

## Analisis Sentimen Presepsi Masyarakat Dalam Menghadapi Resesi 2023 Pada *Twitter* Dengan Metode *Bidirectional Encoder Representations From Transformers (BERT)*

Muhammad Nurcahyo Kursiyanto<sup>1\*</sup>, Bagus Setya Rintyarna<sup>2</sup>, Qurrota A'yun<sup>3</sup>

Teknik Informatika, Universitas Muhammadiyah Jember<sup>1,2,3</sup>

Email: muh.nurcahyok@gmail.com<sup>1\*</sup>, bagus.setya@unmuhjember.ac.id<sup>2</sup>, qurrota.ayun@unmuhjember.ac.id<sup>3</sup>

### ABSTRAK

Pada tahun 2023, dunia menghadapi tantangan ekonomi yang berat akibat kombinasi faktor seperti meningkatnya inflasi, eskalasi perang Rusia-Ukraina, dan kelanjutan pandemi COVID-19. Dampak krisis global ini juga dirasakan di Indonesia, terutama dalam bentuk tingginya tingkat inflasi yang mengkhawatirkan. Para pemimpin negara, termasuk Presiden Jokowi dan Menteri Keuangan Sri Mulyani Indrawati, mengungkapkan keprihatinan atas ketidakpastian ekonomi global dan permasalahan inflasi yang semakin meningkat di dalam negeri. Untuk menghadapi situasi yang kompleks ini, berbagai penelitian dilakukan, salah satunya menggunakan model BERT dalam analisis sentimen terhadap data 2285 *tweet* yang dikumpulkan dari periode 01 Januari hingga 20 Maret. Model BERT dilatih dengan 10 *epoch*, menggunakan *batch size* 16, dan *learning rate* 5e-5, dan berhasil mencapai tingkat akurasi sebesar 95%, menunjukkan performa yang sangat baik dalam klasifikasi sentimen. Hasil penelitian menunjukkan bahwa dari total 2285 *tweet* yang dianalisis, sekitar 40,41% diantaranya diklasifikasikan sebagai sentimen *positive*, sementara 58,60% sisanya dikategorikan sebagai sentimen *negative*. Selain itu, ditemukan bahwa jumlah *tweet* dengan sentimen *negative* dan *positive* paling tinggi terjadi pada bulan Januari, dengan masing-masing 970 *tweet* yang bersifat *negative* dan 736 *tweet* yang bersifat *positive*. Penelitian ini memberikan gambaran mengenai pandangan dan reaksi masyarakat di media sosial terhadap kondisi ekonomi dan situasi global di tahun yang kritis ini. Dengan adanya informasi ini, para pengambil kebijakan dapat lebih memahami sentimen publik, dan diharapkan dapat mengambil langkah-langkah strategis untuk menghadapi tantangan ekonomi dan mengurangi dampak *negative* pada masyarakat Indonesia.

**Kata Kunci:** Analisis Sentimen, Resesi 2023, Model BERT, *Twitter*, Inflasi

### ABSTRACT

In 2023, the world faced significant economic challenges due to a combination of factors such as rising inflation, the escalation of the Russia-Ukraine war, and the ongoing COVID-19 pandemic. The global crisis also affected Indonesia, particularly in the form of worrying inflation rates. National leaders, including President Jokowi and Finance Minister Sri Mulyani Indrawati, expressed concerns over the global economic uncertainty and the increasing inflation issues within the country. To tackle this complex situation, various studies were conducted, including one that utilized the BERT model for sentiment analysis on a dataset of 2285 tweets collected from January 1st to March 20th. The BERT model was trained with 10 epochs, a batch size of 16, and a learning rate of 5e-5, resulting in an impressive accuracy rate of 95% in sentiment classification. The research findings indicated that out of the total 2285 analyzed tweets, approximately 40.61% were classified as positive sentiment, while the remaining 59.39% were categorized as negative sentiment. Furthermore, it was discovered that the highest number of tweets with negative and positive sentiment occurred in January, with 982 tweets being negative and 724 tweets being positive. This study provides insights into the perspectives and reactions of society on social media regarding the economic conditions and global situations in this critical year. Armed with this information, policymakers can better understand public sentiment and take strategic measures to confront economic challenges and mitigate their negative impact on Indonesian society. Given the context of global uncertainty and high inflation rates, understanding public sentiment becomes crucial in formulating appropriate economic policies to face a future full of challenges.

**Keywords:** Sentiment Analysis, 2023 Recession, BERT Model, *Twitter*, Inflation

## 1. PENDAHULUAN

Belakangan ini, dunia sedang menghadapi tantangan ekonomi yang serius, terutama dengan adanya resesi global yang disebabkan oleh inflasi yang merajalela dan konflik berkepanjangan antara Rusia dan Ukraina. Ketegangan yang semakin meningkat tersebut memiliki dampak yang sangat besar di tingkat internasional, terutama bagi negara-negara yang sangat bergantung pada komoditas seperti minyak dan logam. Rusia sebagai produsen minyak terbesar ketiga di dunia memegang peran penting

dalam fluktuasi harga komoditas, yang berpotensi memicu resesi ekonomi di berbagai negara. Selain itu, kebijakan yang kurang tepat yang diterapkan oleh bank sentral dan pemerintah juga dapat memperburuk situasi, seperti yang terjadi selama pandemi COVID-19 yang masih berlangsung, yang telah menambah masalah ekonomi global.

Bank Dunia bahkan telah memprediksi kemungkinan terjadinya resesi ekonomi global pada tahun depan, yaitu tahun 2023, dan indikasi dari kenaikan suku bunga acuan secara agresif oleh bank sentral di berbagai negara semakin memperkuat prediksi tersebut dengan tujuan untuk meredam inflasi.

Di tengah suasana ketidakpastian ekonomi global ini, Indonesia, seperti banyak negara lainnya, merasa cemas. Presiden Jokowi dan Menteri Keuangan Sri Mulyani Indrawati telah menyatakan keprihatinan yang mendalam mengenai inflasi yang melonjak, di mana inflasi Indonesia mencapai 5,42% per November 2022 dan diprediksi akan mencapai 6% pada awal tahun 2023 (Hutagaol dkk., 2022). Tekanan inflasi yang sedemikian besar memerlukan kebijakan ekonomi yang hati-hati di Indonesia untuk meminimalkan potensi dampak dari resesi global yang diperkirakan akan terjadi pada tahun 2023.

