

# ANALISIS SENTIMEN PROGRAM MAKAN BERGIZI GRATIS BERDASARKAN KOMENTAR DI MEDIA SOSIAL X MENGGUNAKAN GRU

Febri Haerani\*

<sup>1</sup> Prodi Teknik Informatika, Universitas Halu Oleo, Kampus Hijau Bumi Tridharma, Anduonohum Kec. Kambu, Kota Kendari, Sulawesi Tenggara, 93232

---

**Keywords:**  
analisis sentimen, GRU,  
media sosial, MBG

**Corespondent Email:**  
febrihaerani5@gmail.com

**Abstrak.** Penelitian ini berfokus pada analisis sentimen masyarakat terhadap program Makan Bergizi Gratis (MBG) dengan memanfaatkan data dari platform media sosial X. Metode yang digunakan adalah *Recurrent Neural Network* (RNN) dengan varian *Gated Recurrent Unit* (GRU), yang dinilai efektif dalam pemrosesan teks. Melalui teknik *web scraping*, diperoleh sebanyak 10.524 komentar dan unggahan pengguna, yang kemudian diklasifikasikan ke dalam dua kategori sentimen, yaitu positif dan negatif. Proses analisis diawali dengan tahapan pra-pemrosesan, meliputi pembersihan teks, penghapusan *stopword*, *lemmatization*, serta tokenisasi. Hasil penelitian menunjukkan bahwa mayoritas pengguna memberikan tanggapan positif terhadap program MBG, meskipun terdapat pula opini negatif. Model GRU menghasilkan nilai *precision*, *recall*, dan *f1-score* sebesar 91% pada sentimen positif serta 88% pada sentimen negatif. Temuan ini menegaskan bahwa GRU, sebagai salah satu varian RNN, mampu mengolah data media sosial secara efektif untuk menangkap dan memahami persepsi publik dalam skala besar.



Copyright © [JITET](#) (Jurnal Informatika dan Teknik Elektro Terapan). This article is an open access article distributed under terms and conditions of the Creative Commons Attribution (CC BY NC)

**Abstract.** This study focuses on analyzing public sentiment toward the Free Nutritious Meal (MBG) program by utilizing data collected from the social media platform X. The method applied is the Recurrent Neural Network (RNN), specifically the Gated Recurrent Unit (GRU) variant, which is considered effective for text-based data processing. Through web scraping techniques, a total of 10,524 user comments and posts were obtained and subsequently classified into two sentiment categories, namely positive and negative. The analysis began with a preprocessing stage that included text cleaning, stopword removal, lemmatization, and tokenization. The findings reveal that the majority of users expressed positive responses to the MBG program, although negative opinions were also present. The GRU model achieved precision, recall, and f1-score values of 91% for positive sentiment and 88% for negative sentiment. These results highlight the capability of GRU, as a variant of RNN, to effectively process social media data in capturing and understanding public perceptions on a large scale.

---

## 1. PENDAHULUAN

Program Makan Begizi Gratis (MBG)

merupakan salah satu inisiatif strategis pemerintah yang bertujuan untuk meningkatkan kesejahteraan pelajar, khususnya dalam aspek

pemenuhan gizi dan peningkatan konsentrasi belajar. Program ini tidak hanya menjadi bagian dari intervensi di sektor pendidikan, tetapi juga berdampak langsung pada sektor Kesehatan dan perekonomian lokal. Implementasi MBG terbukti efektif dalam meningkatkan konsentrasi belajar siswa, menurunkan angka *stunting*, serta memberikan kontribusi terhadap penguatan Usaha Mikro, Kecil, dan Menengah (UMKM) yang menjadi mitra penyedia bahan pangan lokal. Bahkan, program ini mendapatkan perhatian dan dukungan dari berbagai organisasi internasional sebagai wujud komitmen terhadap pembangunan berkelanjutan di bidang pendidikan dan Kesehatan Masyarakat. Salah satu contoh keberhasilan serupa dapat dilihat dalam program-program yang dilakukan di negara-negara berkembang lainnya, yang berhasil memperlihatkan hubungan antara pemenuhan gizi yang baik dengan peningkatan hasil pendidikan dan pengurangan angka kemiskinan [1].

