximity*: Semakin dekat secara geografis dan psikologis pembaca dengan suatu kejadian, semakin tinggi nilai beritanya.
3. *Timeliness*: Mengacu pada kejadian yang terjadi baru-baru ini.
4. *Prominence*: Berkaitan dengan seberapa terkenal orang yang terlibat atau menjadi subjek dari suatu peristiwa.
5. *Novelty*: Mengacu pada sesuatu yang baru, tidak lazim, aneh, atau unik.
6. *Conflict*: Termasuk dalam kategori perang, politik, dan kejahatan.

2.3 NATURAL LANGUAGE PROCESSING

Bahasa dapat didefinisikan sebagai serangkaian aturan atau kumpulan simbol dimana simbol-simbol itu digabungkan dan digunakan untuk menyampaikan atau menyebarkan informasi. Karena tidak semua orang mungkin terampil dalam bahasa khusus mesin, *Natural Language Processing* (NLP) atau yang biasa disebut pemrosesan bahasa alami hadir untuk memenuhi kebutuhan pengguna yang tidak memiliki waktu cukup untuk mempelajari bahasa baru atau menguasai sepenuhnya. NLP adalah bagian dari kecerdasan buatan dan linguistik yang bertujuan untuk mengajarkan komputer bagaimana memahami kalimat atau kata-kata yang ditulis dalam bahasa manusia (Khurana et al., 2023). Dengan kata lain, NLP adalah suatu teknik komputasional yang memecah bahasa manusia menjadi bagian-bagian kecil, menganalisis bagaimana bagian-bagian tersebut saling terkait, dan menyelidiki cara bagaimana bagian-bagian tersebut digabungkan untuk membentuk konten atau informasi yang memiliki makna atau relevansi (Wong et al., 2018).

Sebagai bidang studi ilmiah, NLP menggabungkan ilmu komputer, linguistik, dan matematika dengan tujuan utama untuk menerjemahkan bahasa manusia dalam jumlah yang besar menjadi perintah yang dapat dijalankan oleh komputer (Kang et al., 2020). NLP dapat diklasifikasikan menjadi dua bagian, yaitu (Khurana et al., 2023):

1. *Natural Language Understanding* (NLU)

Natural Language Understanding (NLU) adalah bagian dari kecerdasan buatan yang memungkinkan mesin atau komputer memahami bahasa manusia dengan tingkat kompleksitas yang mirip dengan manusia. Teknologi ini memungkinkan sistem untuk mengurai, menganalisis, dan menginterpretasi teks yang diberikan dengan cara mengekstrak berbagai elemen seperti konsep, entitas, tingkat emosi, kata kunci, dan bahkan nuansa atau konteks tersirat. Dengan demikian, NLU memungkinkan komputer untuk tidak hanya memproses kata-kata, tetapi juga mengerti makna dan tujuan di balik komunikasi manusia.

2. *Natural Language Generation* (NLG)

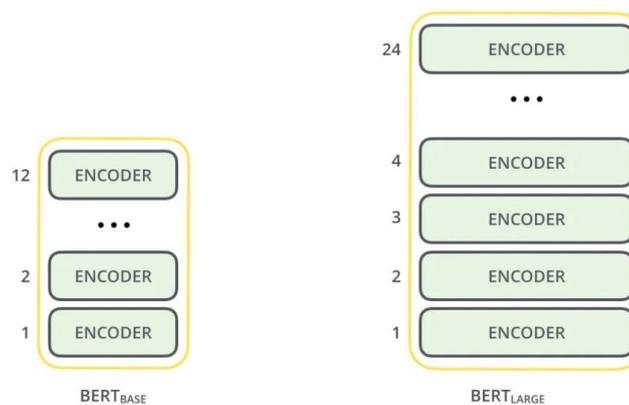
Natural Language Generation (NLG) adalah salah satu bagian dari kecerdasan buatan yang memungkinkan komputer atau sistem untuk menciptakan teks atau tulisan dengan mempertimbangkan konteks dan makna dari data atau informasi yang dimilikinya. Proses NLG melibatkan analisis mendalam terhadap dataset atau pengetahuan yang tersedia, memungkinkan sistem untuk menyusun frasa-frasa, membentuk kalimat-kalimat dan bahkan menciptakan paragraf-paragraf yang tidak hanya gramatikal, tetapi juga mengandung makna yang sesuai dengan tujuan komunikasi.

NLP telah menjadi fokus utama pengembangan teknologi informasi dalam beberapa tahun terakhir. Dengan semakin matangnya kemampuan NLP, teknologi ini telah berhasil diimplementasikan secara luas dalam berbagai aspek kehidupan sehari-hari. Perkembangan ini terlihat melalui berbagai aplikasi dunia nyata yang mengandalkan NLP, contohnya adalah *machine translation*, *email spam detection*, *question answering*, *information extraction*, dan *summarization* (Khurana et al., 2023).

2.4 BERT

BERT (*Bidirectional Encoder Representations from Transformer*) merupakan terobosan signifikan dalam dunia pemrosesan bahasa alami (NLP). BERT adalah sebuah model yang dirancang untuk memahami arti dan hubungan kata-kata dalam suatu teks secara *bidireksional* dengan mempertimbangkan konteks kiri dan kanan

pada semua lapisan. Tidak hanya bergantung pada satu arah, model BERT dapat mempelajari konteks kata dengan menganalisis kata-kata di sekitarnya. Fondasi dari pendekatan BERT merujuk pada teknologi *transformer*, yang terfokus pada pembelajaran relasi kontekstual antar kata dalam teks. Terdapat dua versi dari BERT yaitu BERTBASE dan BERTLARGE. BERTBASE memiliki 12 lapisan, 768 *hidden size*, 12 *self-attention heads* dan total parameter sebesar 110 juta. Sedangkan untuk BERTLARGE memiliki 24 lapisan, 1024 *hidden size*, 16 *self-attention heads*, dan total parameter sebesar 340 juta (Devlin et al., 2019). Ilustrasi arsitektur BERT dapat dilihat pada gambar 2.1.



Gambar 2.1 Ilustrasi arsitektur BERT

Model BERT dapat memahami dan menganalisis teks dengan mempertimbangkan struktur, konteks, dan hubungan antar kata-kata serta kalimat. Hal ini dikarenakan BERT menggunakan tiga komponen penting yang menjadi input dari model BERT, yaitu (Yulita et al., 2023):

1. *Token Embedding*

Token Embedding adalah representasi dari kata-kata dalam teks. *Token embedding* berfungsi untuk mengubah teks masukan menjadi token-token terpisah dan memberikan identifikasi unik (ID) untuk setiap token. Setelah ID ditetapkan, setiap token akan diubah menjadi representasi khusus untuk token tersebut. Langkah berikutnya adalah memasukkan token [CLS] ke setiap *input* dan token [SEP] ke setiap *output*. Token [CLS] bertujuan sebagai penanda awal dari teks dan [SEP] bertindak sebagai penanda pembatas antara teks yang diberikan.

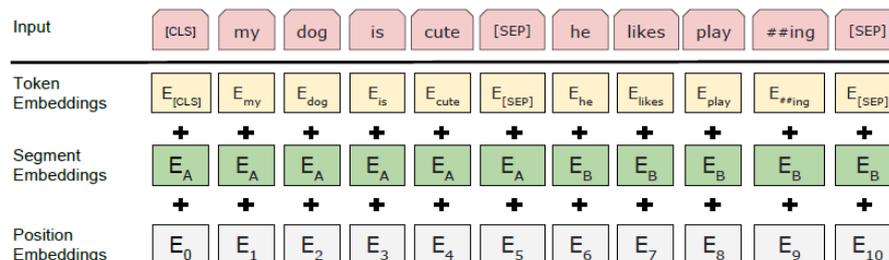
2. Segment Embedding

Segment embedding adalah bagian komponen yang ditambahkan pada token input yang bertujuan untuk memungkinkan pengidentifikasian antara kalimat-kalimat dan menetapkan urutan relatif di antara mereka. Dengan *segment embedding*, model dapat membedakan antara bagian-bagian dari teks yang berasal dari kalimat yang berbeda, membantu dalam memahami konteks dan hubungan antara kalimat-kalimat tersebut.

3. Position Embedding

Pada tahap *position embedding*, masing-masing token *input* diberikan lapisan tambahan yang memungkinkan penentuan posisinya dalam urutan. *Position embedding* penting karena tanpa pengetahuan tentang posisi relatif dari setiap token dalam urutan, model tidak akan dapat memahami hubungan antara kata-kata dalam sebuah frasa atau kalimat. *Position embedding* memungkinkan model untuk membedakan antara kata-kata yang memiliki makna berbeda dalam konteks yang sama.

Untuk token tertentu, representasi *input* dibuat dengan menjumlahkan token, *segment*, dan *position embeddings* yang sesuai sehingga representasi input pada BERT akan terlihat seperti gambar 2.2.



Gambar 2.2 Representasi *input* pada BERT (Devlin et al., 2019)

Proses pelatihan awal (*pre-training*) dari model BERT menggunakan data teks yang diambil dari BooksCorpus dan Wikipedia Inggris yang tidak memiliki label atau anotasi tambahan. Data ini memiliki total sekitar 800 juta kata dari BooksCorpus dan 2.500 juta kata dari Wikipedia Inggris. BERT menjalani *pre-training* dengan dua jenis tugas *unsupervised*, yaitu *Masked Language Model* (MLM) dan *Next Sentence Prediction* (NSP).

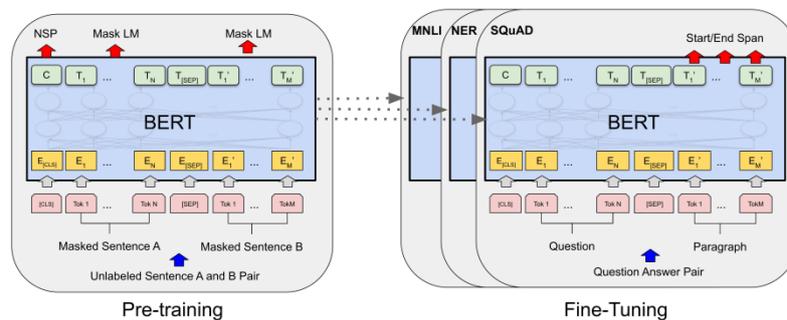
1. *Masked Language Model (MLM)*

Masked Language Model (MLM) adalah tugas di mana model dilatih untuk mengisi kekosongan dalam teks. Dalam tugas MLM ini, sekitar 15% dari kata dalam setiap urutan *input* secara acak disamarkan dengan token [MASK]. Model kemudian diminta untuk menggunakan konteks dari kata-kata di sekitarnya untuk memprediksi identitas asli dari token yang tersamarkan tersebut. Melalui latihan ini, model diberi kemampuan untuk memahami hubungan dan struktur bahasa yang lebih dalam, sehingga memungkinkannya untuk mengisi kekosongan dengan kata-kata yang tepat dalam berbagai konteks.

2. *Next Sentence Prediction (NSP)*

Next Sentence Prediction (NSP) adalah tugas di mana model memprediksi apakah kalimat kedua dalam sepasang kalimat memiliki hubungan logis dengan kalimat pertama. Dengan melakukan ini, NSP bertujuan untuk mengajarkan model untuk memahami dan mengenali konteks dan keterkaitan antara dua kalimat.

Model BERT yang telah melalui proses *pre-training* kemudian dapat disesuaikan kembali (*fine-tuning*) untuk menyelesaikan berbagai tugas khusus seperti *question answering*. Proses *fine-tuning* ini hanya memerlukan satu lapisan *output* tambahan pada model yang telah dilatih sebelumnya tanpa perlu melakukan perubahan yang besar pada arsitektur untuk menyesuaikannya dengan tugas spesifik (Devlin et al., 2019). Ilustrasi dari *pre-training* dan *fine-tuning* dari BERT dapat dilihat pada gambar 2.3.



Gambar 2.3 Ilustrasi *pre-training* dan *fine-tuning* BERT (Devlin et al., 2019)

2.5 INDOBERT

IndoBERT adalah model yang dikembangkan berdasarkan arsitektur BERT yang dilatih menggunakan data korpus bahasa Indonesia. IndoBERT dibangun menggunakan kumpulan data berukuran besar yang disebut Indo4B. Koleksi data ini mengandung sekitar 4 miliar kata yang terdiri dari sekitar 250 juta kalimat atau disebut juga Indo4B. Data dalam Indo4B terdiri dari kalimat-kalimat dalam bahasa Indonesia, termasuk yang bersifat formal maupun sehari-hari. Data ini dikumpulkan dari 12 sumber berbeda, dimana dua diantaranya berfokus pada bahasa Indonesia sehari-hari, delapan berfokus pada bahasa Indonesia formal, dan sisanya menggunakan gaya campuran antara bahasa sehari-hari dan formal.