Tak hanya itu, fenomena media sosial juga menjadi hal menarik untuk diobservasi. Pada awal tahun 2023, jumlah pengguna Twitter di seluruh dunia mencapai 556 juta, meningkat sebesar 27,4% dibandingkan dengan periode yang sama tahun sebelumnya. Amerika Serikat menempati peringkat pertama dengan 95,4 juta pengguna, diikuti oleh Jepang, India, dan Brasil. Indonesia menempati peringkat kelima dengan 24 juta pengguna Twitter. Data ini menunjukkan bahwa Twitter tetap menjadi platform media sosial yang populer dan signifikan di seluruh dunia dengan pertumbuhan pengguna yang terus meningkat. Twitter menjadi platform yang tepat untuk menggali sentimen dan persepsi masyarakat terkait Resesi 2023. Melalui Twitter, terdapat banyak pandangan masyarakat tentang resesi yang terdiri dari komentar *positive* dan *negative*. Tujuan dari klasifikasi sentimen ini memberikan manfaat dalam memahami pandangan masyarakat terhadap kondisi ekonomi saat ini. Dengan memahami sentimen masyarakat, pemerintah dan pelaku ekonomi dapat mengambil langkah-langkah yang tepat untuk mengatasi resesi dan memperbaiki kondisi ekonomi. Selain itu, klasifikasi sentimen juga dapat membantu dalam merancang strategi komunikasi yang efektif untuk menjelaskan situasi ekonomi kepada masyarakat. Oleh karena itu, diperlukan solusi untuk mengklasifikasikan komentar menjadi *positive* atau *negative* dengan menggunakan metode *Bidirectional Encoder Representations from Transformers* (BERT). BERT merupakan teknik dalam pemrosesan bahasa alami yang efektif dalam memahami konteks kalimat dengan memperhatikan kata-kata sebelum dan sesudah kata target (Kenton & Toutanova, 2019). Dalam penelitian ini, metode BERT akan digunakan untuk menganalisis sentimen dan mengevaluasi efektivitasnya pada *tweet* yang informal dan beragam terkait Resesi 2023. Hasil analisis sentimen akan digunakan untuk memberikan wawasan baru bagi pengambilan kebijakan dalam menghadapi Resesi 2023.

## 2. KAJIAN PUSTAKA

Tabel 1 berikut menunjukkan tinjauan pustaka yang digunakan sebagai referensi atau pembandingan terhadap penelitian ini.

Table 1. Penelitian Terdahulu

Judul	Dataset	Metode Analisis Sentimen	Hasil Penelitian
Analisis Sentimen Kuhp Baru Pada Data Twitter Menggunakan Model BERT (Abdurrazzaq & Tjong, 2022)	Dataset <i>tweets</i> dengan kata kunci #rkuhp sebanyak 413 <i>tweet</i> (Bahasa Indonesia)	<ul style="list-style-type: none"> <li>• Model BERT</li> <li>• <i>Preprocessing: Case foldig, Cleaning, Stopword, Stemming</i></li> <li>• <i>Negative, Positive</i> dan <i>Neutral</i></li> </ul>	Model BERT mampu mencapai akurasi 81%, unggul 6% dibandingkan dengan model SVM

Analisis Sentimen Terhadap <i>Game Genshin Impact</i> Menggunakan Bert )(Kusnadi dkk., 2021)	Data yang berasal dari google playstore dengan game yang berjudul <i>Genshin Impact</i> sebanyak 12000 dataset (Bahasa Inggris)	<ul style="list-style-type: none"> <li>• Model BERT</li> <li>• <i>Scrapping</i>: menggunakan package google play scraper</li> <li>• <i>Negative, Neutral</i> dan <i>Positive</i></li> </ul>	Model BERT memiliki akurasi 0.86, <i>Recall</i> 0.78, dan <i>F1-score</i> 0.82 untuk sentimen <i>Positive</i> , akurasi 0.71, <i>Recall</i> 0.75, dan <i>F1-score</i> 0.73 untuk sentimen <i>Negative</i> , dan akurasi 0.55, <i>Recall</i> 0.58, dan <i>F1-score</i> 0.56 untuk sentimen <i>Neutral</i>
Analisis Sentimen Sederhana Menggunakan Algoritma LSTM dan BERT untuk Klasifikasi Data Spam dan Non-Spam (Riyantoko dkk., 2022)	Data dari UCI – <i>Machine Learning</i> “SMS Spam Collection Data Set”. Pada data tersebut terdapat 5572 sms yang diekstrak dari Grumbletext Web site (Bahasa Inggris)	<ul style="list-style-type: none"> <li>• Model BERT, Naïve Bayes, XGBoost,LSTM</li> <li>• <i>Preprocessing</i>: <i>Case Folding, Tokenisasi, Filtering, Normalisasi, Stemming</i> atau <i>Lematization</i> dan <i>Term Weighting</i>.</li> <li>• HAM dan SPAM</li> </ul>	Metode BERT dan LSTM memiliki tingkat akurasi yang tinggi secara urut, yaitu 99,35% dan 98,22%. Performansi model dipengaruhi oleh jenis data.
Sentimen Analisis Terhadap Kebijakan Penyelenggara Sistem Elektronik (Pse) Menggunakan Algoritma <i>Bidirectional Encoder Representations from Transformers</i> (Bert) (Kurniawan & Aldino, 2022)	Data yang diperoleh dari Twitter yang diambil dari Sentimen-sentimen yang diberikan pengguna di <i>tweet</i> dengan #PSE yang diunggah pada February 2022 Sebanyak 5.016 (Bahasa Indonesia)	<ul style="list-style-type: none"> <li>• Model BERT</li> <li>• <i>Preprocessing</i>:</li> <li>• <i>Case Folding, Cleaning, Tokenisasi, Steaming, Stopwords Removal, Normalisasi</i></li> <li>• <i>Negative , Neutral</i> dan <i>Positive</i></li> </ul>	Analisis sentimen menemukan bahwa <i>Bidirectional Encoder Representations from Transformers</i> (BERT) memiliki akurasi 69%, 55%, dan 55% pada dua waktu berbeda menggunakan <i>Hyperparameter</i> yang sama, yaitu <i>Batch size</i> 16, dan <i>Epoch</i> 5
Analisis Sentimen Customer Review Aplikasi Ruang Guru dengan Metode BERT ( <i>Bidirectional Encoder Representations from Transformers</i> )(Atmaja, 2021)	Data yang akan di scraping kurang lebih sekitar 12000 records yang terdiri dari rating 1-5 pada platform Google Play Store (bahasa Inggris)	<ul style="list-style-type: none"> <li>• Model BERT</li> <li>• <i>Scraping</i>: library <i>google_play_scraper</i> sebagai tools untuk mengambil data dan proses ekstraksi</li> <li>• <i>Preprocessing</i>:</li> <li>• membersihkan karakter</li> <li>• utf-8, titik koma, emoticon, dan proses text correction</li> <li>• <i>Negative, Neutral</i> dan <i>Positive</i></li> </ul>	Berdasarkan dari nilai F1 Score yang didapat dari presisi dan <i>Recall</i> yakni 98.9% dan nilai akurasi bernilai 99%. Dengan ini dapat disimpulkan bahwa metode <i>pre-trained</i> BERT sangat efektif untuk di implementasi analisis sentimen.