Namun demikian, implementasi suatu program berskala nasional seperti MBG tentu tidak terlepas dari berbagai dinamika dan beragam tanggapan masyarakat. Media sosial, khususnya *platform X* (sebelumnya dikenal sebagai Twitter), telah menjadi salah satu kanal utama bagi masyarakat untuk menyampaikan opini, kritik, serta dukungan terhadap kebijakan-kebijakan pemerintah. Analisis sentimen melalui media sosial menjadi sarana yang sangat efektif untuk memahami persepsi publik secara menyeluruh terhadap kebijakan tersebut, serta memberikan *feedback* yang sangat berguna bagi pengambil kebijakan untuk mengevaluasi keberhasilan atau kekurangan program yang ada. *Platform-platform* media social memiliki sifat dinamis yang memudahkan pemantauan opini publik secara *real-time*. Oleh karena itu, penting untuk memanfaatkan teknologi dalam mengolah data yang besar dan kompleks dari sumber-sumber tersebut untuk menghasilkan analisis yang lebih mendalam dan akurat.[2]

Sejalan dengan perkembangan teknologi kecerdasan buatan, terutama dalam ranah *deep learning*, berbagai metode telah diterapkan untuk analisis sentimen berbasis teks. Salah

satu pendekatan yang populer dan terbukti efektif adalah pemanfaatan *Recurrent Neural Network* (RNN) beserta variannya *Gated Recurrent Unit* (GRU). Model ini mampu menangkap dependensi urutan dalam teks dan telah digunakan secara luas dalam berbagai domain.

Pada penelitian sebelumnya oleh [3] menunjukkan bahwa penerapan *model Gated recurrent Unit* (GRU) yang dipadukan dengan *word embedding* GloVe menghasilkan akurasi yang cukup tinggi yaitu 75% dalam mengklasifikasikan emosi terhadap konflik Israel-Palestina di media sosial. Hasil tersebut menunjukkan efektivitas arsitektur RNN dalam memahami konteks dan nuansa emosi dalam teks, sehingga berguna dalam merumuskan strategi komunikasi dan kebijakan. Penelitian sebelumnya juga yang menggunakan model *Gated Recurrent Unit* (GRU) [4] menunjukkan hasil yang cukup baik yaitu MSE sebesar 0,0009, RMSE sebesar 0.17325, dan MAE sebesar 0.0207 dalam memprediksi harga indeks penutupan saham LQ45. Capaian ini membuktikan bahwa model GRU memiliki kemampuan yang akurat dalam menangkap pola pergerakan harga saham, sehingga dapat digunakan sebagai pendekatan yang efektif dalam analisis prediktif pasar keuangan. Selanjutnya, Penelitian [5] mengenai analisis sentimen yang menggabungkan *metode Gated Recurrent Unit* (GRU) dengan *FastText word embedding* menunjukkan hasil yang sangat memuaskan. Model yang dikembangkan berhasil mencapai tingkat akurasi sebesar 91% dalam mengklasifikasikan sentimen terhadap ulasan hotel. Capaian ini mengindikasikan bahwa kombinasi GRU dengan *FastText* mampu menangkap konteks dan makna kata secara lebih efektif, sehingga meningkatkan akurasi dalam memahami opini pengguna terhadap layanan hotel.

Beberapa kajian telah dilakukan untuk mengevaluasi sentimen terkait program pemerintah Makan Bergizi Gratis, namun hingga kini belum banyak yang memanfaatkan *Gated Recurrent Unit* (GRU) dalam membangun model sentimen. Salah satu studi yang telah dilakukan adalah oleh [6], yang mengimplementasikan model *Support Vector*

*Machine* (SVM) dalam analisis sentimen program tersebut. Hasil kajian menunjukkan bahwa SVM dapat mencapai tingkat akurasi yang tinggi, yakni 94%, yang membuktikan keefektifannya dalam menangani dan mengkategorikan data sentimen secara optimal. Penelitian berikutnya yang dilakukan oleh [7] menerapkan algoritma Naïve Bayes dalam analisis sentimen MBG. Model yang dikembangkan berhasil mencapai tingkat akurasi yang cukup tinggi, yaitu 72.2%, menunjukkan bahwa pendekatan ini memiliki kemampuan yang baik dalam mengklasifikasikan sentimen berdasarkan pola data yang tersedia. Hasil ini mengonfirmasi efektivitas Naïve Bayes sebagai metode yang dapat mengelola dan mengolah data sentimen secara probabilistik, meskipun masih terdapat peluang untuk meningkatkan akurasi dengan pendekatan yang lebih kompleks atau kombinasi metode lainnya. Penelitian berikutnya yang dilakukan oleh [8] mengadopsi metode *Bidirectional Long Short-Term Memory* (BiLSTM) dalam analisis sentimen MBG. Model yang dikembangkan menunjukkan performa yang sangat baik dengan tingkat akurasi mencapai 88,8%, menandakan bahwa pendekatan BiLSTM mampu memahami konteks dan pola bahasa secara lebih mendalam dibandingkan metode konvensional. Terakhir, penelitian yang dilakukan oleh [9] menerapkan algoritma *Natural Language Processing* (NLP) untuk menganalisis sentimen terhadap program Makan Bergizi Gratis (MBG). Namun, hasil yang diperoleh menunjukkan bahwa model memiliki tingkat akurasi yang cukup rendah, yaitu 20%, yang mengindikasikan bahwa pendekatan ini belum mampu memprediksi sentimen secara optimal. Temuan yang diperoleh memberikan kontribusi berarti bagi pengelola program dalam menafsirkan pandangan publik secara lebih luas dan mengupayakan strategi peningkatan secara konsisten.