IndoBERT memiliki empat varian model, yakni IndoBERTBASE, IndoBERTLARGE, IndoBERT-liteBASE, dan IndoBERT-liteLARGE. Semua model IndoBERT dilatih menggunakan TPU v3-8 dalam dua tahap. Dalam tahap pertama, model dilatih dengan *maximum sequence length* 128. Dalam tahap kedua, model dilatih dengan *maximum sequence length* 512. *Hyperparameter* untuk *pre-trained* model IndoBERT dapat dilihat pada gambar 2.4.

1. Dalam proses pelatihan model IndoBERT, digunakan dua jenis model yaitu IndoBERTBASE dan IndoBERTLARGE. Pada fase pertama pelatihan, digunakan *batch size* sebesar 256 dan *learning rate* $2e-5$. Namun, untuk model IndoBERTLARGE, *learning rate* kemudian disesuaikan menjadi $1e-4$ untuk memastikan stabilitas pelatihan. Selain itu, karena terdapat keterbatasan memori, pada fase kedua pelatihan *batch size* dikurangi menjadi 128 dan *learning rate* menjadi $8e-5$.
2. Dalam proses pelatihan model IndoBERT-lite, tim peneliti mengadopsi konfigurasi *hyperparameter* yang mirip dengan yang digunakan dalam ALBERT (Lan et al., 2020). Pada fase pertama, model dasar dilatih dengan *batch size* sebesar 4096, kemudian pada fase kedua *batch size* dikurangi menjadi 1024. Untuk model yang lebih besar, karena keterbatasan daya komputasi, *batch size* pada tahap pertama adalah 1024, dan pada tahap kedua adalah 256.

Model	Maximum Sequence Length = 128				Maximum Sequence Length = 512			
	Batch Size	Learning Rate	Steps	Duration (Hr.)	Batch Size	Learning Rate	Steps	Duration (Hr.)
IndoBERT-lite _{BASE}	4096	0.00176	112.5 K	38	1024	0.00088	50 K	23
IndoBERT _{BASE}	256	0.00002	1 M	35	256	0.00002	68 K	9
IndoBERT-lite _{LARGE}	1024	0.00044	500 K	134	256	0.00044	129 K	45
IndoBERT _{LARGE}	256	0.0001	1 M	89	128	0.00008	120 K	32

Gambar 2.4 *Hyperparameter pre-trained model* IndoBERT (Wilie et al., 2020)

Model IndoBERT-lite dapat mencapai hasil atau kinerja yang hampir sama dengan model IndoBERT dengan menggunakan lebih sedikit parameter dan dengan menggunakan sumber daya komputasi yang lebih sedikit (Wilie et al., 2020).

2.6 INDOBERTTWEET

IndoBERTTweet adalah *pre-trained model* yang dilatih dengan memperluas model BERT berbahasa Indonesia (IndoBERT) dengan menambahkan kosakata khusus dari twitter Indonesia. IndoBERTTweet dilatih menggunakan kumpulan data komentar twitter sebanyak 26 juta data dengan 409 juta token kata. Proses pengambilan data untuk model IndoBERTTweet menggunakan API resmi twitter dengan menggunakan 60 kata kunci yang melibatkan empat fokus utama, yakni ekonomi, kesehatan, pendidikan, dan pemerintahan.

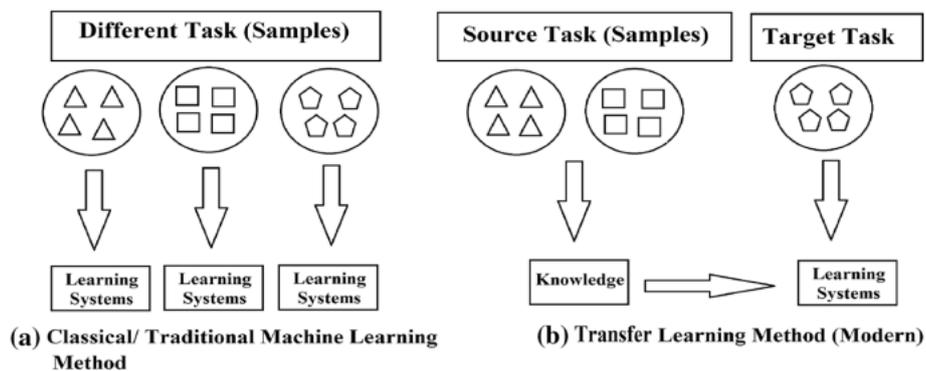
IndoBERTTweet adalah sebuah model bahasa yang menggunakan arsitektur *transformer*. IndoBERTTweet Memiliki 12 *hidden layers* dengan 768 unit pemrosesan informasi di setiap lapisannya. Model ini juga dilengkapi dengan 12 *attention heads*, dan 3 lapisan *feed-forward hidden layers (dimension=3,072)*. *Maximum sequence length* yang diatur adalah 128 token berdasarkan rata-rata jumlah kata per dokumen dalam korpus twitter yang digunakan dalam penelitian (Koto et al., 2021).

2.7 TRANSFER LEARNING

Transfer learning adalah salah satu metode dalam *machine learning* di mana sebuah model yang sudah dilatih sebelumnya untuk menyelesaikan tugas tertentu digunakan kembali sebagai dasar yang kemudian disesuaikan atau diadaptasi untuk menyelesaikan tugas lain yang berbeda dan dengan menggunakan dataset yang berbeda pula. *Transfer learning* digunakan untuk mengatasi masalah ketika hanya memiliki sedikit data untuk melatih suatu tugas tertentu. Hal ini dilakukan dengan

cara menggunakan kembali *neural network* yang sudah dilatih sebelumnya dan disesuaikan untuk tugas baru (Ebbehoj et al., 2022).

Dalam *deep learning*, ketika melatih model untuk melakukan tugas tertentu, maka harus diberi data berlabel yang relevan dengan tugas yang ingin dilakukan. Saat menerapkan model yang sudah dilatih tersebut pada tugas tugas lain yang menggunakan data berbeda, maka harus dilatih ulang menggunakan data berlabel baru yang berkaitan dengan tugas yang baru pula. Namun, dengan *transfer learning*, jika data untuk tugas baru yang mirip dengan data yang digunakan saat melatih model awal, maka tidak perlu memberikan banyak data baru seperti saat mulai melatih model dari awal. Hal ini dikarenakan pengetahuan yang diperoleh dari model lama dapat ditransfer ke model baru untuk tugas yang baru (Sun et al., 2021). Ilustrasi perbedaan antara *traditional machine learning* dan *transfer learning* dapat dilihat pada gambar 2.5



Gambar 2.5 Ilustrasi perbedaan *traditional machine learning* dan *transfer learning* (Hosna et al., 2022)

Salah satu metode dari *transfer learning* yaitu *fine-tuning*. *Fine-tuning* adalah suatu metode di mana model yang sudah ada diambil dan diubah sedikit agar sesuai dengan tugas atau dataset tertentu. Pada saat *fine-tuning*, lapisan-lapisan tingkat tinggi dapat diubah sedangkan lapisan-lapisan awal dari model dasar tetap dan tidak dapat dilatih untuk mempertahankan pengetahuan yang sudah ada. Setelah melakukan perubahan, model perlu dikompilasi ulang untuk memasukkan perubahan tersebut dan kemudian proses pelatihan model dimulai kembali dengan penyesuaian baru yang telah dilakukan. Pendekatan *fine-tuning* dapat meningkatkan akurasi sebesar beberapa persen (Gupta, 2021). Saat ini, tidak ada aturan umum yang harus diikuti untuk menentukan lapisan-lapisan mana yang harus disesuaikan atau

pengaturan *hyperparameter* apa yang harus digunakan saat melakukan *fine-tuning*. Sebagian besar keputusan didasarkan pada pengalaman sebelumnya dalam menangani masalah yang sama. Hal ini melibatkan berbagai uji coba pengaturan untuk mencari pengaturan yang paling baik guna meningkatkan performa model. Proses ini memakan waktu yang signifikan karena melibatkan serangkaian percobaan dan evaluasi yang berulang (Vrbančič & Podgorelec, 2020).

2.8 CONFUSION MATRIX

Confusion matrix merupakan teknik yang diterapkan untuk mengevaluasi performa sistem klasifikasi. *Confusion matrix* menyajikan informasi mengenai hasil prediksi dari model klasifikasi pada dataset pengujian. *Confusion matrix* diklasifikasikan ke dalam 4 kategori yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

- *True Positive* (TP): Hasil di mana sistem memprediksi kelas positif dengan benar.
- *True Negative* (TN): Hasil di mana sistem memprediksi kelas negatif dengan benar.
- *False Positive* (FP): Hasil di mana sistem memprediksi kelas positif namun seharusnya adalah kelas negatif.
- *False Negative* (FN): Hasil di mana sistem memprediksi kelas negatif namun seharusnya adalah kelas positif. Tabel *confusion matrix* dapat dilihat pada tabel 2.1.

Tabel 2.1 Tabel *confusion matrix*

Nilai Prediksi	Nilai Sebenarnya	
	1	0
1	TP (<i>True Positive Correct result</i>)	FP (<i>False Positive Unexpected result</i>)
0	FN (<i>False Negative Missing result</i>)	TN (<i>True Negative Correct absence of result</i>)

Confusion matrix membantu dalam mengukur sejauh mana model klasifikasi dapat membedakan antara kelas yang berbeda. Dengan informasi dari matriks ini, maka dapat dihitung metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *f1 score*

untuk memahami kinerja model secara lebih mendalam. *Accuracy* adalah tingkat ketepatan antara prediksi dengan nilai sebenarnya. *Precision* adalah tingkat ketepatan antara kasus yang diprediksi positif dan hasil yang positif benar sesuai data sebenarnya. *Recall* adalah tingkat keberhasilan kasus positif dari data sebenarnya diprediksi secara positif dengan benar. *F1 Score* adalah metrik evaluasi yang menggabungkan nilai *precision* dan *recall* secara bersamaan. Rumus untuk menghitung nilai *accuracy*, *precision*, *recall* dan *f1 score* adalah sebagai berikut (Dey et al., 2020):

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (2.1)$$

$$Precision = \frac{TP}{(TP + FP)} \quad (2.2)$$

$$Recall = \frac{TP}{(TP + FN)} \quad (2.3)$$

$$F1\ Score = \frac{(2 \times Recall \times Precision)}{(Recall + Precision)} \quad (2.4)$$

2.9 PENELITIAN TERKAIT

Penelitian terkait deteksi emosi pada teks telah dilakukan sebelumnya oleh beberapa peneliti diantaranya oleh penelitian yang dilakukan oleh Andrea Chiorrini dkk (2021) dengan judul "*Emotion and sentiment analysis of tweets using BERT*". Penelitian ini menggunakan model BERT untuk melakukan analisis sentimen dan pengenalan emosi dari data Twitter. Pada pengenalan emosi, data yang digunakan sebanyak 6755 tweet yang terdiri dari empat label emosi yaitu *anger* (marah), *fear* (takut), *happiness* (senang), dan *sadness* (sedih). Selain itu, pada pengenalan emosi dilakukan teknik *undersampling* karena data untuk setiap kelas tidak terdistribusi secara merata. Hasil dari penelitian menunjukkan bahwa model mencapai akurasi 92% untuk analisis sentimen dan 90% untuk pengenalan emosi (Chiorrini et al., 2021).

Penelitian lainnya dilakukan oleh Daniel Haryadi dkk. (2019) dengan judul "*Emotion Detection in Text using Nested Long Short-Term Memory*". Penelitian ini menggunakan teknik *deep learning* yaitu *Long Short-Term Memory* (LSTM) dan

Nested Long Short-Term Memory (Nested LSTM) serta membandingkannya dengan *Support Vector Machine* (SVM). Data yang digunakan sebanyak 980.549 untuk data pelatihan dan 144.160 untuk data pengujian. Penelitian ini mengklasifikasikan tujuh emosi yaitu *anger* (marah), *fear* (takut), *joy* (bahagia), *love* (cinta), *sadness* (sedih), *surprise* (terkejut), dan *thankfulness* (rasa syukur). Hasil dari penelitian menunjukkan bahwa Nested LSTM dan LSTM memberikan kinerja yang lebih baik daripada SVM untuk mendeteksi emosi dalam teks dengan akurasi sebesar 99,167% untuk Nested LSTM dan 99.154% untuk LSTM (Haryadi & Kusuma, 2019).