Berdasarkan Tabel 1, maka perbedaan antara penelitian terdahulu dan penelitian yang dilakukan adalah sebagai berikut:

1. Dataset yang digunakan adalah data *tweet* yang diambil dari Twitter dengan menggunakan *Snsrape* dan menggunakan kata kunci "resesi 2023" serta melakukan filter tanggal dari 01 Januari hingga 20 Maret 2023. Diperoleh sebanyak 2941 *tweet* hasil.
2. Analisis Sentimen yang digunakan untuk menilai pandangan masyarakat hanya terdiri dari dua kategori, yaitu *negative* dan *positive*. Hal ini dipilih karena pada penelitian sebelumnya, akurasi dalam mengidentifikasi sentimen *neutral* sangat rendah. Jika terlalu banyak *tweet* yang dikategorikan sebagai *neutral*, akan sulit untuk menentukan kebijakan yang tepat dalam menghadapi resesi 2023

3. Penelitian ini menggunakan model *BERT-Base Multilingual* (mBERT) karena dataset yang digunakan berbahasa Indonesia. mBERT adalah model bahasa yang telah dilatih dalam beberapa bahasa, termasuk bahasa Indonesia, sehingga dapat secara efektif mengatasi teks dalam berbagai bahasa tanpa perlu melatih model khusus untuk setiap bahasa yang berbeda.

#### A. Resesi Ekonomi

Resesi ekonomi adalah kondisi ketika terjadi penurunan signifikan dalam aktivitas ekonomi yang mencakup produksi, investasi, dan konsumsi dalam jangka waktu yang signifikan (Hutagaol dkk., 2022). Pada umumnya, resesi terjadi setelah fase pertumbuhan ekonomi yang panjang dan terus meningkat. Penyebab utama resesi ekonomi adalah ketidakseimbangan dalam pasokan dan permintaan barang dan jasa, kenaikan harga-harga, peningkatan suku bunga yang tidak terkendali, atau situasi yang memengaruhi kondisi ekonomi global, seperti perang atau pandemi.

#### B. Analisis Sentimen

Analisis Sentimen adalah proses yang menganalisis dan mengidentifikasi emosi dan perasaan yang terkandung dalam data seperti teks, gambar, atau suara (Zain dkk., 2021). Hasil dari analisis ini dapat berupa klasifikasi *positive*, *negative*, atau *neutral*, atau skor sentimen yang menunjukkan seberapa kuat perasaan *positive* atau *negative* yang dirasakan. Sentimen Analisis digunakan di berbagai industri seperti pemasaran, *e-commerce*, dan media sosial untuk memahami bagaimana masyarakat memandang produk atau merek tertentu dan mengambil tindakan yang tepat berdasarkan hasil analisis tersebut.

#### C. Twitter

*Twitter* adalah platform media sosial yang memungkinkan pengguna untuk berkomunikasi dan berbagi informasi dalam bentuk pesan pendek yang disebut "*tweet*" (Abdurrazzaq & Tjiong, 2022). *Twitter* digunakan secara luas untuk berbagi berita, opini, ide, dan konten multimedia seperti foto, video, dan GIF. Sebagai salah satu platform media sosial paling populer di seluruh dunia, *Twitter* menjadi sumber berita dan informasi penting, terutama dalam situasi yang berkaitan dengan kejadian penting secara global. *Twitter* juga digunakan secara luas oleh publik figur, selebritas, dan pemimpin politik untuk berkomunikasi dengan penggemar dan pemilih mereka.

#### D. Natural Language Processing

*Natural Language Processing* (NLP) adalah cabang ilmu komputer yang memproses bahasa manusia (Khurana dkk., 2023). Tujuannya adalah mengembangkan algoritma dan model untuk membantu komputer memahami, menganalisis, dan memproduksi bahasa manusia. NLP memanfaatkan teknik seperti *tokenisasi*, *stemming*, *lemmatization*, *parsing*, dan *semantic analysis* pada dokumen teks seperti artikel, email, laporan keuangan, dan buku. NLP digunakan untuk aplikasi seperti klasifikasi dokumen, analisis sentimen, terjemahan mesin, *chatbot*, dan pengenalan suara. NLP bergantung pada linguistik, kecerdasan buatan, pembelajaran mesin, kamus, tesaurus, korpus teks, rekognisi suara, dan pemrosesan citra. Teknik baru seperti *deep learning*, *transfer learning*, dan BERT terus memperkaya pengembangan teknologi NLP.

#### E. Bidirectional Encoder Representations from Transformers

*Bidirectional Encoder Representations from Transformers* (BERT) merupakan adalah model *deep learning* yang dikembangkan oleh Google AI Language pada tahun 2018 untuk meningkatkan kemampuan model dalam memahami konteks dan makna kata dalam sebuah kalimat. BERT menggunakan teknik *bidirectional* yang dapat membaca kalimat dari dua arah dan memanfaatkan model *Transformer* untuk memproses teks secara paralel dan memahami konteks yang lebih luas dalam teks (Ravichandiran, 2021).