Dengan demikian, studi ini dimaksudkan untuk menilai pandangan publik tentang inisiatif Makan Bergizi Gratis (MBG) melalui pemanfaatan teknologi *deep learning*, khususnya model *Gated Recurrent Unit*. Pandangan tersebut dikategorikan menjadi dua

jenis, yakni mendukung dan menentang, dengan mengacu pada ulasan masyarakat yang dikumpulkan dari *platform* media sosial X. Di samping itu, penelitian ini juga akan mengevaluasi kinerja berbagai model dengan menggunakan ukuran penilaian seperti tingkat keakuratan dan skor F1, serta bertujuan menyajikan pemahaman yang lebih mendalam tentang bagaimana masyarakat memandang program MBG, yang nantinya dapat dijadikan referensi penting dalam proses pembuatan kebijakan.

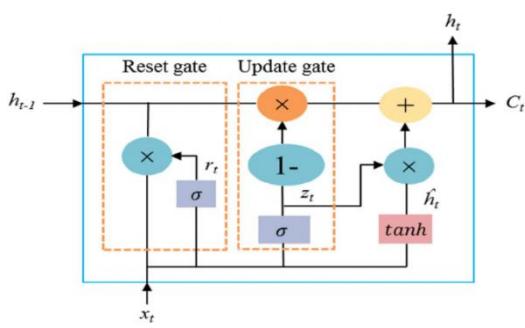
Kebaruan dalam penelitian ini terletak pada penerapan metode *Gated Recurrent Unit* (GRU), yang belum banyak digunakan sebelumnya dalam analisis sentimen dengan pendekatan tersebut. Selain itu, penelitian ini mengintegrasikan GRU dengan *FastText* untuk meningkatkan pemahaman konteks teks, sekaligus berfokus pada data *real-time* yang diambil langsung dari opini publik di media sosial X. Pendekatan ini diharapkan dapat memberikan kontribusi bagi pengembangan literatur ilmiah di bidang evaluasi program sosial berbasis data digital, serta memperlihatkan bagaimana metode *Natural Language Processing* (NLP) dan *deep learning* dapat dimanfaatkan secara efektif dalam mendukung perumusan dan evaluasi kebijakan publik berdasarkan data yang lebih akurat dan terkini.

## 2. TINJAUAN PUSTAKA

### 2.1 *Gated Recurrent Unit* (GRU)

*Gated recurrent Unit* (GRU) adalah salah satu model dalam bidang deep learning yang dikembangkan sebagai varian dari *Long Short-Term Memory* (LSTM). Model ini diperkenalkan oleh Cho pada tahun 2014. GRU dirancang dengan struktur komputasi yang lebih sederhana dibandingkan LSTM, sehingga mampu memberikan hasil prediksi yang akurat dan tetap efisien dalam penerapannya [10]. *Gated Recurrent Unit* (GRU) beroperasi dengan memproses data secara berurutan, di mana setiap elemen diproses satu per satu. Pada setiap langkah waktu, GRU memperbarui keadaan tersembunyi (*hidden state*) berdasarkan masukan yang diterima dan keadaan tersembunyi sebelumnya. Proses ini

melibatkan perhitungan vektor aktivasi kandidat yang menyatukan informasi dari masukan saat ini dan keadaan tersembunyi terdahulu. Vektor tersebut kemudian digunakan untuk memperbarui keadaan tersembunyi pada langkah selanjutnya. Secara struktural, arsitektur GRU terdiri atas lapisan masukan, lapisan tersembunyi, gerbang reset, gerbang pembaruan, vektor aktivasi kandidat, serta lapisan keluaran[11]. Arsitektur GRU ditunjukkan pada Gambar 1.



