

# Komparasi Metode BERT, VADER, dan RoBERTa untuk Analisis Sentimen Masyarakat terhadap Keputusan Pasangan Childfree

Debi Safa Nurdewanti, Rastri Prathivi\*

Fakultas Teknologi Informasi dan Komunikasi, Teknik Informatika, Universitas Semarang, Semarang, Indonesia

Email: <sup>1</sup>debisafa21@gmail.com, <sup>2,\*</sup>vivi@usm.ac.id

Email Penulis Korespondensi: vivi@usm.ac.id

Submitted: 19/11/2024; Accepted: 02/12/2024; Published: 18/12/2024

**Abstrak**—Penelitian ini membahas fenomena *childfree* di Indonesia, yang semakin ramai dibicarakan seiring dengan perubahan sosial dan ekonomi. Meskipun stigma negatif masih melekat pada keputusan pasangan untuk tidak memiliki anak, kesadaran masyarakat mengenai pilihan *childfree* terus meningkat. Penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap keputusan *childfree* dengan menggunakan tiga metode analisis sentimen, yaitu BERT, RoBERTa, dan VADER. Hasil analisis menunjukkan bahwa metode BERT memiliki akurasi tertinggi mencapai 99%, menandakan kemampuannya dalam mengklasifikasikan sentimen dengan sangat akurat. Sebaliknya, metode RoBERTa dan VADER menunjukkan akurasi yang lebih rendah, masing-masing sebesar 50% dan 41%. Kedua metode tersebut mengalami kesulitan dalam membedakan kelas-kelas sentimen, yang berakibat pada banyaknya kesalahan klasifikasi. Evaluasi menggunakan confusion matrix menunjukkan bahwa RoBERTa dan VADER memiliki jumlah kesalahan klasifikasi yang signifikan, dengan jumlah FP pada RoBERTa sebanyak 9 dan FN sebanyak 19, serta jumlah FP pada VADER sebesar 16 dan FN sebesar 84. Sementara itu, BERT hampir tidak melakukan kesalahan dalam klasifikasi, dengan jumlah FP sebanyak 0 dan FN sebanyak 1. Hasil ini menegaskan bahwa metode BERT lebih unggul untuk analisis sentimen fenomena *childfree* dibandingkan dengan metode RoBERTa dan VADER. Penelitian ini memberikan wawasan tentang bagaimana pandangan masyarakat terhadap fenomena *childfree* serta menemukan metode analisis sentimen terbaik diantara tiga metode.

**Kata Kunci:** Childfree; Analisis Sentimen; BERT; RoBERTa; VADER

**Abstract**—This research discusses the phenomenon of *childfree* in Indonesia, which is increasingly being discussed in line with social and economic changes. Although a negative stigma is still attached to a couple's decision not to have children, public awareness of the *childfree* option continues to increase. This study aims to analyze public sentiment towards *childfree* decisions using three sentiment analysis methods, namely BERT, RoBERTa, and VADER. The analysis results show that the BERT method has the highest accuracy of 99%, signaling its ability to classify sentiment very accurately. In contrast, the RoBERTa and VADER methods show lower accuracy, at 50% and 41% respectively. Both methods had difficulty in distinguishing the sentiment classes, which resulted in many misclassifications. Evaluation using the confusion matrix shows that RoBERTa and VADER have a significant number of misclassifications, with RoBERTa having 9 FPs and 19 FNs, and VADER having 16 FPs and 84 FNs. Meanwhile, BERT has almost no errors in classification, with a total FP of 0 and FN of 1. These results confirm that the BERT method is superior for sentiment analysis of the *childfree* phenomenon compared to the RoBERTa and VADER methods. This research provides insight into how people view the *childfree* phenomenon and finds the best sentiment analysis method among the three methods.

**Keywords:** Childfree; Sentiment Analysis; BERT; RoBERTa; VADER

## 1. PENDAHULUAN

Para peneliti telah menggunakan pendekatan modern untuk menyelidiki fenomena tanpa anak di negara-negara maju dalam beberapa tahun terakhir. Melihat fenomena ini, ada banyak pendapat yang berkembang. Salah satunya, menurut penelitian yang ditulis oleh Jenuri, yang mengutip studi riset Doyle, adalah bahwa perempuan yang tinggal di negara-negara industri umumnya menjadi anggota komunitas *childfree*, didorong oleh masalah seperti kesetaraan gender, akses kontrasepsi, dan peningkatan keterlibatan dalam dunia kerja [1]. Menurut definisi umum dari *childfree* dalam kamus Collins dan Macmillan, *childfree* adalah keputusan atau pilihan hidup seseorang yang secara sadar memilih untuk tidak memiliki anak dengan melahirkan anak kandung, membesarkan anak tiri, atau anak angkat [2]. *Childfree* sendiri didasarkan pada keputusan bersama pasangan suami istri untuk tidak memiliki anak [3]. Istilah *childfree* dikenal oleh masyarakat pada tahun 1972, dimana terdapat dua istilah, yaitu *childfree* dan *childless*. Kedua istilah tersebut memiliki arti yang berbeda meskipun mirip. *Childfree* berarti “bebas anak” yang disebabkan oleh kesengajaan. Sedangkan *childless* berarti “tidak memiliki anak” dengan alasan yang tidak disengaja, seperti kesehatan dan psikologis [4]. Karena masyarakat Indonesia cenderung konservatif dan percaya bahwa tidak memiliki anak adalah stigma negatif, istilah *childfree* masih kurang dikenal di masyarakat [5]. Dengan tingkat kelahiran 2.261 anak, Indonesia adalah negara yang mendukung kelahiran anak, dan 93% orang Indonesia percaya bahwa memiliki anak adalah hal penting dalam pernikahan. Hal ini didasarkan pada pemikiran masyarakat Indonesia yang menganggap anak dapat memberikan manfaat sosial sebagai sumber ketenteraman dan status sosial, manfaat ekonomi sebagai sumber pendapatan dan jaminan hari tua, manfaat budaya sebagai ahli waris, manfaat agama sebagai janji Tuhan, dan manfaat psikologis sebagai sumber kepuasan keluarga [6]. Namun, seiring dengan meningkatnya kesadaran akan berbagai faktor sosial, ekonomi, dan kesehatan telah mendorong banyak orang untuk mempertimbangkan tidak memiliki anak sebagai pilihan hidup. Sejalan dengan angka kelahiran di Indonesia yang menurun di setiap tahunnya. Pada tahun 2020, angka kelahiran tercatat 4,69 juta dan terus menurun setiap tahun hingga menjadi 4,62 juta pada tahun 2023, menurut data dari Badan Pusat Statistik (BPS) [7].