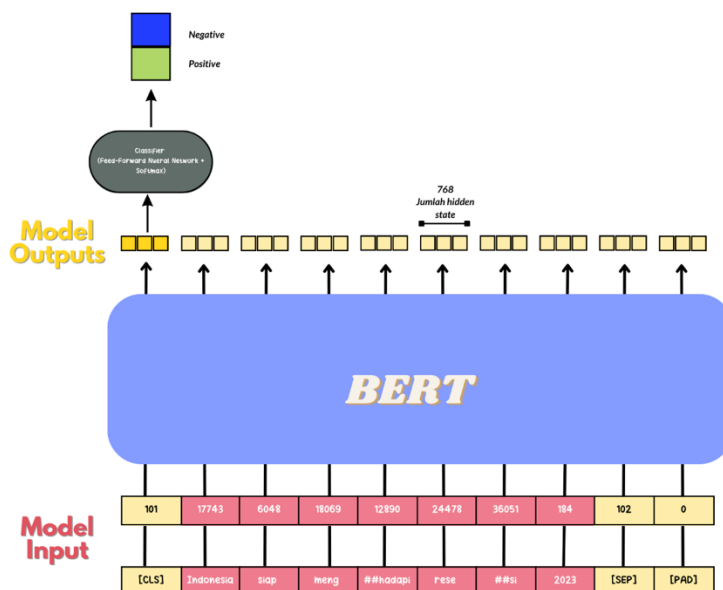
Sebelum proses *training* menggunakan model BERT, *dataset* harus disesuaikan dengan representasi *input* yang dapat diterima oleh BERT. BERT menerima masukan berupa token teks, yang

kemudian diwakili dalam bentuk urutan vektor numerik. Proses ini melibatkan beberapa tahap seperti tokenisasi, pemberian token, pembuatan urutan, dan vektorisasi. Setelah itu, masukan dijadikan sebagai *input* untuk model BERT.



Gambar 1. Contoh Representasi *Input* pada BERT


*Tokenisasi* kalimat menggunakan teknik *WordPiece* adalah langkah awal dalam mempersiapkan sebuah kalimat untuk direpresentasikan pada model BERT. Tahap ini melibatkan mengubah setiap kata dalam kalimat menjadi *token* kata dan subkata. *Tokenizer WordPiece* memeriksa setiap kata pada kalimat dan memecahnya menjadi subkata jika tidak ditemukan pada vocabulary, menggunakan simbol *##* untuk menunjukkan *token* subkata. *Token* khusus [CLS] dan [SEP] ditambahkan pada awal dan akhir kalimat masing-masing. *Token* [CLS] menandai awal kalimat dan berfungsi sebagai penunjuk sentimen kalimat untuk tugas klasifikasi sentimen. *Token* [SEP] memisahkan kalimat satu dengan yang berikutnya. Setiap *token* diberikan ID, dan *embedding* kalimat dan *embedding* posisi dibuat untuk menunjukkan posisi setiap kata pada kalimat. Proses ini mempersiapkan representasi *input* yang tepat untuk diproses pada model BERT.



Gambar 2. Ilustrasi Proses Klasifikasi Menggunakan BERT

*Model* BERT adalah sebuah model yang menerima urutan kata atau kalimat sebagai input dan memprosesnya melalui serangkaian *encoder* yang menggunakan mekanisme *self-attention*. Setelah melewati semua *encoder*, tiap token pada setiap posisi menghasilkan vektor output dengan ukuran yang ditentukan. Dalam analisis sentimen, *output* dari posisi pertama, yaitu token [CLS], digunakan sebagai input untuk *classifier*. Gambar 2 menunjukkan ilustrasi klasifikasi menggunakan metode BERT.

*Classifier layer* adalah layer terakhir dari model BERT yang bertanggung jawab untuk melakukan klasifikasi teks dengan menggunakan *fully connected neural network* dengan fungsi aktivasi *softmax*. Layer terakhir dari *classifier layer* menghasilkan *output* berupa prediksi probabilitas kasar dari kalimat yang akan diklasifikasikan. *Softmax* kemudian mengubah nilai logits menjadi probabilitas dengan menjumlahkannya sehingga total probabilitasnya adalah tepat 1. Dengan cara ini, nilai probabilitas setiap kelas dapat ditentukan dan digunakan untuk melakukan klasifikasi teks. Gambar 3 menunjukkan ilustrasi layer untuk analisis sentimen.



Gambar 3. Ilustrasi Layer untuk Analisis Sentimen

Sebagai contoh, terdapat vektor logits = [1.25,1.16] yang harus dikonversi ke distribusi probabilitas dari sebuah komentar agar dapat diklasifikasi ke dalam kelas *positive* dan *negative*. Maka, langkah untuk mendapatkan probabilitas yaitu sebagai berikut :

1. Hitung seluruh eksponensial dari setiap elemen pada vektor.

$$e^{z1} = e^{1.25} = 3.50$$

$$e^{z2} = e^{1.16} = 3.21$$

2. Normalisasi nilai dengan menjumlahkan semua eksponensial.

$$\sum_{j=1}^K e^{z_j} = 3.50 + 3.21 = 6.71$$

3. Bagi eksponensial dari setiap elemen dengan normalisasi untuk memperoleh *output softmax* dari tiap elemen yang ada.

$$\sigma(\vec{z})_1 = \frac{3.50}{6.71} = 0.52$$

$$\sigma(\vec{z})_2 = \frac{3.21}{6.71} = 0.48$$

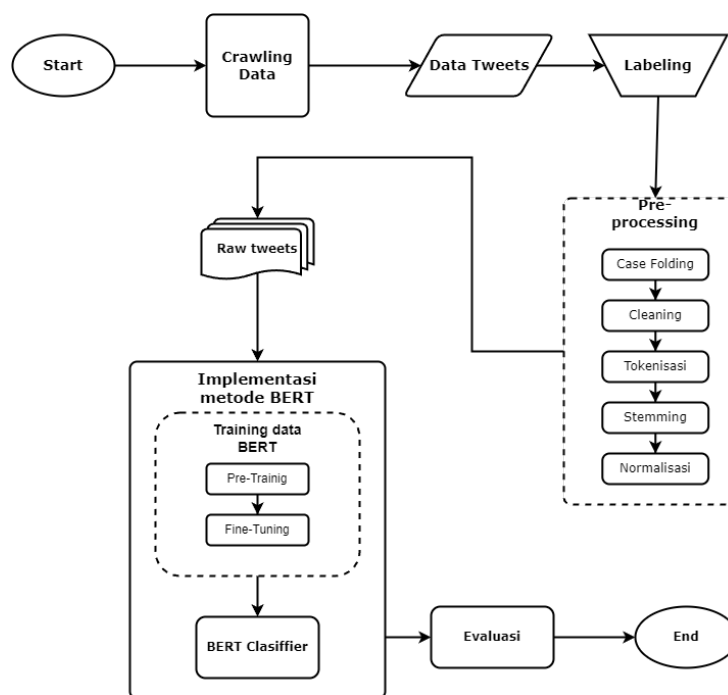
Untuk memastikan apakah hasil prediksi dari tiap probabilitas adalah 1, maka semua probabilitas dijumlahkan.

$$\sigma(\vec{z})_1 + \sigma(\vec{z})_2 = 0.52 + 0.48 = 1$$

Hasil probabilitas prediksi dari BERT akan menunjukkan seberapa besar kemungkinan sebuah komentar akan masuk ke dalam kategori sentimen tertentu, seperti *positive* atau *negative*. Sebagai contoh, sebuah komentar memiliki probabilitas sebesar 0.52 untuk masuk ke dalam kategori sentimen *positive*, dan probabilitas sebesar 0.48 untuk masuk ke dalam kategori sentimen *negative*.