Penelitian lainnya dilakukan oleh Acheampong Francisca Adoma dkk. (2020) dengan judul "*Comparative Analyses of BERT, RoBERTa, DistilBERT, and XLNet for Text-Based Emotion Recognition*". Penelitian ini dilakukan untuk menganalisis efektivitas model *transformer* yaitu BERT, RoBERTa, DistilBERT, dan XLNet dalam mengenali emosi dari teks. Model yang diimplementasikan disesuaikan ulang dengan data ISEAR untuk membedakan emosi menjadi *anger* (marah), *disgust* (jijik), *sadness* (sedih), *fear* (takut), *joy* (gembira), *shame* (malu), dan *guilt* (bersalah). Hasil dari penelitian menunjukkan bahwa dengan menggunakan *hyperparameter* yang sama didapatkan akurasi sebesar 74.31% untuk RoBERTa, 72.99% untuk XLNet, 70.09% untuk BERT dan 66.93% untuk DistilBERT (Adoma et al., 2020).

BAB III METODOLOGI PENELITIAN

3.1 WAKTU DAN LOKASI PENELITIAN

Penelitian ini dilaksanakan di Ruang Riset *Data Mining and Information Retrieval* (DMIR), Gedung FMIPA Blok D Lantai 2, Universitas Syiah Kuala. Pelaksanaan penelitian ini terhitung sejak bulan Agustus 2023 sampai dengan bulan Desember 2023.

3.2 ALAT DAN BAHAN

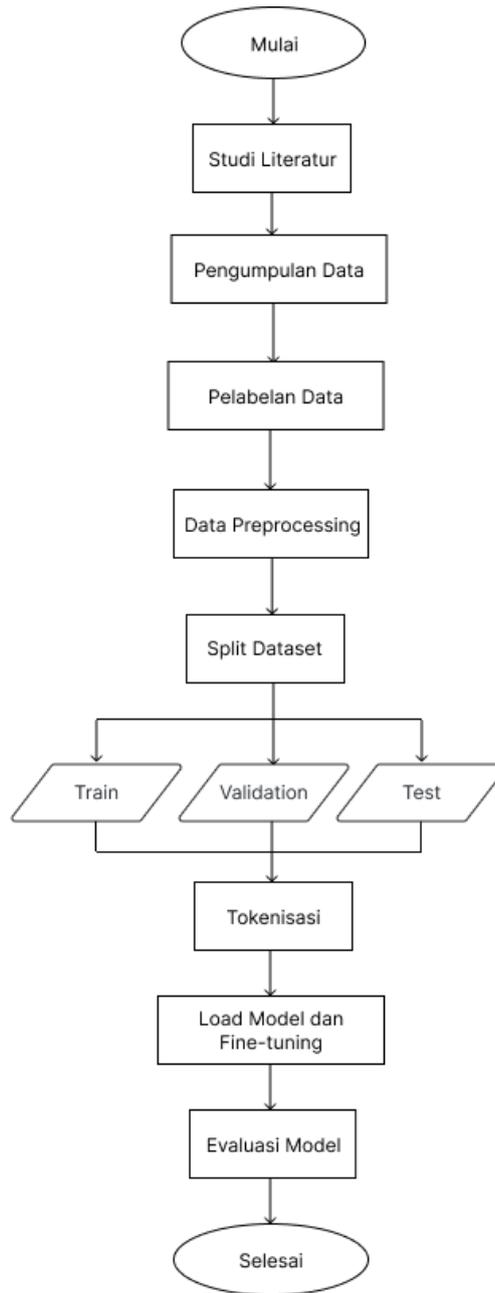
Pada pelaksanaan penelitian ini, penulis membutuhkan beberapa alat dan bahan yang digunakan seperti perangkat keras dan perangkat lunak. Adapun perangkat keras (*hardware*) yang digunakan adalah laptop merek HP dengan spesifikasi processor Intel ® Core™ i7-8565U dan RAM 8 GB dan perangkat lunak (*software*) yang digunakan adalah Windows 10 dan *Google Collaboratory* yang didukung dengan *library* sebagai berikut:

- a. *Selenium* 4.11.2
- b. *Pandas* 1.5.3
- c. *Numpy* 1.23.5
- d. *TensorFlow* 2.14.0
- e. *Transformers* 4.34.1
- f. *Scikit-learn* 1.2.2
- g. *Matplotlib* 3.7.1

Adapun bahan lain yang digunakan adalah komentar-komentar dari beberapa postingan pada akun berita di Instagram.

3.3 CARA KERJA

Adapun cara kerja pada penelitian ini terdiri dari beberapa tahapan. Berikut merupakan alur kerja pada penelitian ini terlihat pada gambar 3.1.



Gambar 3.1 Alur Kerja Penelitian

3.3.1 Studi Literatur

Langkah awal yang diambil adalah melakukan studi literatur, yang melibatkan pencarian informasi terkait dengan isu atau objek penelitian. Proses studi literatur dilakukan dengan memilih, menelusuri, membaca, mencatat, dan melakukan kajian pustaka. Tujuan dari tahap ini adalah untuk mencari landasan teori, kerangka berpikir, maupun mencari hipotesis penelitian.

3.3.2 Pengumpulan Data

Penelitian ini menggunakan data yang diperoleh dari interaksi pengguna berupa komentar pada akun berita di platform Instagram. Komentar dikumpulkan dari postingan di dua akun berita Instagram yaitu @detikcom dan @kumparancom karena kedua akun tersebut memiliki jumlah komentar yang banyak. Data komentar dikumpulkan menggunakan teknik *scraping*, yang secara otomatis mengambil informasi dari halaman *website*. *Scraping* dilakukan dengan menggunakan *Chrome Driver* dan *library Selenium*. Data komentar yang dikumpulkan disimpan dalam format CSV untuk memudahkan analisis selanjutnya.

3.3.3 Pelabelan Data

Proses pelabelan data adalah langkah di mana setiap data yang telah terkumpul akan diberikan label. Proses ini dilakukan secara manual dengan melakukan analisis mendalam untuk mengenali emosi yang paling dominan dalam setiap komentar. Pada penelitian ini, terdapat empat label emosi yang digunakan yaitu marah, sedih, senang, dan takut. Tujuan dari pelabelan data adalah untuk mendapatkan kualitas data yang baik (Jaluwana et al., 2022). Data yang diberi label selanjutnya akan divalidasi oleh alumni S1 psikologi untuk memastikan bahwa interpretasi emosi pada setiap komentar dilakukan dengan akurat sesuai dengan prinsip psikologis yang ada.

3.3.4 Data Preprocessing

Data komentar yang sudah berhasil dikumpulkan selanjutnya akan masuk ke dalam tahapan *preprocessing*. *Preprocessing* melibatkan serangkaian proses untuk menyiapkan dan menyesuaikan data teks sebelum dilakukan analisis atau tahapan pemrosesan berikutnya. Tujuan dari langkah *preprocessing* dalam penelitian ini adalah untuk membersihkan, mengorganisir, dan menyiapkan data agar sesuai dengan kebutuhan analisis. Berikut adalah beberapa langkah *preprocessing* yang dilakukan dalam penelitian ini:

a. *Case folding*

Langkah *case folding* digunakan untuk mengubah seluruh huruf dalam teks menjadi huruf kecil (Sari & Ruldeviyani, 2020). Tujuannya adalah untuk

mencegah adanya perbedaan dalam pengenalan antara huruf besar dan huruf kecil dalam data, sehingga memastikan bahwa data yang dihasilkan tetap konsisten dan seragam. Sebagai contoh kata "MERDEKA" dan "Merdeka" akan diubah keduanya menjadi kata "merdeka" dengan semua huruf menggunakan huruf kecil sehingga tidak ada perbedaan antara kedua kata setelah diterapkannya tahapan *case folding*.

b. *Data cleaning*

Pada tahapan *data cleaning* dilakukan pembersihan data dari komponen-komponen yang tidak terlalu relevan atau penting untuk tujuan penelitian. Hal ini termasuk di dalamnya penghapusan elemen-elemen seperti *link*, *username*, angka, *emoji*, dan tanda baca yang tidak memberikan kontribusi signifikan terhadap analisis yang dilakukan.

c. Normalisasi

Tahapan normalisasi bertujuan untuk memastikan bahwa kata atau frasa yang ada ditulis secara konsisten. Pada tahapan ini dilakukan pengubahan akronim dan singkatan yang sering digunakan dalam bahasa sehari-hari menjadi bentuk lengkap atau bentuk yang sesuai dengan kamus yang tersedia. Contohnya kata "jg" akan diubah menjadi kata "juga" sehingga model menganggap kedua kata tersebut sama.

d. *Remove stopwords*

Remove stopwords merupakan tahapan untuk menghilangkan kata-kata umum yang tidak memberikan banyak informasi penting dalam analisis teks (Miyajiwala et al., 2022). Tahapan ini akan menggunakan *library stopwords* Bahasa Indonesia yang disediakan oleh *library* Sastrawi.

e. *Stemming*

Proses stemming bertujuan untuk menyederhanakan kata-kata menjadi bentuk dasarnya (Rosid et al., 2020). Sebagai contoh, kata "mengambil", "mengambilkan", dan "diambil" akan diubah menjadi bentuk dasar "ambil".

3.3.5 *Split Dataset*

Sebelum melangkah ke tahap berikutnya, data yang sudah diberi label akan dipartisi menjadi tiga bagian, yaitu data latih (*train*), data uji (*test*), dan data validasi (*validation*). Data latih digunakan untuk mengembangkan model, data uji digunakan

untuk menguji dan mengevaluasi akurasi model, sementara data validasi digunakan untuk memvalidasi kinerja model dan mengurangi risiko *overfitting* (Imaduddin et al., 2023). Data akan dibagi sebesar 70% data *train*, 15% data *validation*, dan 15% data *test*.

3.3.6 Tokenisasi

Tokenisasi merupakan langkah dalam memisahkan teks atau data teks menjadi unit-unit yang lebih kecil, yang disebut sebagai token. Untuk membangun model dengan model *pre-trained* BERT baik itu IndoBERT ataupun IndoBERTweet diperlukan teknik tokenisasi khusus. BERT memiliki token spesifik seperti [CLS] untuk menentukan kategori klasifikasi dari kalimat *input*, dan [SEP] untuk menandai akhir dari kalimat. Selain itu, diperlukan token [PAD] atau padding untuk menyesuaikan panjang kalimat dari semua data. Pada penelitian ini, tokenisasi untuk model IndoBERT dilakukan oleh *tokenizer* milik IndoBERT dan tokenisasi untuk model IndoBERTweet dilakukan oleh *tokenizer* milik IndoBERTweet.

3.3.7 Load Model

Dalam penelitian ini, terdapat dua model yang akan dimuat.

a. IndoBERT

Pada penelitian ini, varian IndoBERT yang dimuat adalah model *indobert-base-pl* karena memiliki sumber daya komputasi yang tidak terlalu besar dengan urutan maksimum yang lebih kecil daripada fase kedua yaitu 128.

b. IndoBERTweet

Pada penelitian ini, varian IndoBERTweet yang dimuat adalah model *indobertweet-base-uncased*.

3.3.8 Fine-tuning

IndoBERT dan IndoBERTweet merupakan *pre-trained model* yang artinya model tersebut sudah dibuat dan dilatih sebelumnya. Namun, model tersebut perlu dilakukan *fine-tuning* agar sesuai dengan data dan keperluan penelitian ini. Berdasarkan penelitian terkait BERT, terdapat tiga parameter yang dapat disesuaikan untuk mengoptimalkan kinerja pada tahap *fine-tuning*, yaitu ukuran batch (*batch*

size), tingkat pembelajaran (*learning rate*), dan jumlah *epoch* (Devlin et al., 2019). Dengan demikian, berdasarkan rekomendasi tersebut, maka akan dilakukan penelusuran untuk mendapatkan nilai terbaik dari ketiga parameter tersebut.