Menurut Analisis Fenomena *Childfree* di Indonesia oleh Siswanto dan Nurhasanah, kesibukan kerja, kurangnya minat terhadap anak-anak, dan trauma masa kecil adalah beberapa alasan mengapa orang memilih untuk tidak memiliki anak [8]. Menurut Tri Rejeki dalam penelitian Amalia Adhandayani, ada beberapa alasan lain mengapa orang memilih untuk tidak memiliki anak: masalah keuangan, kekhawatiran tentang perkembangan anak, masalah lingkungan, dan alasan emosional atau "insting" ibu. Ini mencakup keinginan naluriah untuk menjadi ibu dan memiliki kemampuan untuk mengasuh, memberi makan, mengganti pakaian, dan tugas lainnya, yang mungkin tidak dirasakan oleh perempuan yang memilih untuk tidak memiliki anak [5]. Adapun menurut penelitian Khasanah dan Ridho, seseorang yang tidak ingin memiliki anak disebut sebagai *childfree*. Pola hidup ini tidak sama dengan pola hidup yang ada di Indonesia. Di mana agama dan adat istiadat Indonesia sangat menganjurkan untuk memiliki banyak anak. Tidak memiliki anak atau menikah tanpa anak menjadi tren, terutama di kalangan generasi milenial di Indonesia [9]. Sedangkan penelitian dari Intan Leilana menyebutkan bahwa *childfree* memungkinkan seseorang untuk memiliki identitas yang positif sebagai pembuat keputusan yang otonom, rasional, dan bertanggung jawab, sedangkan orang yang tidak dapat memilih *childfree* karena berbagai alasan memiliki kesan tanpa cela yang berkaitan dengan penyimpangan dari kebiasaan menjadi orang tua [10]. Dengan demikian, meningkatnya jumlah perempuan yang mempunyai tanggung jawab utama dalam membuat keputusan untuk tidak memiliki anak menunjukkan bahwa angka ini akan terus meningkat [11]. Akibatnya, struktur demografi akan kehilangan sebagian kelompok usia tertentu [12].

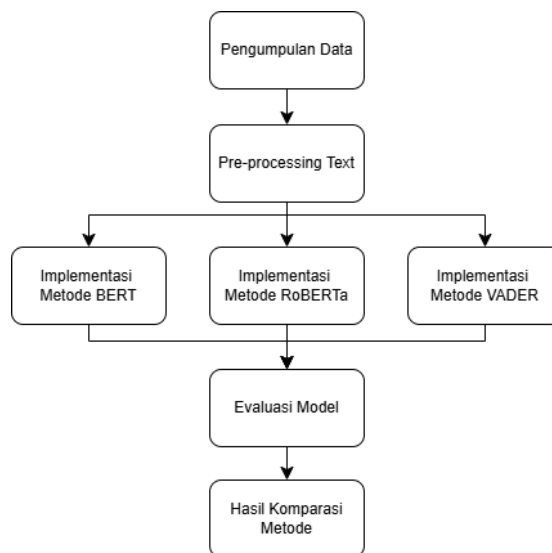
Fenomena ini terus dibicarakan di kalangan masyarakat Indonesia dan semakin dibahas di *platform* sosial media seperti Twitter, yang sekarang menjadi X, salah satu *platform* yang paling banyak digunakan di Indonesia [13]. Di *platform* X, masyarakat Indonesia menyuarakan pendapat yang sangat beragam, mulai dari yang positif hingga yang negatif. Karena perbedaan pendapat dan cara berpikir, tidak jarang ada perdebatan di aplikasi tersebut. Menggabungkan API Twitter dan bahasa pemrograman Python dapat digunakan untuk mengumpulkan data tweet dari X. Dari aplikasi tersebut didapatkan data yang nantinya akan menjadi sampel dan kemudian diolah. Untuk memahami jenis konten dari sejumlah data tweet, diperlukan proses text mining pada data tersebut. Komentar-komentar yang dihasilkan dari proses text mining dapat diolah lebih lanjut untuk mengetahui analisis sentimennya [14]. Analisis sentimen merupakan proses untuk mengekstraksi, memproses, dan memahami data teks yang tidak terstruktur guna memperoleh informasi dan sentimen dari sebuah kalimat opini. Proses ini digunakan untuk mengevaluasi opini serta kecenderungan suatu opini terhadap topik tertentu, baik itu negatif maupun positif. Analisis sentimen adalah bagian dari *Natural Language Processing* (NLP) yang bertujuan untuk mengidentifikasi dan mengekstraksi opini dalam bentuk teks [15]. Komentar dan pendapat orang-orang di media sosial X digunakan sebagai sumber untuk mengumpulkan pendapat publik [16].

Ada berbagai teknik metode yang dapat digunakan untuk menganalisis sentimen, seperti *Bidirectional Encoder Representations from Transformers* (BERT), *Robustly Optimized BERT Pretraining Approach* (RoBERTa), serta *Valence Aware Dictionary and sEntiment Reasoner* (VADER). Ketiga metode tersebut dipilih karena relevansi dan keunggulannya dalam menganalisis sentimen masyarakat terhadap suatu fenomena. Metode BERT merupakan model representasi berbasis *fine-tuning* pertama yang menghasilkan hasil tugas NLP modern [17]. Kelebihan dari BERT adalah mengurangi sekuensial kiri ke kanan seperti RNN karena menggunakan arsitektur *transformer* dua arah (*bidirectional*) [18]. Metode VADER dibuat untuk menganalisis sentimen dalam teks singkat seperti *tweet*. VADER terkenal karena kemampuan untuk menghasilkan hasil yang cepat dan cukup akurat tanpa melakukan pelatihan khusus. Metode RoBERTa merupakan pengembangan lebih lanjut dari metode BERT. RoBERTa memiliki kemampuan untuk menangani situasi yang lebih luas, kompleks, serta memberikan analisis lebih mendalam [19]. Menurut penelitian Afi, dkk (2024) BERT memiliki akurasi sebesar 95% dalam sentimen analisis terhadap komentar pengguna *platform e-commerce* [20]. Selanjutnya, pada metode RoBERTa menurut penelitian Bagas, dkk (2024) menghasilkan akurasi sebesar 88% dalam sentimen analisis *review* hotel bahasa inggris [21]. Sedangkan dalam penelitian analisis sentimen pengunjung pada *platform Google Maps* oleh Elinda, dkk (2024) menggunakan metode VADER menghasilkan akurasi sebesar 72% [22]. Berdasarkan hasil akurasi dari beberapa penelitian di atas, maka penelitian ini akan membandingkan ketiga metode tersebut, yaitu BERT, RoBERTa, dan VADER untuk mengetahui metode mana yang mempunyai akurasi paling tinggi dalam melakukan analisis sentimen masyarakat terhadap keputusan pasangan *childfree*.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini menggunakan metode analisis sentimen dengan teknik pengambilan data (*data scraping*), menggunakan *Google Colab Notebook* dengan bahasa pemrograman *Python*. Proses *data scraping* dilakukan dengan bahasa *Python* untuk mengumpulkan data, yang nantinya akan dilanjutkan dengan tahap pra-pemrosesan data sebelum mengolah dataset menggunakan tiga metode, yaitu BERT, RoBERTa, dan VADER melalui *Google Colab*. Data yang digunakan dalam penelitian ini merupakan data *tweet* yang memiliki kata kunci "*childfree*" dalam aplikasi X. Tahapan yang dilakukan dalam penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Pada Gambar 1 merupakan tahapan penelitian analisis sentimen terhadap fenomena *childfree*. Dimulai dengan pengumpulan data, kemudian dilakukan tahapan *pre-processing* teks. Setelah itu, mengimplementasikan ketiga metode analisis sentimen, yaitu BERT, RoBERTa, dan VADER. Tahapan berikutnya merupakan evaluasi model yang dilakukan di setiap metode, nantinya akan menghasilkan komparasi metode untuk menentukan metode yang terakurat.