### 3. METODE PENELITIAN

Analisis sentimen terhadap resesi tahun 2023 dilakukan dengan menggunakan metode *Bidirectional Encoder Representations from Transformers* (BERT) yang melibatkan serangkaian langkah, sebagaimana dijelaskan dalam Gambar 4.



Gambar 4 Tahapan Penelitian

#### A. Crawling Data

*Snscape* adalah salah satu metode pengambilan informasi dari *Twitter* yang tidak memerlukan penggunaan API. Keuntungan dari *Snscape* adalah dapat mengambil informasi dasar seperti profil pengguna, konten *tweet*, dan sumber, serta tidak terbatas pada satu platform saja karena juga dapat digunakan pada jaringan sosial media lainnya seperti *Twitter* dan *Instagram*. Proses pengambilan data menggunakan teknik *Snscape* dilakukan dengan menggunakan kata kunci "resesi 2023" serta memfilter tanggal antara 1 Januari - 20 Maret 2023. Dari proses ini, berhasil didapatkan sebanyak 2941 hasil *tweet*.

#### B. Labelling

Langkah berikutnya adalah melakukan pelabelan sentimen pada 2941 *tweet* terkait Resesi 2023. Proses pelabelan sentimen akan membagi data *tweet* menjadi tiga kategori, yaitu *negative*, *neutral*, dan *positive*. Untuk memastikan hasil yang akurat, pelabelan sentimen melibatkan tujuh orang mahasiswa dan seorang validator ahli bahasa. Setelah proses pelabelan selesai, data *tweet* yang telah diberi label sentimen akan siap digunakan untuk analisis lebih lanjut terkait resesi pada periode tersebut di Indonesia.

Sebanyak 2285 *tweet* yang terdiri dari sentimen *negative* dan *positive* akan digunakan untuk pelatihan atau pengujian pada model BERT. Dengan demikian, model BERT akan dihadapkan pada data yang telah dilabeli secara tepat, memungkinkan analisis sentimen yang lebih akurat terkait dengan respons dan persepsi masyarakat terhadap peristiwa ekonomi penting seperti resesi.

### C. Preprocessing

*Preprocessing* data adalah tahap awal dalam analisis teks yang bertujuan untuk membersihkan, mempersiapkan, dan mengubah data mentah menjadi bentuk yang dapat diolah oleh model. Berikut adalah beberapa teknik *preprocessing* data yang sering digunakan dalam analisis teks.

1) *Case Folding*

*Case Folding* merupakan teknik untuk mengubah semua karakter dalam teks menjadi huruf kecil atau huruf besar. Tujuannya adalah untuk mengurangi variasi karakter dalam teks.

2) *Data Cleaning*

*Data Cleaning* merupakan teknik untuk menghapus karakter-karakter yang tidak diperlukan dalam teks seperti tanda baca, karakter khusus, atau angka. Tujuannya adalah untuk membersihkan teks dari karakter-karakter yang tidak relevan. *Data Cleaning* sangat penting dalam analisis teks, karena kebersihan dan kualitas data akan sangat mempengaruhi hasil analisis.

3) *Tokenisasi*

*Tokenisasi* merupakan teknik untuk memecah teks menjadi bagian-bagian yang lebih kecil seperti kata atau frasa. Tujuannya adalah untuk memproses teks menjadi unit-unit yang lebih kecil sehingga dapat diolah oleh model. Token yang dihasilkan akan digunakan untuk menghitung frekuensi dan analisis sentimen, sehingga prediksi lebih akurat.

4) *Stemming*

*Stemming* merupakan teknik untuk mengubah kata-kata dalam teks menjadi kata dasarnya. Tujuannya adalah untuk mengurangi variasi kata dalam teks sehingga dapat mempercepat proses analisis.

5) *Normalisasi*

*Normalisasi* merupakan teknik untuk mengubah kata-kata dalam teks menjadi bentuk standar seperti mengubah kata-kata dalam bahasa Inggris menjadi bentuk dasarnya. Tujuannya adalah untuk memperbaiki kesalahan penulisan dan mempercepat proses analisis. Sebagai contoh, kata "bgt" menjadi "banget". Tanpa proses *normalisasi*, sistem mungkin akan menganggap "bgt" dan "banget" sebagai kata yang berbeda, padahal keduanya memiliki makna yang sama, namun seharusnya dianggap sebagai kata yang sama. *Normalisasi* dapat dilakukan menggunakan kamus alay sebagai referensi untuk mengubah kata-kata tidak baku menjadi kata baku. Setelah proses *normalisasi* selesai, dataset dapat lebih mudah diproses dan dianalisis dengan hasil yang lebih konsisten.

### D. Split Dataset

Sebelum melakukan klasifikasi, dataset perlu dibagi menjadi dataset *training* dan dataset validasi. Dataset *training* akan digunakan untuk melatih model, sedangkan dataset validasi akan membantu mengurangi kemungkinan *overfitting* yang sering terjadi pada jaringan syaraf tiruan. Pembagian dataset *training* dan validasi sebaiknya dilakukan dengan rasio 80:20, di mana 80% dataset digunakan untuk *training* dan 20% sisanya digunakan untuk validasi.