3.3.9 Evaluasi Model

Setelah proses *fine-tuning* dilakukan, maka tahap selanjutnya adalah evaluasi model. Evaluasi akan dilakukan menggunakan *confusion matrix* untuk mengukur kinerja model yang dihasilkan dari proses *fine-tuning*. Penelitian ini memanfaatkan *f1 score*, *precision*, *recall*, dan *accuracy* sebagai kriteria evaluasi.

BAB IV HASIL DAN PEMBAHASAN

4.1 PENGUMPULAN DATA

Tahap awal dimulai dengan mengumpulkan data yang diperlukan. Data yang diperlukan dalam hal ini adalah komentar yang ditinggalkan oleh pengguna pada unggahan akun berita pada akun instagram @kumparancom dan @detikcom dari bulan April 2023 hingga bulan Agustus 2023. Proses pengumpulan data dilakukan dengan teknik *scraping* menggunakan *library Selenium*. *Selenium* memiliki *browser* sendiri yang disebut dengan *webdriver* contohnya *chrome driver* yang dirancang untuk berinteraksi dengan *browser google chrome*. Proses *scraping* pada penelitian ini dilakukan dengan memberikan *tag* yang berisi komentar pengguna dan selanjutnya komentar tersebut akan dikumpulkan secara otomatis oleh *selenium*. Total data yang berhasil dikumpulkan adalah sebanyak 5002 komentar. Contoh data yang telah dikumpulkan dapat dilihat pada tabel 4.1.

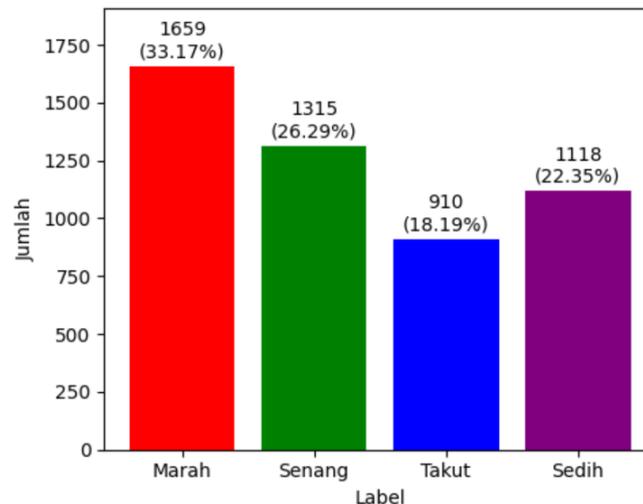
Tabel 4.1 Contoh data yang telah dikumpulkan

No	Komentar
1	bahaya skali ???? klo sedang human error' atau tecnology error' gimanah tuh ???? bisa menyebabkan kecelakaan dongggg ?????? kenapa tdk secepatnya di rubah dan di perbaiki ??
2	@nadiemmakarim Izin dgn segala hormat, tolong diusust tuntas sistem kebijakan pendidikan kita pak, skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org !!!,
3	Kereen....ada aja ide kreatifnya
4	Kasih an anak2 kelas menengah kebawah yg akses pendidikan mereka cuma mampu di sekolah negeri, kalau gurunya juga kurang oke, padahal muridnya berpotensi hebat Æ°Å,ËœÆ¢
5	Tidak ada manfaatnya .bubarkan saja,
6	allhamdulillah di kampus pertama ospek aku dapat hokben, mcd, naspad sederhana dan KFC. Di kampus ke dua walau tidak semewah yg pertama tapi minimal fastfood yg sudah terkenal. Cape ospek pun saat terimakan jd terhibur dan semangat.

4.2 PELABELAN DATA

Data yang sudah terkumpul selanjutnya diberikan label emosi. Label emosi yang digunakan pada penelitian ini yaitu marah, sedih, senang dan takut. Pelabelan data dilakukan secara manual dengan membaca satu persatu komentar dan

menentukan emosi dominan yang terkandung dalam setiap komentar yang ada. Hasil pelabelan data selanjutnya divalidasi oleh alumni S1 jurusan psikologi. Distribusi label emosi pada data yang sudah dikumpulkan dapat dilihat pada gambar 4.1.



Gambar 4.1 Distribusi label emosi pada data

Berdasarkan gambar 4.1 menunjukkan bahwa emosi marah merupakan emosi terbanyak pada dataset dengan persentase 33.2% yang mengindikasikan bahwa postingan berita cenderung menciptakan emosi marah pada pengguna. Selanjutnya, emosi senang mencapai 26.3%, emosi sedih 22.4% dan emosi takut 18.2%. Contoh hasil pelabelan data manual yang telah divalidasi dapat dilihat pada tabel 4.2.

Tabel 4.2 Contoh hasil pelabelan data

No	Komentar	Label
1	bahaya skali ???? klo sedang human error' atau tecnology error' gimana tuh ???? bisa menyebabkan kecelakaan dongggg ????? kenapa tdk secepatnya di rubah dan di perbaiki ??	Takut
2	@nadiemmakarim Izin dgn segala hormat, tolong diusust tuntas sistem kebijakan pendidikan kita pak, skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org !!!,	Marah
3	Kasih an anak2 kelas menengah kebawah yg akses pendidikan mereka cuma mampu di sekolah negeri, kalau gurunya juga kurang oke, padahal muridnya berpotensi hebat ã°Å,ËœÀ¢	Sedih
4	Tidak ada manfaatnya .bubarkan saja,	Marah
5	allhamdulillah di kampus pertama ospek aku dapat hokben, mcd, naspad sederhana dan KFC. Di kampus ke dua walau tidak semewah yg pertama tapi minimal fastfood yg sudah terkenal. Cape ospek pun saat terhibur jd terhibur dan semangat.	Senang

4.3 DATA PREPROCESSING

Data yang telah dikumpulkan perlu menjalani tahap *preprocessing* terlebih dahulu. *Preprocessing* data dilakukan untuk membersihkan data agar data tersebut menjadi lebih bersih dan terstruktur sehingga lebih efisien dan efektif untuk dilakukan analisis lebih lanjut.

4.3.1 Case folding

Case folding pada penelitian ini bertujuan untuk mengubah semua huruf dalam teks menjadi huruf kecil. Pada penelitian ini, *case folding* dilakukan dengan menggunakan fungsi *text.lower()*. Contoh hasil *case folding* dapat dilihat pada tabel 4.3.

Tabel 4.3 Contoh hasil *case folding*

<i>Input</i>	<i>Output</i>
Bahaya Skali klo sedang human error' atau Tecnology error' Gimana tuh ??? bisa menyebabkan kecelakaan dongggg ????? kenapa tdk secepatnya di rubah dan di perbaiki ??	bahaya skali ??? klo sedang human error' atau tecnology error' gimana tuh ??? bisa menyebabkan kecelakaan dongggg ????? kenapa tdk secepatnya di rubah dan di perbaiki ??
@nadiemmakarim Izin dgn segala hormat, tolong diusust tuntas sistem kebijakan pendidikan kita pak, skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org !!!,	@nadiemmakarim izin dgn segala hormat, tolong diusust tuntas sistem kebijakan pendidikan kita pak, skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org !!!,

4.3.2 Data cleaning

Pada proses *data cleaning*, dilakukan pembersihan data untuk menghilangkan unsur-unsur yang kurang relevan atau tidak terlalu penting untuk penelitian ini. Tahapan *data cleaning* yang dilakukan pada penelitian ini diantaranya yaitu menghapus *tag*, *hashtag*, *URL*, *mention (username)*, tanda baca, angka, emoji, spasi berlebih, dan menghilangkan pengulangan karakter yang sama (lebih dari 2 karakter yang sama diganti dengan 1 karakter). Contoh hasil *data cleaning* dapat dilihat pada tabel 4.4.

Tabel 4.4 Contoh hasil *data cleaning*

<i>Input</i>	<i>Output</i>
bahaya skali ??? klo sedang human error' atau tecnology error' gimana tuh ??? bisa menyebabkan kecelakaan	bahaya skali klo sedang human error' atau tecnology error' gimana tuh bisa menyebabkan kecelakaan dong kenapa

dongggg ?????? kenapa tdk secepatnya di rubah dan di perbaiki ??	tdk secepatnya di rubah dan di perbaiki
@nadiemmakarim izin dgn segala hormat, tolong diusust tuntas sistem kebijakan pendidikan kita pak, skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org !!!,	izin dgn segala hormat tolong diusust tuntas sistem kebijakan pendidikan kita pak skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org

4.3.3 Normalisasi

Normalisasi dilakukan dengan mengganti kata-kata *slang* atau tidak formal dalam kalimat menjadi kata-kata yang lebih umum atau sesuai dengan kamus yang tersedia. Proses normalisasi dimulai dengan membaca kamus kata *slang* yang berisi pasangan kata-kata *slang* dan kata-kata yang lebih umum atau benar. Kemudian kamus *slang* tersebut diubah menjadi bentuk *dictionary*. Setiap kalimat dibagi menjadi kata-kata terpisah. Untuk setiap kata dalam kalimat akan diperiksa apakah kata tersebut terdapat di dalam *dictionary*. Jika kata tersebut ditemukan dalam *dictionary*, maka kata tersebut diganti dengan nilai yang sesuai dalam *dictionary*. Jika kata tidak ada dalam *dictionary*, maka kata tersebut tetap dipertahankan dalam bentuk aslinya. Proses normalisasi teks pada penelitian ini menggunakan leksikon colloquial-indonesian-lexicon.csv (Aliyah Salsabila et al., 2018). Kamus yang digunakan berisi 151.167 kata *slang* beserta artinya. Contoh hasil normalisasi data dapat dilihat pada tabel 4.5.

Tabel 4.5 Contoh hasil normalisasi data

<i>Input</i>	<i>Output</i>
bahaya skali klo sedang human error atau tecnology error gimanah tuh bisa menyebabkan kecelakaan dong kenapa tdk secepatnya di rubah dan di perbaiki	bahaya sekali kalau sedang human error atau tecnology error gimanah itu bisa menyebabkan kecelakaan dong kenapa tidak secepatnya di rubah dan di perbaiki
izin dgn segala hormat tolong diusust tuntas sistem kebijakan pendidikan kita pak skrg hanya perkara iuran kas yg udh disetujui udh berani membunuh org	izin dengan segala hormat tolong diusust tuntas sistem kebijakan pendidikan kita pak sekarang hanya perkara iuran kas yang sudah disetujui sudah berani membunuh orang

4.3.4 Remove Stopwords

Tahapan *remove stopwords* dilakukan dengan cara memeriksa setiap kata pada dataset dan jika termasuk dalam daftar *stopwords*, maka kata tersebut akan

dihapus. Proses *remove stopwords* pada penelitian ini menggunakan *library Sastrawi*. Contoh hasil *remove stopwords* data dapat dilihat pada Tabel 4.6.

Tabel 4.6 Contoh hasil *remove stopwords*

<i>Input</i>	<i>Output</i>
bahaya sekali kalau sedang human error atau technology error gimanah itu bisa menyebabkan kecelakaan dong kenapa tidak secepatnya di rubah dan di perbaiki	bahaya human error tecnologia error gimanah menyebabkan kecelakaan secepatnya rubah perbaiki
izin dengan segala hormat tolong diusust tuntas sistem kebijakan pendidikan kita pak sekarang hanya perkara iuran kas yang sudah disetujui sudah berani membunuh orang	izin hormat tolong diusust tuntas sistem kebijakan pendidikan perkara iuran kas disetujui berani membunuh

4.3.5 *Stemming*

Pada penelitian ini, *stemming* dilakukan dengan menggunakan *library Sastrawi*. Proses ini dilakukan untuk mengubah kata menjadi bentuk dasarnya. Contoh hasil *stemming* data dapat dilihat pada tabel 4.7.

Tabel 4.7 Contoh hasil *stemming*

<i>Input</i>	<i>Output</i>
bahaya human error tecnologia error gimanah menyebabkan kecelakaan secepatnya rubah perbaiki	bahaya human error tecnologia error gimanah sebab celaka cepat rubah baik
izin hormat tolong diusust tuntas sistem kebijakan pendidikan perkara iuran kas disetujui berani membunuh	izin hormat tolong diusust tuntas sistem bijak didik perkara iur kas tuju berani bunuh

4.4 VISUALISASI DATA

Visualisasi data pada teks dilakukan untuk membantu memperjelas dan mempermudah pemahaman informasi yang terkandung dalam teks. Visualisasi data pada penelitian ini disajikan menggunakan *wordcloud*. *Wordcloud* merupakan teknik analisis teks yang menampilkan representasi grafis dari frekuensi kata-kata dalam teks asli. Semakin sering kata tersebut muncul dalam dokumen semakin besar ukuran kata tersebut dalam visualisasi *wordcloud*.