## 2.2 Pengumpulan Data

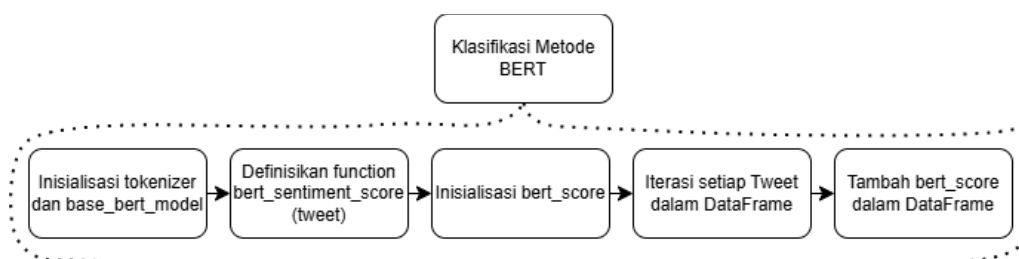
Metode *crawling* digunakan untuk mengumpulkan data *tweet* dari platform X menggunakan library “*tweet-harvest*”. *Tweet-harvest* adalah alat yang menggunakan *Application Programming Interface* (API) Twitter untuk melakukan *crawling* data media sosial yang ditulis dengan Python [23]. Keunggulan *Tweet Harvest* adalah memungkinkan pengguna untuk mengumpulkan lebih banyak data dan dapat dijalankan dalam bentuk *Command Line Interface* (CLI) dengan hanya menggunakan *auth\_token* [24]. Hasil dari *crawling* data didapat data *tweets* sebanyak 516 *tweets* dengan kata kunci “*childfree*”.

## 2.3 Pre-processing Data

Proses ini mengubah data mentah menjadi data yang siap digunakan. *Pre-processing* data dilakukan untuk menyatukan bentuk data kata dan menghilangkan data yang tidak perlu, seperti *noise*, piktogram, URL, dan lainnya yang nantinya akan diproses oleh proses selanjutnya [25].

## 2.4 Metode BERT


Data yang sudah dibagi selanjutnya akan diimplementasikan pada metode BERT. Metode BERT merupakan metode yang mempertimbangkan konteks sekitarnya saat menganalisis teks dua arah [20]. *Masked Language Model* (MLM) digunakan untuk merepresentasikan teks dua arah tersebut. BERT bekerja dengan menyiapkan tokenizer yang dapat mengubah teks menjadi token yang dapat dibaca model dan melakukan analisis sentimen pada teks multibahasa. Dalam model BERT, token menggunakan model *embedding* token yang berbeda pada transformer; contohnya, token menggunakan *Positional Embeddings* untuk menunjukkan posisi token dalam urutan. Token klasifikasi khusus [CLS] adalah token pertama dalam setiap urutan, diikuti oleh token teks pertama, token pemisah [SEP], token teks kedua, dan token terakhir. Urutan ini diulang sampai selesai [18]. Setelah melakukan analisis sentimen *tweet* menggunakan model BERT, klasifikasi sentimen akan dikembalikan ke kelas sentimen dengan angka 1 sampai 5 yang mewakili sentimen negatif, netral, ataupun positif. Kelas sentimen ini akan disimpan pada hasil sentimen dalam kolom “*bert\_score*”. Langkah selanjutnya adalah memberi label pada setiap teks sesuai dengan skor BERT yang telah didapat. Tahapan yang dilakukan oleh metode BERT dapat dilihat pada Gambar 2.



Gambar 2. BERT Flowchart

## 2.5 Metode RoBERTa


Metode RoBERTa merupakan pembaruan dari metode BERT. Input yang digunakan sama dengan model BERT, tetapi model RoBERTa tidak menggunakan NSP, tidak menggunakan *Segment Embedding* (*token\_type\_ids*), dan menggunakan *masking* dinamis pada MLM. RoBERTa adalah metode *pre-training* BERT yang dioptimalkan dengan kuat yang memasukkan kata-kata dan mengubah hyperparameter [18]. RoBERTa menganalisis sentimen pada teks, lengkap dengan *tokenizer* yang sesuai untuk mengklasifikasikan sentimen, yaitu negatif, positif, maupun netral. Setelah itu, memberikan skor sentimen dari model RoBERTa dalam bentuk probabilitas bagi setiap kategori sentimen dengan ketentuan skor dikembalikan dalam bentuk *dictionary* tiga kunci (*roberta\_neg*, *roberta\_neu*, *roberta\_pos*) yang mewakili sentimen negatif, netral, dan positif. Setiap hasil yang disimpan dalam *dictionary* mempunyai ID teks yang akan menjadi kunci untuk merujuk ke skor sentimen. DataFrame RoBERTa memiliki kolom ID dan kolom probabilitas untuk kategori sentimen (negatif, netral, positif). Terakhir dalam model RoBERTa adalah melakukan *labeling* data berdasarkan hasil sentimen RoBERTa yang telah tersedia. Tahapan metode RoBERTa dapat dilihat pada Gambar 3 di bawah ini.



Gambar 3. Metode RoBERTa

## 2.6 Metode VADER

VADER adalah teknik analisis sentimen yang berbasis aturan dan berbasis leksikon. VADER memiliki banyak keunggulan, antara lain mendukung klasifikasi emoji, membutuhkan sumber daya yang lebih sedikit, memiliki intensitas komputasi yang rendah, dan tidak mengalami kompromi antara kecepatan dan kinerja. Selain itu, tidak memerlukan data pelatihan. VADER berfungsi dengan lebih baik untuk teks yang berasal dari media sosial dan sumber web lainnya [22]. Analisis sentimen yang dihasilkan dari model VADER akan disimpan dalam *dictionary res\_vader*. Setiap *entry* dalam *dictionary* berisi ID dan skor sentimen (positif, netral, negatif, dan komposit) sebagai nilai. DataFrame vader didapat dari konversi *dictionary* dan kemudian dilakukan manipulasi terhadap ID *tweet* menjadi kolom biasa dan kolom sentimen berubah nama menjadi *vader\_neg*, *vader\_neu*, *vader\_pos*, dan *vader\_compound*. Kemudian dalam model VADER juga dilakukan *labeling* data berdasarkan hasil sentimen yang telah didapatkan. Tahapan metode VADER dapat dilihat pada Gambar 4.