### E. Implementasi BERT

Dibutuhkan sebuah data *loader* untuk tiap masing-masing dataset agar dapat melakukan iterasi dan menjaga memori saat *training*. Data *loader* ini memungkinkan dataset tidak perlu dimasukkan ke dalam memori secara bersamaan. Data *loader* akan menghasilkan komentar-komentar yang sudah dilakukan proses tokenisasi dengan panjang maksimal 50 kata. Untuk analisis sentimen, digunakan layer tambahan dengan *dropout* probabilitas 0.1 seperti yang dijelaskan dalam penelitian Kenton & Toutanova (2019). Selain itu, dilakukan *Fine-tuning* dengan menggunakan beberapa hyperparameter yang disarankan untuk BERT. Pada penelitian ini menggunakan hyperparameter sebagai berikut:

1. *Batch size*: 16
2. *Epoch*: 10



3. *Learning rate*: 5e-5 (0.00005)

Pemilihan *Hyperparameter* didasarkan pada pertimbangan beberapa faktor. *Batch size* sebesar 16 dipilih karena semakin besar *batch size*, waktu yang dibutuhkan untuk menyelesaikan satu batch juga semakin lama (Tayyab & Sarkar, 2016). Selain itu, *learning rate* 5e-5 dipilih karena membantu menghindari masalah "*catastrophic forgetting*" dan memungkinkan model BERT untuk mempertahankan pengetahuan yang telah dipelajari sebelumnya, sambil tetap belajar dari data baru dalam proses *fine-tuning* (Chow, 2023).

Dalam penentuan jumlah *epoch* yang optimal didasarkan pada serangkaian eksperimen yang dilakukan oleh peneliti sebelumnya. Pertama, Devlin dkk. (2019) menggunakan 3 *epoch* untuk melatih model, sebagai titik awal untuk mengevaluasi performa dasar model. Kemudian, Abdurrazzaq & Tjiong, (2022), Nata & Apridonal, (2020), dan Akhmad, (2023) meningkatkan jumlah *epoch* menjadi 5, menguji apakah peningkatan ini membawa perbaikan yang signifikan dalam akurasi atau konvergensi model. Terakhir, Kamath dkk., (2022) dan Kusnadi dkk., (2021) memperluas eksplorasi hingga 10 *epoch*, dengan tujuan untuk mengeksplorasi apakah melatih model dalam jangka waktu yang lebih lama akan menghasilkan peningkatan yang lebih besar atau jika model sudah mencapai titik konvergensi. Berdasarkan serangkaian eksperimen yang telah dilakukan penelitian sebelumnya, maka pada penelitian ini menentukan jumlah *epoch* yang optimal dengan melakukan tiga percobaan berbeda, yaitu 3 *epoch* dalam percobaan pertama, 5 *epoch* dalam percobaan kedua, dan 10 *epoch* dalam percobaan ketiga, mengacu pada hasil penelitian sebelumnya.

Tabel 4. Perbedaan antara model BERT-Base Multilingual dan BERT-Base

Fitur	BERT-Base Multilingual	BERT-Base
Jumlah Layer	12	12
Jumlah Hidden Unit	768	768
Total Parameter	Sekitar 110 juta	Sekitar 110 juta
Bahasa	Multiple (lebih dari 100 bahasa	Terutama bahasa Inggris

Hasil *fine-tuning* model BERT yang melibatkan langkah-langkah seperti persiapan dataset dengan membaca dataset dari file berekstensi CSV dan mengkonversi label sentimen, kemudian dilakukan tokenisasi dan encoding pada setiap kalimat dalam dataset menggunakan *tokenizer BERT*. Hasil *encoding* berupa *input\_ids*, *attention\_masks*, dan *labels* digunakan untuk membuat dataset PyTorch. Selanjutnya, dataset dibagi menjadi data *training* dan *validation* dengan rasio pembagian 80:20, yang digunakan untuk melatih model melalui data *loader*. Model BERT untuk klasifikasi urutan dimuat dan dioptimasi menggunakan *optimizer AdamW* dengan pengaturan tertentu. Selama *training*, model diperbarui berdasarkan *loss* yang dihitung dari perbandingan prediksi dengan label yang sebenarnya. Evaluasi model dilakukan pada data *validation* setiap *epoch* untuk mengukur akurasi dan *loss*. Statistik pelatihan seperti *loss* dan akurasi disimpan, dan setelah pelatihan selesai, total waktu pelatihan dicatat.

Tabel 5. Hasil proses *Fine-tuning* model BERT dari 3 Percobaan dengan jumlah *epoch* yang berbeda

Percobaan	Jumlah Epoch	Rata-rata Training Loss per Epoch	Waktu per Epoch	Akurasi Validasi	Loss Validasi	Waktu Total Training
1	3	0.55	0:10:37	0.74	0.57	0:31:50
2	5	0.37	0:10:14	0.73	0.88	0:53:47
3	10	<b>0.27</b>	0:10:56	<b>0.76</b>	1.12	1:56:21

Berdasarkan Tabel 5 hasil dari ketiga percobaan tersebut, dipilihlah percobaan ketiga dengan 10 *epoch*. Pada 10 *epoch*, *training loss* mencapai 0.24, yang menunjukkan bahwa semakin rendah

*training* loss, semakin baik model tersebut dalam menyesuaikan diri dengan data pelatihan. Di samping itu, akurasi validasi juga meningkat. Oleh karena itu, pilihan model ini menjadi yang paling optimal.

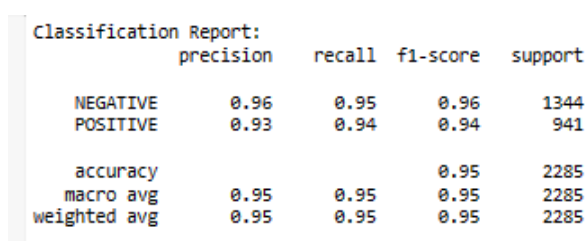
#### F. Evaluasi

Dalam evaluasi model, kinerja model dalam memprediksi hasil analisis sentimen dari teks yang belum pernah dilihat sebelumnya dievaluasi menggunakan metrik evaluasi seperti akurasi, presisi (*precision*), *recall*, dan *F1-score*. Metrik-metrik evaluasi ini sangat membantu untuk mengidentifikasi kelemahan model atau algoritma dan memperbaikinya agar dapat memberikan hasil prediksi yang lebih baik.

### 4. HASIL DAN PEMBAHASAN

Hasil dan pembahasan merupakan hasil penelitian atau analisa yang dilakukan dalam penelitian. Temuan-temuan dalam analisa perlu dijabarkan secara rinci dalam pembahasan.

#### A. Hasil implementasi Model BERT



Classification Report:				
	precision	recall	f1-score	support
NEGATIVE	0.96	0.95	0.96	1344
POSITIVE	0.93	0.94	0.94	941
accuracy			0.95	2285
macro avg	0.95	0.95	0.95	2285
weighted avg	0.95	0.95	0.95	2285

Gambar 5. *Classification Report* pada 10 *Epoch*

Berdasarkan Gambar 5, dapat menyimpulkan bahwa model BERT ini memiliki performa yang sangat baik dalam memprediksi dua kelas, yaitu *Negative* dan *Positive*. Dalam hal presisi (*precision*), model ini mencapai 96% untuk kelas *Negative* dan 93% untuk kelas *Positive*. Presisi mengukur sejauh mana hasil prediksi *Positive* yang diberikan oleh model adalah benar.