Gambar 1. Arsitektur GRU

Persamaan GRU:

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (1)$$

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (2)$$

$$h_t = (1 - z_t) \times h_{t-1} + z_t \times \hat{h}_t \quad (3)$$

## 2.2 Program MBG

Program Makanan Bergizi Gratis (MBG) merupakan bantuan pangan yang ditujukan untuk menyediakan makanan sehat dan bernutrisi yang kemudian disalurkan pada anak sekolah, keluarga dengan keterbatasan ekonomi, dan komunitas rentan. Program ini disusun untuk memastikan terpenuhinya kebutuhan gizi, terutama pada anak-anak, sehingga dapat mendukung pertumbuhan, menjaga kondisi kesehatan, dan menunjang aktivitas sehari-hari. Paket makanan yang diberikan dalam MBG dirancang sesuai standar gizi seimbang, meliputi sumber karbohidrat, protein, vitamin, dan mineral. Pelaksanaan program ini diarahkan pada peningkatan status gizi, perbaikan kualitas kesehatan, penguatan kemampuan konsentrasi belajar, serta peningkatan kesejahteraan Masyarakat. MBG dibentuk sebagai bentuk komitmen pemerintah terhadap keberlanjutan penyediaan gizi seimbang [12].

## 2.3 Evaluasi Model

Evaluasi model adalah proses untuk memastikan kesesuaian model yang dikembangkan dengan tujuan penelitian, sekaligus menilai tingkat efektivitas pembelajaran mesin dalam melakukan klasifikasi. Salah satu teknik standar yang sering diterapkan dalam proses ini adalah *confusion matrix*. *confusion matrix* berfungsi untuk menganalisis tingkat akurasi model dalam mendekripsi dan mengklasifikasikan objek dengan cara membandingkan hasil prediksi yang dihasilkan model dengan data aktual. Contoh ilustrasi *confusion matrix* disajikan pada Tabel 2.1.

Tabel 1 *Confusion matriks*

<i>Confusion matrix</i>		<i>Predicted Class</i>	
		Positif	Negatif
<i>True Class</i>	Positif	TP ( <i>True Positif</i> )	FP ( <i>False Positif</i> )
	Negatif	FN ( <i>False Negatif</i> )	TN ( <i>True Negatif</i> )

Keterangan :

- TP (*True Positif*) : Merupakan prediksi yang diklasifikasikan sebagai positif dan sesuai dengan label aktual positif.
- TN (*True Negatif*) : Menunjukkan jumlah prediksi yang diklasifikasikan sebagai negative dan sesuai dengan label aktual negatif.
- FP (*False Positif*) : Merupakan jumlah prediksi yang diklasifikasikan sebagai positif, padahal label aktualnya negatif.
- FN (*False Negatif*) : menunjukkan jumlah prediksi yang diklasifikasikan sebagai negatif, padahal label aktualnya positif.

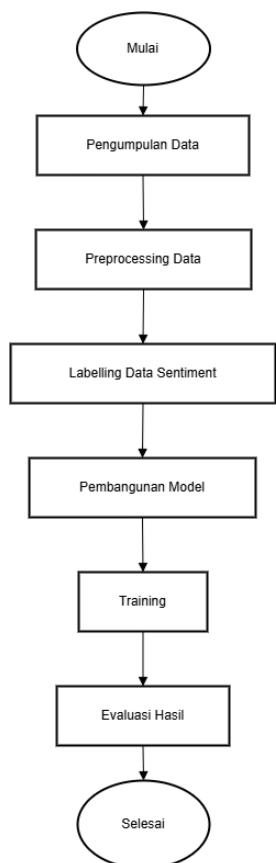
## 2.4 Analisis Sentimen

Analisis sentimen adalah teknik yang diterapkan untuk menemukan ungkapan emosi yang terkandung dalam tulisan, yang selanjutnya dikelompokkan berdasarkan jenis sentimen yang bersifat mendukung atau menentang. Proses ini tidak hanya berfokus pada pengenalan kata atau frasa yang bersifat emosional, tetapi juga mencakup analisis opini,

evaluasi, dan emosi yang terkandung dalam teks. Analisis dilakukan terhadap berbagai entitas, seperti produk, layanan, maupun isu sosial, dengan tujuan memperoleh gambaran yang lebih komprehensif mengenai persepsi publik [13].

### 3. METODE PENELITIAN

Penelitian ini dilaksanakan melalui serangkaian tahapan terstruktur, mulai dari pengumpulan data, *preprocessing*, labeling data sentimen, pembangunan model, *training*, dan evaluasi model, yang keseluruhan alur kerjanya dipaparkan pada Gambar 2.