Gambar 4. Metode VADER

## 2.7 Evaluasi Model dan Komparasi Metode

Masing-masing model yang telah diimplementasikan akan dievaluasi menggunakan *Accuracy*, *Precision*, *Recall*, serta *F1 Score* yang nantinya akan menghasilkan nilai akurasi dan persentasi sentimen masyarakat terhadap fenomena *childfree* berdasarkan jenis sentimen yang tersebar di *platform X* baik itu nilai negatif maupun positif. Evaluasi akan dilakukan terhadap model yang nantinya berguna untuk langkah komparasi metode. Komparasi metode adalah langkah untuk membandingkan dan menarik kesimpulan terhadap kinerja metode tersebut berdasarkan akurasi yang ada.

# 3. HASIL DAN PEMBAHASAN

## 3.1 Crawling

Hasil yang diperoleh dari teknik *crawling* yang menggunakan kata kunci *childfree* untuk mengumpulkan data raw mendapatkan *tweet* sebanyak 516 *tweets*. Setelah proses *crawling* selesai, terdapat 15 atribut yang dikumpulkan, seperti *conversation\_id\_str*, *created\_at*, *favorite\_count*, dll. Dari banyaknya atribut yang ada, hanya beberapa atribut penting yang akan digunakan, yaitu *created\_at*, *full\_text*, *tweet\_url*, dan *username*. Atribut-atribut tersebut yang

nantinya digunakan untuk *pre-processing* dan analisis data. Tabel 1 menunjukkan hasil *crawling* dengan kata kunci *childfree*.

**Tabel 1.** Hasil Crawling dengan Kata Kunci Childfree

created_at	full_text	tweet_url	username
Thu Apr 18 05:49:26 ...	kalau begitu ngapain punya anak kalau gk ada waktu buat bermain scara fisik dg ...	https://twitter.com/Striant_oky/status/1780836013134508071	Striant_oky
Thu Apr 18 05:25:12 ...	Kalau orang tanya kenapa aku childfree Oknum Ares Ezra Shankara ...	https://twitter.com/deviIishgirl/status/1780829916512313762	deviIishgirl
...	...	...	...
Sun Apr 07 13:57:21 ...	iya deh..... sama..... gue juga..... gajadi childfree..... https://t.co/j7NdnK0g37	https://twitter.com/hannitelkom/status/17769725356510208	hannitelkomsel

### 3.2 Pre-processing Data

Pre-processing data adalah serangkaian langkah atau tahapan yang dilakukan pada data mentah sebelum data digunakan untuk analisis atau pengembangan model. Tujuan utama dari preprocessing data adalah untuk meningkatkan kualitas data, menjamin hasil analisis akurat, dan mengatasi masalah atau kekurangan yang mungkin muncul dengan data mentah [26]. Tahapan pre-processing data pada penelitian ini menggunakan library deep-translator untuk menerjemahkan teks pada kolom ‘full\_text’ ke dalam bahasa Inggris. Setelah terjemahan selesai, hasilnya dan ID ditambahkan ke df. Di bawah ini merupakan hasil dari pre-processing data yang telah diterjemahkan ditunjukkan pada Tabel 2.

**Tabel 2.** Hasil Pre-processing Data

ID	username	full_text	created_at	tweet_url	tr_tweet
1	Striant_oky	kalau begitu ngapain punya ...	Thu Apr 18 ...	https://twitter.com/Striant_oky/	If that's the case, why have ...
2	deviIishgirl	Kalau orang tanya kenapa ...	Thu Apr 18 ...	https://twitter.com/deviIishgirl/	If people ask why ...
...	...	...	...	...	...
516	hannitelkomsel	iya deh sama gue juga gajadi ...	Sun Apr 07 ...	https://twitter.com/hannitelkomsel/	Yes, I am also ...

Dari Tabel 2, dapat dilihat bahwa *tweet* asli pada kolom *full\_text* memiliki beberapa perubahan, salah satunya penghapusan tanda baca yang berlebih. Selain itu, juga dapat terlihat hasil terjemahan teks pada kolom *tr\_tweet* yang diterjemahkan menggunakan *library deep\_translator*.

### 3.3 Metode BERT

Data yang telah melalui tahap pre-processing selanjutnya akan diimplementasikan ke dalam metode pertama, yaitu Base BERT Model. Metode ini merupakan representasi model berbasis *fine-tuning* pertama yang menghasilkan tugas NLP modern [18]. BERT diterapkan untuk menghasilkan skor sentimen yang nantinya akan digunakan sebagai parameter dalam labeling teks. Hasil implementasi dari Base BERT Model ditunjukkan oleh Gambar 5 dan Tabel 3.



**Gambar 5.** Implementasi Base BERT Model

Pada Gambar 5 merupakan proses pengunduhan *file* model atau tokenisasi untuk model *machine learning* berbasis transformer, yaitu model BERT. Setiap baris mengandung *file* yang diperlukan, seperti *tokenizer\_config.json*, *config.json*, *vocab.txt*, *special\_tokens\_map.json*, dan *pytorch\_model.bin*. Status pengunduhan ditampilkan dalam bentuk progress bar hijau, yang menunjukkan bahwa semua file telah diunduh dengan sukses. *File* model terbesar adalah *pytorch\_model.bin*.

**Tabel 3.** Hasil Implementasi Metode BERT

ID	username	full_text	...	bert_score
1	Striant_oky	kalau begitu ngapain punya anak kalau gk ada ...	...	3

2	devilishgirl	Kalau orang tanya kenapa aku childfree Oknum A...	...	1
...	...	...	...	...
516	hannitelkomsel	iya deh sama gue juga gajadi childfree	...	5

Pada Tabel 3 menunjukkan hasil dari implementasi metode BERT yang telah memperoleh *bert\_score*. Nilai *bert\_score* diberikan sesuai dengan sentimen yang dianalisis berdasarkan teks yang ada.

### 3.4 Metode RoBERTa

Metode RoBERTa merupakan metode kedua yang diimplementasikan pada data dari penelitian ini. Sama seperti metode BERT, metode ini diterapkan untuk menghasilkan skor sentimen yang nantinya akan digunakan sebagai parameter dalam labeling teks sentimen. Perbedaan yang terlihat dari kedua metode ini adalah waktu pada saat memproses data. RoBERTa menggunakan lebih banyak data dan membutuhkan waktu training model yang lebih lama, serta masuk dalam model yang berkomputasi mahal [18]. Pada Gambar 6 dan Tabel 4 merupakan hasil dari implementasi metode RoBERTa.