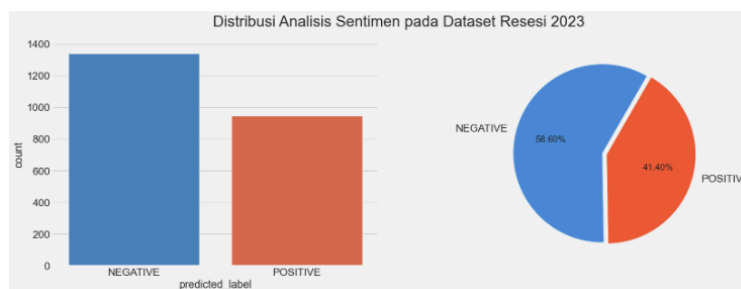
Selanjutnya, dalam hal *Recall*, model ini memiliki nilai 95% untuk kelas *Negative* dan 94% untuk kelas *Positive*. *Recall* mengukur sejauh mana model dapat mengidentifikasi semua instance yang sebenarnya termasuk dalam kelas tersebut.

*F1-score*, yang menggabungkan presisi dan *recall*, juga menunjukkan performa yang baik, dengan nilai 0.96 untuk kelas *Negative* dan 0.94 untuk kelas *Positive*. *F1-score* adalah metrik yang baik untuk diseimbangkan antara presisi dan *recall*.

Akurasi keseluruhan model ini adalah 95%, yang menunjukkan bahwa sebagian besar prediksi yang dilakukan oleh model adalah benar. Dengan demikian, berdasarkan *classification report*, dapat disimpulkan bahwa model klasifikasi ini telah berhasil dengan baik dalam melakukan klasifikasi antara kelas *negative* dan *positive* dengan akurasi yang tinggi serta seimbang antara presisi dan *recall*.

#### G. Hasil Visualisasi Distribusi *Tweet* pada Fenomena Resesi 2023

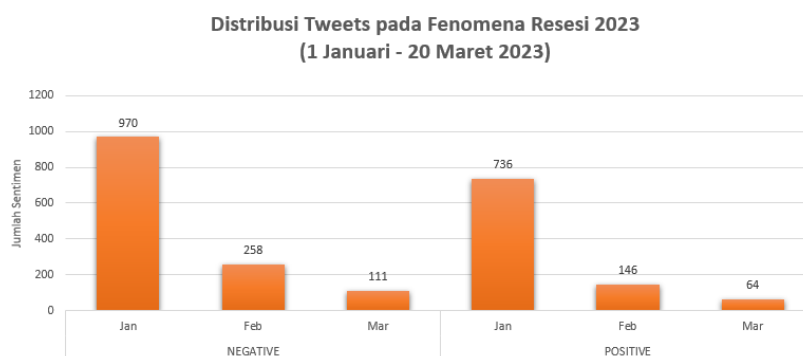
Penelitian ini menggunakan data dari 2285 *Tweets* yang diambil dengan filter tanggal 01 Januari hingga 20 Maret. Setelah dilakukan analisis, ditemukan bahwa dari 2285 *Tweet* tersebut, sebanyak 40,61% diklasifikasikan sebagai sentimen *positive*, sementara 59,39% lainnya diklasifikasikan sebagai sentimen *negative*. Perlu dicatat bahwa sentimen *negative* dan *positive* paling banyak terjadi pada bulan Januari, dengan masing-masing 982 *tweets negative* dan 724 *tweets positive*. Hasil ini memberikan gambaran yang relevan tentang persepsi dan reaksi masyarakat terhadap peristiwa resesi, dengan mayoritas sentimen cenderung *negative* pada bulan tersebut. Informasi yang didapatkan dari analisis ini menjadi sangat berharga bagi para pemangku kebijakan dalam memahami sentimen publik terkait kondisi ekonomi saat itu dan merumuskan langkah-langkah kebijakan yang tepat guna mengatasi tantangan yang dihadapi akibat resesi tersebut.



Gambar 6. Diagram Lingkaran jumlah *Tweets Negative* dan *Positive*

Hasil ini menunjukkan bahwa hasil analisis sentimen menggunakan model BERT telah berhasil mencapai tingkat akurasi sebesar 95%, suatu angka yang menandakan bahwa model ini mampu melakukan tugasnya dengan sangat baik. Informasi selanjutnya dapat ditemukan pada Gambar 7, yang memperlihatkan distribusi hasil analisis sentimen pada dataset resesi 2023. Dataset ini terdiri dari 2285 data *Tweet* yang berhasil diambil melalui proses scraping mulai dari tanggal 1 Januari hingga 20 Maret 2023.

Dari total 2285 *tweet*, sekitar 41,40% diantaranya diklasifikasikan sebagai sentimen *Positive*, sementara sisanya, yaitu sekitar 58,60%, diklasifikasikan sebagai sentimen *Negative*. Hasil ini menggambarkan bahwa pandangan masyarakat yang terekam dalam dataset cenderung lebih *Negative* daripada *Positive* terkait dengan situasi resesi pada periode tersebut.



Gambar 7. Distribusi *Tweets* pada fenomena resesi 2023 per Bulan

Berdasarkan Gambar 7 terlihat bahwa sentimen *negative* memiliki jumlah *tweet* yang lebih tinggi dibandingkan dengan sentimen *positive* untuk setiap bulan yang diamati. Ini menunjukkan bahwa pengguna media sosial cenderung lebih banyak mengungkapkan pendapat atau perasaan *negative* dalam periode tersebut. Secara lebih rinci, pada bulan Januari, jumlah *tweet* dengan sentimen *negative* mencapai 970, sementara *tweet* dengan sentimen *positive* mencapai 736. Pada bulan Februari, pola serupa terlihat dengan 258 *Tweet Negative* dan 146 *Tweet Positive*. Bulan Maret juga mencatat perbedaan yang signifikan dengan 111 *Tweet Negative* dan hanya 64 *Tweet Positive*.