4.6 TOKENISASI

Dataset yang digunakan harus disesuaikan dengan format *input* yang diterima oleh model, baik itu *IndoBERT* ataupun *IndoBERTtweet*. Maka dari itu, diperlukan penambahan token khusus yaitu token [CLS] pada awal untuk memberi tahu model bahwa proses klasifikasi sedang dilakukan, dan token [SEP] pada tiap akhir kalimat untuk menandai akhir dari kalimat tersebut. Pada penelitian ini, panjang maksimum urutan kalimat diatur menjadi 98 sesuai dengan panjang maksimal teks pada data yang telah melewati seluruh tahapan *preprocessing*. Jika panjang suatu kalimat melebihi batas maksimum yang ditetapkan, maka kalimat akan dipotong (*truncate*). Sebaliknya, jika panjang kalimat kurang dari batas maksimum yang telah ditentukan, maka *padding* akan dilakukan dengan menambahkan token [PAD].

Proses tokenisasi pada setiap kata dalam kalimat dilakukan dengan menggunakan *tokenizer*. *Tokenizer* akan memeriksa apakah setiap kata dalam kalimat terdapat dalam kamus (*vocabulary*). Jika tidak ditemukan, kata tersebut akan dipecah menjadi subkata (*subword*) dengan menggunakan simbol *##*. Selanjutnya, dilakukan pengkodean (*encoding*) menggunakan *tokenizer* sesuai dengan indeks *vocabulary* dari *pre-trained IndoBERT* dan *IndoBERTtweet*. Hasil *tokenizer IndoBERT* dan *IndoBERTtweet* dapat dilihat pada tabel 4.9 dan 4.10.

Tabel 4.9 Hasil *tokenizer IndoBERT*

Kalimat	Tokenisasi	Encoding
bahaya human error tecnology error gimanah sebab celaka cepat rubah baik	['[CLS]', 'bahaya', 'human', 'error', 'te', '##c', '##no', '##log', '##y', 'error', 'gimana', '##h', 'sebab', 'celaka', 'cepat', 'rubah', 'baik', '[SEP]', '[PAD]', [PAD]', '[PAD]', ...'[PAD]']	[2, 5275, 8879, 8668, 908, 30373, 1867, 4880, 30371, 8668, 4255, 30369, 1440, 25445, 972, 20602, 342, 3, 0, 0, 0, ... 0]
izin hormat tolong diusust tuntas sistem bijak didik perkara iur kas tuju berani bunuh	['[CLS]', 'izin', 'hormat', 'tolong', 'dius', '##ust', 'tuntas', 'sistem', 'bijak', 'didik', 'perkara', 'i', '##ur', 'kas', 'taju', 'berani', 'bunuh', '[SEP]', [PAD]', '[PAD]', '[PAD]', ...'[PAD]']	[2, 4219, 9674, 3854, 7702, 1525, 8990, 737, 7051, 3203, 5510, 89, 58, 575, 23641, 3797, 7576, 3, 0, 0, 0, ...0]

Tabel 4.10 Hasil *tokenizer* IndoBERTtweet

Kalimat	Tokenisasi	Encoding
bahaya human error tecnology error gimanah sebab celaka cepat rubah baik	['[CLS]', 'bahaya', 'human', 'error', 'te', '##c', '##no', '##log', '##y', 'error', 'gimana', '##h', 'sebab', 'celaka', 'cepat', 'rubah', 'baik', '[SEP]', '[PAD]', '[PAD]', '[PAD]', ... '[PAD]']	[3, 7340, 8071, 21273, 2042, 949, 2918, 13074, 950, 21273, 15089, 945, 2714, 24770, 3218, 25912, 1983, 4, 0, 0, 0, ...0]
izin hormat tolong diusust tuntas sistem bijak didik perkara iur kas tuju berani bunuh	['[CLS]', 'izin', 'hormat', 'tolong', 'dius', '##ust', 'tuntas', 'sistem', 'bijak', 'didik', 'perkara', 'iu', '##r', 'kas', 'tju', 'berani', 'bunuh', [SEP]', '[PAD]', '[PAD]', '[PAD]', ... '[PAD]']	[3, 5297, 10902, 9917, 8517, 3653, 10766, 2289, 10946, 8820, 4704, 24150, 934, 2164, 31615, 5115, 7290, 4, 0, 0, 0, ...0]

Pada tabel 4.9 dan 4.10, kalimat yang dimasukkan tidak sama panjang dan tidak mencapai panjang maksimal yang telah diatur, sehingga dilakukan penambahan token [PAD] untuk menyesuaikan panjang kalimat menjadi sama dengan panjang maksimal urutan yang telah ditentukan.

4.7 FINE-TUNING

Sebelum melatih model maka *hyperparameter* harus diatur atau ditentukan terlebih dahulu. Nilai *hyperparameter* dipilih berdasarkan pada hasil uji coba yang telah dilakukan untuk memastikan bahwa nilai tersebut memberikan hasil yang optimal. *Hyperparameter* yang digunakan dalam penelitian ini dapat dilihat pada tabel 4.11.

Tabel 4.11 *Hyperparameter* IndoBERT dan IndoBERTtweet

Hyperparameter	Nilai
<i>Maximum sequence length</i>	98
<i>Batch Size</i>	16
<i>Optimizer</i>	AdamW
<i>Learning Rate</i>	2e-5
<i>Epoch</i>	10

4.8 EVALUASI MODEL

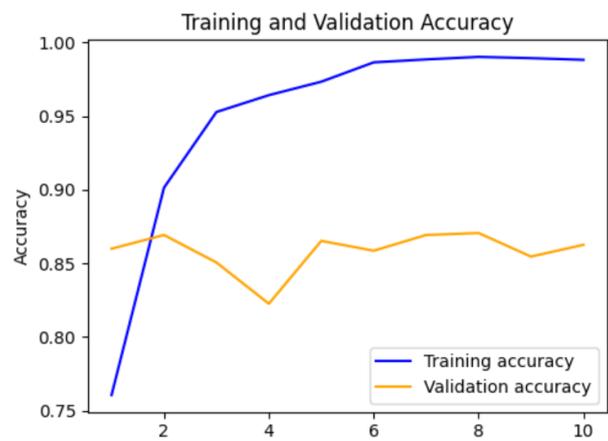
Pada penelitian ini dilakukan dua skenario. Pada skenario pertama, dataset yang digunakan adalah dataset yang melalui seluruh proses *preprocessing*.

Sedangkan pada skenario kedua, dataset yang digunakan adalah dataset yang hanya melalui proses *case folding*, *data cleaning* dan normalisasi tanpa melibatkan tahap *remove stopwords* dan *stemming*.

4.8.1 IndoBERT

4.8.1.1 Skenario Pertama

Setelah melakukan proses *fine-tuning* pada IndoBERT skenario pertama, maka diperoleh grafik perubahan nilai akurasi pada setiap *epoch*. Grafik akurasi model IndoBERT untuk skenario pertama dapat dilihat pada gambar 4.6.



Gambar 4.6 Grafik akurasi model IndoBERT pada skenario pertama

Berdasarkan gambar 4.6 menunjukkan bahwa pada awal pelatihan, model memiliki tingkat akurasi *train* yang rendah karena model belum mengenali dengan baik pola-pola data. Seiring berjalannya proses *fine-tuning*, akurasi *train* cenderung meningkat. Akurasi *validation* pada awalnya juga meningkat hingga *epoch* ke-2, kemudian menurun hingga *epoch* ke-4. Akurasi *validation* setelahnya kembali meningkat pada *epoch* ke-5 dan kemudian cenderung stabil hingga akhir *epoch* dengan rentang nilai akurasi sebesar 0.85 hingga 0.87. Selanjutnya terdapat grafik *loss* model IndoBERT skenario pertama yang dapat dilihat pada gambar 4.7.



Gambar 4.7 Grafik *loss* model IndoBERT pada skenario pertama

Berdasarkan gambar 4.7 menunjukkan bahwa nilai *loss* untuk data *train* secara konsisten menurun hingga *epoch* ke-6 dan setelahnya cenderung stabil hingga *epoch* terakhir. Nilai *loss* pada data *validation* awalnya sedikit menunjukkan pola menurun hingga *epoch* ke-2, namun setelahnya meningkat hingga *epoch* ke-4. Nilai *loss* pada data *validation* kembali menurun pada *epoch* ke-5 dan kemudian cenderung stabil hingga *epoch* ke-10 dengan rentang 0.58 hingga 0.61. Setelah proses *fine-tuning*, selanjutnya model dievaluasi menggunakan *confusion matrix* yang dapat dilihat pada tabel 4.12.

Tabel 4.12 Confusion matrix model IndoBERT skenario pertama

<i>Actual</i>	<i>Prediction</i>			
	Marah	Senang	Takut	Sedih
Marah	218	6	7	18
Senang	23	166	3	6
Takut	8	1	117	10
Sedih	20	7	1	140

Berdasarkan tabel 4.12 menunjukkan bahwa model IndoBERT pada skenario pertama berhasil memprediksi dengan benar emosi marah sebanyak 218 dari 249 data, senang 166 dari 198 data, takut 117 dari 136 data, dan sedih 140 dari 168 data. Terdapat sedikit kesulitan dalam membedakan emosi marah dan sedih dimana 20 data dengan label sedih salah diprediksi sebagai marah dan 18 data dengan label marah salah diprediksi sebagai sedih. Selain itu terdapat kesalahan prediksi dimana 23 data dengan label senang diprediksi sebagai marah dan 10 data dengan label takut diprediksi sebagai emosi sedih.

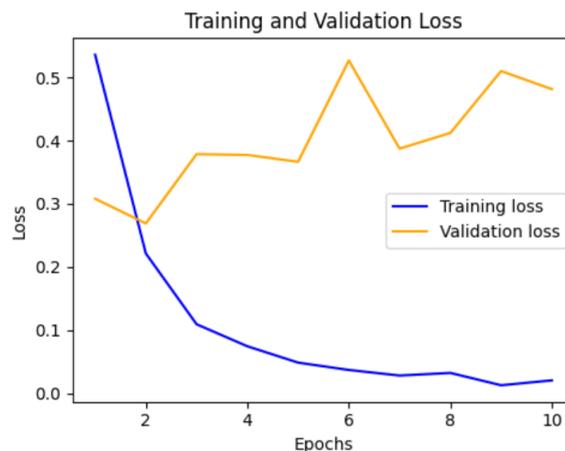
4.8.1.2 Skenario Kedua

Setelah melakukan proses *fine-tuning* pada IndoBERT skenario kedua, maka diperoleh grafik perubahan nilai akurasi pada setiap *epoch*. Grafik akurasi model IndoBERT untuk skenario kedua dapat dilihat pada gambar 4.8.



Gambar 4.8 Grafik akurasi model IndoBERT pada skenario kedua

Berdasarkan gambar 4.8 menunjukkan bahwa nilai akurasi *train* pada *epoch* ke-1 yaitu sebesar 0.80 dan setelahnya cenderung meningkat hingga epoch terakhir dan mencapai akurasi sebesar 0.99. Sedangkan nilai akurasi data *validation* relatif stabil pada saat *epoch* pertama hingga *epoch* terakhir dengan rentang nilai akurasi antara 0.87 hingga 0.91. Selanjutnya terdapat grafik *loss* model IndoBERT skenario kedua yang dapat dilihat pada gambar 4.9.



Gambar 4.9 Grafik *loss* model IndoBERT pada skenario kedua

Berdasarkan gambar 4.9 menunjukkan bahwa nilai *loss* untuk data *train* cenderung menunjukkan pola menurun hingga *epoch* terakhir. Sementara itu, nilai

loss pada data *validation* menurun hingga *epoch* ke-2 namun setelahnya cenderung meningkat hingga *epoch* ke-6. Nilai *loss* pada data *validation* kembali menurun pada *epoch* ke-7 namun kemudian kembali menunjukkan pola meningkat hingga *epoch* ke-9. Nilai *loss validation* setelahnya sedikit menurun pada akhir *epoch* dengan nilai sebesar 0.48. Setelah proses *fine-tuning*, selanjutnya model dievaluasi menggunakan *confusion matrix* yang dapat dilihat pada tabel 4.13.