Gambar 6. Implementasi Metode RoBERTa

Pada Gambar 6 menunjukkan proses yang sama dengan metode BERT, yaitu proses pengunduhan *file* model atau tokenisasi. Setiap baris mengandung *file* yang diperlukan, seperti *config.json*, *vocab.json*, *merges.txt*, *special\_tokens\_map.json*, dan *pytorch\_model.bin*. Status pengunduhan ditampilkan dalam bentuk progress bar hijau, yang menunjukkan bahwa semua file telah diunduh dengan sukses. File model terbesar adalah *pytorch\_model.bin*.

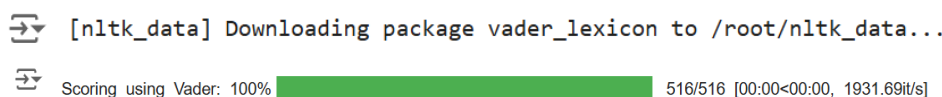
Tabel 4. Hasil Implementasi Metode RoBERTa

ID	username	full_text	...	roberta_neg	roberta_neu	roberta_pos
1	Striant_oky	kalau begitu ngapain punya anak kalau gk ada ...	...	0.363286	0.587633	0.049081
2	devilishgirl	Kalau orang tanya kenapa aku childfree Oknum A...	...	0.108027	0.861958	0.030015
...	...	...	...	...	...	...
516	hannitelkomsel	iya deh sama gue juga gajadi childfree	...	0.006571	0.349923	0.643506

Dari Tabel 4, terdapat kolom *roberta\_neg*, *roberta\_neu*, *roberta\_pos* yang berisi skor sentimen dari data yang dianalisis. *Roberta\_neg* menyimpan skor probabilitas untuk kategori “negatif”, *roberta\_neu* untuk menyimpan skor probabilitas untuk kategori “netral”, sedangkan *roberta\_pos* untuk menyimpan skor probabilitas kategori “positif”. Cara untuk menentukan sentimen analisis RoBERTa, yaitu dengan melihat skor yang paling tinggi di antara kolom *roberta\_neg*, *roberta\_neu*, *roberta\_pos*.

### 3.5 Metode VADER

Metode ketiga yang dipakai adalah metode VADER (*Valence Aware Dictionary and sEntiment Reasoner*). Metode ini merupakan metode sederhana berbasis aturan untuk analisis sentimen. VADER berguna untuk memberikan skor sentimen dengan cara mengunduh leksikon VADER agar dapat mengenali kata dan frasa yang umum dalam sehari-hari [22]. VADER sangat efektif dalam situasi yang membutuhkan respon cepat terhadap perubahan sentimen publik [19]. Hasil implementasi dari metode VADER ditunjukkan oleh Gambar 7 dan Tabel 5.



Gambar 7. Implementasi Metode VADER

Dari Gambar 7 menunjukkan proses implementasi metode VADER dengan mengunduh *file package vader\_lexicon*. Setelah mengunduh *package*, maka selanjutnya menghitung skor sentimen teks menggunakan metode VADER. Dari gambar di atas, terlihat bahwa metode VADER berhasil memberikan skor untuk seluruh teks.

**Tabel 5.** Hasil Implementasi Metode VADER

ID	username	full_text	...	vader_neg	vader_neu	vader_pos	Vader_compound
1	Striant_oky	kalau begitu ngapain punya anak kalau gk ada ...	...	0.000	0.939	0.061	0.3400
2	deviIishgirl	Kalau orang tanya kenapa aku childfree Oknum ...	...	0.000	1.000	0.000	0.0000
...	...	...	...	...	...	...	...
516	hannitelkom sel	iya deh sama gue juga gajadi childfree	...	0.000	0.526	0.474	0.4019

Dari Tabel 5, terdapat kolom *vader\_neg*, *vader\_neu*, *vader\_pos*, dan *Vader\_compound* yang masing-masing dari kolom tersebut berisi nilai sentimen. *Vader\_neg* menunjukkan skor sentimen negatif dari teks, *vader\_neu* menunjukkan skor sentimen netral dari teks, sedangkan *vader\_pos* menunjukkan skor sentimen positif dari teks dengan masing-masing skor sentimen berkisar antara 0 hingga 1. Kemudian untuk *Vader\_compound* merupakan nilai yang dihitung berdasarkan skor sentimen negatif, netral, dan positif dengan rentang nilai berkisar 0 hingga 1.

### 3.6 Labeling Data

Pada tahap labeling data, dilakukan proses *auto labeling* (pelabelan otomatis) atau proses menempelkan label atau tag pada dokumen maupun data secara otomatis tanpa campur tangan manusia. Proses ini lebih menghemat waktu dan biaya daripada pelabelan manual. *Auto labeling* adalah metode untuk meningkatkan produktivitas dan kualitas dalam berbagai tugas, seperti analisis sentimen [27]. Penelitian ini menggunakan kode perintah untuk pemberian labeling pada data berdasarkan skor yang telah didapat. Kode perintah dapat dilihat pada Algoritma 1 di bawah ini.

**Algoritma 1.** Kode Perintah Labeling

```
bert_condition = lambda x: 'positive' if x > 3 else ('negative' if x < 3 else 'neutral')
vader_condition = lambda x: 'positive' if x > 0 else ('negative' if x < 0 else 'neutral')
roberta_condition = lambda pos, neg, neu: 'positive' if (pos > neg) and (pos > neu) else ('negative' if (neg > pos) and (neg > neu) else 'neutral')
```

Pada Algoritma 1 dapat terlihat bahwa proses labeling dilakukan di setiap skor yang didapatkan pada masing-masing metode. Dalam metode BERT, label dibagi menjadi tiga kategori sesuai dengan skor berdasarkan ambang batas yang ditentukan. Jika skor lebih besar dari 3, maka akan dimasukkan ke dalam kategori ‘*positive*’. Jika skor kurang dari 3, data akan diberikan label ‘*negative*’, sedangkan untuk skor sama dengan 3 akan dikategorikan ‘*neutral*’. Di metode kedua, metode VADER, label dikategorikan menjadi tiga. Pembagian kategori meliputi skor lebih besar dari 0, kurang dari 0, dan sama dengan 0. Untuk skor lebih besar dari 0 akan dikategorikan sebagai sentimen ‘*positive*’, skor kurang dari 0 dimasukkan ke dalam kategori ‘*negative*’, dan skor sama dengan 0 akan dikategorikan sebagai sentimen ‘*neutral*’. Tidak seperti *bert\_condition*, fungsi *vader\_condition* menggunakan pendekatan yang lebih sederhana dengan satu ambang batas (0) untuk menentukan kategori sentimen. Pada metode RoBERTa, label dibagi menjadi tiga kategori sesuai dengan skor sentimen yang paling dominan. Jika skor positif lebih besar dari pada skor negatif dan skor netral, maka akan dikategorikan sebagai sentimen ‘*positive*’. Jika skor negatif lebih besar dari skor positif dan skor netral, maka teks akan dimasukkan ke dalam kategori ‘*negative*’. Dan jika skor sentimen tidak memenuhi kondisi-kondisi tersebut, maka akan dikategorikan sebagai sentimen ‘*neutral*’. Dari penjelasan di atas, hasil labeling data dapat terlihat sebagai berikut pada Tabel 6.