Hasil analisis sentimen ini dapat memberikan wawasan yang berharga untuk pengambilan kebijakan dalam menghadapi tantangan resesi tahun 2023. Dengan memahami perasaan dan pandangan masyarakat yang tercermin dalam data media sosial, kebijakan dapat diarahkan untuk meredakan kekhawatiran dan meningkatkan pandangan *Positive* dalam upaya mengatasi dampak resesi.

## 5. KESIMPULAN

Berdasarkan hasil pengujian dari implementasi model BERT dalam melakukan analisis sentimen, maka diperoleh kesimpulan sebagai berikut :

1. Model BERT memiliki performa yang sangat baik dalam memprediksi kelas *Negative* dan *Positive*. Presisi untuk *Negative* mencapai 96%, sedangkan *Positive* mencapai 93%. *Recall*

untuk *Negative* adalah 95%, dan *Positive* adalah 94%. *F1-score* juga menunjukkan hasil yang baik, dengan nilai 0.96 untuk *Negative* dan 0.94 untuk *Positive*. Model ini memiliki akurasi keseluruhan 95%, menunjukkan kemampuannya dalam klasifikasi sentimen pada *Tweets* terkait Resesi 2023 dengan seimbang antara presisi dan *Recall*. Hasil ini menunjukkan keefektifan BERT dalam memproses teks dan potensinya sebagai metode andal untuk menganalisis sentimen pada *Tweet* yang terkait dengan peristiwa ekonomi penting seperti resesi.

2. Hasil analisis sentimen terkait Resesi 2023 menggunakan model BERT mengungkapkan bahwa dari keseluruhan data, sekitar 41,40% diklasifikasikan sebagai sentimen *Positive*, sementara 58,60% sisanya diklasifikasikan sebagai sentimen *Negative*. Selain itu, data menunjukkan bahwa distribusi *Tweet* dengan sentimen *Negative* dan *Positive* paling signifikan terjadi pada bulan Januari, dengan masing-masing mencapai 970 *Tweet Negative* dan 736 *Tweet Positive*. Temuan ini memberikan pemahaman yang relevan mengenai pandangan dan respons masyarakat terhadap peristiwa resesi, yang mayoritas cenderung bersifat *Negative* pada bulan tersebut. Informasi yang dihasilkan dari analisis ini menjadi sangat berharga bagi para pengambil kebijakan untuk memahami pandangan publik terkait kondisi ekonomi saat itu dan merumuskan langkah-langkah kebijakan yang tepat guna mengatasi tantangan yang timbul akibat resesi tersebut. Dengan demikian, hasil analisis sentimen ini memberikan wawasan baru yang berharga untuk pengambilan kebijakan dalam menghadapi Resesi 2023.

## 6. DAFTAR PUSTAKA

- Abdurrazzaq, M. A., & Tjong, E. L. (2022). Analisis Sentimen KUHP Baru Pada Data Twitter Menggunakan BERT. *Jurnal Komunikasi, Sains dan Teknologi*, 1(2), 83-88.
- Akhmad. (2023). Analisis sentimen ulasan aplikasi dlu ferry pada google play store menggunakan bidirectional encoder representations from transformers. *Analisis sentimen ulasan aplikasi dlu ferry pada google play store menggunakan bidirectional encoder representations from transformers*, 13(mi), 5–24. <https://doi.org/10.30649/japk.v13i2.94>
- Atmaja, R. M. R. W. P. K., & Yustanti, W. (2021). Analisis Sentimen Customer Review Aplikasi Ruang Guru dengan Metode BERT (Bidirectional Encoder Representations from Transformers). *Journal of Emerging Information System and Business Intelligence (JEISBI)*, 2(3).
- Chow, M. Y. (2023). Analysis of Embedded System's Functional Requirement using BERT-based Name Entity Recognition for Extracting IO Entities. *Journal of Information Processing*, 31, 143-153
- Hutagaol, Y. R. T., Sinurat, R. P. P., & Shalahuddin, S. M. (2022). Strategi Penguatan Keuangan Negara Dalam Menghadapi Ancaman Resesi Global 2023 Melalui Green Economy. *Jurnal Pajak Dan Keuangan Negara (PKN)*, 4(1S), 378-385.
- Kamath, U., Graham, K., & Emara, W. (2022). *Transformers For Machine Learning: A Deep Dive*. Chapman and Hall/CRC.
- Kenton, J. D. M. W. C., & Toutanova, L. K. (2019). Bert: Pre-training of deep bidirectional transformers for language understanding. *In Proceedings of naacL-HLT (Vol. 1, p. 2)*.
- 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.
- Kurniawan, B., Aldino, A. A., & Isnain, A. R. (2022). Sentimen Analisis Terhadap Kebijakan Penyelenggara Sistem Elektronik (PSE) Menggunakan Algoritma Bidirectional Encoder

Representations From Transformers (BERT). *Jurnal Teknologi dan Sistem Informasi*, 3(4), 98-106

- Kusnadi, R., Yusuf, Y., Andriantony, A., Yaputra, R. A., & Caintan, M. (2021). Analisis sentimen terhadap game genshin impact menggunakan bert. *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, 6(2), 122-129.
- Nata, A., & Apridonol, Y. (2020). Kombinasi Metode Ahp Dan Mfep Dalam Upaya Meningkatkan Kualitas Penerima Bantuan Siswa Miskin. *JURTEKSI (Jurnal Teknologi dan Sistem Informasi)*, 6(2), 179-186.
- Ravichandiran, S. (2021). Getting Started with Google BERT: Build and train state-of-the-art natural language processing models using BERT. Packt Publishing Ltd
- Riyantoko, P., Fahrudin, T., Prasetya, D., Trimono, T., & Timur, T. (2022). Analisis Sentimen Sederhana Menggunakan Algoritma LSTM dan BERT untuk Klasifikasi Data Spam dan Non-Spam. *PROSIDING SEMINAR NASIONAL SAINS DATA*, 2(1), 103-111. <https://doi.org/https://doi.org/10.33005/senada.v2i1.53>
- Tayyab, M., & Sarkar, B. (2016). Optimal Batch Quantity In A Cleaner Multi-Stage Lean Production System With Random Defective Rate. *Journal of Cleaner Production*, 139, 922-934. <https://doi.org/10.1016/j.jclepro.2016.08.062>
- Zain, M. M., Simbolon, R. N., Sulung, H., & Anwar, Z. (2021). Analisis sentimen pendapat masyarakat mengenai vaksin COVID-19 pada media sosial Twitter dengan robustly optimized Bert pretraining approach. *Jurnal Komputer Terapan*, 7(2), 280-289