Tabel 4.13 *Confusion matrix* model IndoBERT skenario kedua

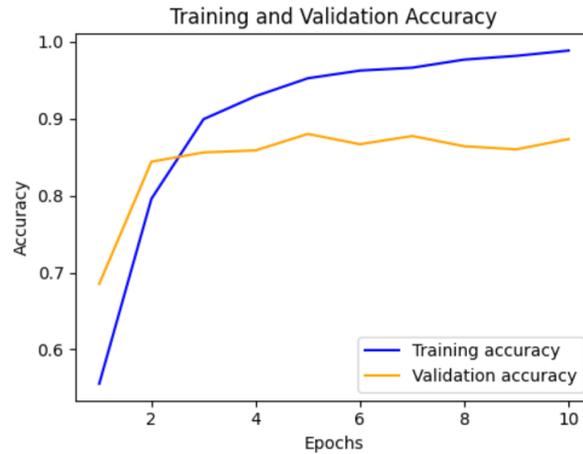
<i>Actual</i>	<i>Prediction</i>			
	Marah	Senang	Takut	Sedih
Marah	219	11	4	15
Senang	5	190	1	2
Takut	13	3	115	5
Sedih	14	10	1	143

Berdasarkan tabel 4.13 menunjukkan bahwa model IndoBERT pada skenario kedua berhasil memprediksi dengan benar emosi marah sebanyak 219 dari 249 data, senang 190 dari 198 data, takut 115 dari 136 data, dan sedih 143 dari 168 data. Model IndoBERT mengalami peningkatan pada skenario kedua dibandingkan skenario pertama terutama dalam memprediksi emosi senang. Pada model IndoBERT skenario kedua juga terdapat sedikit kesulitan dalam membedakan emosi marah dan sedih dimana 14 data dengan label sedih salah diprediksi sebagai marah dan 15 data dengan label marah salah diprediksi sebagai sedih. Selain itu terdapat kesalahan prediksi dimana 11 data dengan label marah diprediksi sebagai senang dan 13 data dengan label takut diprediksi sebagai emosi marah.

4.8.2 IndoBERTweet

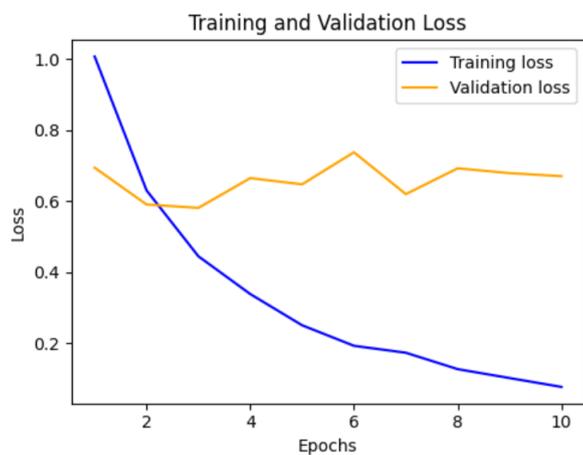
4.8.2.1 Skenario Pertama

Setelah melakukan proses *fine-tuning* pada IndoBERTweet skenario pertama, maka diperoleh grafik perubahan nilai akurasi pada setiap *epoch*. Grafik akurasi model IndoBERTweet untuk skenario pertama dapat dilihat pada gambar 4.10.



Gambar 4.10 Grafik akurasi model IndoBERTweet pada skenario pertama

Berdasarkan gambar 4.10 menunjukkan bahwa pada awal pelatihan, model memiliki tingkat akurasi *train* yang rendah yaitu sebesar 0.55. Seiring berjalannya proses *fine-tuning*, akurasi *train* secara konsisten meningkat hingga mencapai 0.98 pada akhir *epoch*. Sementara itu, akurasi *validation* pada awalnya juga meningkat hingga *epoch* ke-2, dan pada epoch selanjutnya cenderung stabil dengan rentang akurasi sebesar 0.85 hingga 0.87. Selanjutnya terdapat grafik *loss* model IndoBERTweet skenario pertama yang dapat dilihat pada gambar 4.11.



Gambar 4.11 Grafik *loss* model IndoBERTweet pada skenario pertama

Berdasarkan gambar 4.11 menunjukkan bahwa nilai *loss* pada data *train* secara konsisten menurun hingga *epoch* terakhir dan mencapai nilai 0.07. Sementara itu, nilai *loss* pada data *validation* cenderung stabil dari awal *epoch* hingga akhir *epoch* dengan rentang nilai *loss* sebesar 0.73 hingga 0.59. Setelah proses *fine-tuning*,

selanjutnya model dievaluasi menggunakan *confusion matrix* yang dapat dilihat pada tabel 4.14.

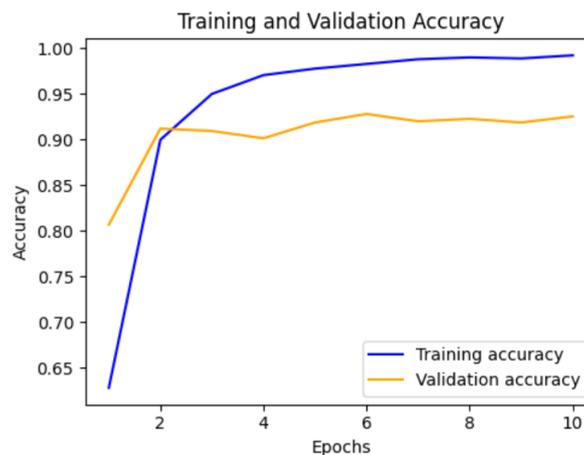
Tabel 4.14 *Confusion matrix* model IndoBERTweet skenario pertama

<i>Actual</i>	<i>Prediction</i>			
	Marah	Senang	Takut	Sedih
Marah	228	6	3	12
Senang	14	178	1	5
Takut	7	2	119	8
Sedih	25	5	0	138

Berdasarkan tabel 4.14 menunjukkan bahwa model IndoBERTweet pada skenario pertama berhasil memprediksi dengan benar emosi marah sebanyak 228 dari 249 data, senang 178 dari 198 data, takut 119 dari 136 data, dan sedih 138 dari 168 data. Terdapat sedikit kesulitan dalam membedakan emosi marah dan sedih dimana 25 data dengan label sedih salah diprediksi sebagai marah dan 12 data dengan label marah salah diprediksi sebagai sedih. Selain itu terdapat kesalahan prediksi dimana 14 data dengan label senang diprediksi sebagai marah.

4.8.2.2 Skenario Kedua

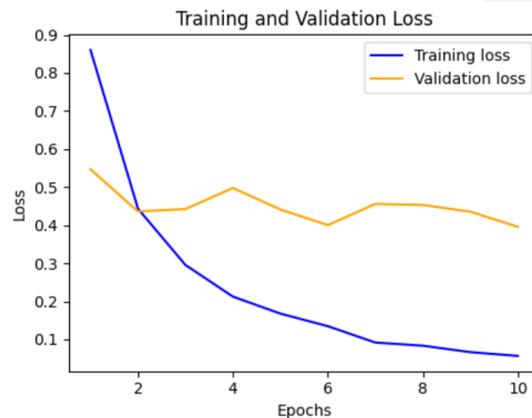
Setelah melakukan proses *fine-tuning* pada IndoBERTweet skenario kedua, maka diperoleh grafik perubahan nilai akurasi pada setiap *epoch*. Grafik akurasi model IndoBERTweet untuk skenario kedua dapat dilihat pada gambar 4.12.



Gambar 4.12 Grafik akurasi model IndoBERTweet pada skenario kedua

Berdasarkan gambar 4.12 menunjukkan bahwa pada awal pelatihan, model memiliki tingkat akurasi *train* yang rendah yaitu sebesar 0.52. Seiring berjalannya

proses *fine-tuning*, akurasi *train* secara konsisten meningkat hingga mencapai akurasi 0.99 pada *epoch* terakhir. Sementara itu, akurasi *validation* pada awalnya juga meningkat hingga *epoch* ke-2, dan pada *epoch* selanjutnya cenderung stabil dengan rentang akurasi sebesar 0.90 hingga 0.92. Selanjutnya terdapat grafik *loss* model IndoBERTweet skenario kedua yang dapat dilihat pada gambar 4.13.



Gambar 4.13 Grafik *loss* model IndoBERTweet pada skenario kedua

Berdasarkan gambar 4.13 menunjukkan bahwa nilai *loss* pada data *train* secara konsisten menurun hingga *epoch* terakhir dimana nilai *loss* pada *epoch* terakhir sebesar 0.05. Sementara itu, nilai *loss* pada data *validation* juga menunjukkan sedikit penurunan meskipun terjadi peningkatan dan penurunan pada beberapa *epoch* selama proses pelatihan. Nilai *loss* pada *epoch* pertama sebesar 0.54 dan nilai *loss* pada *epoch* terakhir sebesar 0.39. Setelah proses *fine-tuning*, selanjutnya model dievaluasi menggunakan *confusion matrix* yang dapat dilihat pada tabel 4.15.

Tabel 4.15 *Confusion matrix* model IndoBERTweet skenario kedua

<i>Actual</i>	<i>Prediction</i>			
	Marah	Senang	Takut	Sedih
Marah	229	2	3	15
Senang	1	194	2	1
Takut	5	0	122	9
Sedih	16	2	0	150

Berdasarkan tabel 4.15 menunjukkan bahwa model IndoBERTweet pada skenario kedua berhasil memprediksi dengan lebih baik dibandingkan skenario pertama karena terjadi peningkatan dalam memprediksi keempat label yang ada. Model IndoBERTweet skenario kedua berhasil memprediksi dengan benar emosi

marah sebanyak 229 dari 249 data, senang 194 dari 198 data, takut 122 dari 136 data, dan sedih 150 dari 168 data. Pada model IndoBERTweet skenario kedua juga terdapat sedikit kesulitan dalam membedakan emosi marah dan sedih dimana 16 data dengan label sedih salah diprediksi sebagai marah dan 15 data dengan label marah salah diprediksi sebagai sedih.

4.8.3 Perbandingan model IndoBERT dan IndoBERTweet

Perbandingan performa model IndoBERT dan IndoBERTweet pada skenario pertama dan skenario kedua dapat dilihat pada tabel 4.16.

Tabel 4.16 Perbandingan model IndoBERT dan IndoBERTweet

Skenario	Model	Akurasi	<i>Precision</i>	<i>Recall</i>	<i>F1 Score</i>
I	IndoBERT	0.8535	0.8628	0.8519	0.8563
	IndoBERTweet	0.8828	0.8895	0.8945	0.8850
II	IndoBERT	0.8881	0.8944	0.8840	0.8880
	IndoBERTweet	0.9254	0.9275	0.9223	0.9245

Berdasarkan tabel 4.16 menunjukkan bahwa model IndoBERTweet menunjukkan performa yang lebih baik dibandingkan model IndoBERT pada semua matriks evaluasi. Pada skenario pertama, model IndoBERTweet lebih baik dibandingkan model IndoBERT dengan akurasi sebesar 88.28%, *precision* 88.95%, *recall* 89.45%, dan *f-1 score* 88.50%. Pada skenario kedua terjadi peningkatan performa pada kedua model dan model IndoBERTweet tetap lebih unggul dibandingkan model IndoBERT dengan akurasi sebesar 92.54%, *precision* 92.75%, *recall* 92.23%, dan *f-1 score* 92.54%. Hal ini menandakan bahwa model IndoBERTweet lebih baik dalam mengklasifikasikan emosi pada penelitian ini dibandingkan dengan model IndoBERT pada kedua skenario yang telah diuji. Selisih akurasi model IndoBERTweet dan IndoBERT pada skenario pertama adalah 2.93% sedangkan selisih akurasi model IndoBERTweet dan IndoBERT pada skenario kedua adalah 3.73%. Contoh hasil klasifikasi emosi model IndoBERT dan IndoBERTweet berdasarkan penelitian ini dapat dilihat pada tabel 4.17.