**Tabel 6.** Hasil Labeling Data

ID	username	full_text	...	sentiment_bert	sentiment_vader	sentiment_roberta
1	Striant_oky	kalau begitu ngapain punya anak kalau gk ada ...	...	neutral	positive	neutral
2	deviIishgirl	Kalau orang tanya kenapa aku childfree Oknum ...	...	negative	neutral	neutral
...	...	...	...	...	...	...
516	hannitelkom sel	iya deh sama gue juga gajadi childfree	...	positive	positive	positive

### 3.7 Evaluasi dan Komparasi

Sebelum melakukan proses evaluasi, sentimen yang bernilai string (‘*negative*’, ‘*positive*’, ‘*neutral*’) akan diubah ke dalam bentuk integer dengan nilai 0 untuk nilai negatif, 1 untuk nilai netral, dan 2 untuk nilai positif. Proses ini dilakukan agar mempermudah analisis dan perhitungan nilai sentimen. Setelah mengubah nilai data menjadi integer,

ditambahkan kolom *ground\_truth* untuk digunakan dalam analisis lebih lanjut. *Ground\_truth* digunakan sebagai label kebenaran yang menunjukkan sentimen yang sebenarnya dalam setiap teks pada data. Ini penting untuk pelatihan, evaluasi, dan analisis model agar dapat mengetahui seberapa baik model-model bekerja. Berikut merupakan hasil dari pelabelan *ground\_truth* yang dapat dilihat pada Tabel 7.

**Tabel 7.** Hasil Pelabelan Integer

ID	username	full_text	...	sentiment_ bert	sentiment_ vader	sentiment_ roberta	ground _truth
1	Striant_oky	kalau begitu ngapain punya anak kalau gk ada ...	...	2	1	2	2
2	devilishgirl	Kalau orang tanya kenapa aku childfree Oknum ...	...	0	2	2	0
...	...	...	...	...	...	...	...
516	hannitelkom sel	iya deh sama gue juga gajadi childfree	...	1	1	1	0

Setelah melakukan pelabelan dengan nilai sentimen diubah ke integer, langkah berikutnya adalah evaluasi model. Evaluasi model dibagi menjadi dua, yaitu evaluasi laporan klasifikasi dan evaluasi *confusion matrix*. Berikut merupakan penjelasan dari masing-masing evaluasi model.

a. Evaluasi Laporan Klasifikasi

Laporan klasifikasi menampilkan nilai *recall*, *precision*, dan *F1-Score* untuk model. Selain itu, laporan klasifikasi menyediakan rangkuman detail kinerja model untuk setiap kelas, yang lebih informatif daripada hanya melihat metrik seperti akurasi [28]. Berikut merupakan hasil evaluasi laporan klasifikasi ditunjukkan pada Tabel 8.

**Tabel 8.** Evaluasi Laporan Klasifikasi

Metode	Laporan Klasifikasi			
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>
BERT	99.03%	99.03%	99.03%	99.03%
RoBERTa	51.49%	50.38%	50.15%	50.38%
VADER	53.62%	41.27%	40.97%	41.27%

Berdasarkan hasil dari Tabel 8, nilai *precision*, *recall*, dan *F1-Score* yang paling tinggi ditunjukkan oleh metode BERT. Ini berarti metode BERT dapat melakukan tugas klasifikasi dengan baik pada keseluruhan data yang menghasilkan akurasi sebesar 99.03%. Sementara itu, pada dua metode yang lain, yaitu metode RoBERTa dan metode VADER menunjukkan nilai *precision*, *recall*, serta *F1-Score* kurang baik dengan nilai akurasi masing-masing metode sebesar 50.38% dan 41.27%. RoBERTa dan VADER kemungkinan mengalami kesulitan dalam membedakan antara kelas-kelas sentimen. Meskipun metode berbasis aturan, VADER mungkin tidak cukup efektif untuk menangkap kompleksitas sentimen yang ada dalam teks, sedangkan RoBERTa dengan akurasi selisih 9.11% lebih tinggi daripada VADER, masih gagal mencapai hasil yang diharapkan. Hasil akurasi ketiga metode tersebut bukan satu-satunya komponen yang mempengaruhi kinerja model. Komponen lain yang diperlukan salah satunya adalah *confusion matrix* yang membantu untuk mengevaluasi kinerja model lebih lanjut [28].

b. Evaluasi *Confusion Matrix*

Evaluasi *confusion matrix* menyajikan total nilai prediksi dan nilai aktual. Nilai aktual dan prediksi menghasilkan empat jenis hasil: positif aktual (TP), negatif aktual (TN), positif salah (FP), dan negatif salah (FN) [29]. Jumlah contoh positif yang diklasifikasikan dengan benar disebut sebagai positif aktual (TP), sedangkan jumlah contoh negatif yang diklasifikasikan dengan benar disebut sebagai negatif aktual (TN). Di sisi lain, jumlah contoh negatif yang sebenarnya tetapi diklasifikasikan sebagai positif dikenal sebagai positif salah (FP), dan jumlah contoh positif yang sebenarnya tetapi diklasifikasikan sebagai negatif disebut negatif salah (FN) [28]. Hasil dari evaluasi *confusion matrix* masing-masing metode dapat dilihat pada Tabel 9, Tabel 10, dan Tabel 11.

**Tabel 9.** Evaluasi *Confusion Matrix* Metode BERT

Actual	Predicted		
	Negative	Positive	Neutral
Negative	216 (TN)	0 (FP)	1
Positive	1 (FN)	105 (TP)	0
Neutral	3	0	190

Pada Tabel 9, terlihat bahwa metode BERT memperoleh evaluasi *confusion matrix* dengan jumlah TN sebanyak 216, FP sebanyak 0, FN sebanyak 1, dan TP sebanyak 105. Berdasarkan data tersebut, bisa disimpulkan bahwa metode BERT melakukan sedikit kesalahan dalam klasifikasi sentimen.

**Tabel 10.** Evaluasi *Confusion Matrix* Metode RoBERTa

Actual	Predicted		
	Negative	Positive	Neutral
Negative	100 (TN)	9 (FP)	48
Positive	19 (FN)	64 (TP)	47
Neutral	101	32	96

Pada Tabel 10, terlihat bahwa metode RoBERTa memperoleh evaluasi confusion matrix dengan jumlah TN sebanyak 100, FP sebanyak 9, FN sebanyak 19, dan TP sebanyak 64. Berdasarkan data tersebut, bisa disimpulkan bahwa metode RoBERTa melakukan kesalahan yang cukup banyak dalam klasifikasi sentimen.

**Tabel 11.** Evaluasi *Confusion Matrix* Metode VADER

Actual	Predicted		
	Negative	Positive	Neutral
Negative	89 (TN)	16 (FP)	29
Positive	84 (FN)	75 (TP)	113
Neutral	47	14	49

Pada Tabel 11, terlihat bahwa metode VADER memperoleh evaluasi confusion matrix dengan jumlah TN sebanyak 89, FP sebanyak 16, FN sebanyak 84, dan TP sebanyak 75. Berdasarkan data tersebut, bisa disimpulkan bahwa metode VADER melakukan kesalahan yang lebih banyak daripada metode RoBERTa dalam klasifikasi sentimen. Dari ketiga tabel di atas, metode yang hampir tidak melakukan kesalahan dalam klasifikasi sentimen adalah metode BERT dengan jumlah FP sebanyak 0 dan FN sebanyak 1. Sedangkan kedua metode yang lain, yaitu RoBERTa dan VADER menunjukkan kinerja yang kurang bagus. Namun, metode RoBERTa menunjukkan kinerja yang lebih baik daripada VADER dengan jumlah FP sebanyak 9 dan FN sebanyak 19 walaupun hasilnya masih jauh di bawah BERT. Sedangkan untuk metode VADER mendapatkan jumlah FP sebanyak 16 dan FN sebanyak 84. Kedua metode ini memiliki jumlah FP dan FN yang signifikan dibandingkan dengan BERT dengan selisih FP pada masing-masing metode sebesar 9 untuk RoBERTa dan 16 untuk VADER, serta selisih FN sebesar 18 untuk RoBERTa dan 83 untuk VADER. Ini berarti RoBERTa dan VADER mengalami kesulitan dalam klasifikasi kelas-kelas sentimen, yang berakibat pada banyaknya kesalahan prediksi.

## 4. KESIMPULAN

Penelitian ini mengangkat fenomena *childfree* di Indonesia sebagai topik yang semakin relevan, mengingat perubahan sosial dan ekonomi yang terjadi saat ini. Terlepas dari stigma negatif yang masih melekat pada keputusan untuk tidak memiliki anak, kesadaran masyarakat akan keputusan tanpa anak ini meningkat. Dengan menggunakan tiga metode analisis sentimen, yaitu BERT, RoBERTa, dan VADER, penelitian ini bertujuan untuk menganalisis sentimen masyarakat terhadap keputusan *childfree* yang dipilih oleh masyarakat. Hasil analisis menunjukkan metode BERT merupakan metode yang sangat baik dalam penelitian ini, dengan akurasi mencapai 99%. Ini menunjukkan kemampuan BERT untuk mengklasifikasikan sentimen dengan sangat akurat, hampir tanpa kesalahan. Sebaliknya, metode RoBERTa dan VADER memiliki akurasi lebih rendah pada masing-masing metode yaitu 50% dan 41%. Keduanya mengalami kesulitan dalam membedakan kelas-kelas sentimen, yang mengakibatkan banyak kesalahan klasifikasi. Menurut hasil evaluasi menggunakan *confusion matrix*, RoBERTa dan VADER memiliki jumlah kesalahan klasifikasi yang signifikan, dilihat dari jumlah FP pada RoBERTa sebanyak 9 dan FN sebanyak 19, serta jumlah FP pada VADER sebesar 16 dan FN sebesar 84, sedangkan BERT hampir tidak melakukan kesalahan dalam klasifikasi yang ditunjukkan oleh jumlah FP sebanyak 0 dan FN sebanyak 1. Hasil ini menunjukkan bahwa metode BERT lebih efektif untuk analisis sentimen dalam bahasan fenomena *childfree* dibandingkan dengan metode RoBERTa dan VADER.

## REFERENCES

- [1] M. Jenuri, Rindu Fajar Islamy, K. Siti Komariah, D. Mayadiana Suwama, and A. Hafidzani Nur Fitria, "Fenomena Childfree di Era Modern: Studi Fenomenologis Generasi Z serta Pandangan Islam terhadap Childfree di Indonesia," *Sos. Budaya*, vol. 19, no. 2, pp. 81–89, 2022, [Online]. Available: <http://dx.doi.org/10.24014/sb.v19i2.16602>
- [2] V. M. Tunggono, *Childfree & Happy*. EA Books, 2021. [Online]. Available: <https://books.google.co.id/books?id=70KGEAAAQBAJ>
- [3] D. Rahman, A. S. Fitria, D. A. Lutfiyanti, I. Irfan M R, S. M. P. Fadillah, and M. Parhan, "Childfree dalam Perspektif Islam: Solusi atau Kontroversi?," *J. Wan. dan Kel.*, vol. 4, no. 1, pp. 1–14, 2023, doi: 10.22146/jwk.7964.
- [4] S. G. R. Nasution Chairul Majid, "Fenomena Childfree Berdasarkan Perspektif Hukum Islam Progresif, Pancasila dan Hak Asasi Manusia (HAM)," *J. Keislam.*, vol. 7, no. 1, pp. 66–79, 2024, doi: <https://doi.org/10.54298/jk.v7i1.239>.
- [5] A. Adhandayani, A. T. Febrianti, N. I. Maulida, and R. Asfrillah, "Kepuasan Pernikahan Tanpa Anak: Sebuah Studi Fenomenologi," *J. Psikogenes.*, vol. 10, no. 1, pp. 76–88, 2023, doi: 10.24854/jps.v10i1.2846.
- [6] M. Patnani, B. Takwin, and W. W. Mansoer, "Bahagia tanpa anak? Arti penting anak bagi involuntary childless," *J. Ilm.*