Tabel 4.17 Hasil prediksi model IndoBERT dan IndoBERTweet

Skenario	Komentar	IndoBERT	IndoBERTweet	Aktual
I	kumpul syukur	Senang	Senang	Marah
	naro bawang sehat sehat iya mas	Senang	Sedih	Sedih

II	sekumpulan orang yang tidak bisa bersyukur	Marah	Marah	Marah
	siapa yang nara bawang disini sehat sehat iya mas	Senang	Sedih	Sedih

Proses *remove stopwords* dan *stemming* dapat mengubah atau mengurangi informasi penting yang ada pada teks. Sebagai contoh seperti yang terlihat pada tabel 4.17. Pada skenario pertama kata “kumpul syukur” diprediksi sebagai emosi senang oleh kedua model sedangkan emosi sebenarnya adalah marah. Sedangkan pada skenario kedua dimana proses *remove stopwords* dan *stemming* tidak dilakukan, kata “sekumpulan orang yang tidak bisa bersyukur” diprediksi dengan benar oleh kedua model sebagai emosi marah. Kata “tidak” merupakan kata yang termasuk ke dalam kamus *stopwords*. Jika kata “tidak” dihilangkan, maka akan memberikan makna yang berbeda sehingga model tidak dapat memprediksi label emosi dengan benar.

Model IndoBERTweet lebih baik dalam mengklasifikasikan data yang berasal dari media sosial dibandingkan dengan model IndoBERT. Hal ini juga dapat dilihat pada tabel 4.17 dimana komentar yang mengandung kata “bawang” berhasil diprediksi sebagai emosi sedih pada model IndoBERTweet namun tidak berhasil diprediksi dengan benar pada model IndoBERT. Kata “bawang” sering menjadi kiasan pada pengguna media sosial untuk menyampaikan rasa sedih.

BAB V

KESIMPULAN DAN SARAN

5.1 KESIMPULAN

Berdasarkan penelitian yang telah dilakukan untuk mendeteksi emosi komentar berita pada media sosial, kesimpulan yang didapatkan adalah sebagai berikut:

1. Model IndoBERT dan IndoBERTweet diterapkan dengan melakukan penyesuaian model terhadap dataset (*fine-tuning*) yang melibatkan serangkaian uji coba *hyperparameter* untuk mendapatkan hasil yang optimal.
2. Model IndoBERT memperoleh akurasi sebesar 85.35% untuk data yang melalui tahapan *remove stopwords* dan *stemming* serta 88.81% untuk data yang tidak melalui tahapan *remove stopwords* dan *stemming*.
3. Model IndoBERTweet memperoleh akurasi sebesar 88.28% untuk data yang melalui tahapan *remove stopwords* dan *stemming* serta 92.54% untuk data yang tidak melalui tahapan *remove stopwords* dan *stemming*.
4. Hasil evaluasi menunjukkan bahwa model IndoBERTweet mencapai kinerja yang lebih baik dibandingkan model IndoBERT.
5. Data yang tidak melewati tahapan *remove stopwords* dan *stemming* mendapatkan hasil yang lebih baik daripada data yang melalui seluruh tahapan *remove stopwords* dan *stemming*.

5.2 SARAN

Adapun saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

1. Mengumpulkan lebih banyak data serta memperluas cakupan emosi yang dapat diidentifikasi.
2. Mengeksplorasi *pre-trained model* bahasa Indonesia lainnya seperti IndoXLNet untuk tugas mendeteksi emosi.
3. Mengeksplorasi berbagai kombinasi tahapan preprocessing untuk melihat pengaruhnya pada akurasi *pre-trained model*.

DAFTAR KEPUSTAKAAN

- Adoma, A. F., Henry, N. M., & Chen, W. (2020). Comparative Analyses of Bert, Roberta, Distilbert, and Xlnet for Text-Based Emotion Recognition. *2020 17th International Computer Conference on Wavelet Active Media Technology and Information Processing, ICCWAMTIP 2020*, 117–121. <https://doi.org/10.1109/ICCWAMTIP51612.2020.9317379>
- Agustina, D. (2018). Peleburan Realitas Nyata dan Maya: Hoax Menjadi Konsumsi Masyarakat Global. *Jurnal Sosiologi Agama*, 12(2), 245. <https://doi.org/10.14421/jsa.2018.122-04>
- Aliyah Salsabila, N., Ardhito Winatmoko, Y., Akbar Septiandri, A., & Jamal, A. (2018). Colloquial Indonesian Lexicon. *Proceedings of the 2018 International Conference on Asian Language Processing, IALP 2018*, 226–229. <https://doi.org/10.1109/IALP.2018.8629151>
- Chiorrini, A., Diamantini, C., Mircoli, A., & Potena, D. (2021). Emotion and sentiment analysis of tweets using BERT. *CEUR Workshop Proceedings*, 2841.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference, I(Mlm)*, 4171–4186.
- Dey, S., Wasif, S., Tonmoy, D. S., Sultana, S., Sarkar, J., & Dey, M. (2020). A Comparative Study of Support Vector Machine and Naive Bayes Classifier for Sentiment Analysis on Amazon Product Reviews. *2020 International Conference on Contemporary Computing and Applications, IC3A 2020*, 217–220. <https://doi.org/10.1109/IC3A48958.2020.233300>
- Ebbehoj, A., Thunbo, M. Ø., Andersen, O. E., Glindtvad, M. V., & Hulman, A. (2022). Transfer learning for non-image data in clinical research: A scoping review. *PLOS Digital Health*, 1(2), e0000014. <https://doi.org/10.1371/journal.pdig.0000014>
- Garcia, R. (2017). Neurobiology of fear and specific phobias. *Learning and Memory*, 24(9), 462–471. <https://doi.org/10.1101/lm.044115.116>
- Gu, S., Wang, F., Patel, N. P., Bourgeois, J. A., & Huang, J. H. (2019). A model for basic emotions using observations of behavior in Drosophila. *Frontiers in Psychology*, 10(APR), 1–13. <https://doi.org/10.3389/fpsyg.2019.00781>
- Gupta, N. (2021). A Pre-Trained Vs Fine-Tuning Methodology in Transfer Learning. *Journal of Physics: Conference Series*, 1947(1). <https://doi.org/10.1088/1742->

- Haryadi, D., & Kusuma, G. P. (2019). Emotion detection in text using nested Long Short-Term Memory. *International Journal of Advanced Computer Science and Applications*, 10(6), 351–357. <https://doi.org/10.14569/ijacsa.2019.0100645>
- Hosna, A., Merry, E., Gyalmo, J., Alom, Z., Aung, Z., & Azim, M. A. (2022). Transfer learning: a friendly introduction. *Journal of Big Data*, 9(1). <https://doi.org/10.1186/s40537-022-00652-w>
- Imaduddin, H., A'la, F. Y., & Nugroho, Y. S. (2023). Sentiment Analysis in Indonesian Healthcare Applications using IndoBERT Approach. *International Journal of Advanced Computer Science and Applications*, 14(8), 113–117. <https://doi.org/10.14569/IJACSA.2023.0140813>
- Kang, Y., Cai, Z., Tan, C. W., Huang, Q., & Liu, H. (2020). Natural language processing (NLP) in management research: A literature review. *Journal of Management Analytics*, 7(2), 139–172. <https://doi.org/10.1080/23270012.2020.1756939>
- Khurana, D., Koli, A., Khatter, K., & Singh, S. (2023). Natural language processing: state of the art, current trends and challenges. *Multimedia Tools and Applications*, 82(3), 3713–3744. <https://doi.org/10.1007/s11042-022-13428-4>
- Koto, F., Lau, J. H., & Baldwin, T. (2021). INDOBERTWEET: A Pretrained Language Model for Indonesian Twitter with Effective Domain-Specific Vocabulary Initialization. *EMNLP 2021 - 2021 Conference on Empirical Methods in Natural Language Processing, Proceedings*, 10660–10668. <https://doi.org/10.18653/v1/2021.emnlp-main.833>
- Kukuh Jaluwana, G. A. M., Gusti Made Arya Sasmita, & I Made Agus Dwi Suarjaya. (2022). Analysis of Public Sentiment Towards Government Efforts to Break the Chain of Covid-19 Transmission in Indonesia Using CNN and Bidirectional LSTM. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(4), 511–520. <https://doi.org/10.29207/resti.v6i4.4055>
- Lan, Z., Chen, M., Goodman, S., Gimpel, K., Sharma, P., & Soricut, R. (2020). Albert: a Lite Bert for Self-Supervised Learning of Language Representations. *8th International Conference on Learning Representations, ICLR 2020*, 1–17.
- Mirzaee, H., Peymanfard, J., Moshtaghin, H. H., & Zeinali, H. (2022). *ArmanEmo: A Persian Dataset for Text-based Emotion Detection*. 1–14. <http://arxiv.org/abs/2207.11808>
- Miyajiwala, A., Ladkat, A., Jagadale, S., & Joshi, R. (2022). On Sensitivity of Deep Learning Based Text Classification Algorithms to Practical Input Perturbations. *Lecture Notes in Networks and Systems*, 507 LNNS, 613–626. https://doi.org/10.1007/978-3-031-10464-0_42
- Nandwani, P., & Verma, R. (2021). A review on sentiment analysis and emotion

- detection from text. *Social Network Analysis and Mining*, 11(1), 1–19. <https://doi.org/10.1007/s13278-021-00776-6>
- Nisa, R., Amriza, S., & Supriyadi, D. (2021). *Komparasi Metode*. 13(2), 130–139.
- Rahardja, U., Lutfiani, N., & Rahmawati, R. (2018). Persepsi Mahasiswa Terhadap Berita Pada Website APTISI. *Sisfotenika*, 8(2), 117. <https://doi.org/10.30700/jst.v8i2.400>
- Realita, E., & Setiadi, U. (2022). Konsumsi Berita Insidental di Media Sosial pada Generasi Dewasa. *Jurnal Riset Komunikasi*, 5(1), 99–112. <https://doi.org/10.38194/jurkom.v5i1.437>
- Rosid, M. A., Fitriani, A. S., Astutik, I. R. I., Mulloh, N. I., & Gozali, H. A. (2020). Improving Text Preprocessing for Student Complaint Document Classification Using Sastrawi. *IOP Conference Series: Materials Science and Engineering*, 874(1). <https://doi.org/10.1088/1757-899X/874/1/012017>
- Sailunaz, K., & Alhaji, R. (2019). Emotion and sentiment analysis from Twitter text. *Journal of Computational Science*, 36, 101003. <https://doi.org/10.1016/j.jocs.2019.05.009>
- Saldanha, F., Devi, P., & Kumari, M. (2021). *Saudi Journal of Humanities and Social Sciences Abbreviated Key Title: Saudi J Humanities Soc Sci Psychological Well-Being and Happiness among Young Adults under the Condition of Lockdown*. 6256, 327–333. <https://doi.org/10.36348/sjhss.2021.v06i09.004>
- Sari, I. C., & Ruldeviyani, Y. (2020). Sentiment Analysis of the Covid-19 Virus Infection in Indonesian Public Transportation on Twitter Data: A Case Study of Commuter Line Passengers. *2020 International Workshop on Big Data and Information Security (IWBIS)*, 23–28. <https://doi.org/10.1109/IWBIS50925.2020.9255531>
- Sun, L., Jiang, Z., Chang, Y., & Ren, L. (2021). Building a patient-specific model using transfer learning for four-dimensional cone beam computed tomography augmentation. *Quantitative Imaging in Medicine and Surgery*, 11(2), 540–555. <https://doi.org/10.21037/QIMS-20-655>
- Tsikandilakis, M., Bali, P., Yu, Z., Karlis, A. K., Tong, E. M. W., Milbank, A., Mevel, P. A., Derrfuss, J., & Madan, C. (2023). “The many faces of sorrow”: An empirical exploration of the psychological plurality of sadness. *Current Psychology*. <https://doi.org/10.1007/s12144-023-04518-z>
- Ulya, M. (2020). Konstruksi Emosi Marah Perspektif Al-Qur’an. *El-'Umdah*, 3(1), 23–46. <https://doi.org/10.20414/el-umdah.v3i1.2152>
- Vrbančič, G., & Podgorelec, V. (2020). Transfer learning with adaptive fine-tuning. *IEEE Access*, 8, 196197–196211. <https://doi.org/10.1109/ACCESS.2020.3034343>