- Psikol. Terap.*, vol. 9, no. 1, p. 117, 2021, doi: 10.22219/jipt.v9i1.14260.
- [7] N. F. Nallanie Farrencia, “Childfree di Indonesia, Fenomena Atau Viral Sesaat?,” *Syntax Idea*, vol. 15, no. 1, pp. 37–48, 2024, doi: <https://doi.org/10.46799/syntax-idea.v6i6.3457>.
- [8] A. S. P. Prasmono and M. D. Kartikasari, “The Childfree Phenomenon in Indonesia: An Analysis of Sentiments on YouTube Video Comments,” *Jambura J. Math.*, vol. 6, no. 1, pp. 29–38, 2024, doi: 10.37905/jjom.v6i1.23591.
- [9] U. Khasanah and M. R. Ridho, “Childfree Perspektif Hak Reproduksi Perempuan Dalam Islam,” *Al-Syakhshiyah J. Law Fam. Stud.*, vol. 3, no. 2, pp. 104–128, 2021, doi: 10.21154/syakhshiyah.v3i2.3454.
- [10] I. Leliana, I. Suryani, A. Haikal, and R. Septian, “Respon Masyarakat Mengenai Fenomena ‘Childfree’ (Studi Kasus influencer Gita Savitri),” vol. 23, no. 1, pp. 36–43, 2020, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/cakrawala>
- [11] Y. He, N. E. T. A. Wahab, H. Muhamad, and D. Liu, “The marital and fertility sentiment orientation of Chinese women and its influencing factors - An analysis based on natural language processing,” *PLoS One*, vol. 19, no. 2 February, pp. 1–23, 2024, doi: 10.1371/journal.pone.0296910.
- [12] F. N. A. Hendro Margono, “Analisis Sentimen Komentar Childfree di Aplikasi X Menggunakan Naive Bayes,” *Indones. J. Comput. Sci.*, vol. 12, no. 2, pp. 284–301, 2024, doi: <https://doi.org/10.33022/ijcs.v13i3.3883>.
- [13] D. Siregar, F. Ladayya, N. Z. Albaqi, and B. M. Wardana, “Penerapan Metode Support Vector Machines (SVM) dan Metode Naive Bayes Classifier (NBC) dalam Analisis Sentimen Publik terhadap Konsep Child-free di Media Sosial Twitter,” *J. Stat. dan Apl.*, vol. 7, no. 1, pp. 93–104, 2023, doi: <https://doi.org/10.21009/JSA.07109>.
- [14] F. Agustine, A. Ompo, M. A. I. Pakereng, T. Informatika, U. Kristen, and S. Wacana, “Penerapan Text Mining Untuk Advertising Pada Data Tweets Zalora Indonesia Dengan Menggunakan Metode K-Means Clustering,” *Progresif J. Ilm. Komput.*, vol. 20, no. 1, pp. 314–324, 2024, doi: <http://dx.doi.org/10.35889/progresif.v20i1.1576>.
- [15] R. Nainggolan, F. Adline, T. Tobing, and E. J. G. Harianja, “Analysis Sentiment in Bukalapak Comments with K-Means Clustering Method,” *Int. J. New Media Technol.*, vol. 9, no. 2, pp. 87–92, 2022, doi: <https://doi.org/10.31937/ijnmt.v9i2.2914>.
- [16] Muhammad Fernanda Naufal Fathon, Eva Yulia Puspaningrum, and Andreas Nugroho Sihananto, “Perbandingan Performa Labeling Lexicon InSet dan VADER pada Analisa Sentimen Rohingya di Aplikasi X dengan SVM,” *Modem J. Inform. dan Sains Teknol.*, vol. 2, no. 3, pp. 62–76, 2024, doi: 10.62951/modem.v2i3.112.
- [17] M. V. Koroteev, “BERT: A Review of Applications in Natural Language Processing and Understanding,” *arXiv Prepr.*, vol. 1, p. 18, 2021, doi: <https://doi.org/10.48550/arXiv.2103.11943>.
- [18] F. Basbeth and D. H. Fudholi, “Klasifikasi Emosi Pada Data Text Bahasa Indonesia Menggunakan Algoritma BERT, RoBERTa, dan Distil-BERT,” *J. Media Inform. Budidarma*, vol. 8, no. 2, p. 1160, 2024, doi: 10.30865/mib.v8i2.7472.
- [19] S. N. K. Nurmadewi Dita, Jailani Zakiul Fahmi, “Perbandingan Performa Algoritma VADER dan RoBERTa pada Twitter Comparison of VADER and RoBERTa Algorithm Performance on,” *Sistemasi*, vol. 13, no. 4, pp. 1547–1557, 2024, doi: <https://doi.org/10.32520/stmsi.v13i4.4198>.
- [20] A. G. Yuda, “Comparison of Service and Ease of e-Commerce User Applications Using BERT,” *J. Sist. Cerdas*, vol. 07, no. 02, pp. 98–107, 2024, doi: <https://doi.org/10.37396/jsc.v7i2.403>.
- [21] B. Setiadi, E. Purwanto, and H. Permatasari, “Optimisasi Klasifikasi Sentimen Pada Review Hotel Bahasa Inggris Dengan Model Roberta Twitter,” *SINTECH (Science Inf. Technol. J.)*, vol. 7, no. 2, pp. 70–79, 2024, doi: 10.31598/sintechjournal.v7i2.1547.
- [22] E. Elinda, H. Yuliansyah, and M. I. A. Latiffi, “Sentiment Analysis of the Sheikh Zayed Grand Mosque’s Visitor Reviews on Google Maps Using the VADER Method,” *Int. J. Adv. Data Inf. Syst.*, vol. 5, no. 1, pp. 71–84, 2024, doi: 10.59395/ijadis.v5i1.1320.
- [23] S. A. Putra and A. Wijaya, “Analisis Sentimen Artificial Intelligence (Ai) Pada Media Sosial Twitter Menggunakan Metode Lexicon Based,” *JuSiTik J. Sist. dan Teknol. Inf. Komun.*, vol. 7, no. 1, pp. 21–28, 2023, doi: 10.32524/jusitik.v7i1.1042.
- [24] R. Darman, “Analisis Sentimen Respons Twitter terhadap Persyaratan Badan Penyelenggara Jaminan Sosial (BPJS) di Kantor Pertanahan,” *Widya Bhumi*, vol. 3, no. 2, pp. 113–136, 2023, doi: 10.31292/wb.v3i2.61.
- [25] A. Jaya, “Analisis Sentimen Pandangan Public Profesi PNS (Pegawai Negeri Sipil) dari Twitter menerapkan indonesian Roberta Base Sentiment Classifier,” *Indones. J. Data Sci.*, vol. 4, no. 1, pp. 38–44, 2023, doi: 10.56705/ijodas.v4i1.66.
- [26] P. Rahayu *et al.*, *Buku Ajar Data Mining*, vol. 1. Jambi: PT. Sonpedia Publishing Indonesia, 2024. [Online]. Available: <https://books.google.co.id/books?id=vCruEAAAQBAJ>
- [27] S. W. Iriananda, R. P. Putra, and A. Farhan, “Kinerja Auto Labelling Pada Analisis Sentimen Terhadap Pasangan Calon Presiden 2024 Di Media Sosial X,” *Conf. Innov. Appl. Sci. Technol.*, vol. 6, no. 1, p. 618, 2023, doi: 10.31328/ciastech.v6i1.5354.
- [28] S. N. V. Sihombing Yogie Oktavianus, “Prediksi Sentimen Pada Teks Media Sosial Corporate University Menggunakan RoBERTa,” *Pros. PITNAS Widyaaiswara*, vol. 1, pp. 302–316, 2024.
- [29] A. Kulkarni, D. Chong, and F. A. Batarseh, “Foundations of data imbalance and solutions for a data democracy,” *Data Democr. Nexus Artif. Intell. Softw. Dev. Knowl. Eng.*, pp. 83–106, 2020, doi: 10.1016/B978-0-12-818366-3.00005-8.