- Wilie, B., Vincentio, K., Winata, G. I., Cahyawijaya, S., Li, X., Lim, Z. Y., Soleman, S., Mahendra, R., Fung, P., Bahar, S., & Purwarianti, A. (2020). *IndoNLU: Benchmark and Resources for Evaluating Indonesian Natural Language Understanding*. 843–857. <http://arxiv.org/abs/2009.05387>
- Wong, A., Plasek, J. M., Montecalvo, S. P., & Zhou, L. (2018). Natural Language Processing and Its Implications for the Future of Medication Safety: A Narrative Review of Recent Advances and Challenges. *Pharmacotherapy*, 38(8), 822–841. <https://doi.org/10.1002/phar.2151>
- Yulita, I. N., Wijaya, V., Rosadi, R., Sarathan, I., Djuyandi, Y., & Prabuwno, A. S. (2023). Analysis of Government Policy Sentiment Regarding Vacation during the COVID-19 Pandemic Using the Bidirectional Encoder Representation from Transformers (BERT). *Data*, 8(3). <https://doi.org/10.3390/data8030046>

LAMPIRAN

Lampiran 1. Fine-tuning batch size 16, dropout 0.5, 70:15:15, maximum sequence length 98

Model	Skenario	Epoch	Learning rate	Akurasi
IndoBERT	I	3	1e-5	0.8628
			2e-5	0.8442
			3e-5	0.8282
		5	1e-5	0.8522
			2e-5	0.8521
			3e-5	0.8428
		10	1e-5	0.8562
			2e-5	0.8535
			3e-5	0.8389
	II	3	1e-5	0.8921
			2e-5	0.8881
			3e-5	0.8495
		5	1e-5	0.8895
			2e-5	0.8988
			3e-5	0.8921
		10	1e-5	0.8934
			2e-5	0.8881
			3e-5	0.8974
IndoBERTtweet	I	3	1e-5	0.8296
			2e-5	0.8509
			3e-5	0.8455
		5	1e-5	0.8521
			2e-5	0.8509
			3e-5	0.8774
		10	1e-5	0.8708
			2e-5	0.8828
			3e-5	0.8854
	II	3	1e-5	0.9001
			2e-5	0.9161
			3e-5	0.9174
		5	1e-5	0.9027
			2e-5	0.9254
			3e-5	0.9187
		10	1e-5	0.9161
			2e-5	0.9254
			3e-5	0.8894

Lampiran 2. Fine-tuning batch size 16, dropout 0.5, 80:10:10, maximum sequence length 98

Model	Skenario	Epoch	Learning rate	Akurasi
IndoBERT	I	3	1e-5	0.8583
			2e-5	0.8783
			3e-5	0.8563
		5	1e-5	0.8523
			2e-5	0.8603
			3e-5	0.8463
		10	1e-5	0.8643
			2e-5	0.8702
			3e-5	0.8403
	II	3	1e-5	0.9201
			2e-5	0.8802
			3e-5	0.9022
		5	1e-5	0.8982
			2e-5	0.8782
			3e-5	0.9062
10		1e-5	0.9182	
		2e-5	0.9122	
		3e-5	0.9122	
IndoBERTtweet	I	3	1e-5	0.8483
			2e-5	0.8423
			3e-5	0.8383
		5	1e-5	0.8623
			2e-5	0.8762
			3e-5	0.8663
		10	1e-5	0.8842
			2e-5	0.8723
			3e-5	0.8842
	II	3	1e-5	0.8982
			2e-5	0.9181
			3e-5	0.9121
		5	1e-5	0.9122
			2e-5	0.9242
			3e-5	0.9122
10		1e-5	0.9202	
		2e-5	0.9222	
		3e-5	0.9161	

Lampiran 3. Fine-tuning batch size 32, dropout 0.5, 75:15:15, maximum sequence length 98

Model	Skenario	Epoch	Learning rate	Akurasi
IndoBERT	I	3	1e-5	0.8655
			2e-5	0.8509
			3e-5	0.8602
		5	1e-5	0.8628
			2e-5	0.8602
			3e-5	0.8522
		10	1e-5	0.8602
			2e-5	0.8575
			3e-5	0.8455
	II	3	1e-5	0.8935
			2e-5	0.8802
			3e-5	0.9022
		5	1e-5	0.8895
			2e-5	0.8782
			3e-5	0.9062
10		1e-5	0.8961	
		2e-5	0.9121	
		3e-5	0.9122	
IndoBERTtweet	I	3	1e-5	0.7057
			2e-5	0.8615
			3e-5	0.8522
		5	1e-5	0.8628
			2e-5	0.8695
			3e-5	0.8655
		10	1e-5	0.8788
			2e-5	0.8894
			3e-5	0.8735
	II	3	1e-5	0.8415
			2e-5	0.8961
			3e-5	0.9094
		5	1e-5	0.9001
			2e-5	0.9121
			3e-5	0.9241
10	1e-5	0.9095		
	2e-5	0.9214		
	3e-5	0.9161		

Lampiran 4. Fine-tuning batch size 16, dropout 0.5, 75:15:15, maximum sequence length 30

Model	Skenario	Epoch	Learning rate	Akurasi
IndoBERT	I	3	1e-5	0.8655
			2e-5	0.8575
			3e-5	0.8495
		5	1e-5	0.8242
			2e-5	0.8535
			3e-5	0.8402
		10	1e-5	0.8642
			2e-5	0.8655
			3e-5	0.8469
	II	3	1e-5	0.8935
			2e-5	0.8935
			3e-5	0.8842
		5	1e-5	0.8988
			2e-5	0.8974
			3e-5	0.8708
10		1e-5	0.8934	
		2e-5	0.8828	
		3e-5	0.8708	
IndoBERTweet	I	3	1e-5	0.8547
			2e-5	0.8469
			3e-5	0.8549
		5	1e-5	0.8495
			2e-5	0.8655
			3e-5	0.8735
		10	1e-5	0.8708
			2e-5	0.8815
			3e-5	0.8815
	II	3	1e-5	0.8948
			2e-5	0.8948
			3e-5	0.9001
		5	1e-5	0.9041
			2e-5	0.9108
			3e-5	0.9081
10		1e-5	0.9174	
		2e-5	0.9134	
		3e-5	0.9108	

Lampiran 5. Bukti *submission* artikel

Jurnal Teknologi Informasi dan Ilmu Komputer

Naskah Masuk

Antrianku 1 Diarsipkan Bantuan

Penugasan Filter Naskah Baru

8315 Mutiawani dkk.
Pengaruh Tahapan Preprocessing Terhadap Model Indobert dan Indobertweet Untuk Mendeteksi E... Naskah Lihat

Jurnal Teknologi Informasi dan Ilmu Komputer

← Kembali ke Naskah Masuk

8315 / Mutiawani dkk. / Pengaruh Tahapan Preprocessing Terhadap Model Indobert dan Indobertweet Untuk Mendeteksi Emosi Pac Pustaka

Alur Kerja **Publikasi**

Naskah Ulasan Copyediting Produksi

File Naskah

▶ 37988	Pernyataan-Etika-Publikasi-2018.pdf	18 December 2023	Lainnya
▶ 37987	Perjanjian-Hak-Cipta-JTIK-2018.pdf	18 December 2023	Lainnya
▶ 37985	JTIK_Ulfia Khairani - hapus afiliasi.docx	18 December 2023	File Utama Naskah

Unduh Semua File

Diskusi Prareview Tambahkan diskusi

Nama	Dari	Jawaban Lalu	Jawaban	Ditutup
Tidak Ada Item				

Lampiran 6. Artikel ilmiah

Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)
Vol. x, No. x, April 2014, hlm. x-x
Akreditasi KEMENRISTEKDIKTI, No. 36/E/KPT/2019

DOI: 10.25126/jtiik...
p-ISSN: 2355-7699
e-ISSN: 2528-6579

PENGARUH TAHAPAN PREPROCESSING TERHADAP MODEL INDOBERT DAN INDOBERTWEET UNTUK MENDETEKSI EMOSI PADA KOMENTAR AKUN BERITA INSTAGRAM

Ulfa Khairani¹, Viska Mutiawani^{1,2}, Hendri Ahmadian³

^{1,2}Universitas Syiah Kuala, Banda Aceh

³Universitas Islam Negeri Ar-Raniry, Banda Aceh

Email: ¹ulfa199@mhs.usk.ac.id, ²viska.mw@usk.ac.id, ³hendri@ar-raniry.ac.id

¹Penulis Korespondensi

(Naskah masuk: dd mmm yyyy, diterima untuk diterbitkan: dd mmm yyyy)

Abstrak

Platform media sosial seperti Instagram telah membentuk ruang di mana berita dapat dengan mudah ditemukan dan menarik perhatian individu. Pada Instagram, dapat memberikan komentar-komentar terhadap berita yang telah dibaca. Pemahaman terhadap emosi yang mengiringi komentar-komentar yang telah diberikan pengguna pada postingan berita dapat membantu memahami bagaimana berita tersebut diserap, diinterpretasi, dan direspons oleh publik. Penelitian ini mengkategorikan empat emosi yaitu marah, senang, takut, dan sedih dengan menggunakan model terlatih IndoBERT dan IndoBERTweet. Penelitian ini bertujuan untuk membandingkan model IndoBERT dan IndoBERTweet dalam mendeteksi emosi pada komentar akun berita Instagram dan mengeksplorasi dampak penggunaan tahapan *preprocessing* khususnya *remove stopwords* dan *stemming* pada kedua model. Hasil penelitian menunjukkan bahwa model yang tidak melalui tahapan *remove stopwords* dan *stemming* menghasilkan kinerja yang lebih baik dibandingkan model yang melalui tahapan *remove stopwords* dan *stemming*, dengan perolehan akurasi sebesar 92,54% untuk model IndoBERTweet dan 88,81% untuk model IndoBERT.

Kata kunci: deteksi emosi, tahapan *preprocessing*, *indoBERT*, *indoBERTweet*

THE INFLUENCE OF PREPROCESSING STAGES ON INDOBERT AND INDOBERTWEET MODELS FOR EMOTION DETECTION IN INSTAGRAM NEWS ACCOUNTS COMMENTS

Abstract

Social media platforms such as Instagram have created a space where news can be easily discovered and attract the attention of individuals. On Instagram, people can provide comments on the news they have read. Understanding the emotions that accompany the comments that users have given on news posts can help understand how the news is absorbed, interpreted and responded to by the public. This research categorizes four emotions, anger, happiness, fear and sadness, using pre-trained models *IndoBERT* and *IndoBERTweet*. This research aims to compare the *IndoBERT* and *IndoBERTweet* models in detecting emotions in Instagram news account comments and explore the impact of preprocessing stages, especially removing stopwords and stemming on both models. The research results showed that the model that did not go through the *remove stopwords* and *stemming* stages produced better performance than the model that went through the *remove stopwords* and *stemming* stages, with an accuracy of 92.54% for the *IndoBERTweet* model and 88.81% for the *IndoBERT* model.

Keywords: emotion detection, preprocessing stages, *IndoBERT*, *IndoBERTweet*

1. PENDAHULUAN

Saat ini, lingkungan jaringan media sosial membentuk wadah dimana berita dapat lebih mudah ditemukan dan menarik perhatian individu (Realita and Setiadi, 2022). Tidak hanya berita besar yang

mendapat sorotan, tetapi juga berita lokal dan topik khusus yang dapat dengan mudah diakses dan disebarluaskan. Kini, masyarakat tidak hanya mengandalkan media tradisional seperti televisi dan surat kabar lagi, tetapi juga berpaling kepada

Lampiran 7. Biodata Penulis

BIODATA

1. Nama : Ulfia Khairani
2. Tempat, tanggal lahir : Geudong, 20 Juni 2001
3. Alamat : Jalan Prada Utama, Lr. Tunggai VII, No. 6,
Kecamatan Syiah Kuala
4. Nama Ayah : Muhammad Fudhil
5. Pekerjaan Ayah : Pensiunan Karyawan Swasta
6. Nama Ibu : Nurhafni Hanafiah
7. Pekerjaan Ibu : Ibu Rumah Tangga
8. Alamat Orang Tua : Jalan Prada Utama, Lr. Tunggai VII, No. 6,
Kecamatan Syiah Kuala
9. Riwayat Pendidikan :

Jenjang	Nama Sekolah	Bidang Studi	Tempat	Tahun Ijazah
SD	SD IT AL-AZHAR BANDA ACEH	-	Banda Aceh	2013
SMP	MTsN MODEL BANDA ACEH	-	Banda Aceh	2016
SMA	SMAN 4 BANDA ACEH	IPA	Banda Aceh	2019

Banda Aceh, 04 Januari 2024

Yang Menyatakan,



Ulfia Khairani

NPM. 1908107010068