Gambar 2. Metode Penelitian

#### 3.1 Pengumpulan Data

Studi ini menggunakan kumpulan data yang terdiri dari 1.524 komentar pengguna, yang diperoleh langsung dari *platform X*. Pengumpulan informasi tersebut dilakukan menggunakan teknik *web scraping*, yakni metode otomatis untuk mengekstrak data dalam volume besar dari berbagai situs *web*. Seluruh

kumpulan data yang berhasil diperoleh disimpan dalam format file CSV.

#### 3.2 Preprocessing

Selanjutnya, dilakukan pra-pemrosesan terhadap data *tweet* yang telah dikumpulkan melalui metode *scraping*. Tahapan ini dilakukan dengan maksud mengolah data mentah yang awalnya tersaji tanpa pola yang jelas agar dapat disusun ulang ke dalam bentuk yang sistematis dan mudah dipahami, sehingga mempermudah tahapan pemrosesan data berikutnya. Dalam penelitian ini[14], pra-pemrosesan teks dilakukan melalui tiga tahapan utama yaitu:

##### a. Cleansing

*Cleansing* adalah tahapan dalam pra-pemrosesan data yang berfokus pada penghilangan karakter – karakter non-alfanumerik untuk meminimalisir *noise* dalam data teks. Karakter - karakter yang umumnya dihapus pada tahap ini meliputi berbagai tanda baca, simbol - simbol khusus seperti penanda pengguna ('@'), tagar ('#'), ekspresi emosi, serta tautan dari berbagai situs *web*[15].

##### b. Stopwords

*Stopwords* adalah salah satu tahapan dalam pra-pemrosesan teks yang difokuskan pada penghapusan kata-kata yang sering muncul tetapi dinilai memiliki nilai informasi yang rendah untuk keperluan analisis. Istilah-istilah umum seperti kata penghubung misalnya “dan” atau “atau”, kata depan seperti “di”, “ke”, dan “dari”, serta kata ganti seperti “saya” dan “kamu” umumnya tidak disertakan karena keberadaannya dianggap tidak berpengaruh secara berarti terhadap penafsiran makna maupun analisis sentimen dalam suatu teks.

##### c. Lemmatization

*Lemmatization* merupakan tahapan penting dalam pra-pemrosesan teks yang bertujuan untuk mereduksi berbagai bentuk infleksi suatu kata ke bentuk dasarnya. Proses ini melibatkan analisis morfologis kata untuk mengidentifikasi akar katanya dan bentuk dasarnya sesuai dengan konteksnya dalam kalimat. Contoh, kata - kata seperti “bremain”, “bermain-main”, dan

“dimainkan” akan direduksi menjadi bentuk dasarnya, yaitu “main”.

#### d. Tokenizing

*Tokenizing* merupakan tahapan dalam bidang pemrosesan bahasa alami (*natural language processing*) yang berfungsi untuk membagi suatu teks utuh menjadi bagian-bagian yang lebih kecil, yang dikenal sebagai token, baik dalam bentuk kata, gabungan kata, maupun karakter. Dengan melakukan pemecahan ini, teks menjadi lebih mudah dikelola dan dianalisis pada tahap pemrosesan selanjutnya. seperti klasifikasi atau ekstraksi informasi. Misalnya, kalimat “MBG adalah program yang berkualitas” akan diubah menjadi deretan token [“MBG”, “adalah”, “program”, “yang”, “Berkualitas”, “.”]. Dengan memisahkan kata-kata secara sistematis, *tokenizing* membantu sistem memahami struktur dan makna dari suatu kalimat atau dokumen.

### 3.3 Labeling Data Sentimen

Dalam studi ini, penentuan label data dilakukan melalui metode berbasis leksikon yang dimanfaatkan untuk mengidentifikasi sentimen pada komentar – komentar yang membahas program Makan Bergizi Gratis yang berasal dari *platform* media sosial X. Penggunaan leksikon membantu dalam menentukan polaritas sentimen (positif, negatif) secara otomatis dari setiap komentar yang dikumpulkan. Leksikon yang digunakan berisi daftar kata-kata dengan nilai polaritas tertentu, sehingga memungkinkan ekstraksi skor sentimen dari teks[16].

### 3.4 Pembangunan Model

Penelitian ini menerapkan arsitektur *gated Recurrent Unit* (GRU) sebagai pendekatan untuk mengkaji sentimen yang terkandung dalam komentar para pengguna pada *platform* media sosial X yang membahas program Makan Bergizi Gratis (MBG).

### 3.5 Training

Setelah arsitektur model klasifikasi sentimen GRU dibangun, langkah selanjutnya yang dilakukan adalah melatih model - model tersebut menggunakan data pelatihan (*training data*) yang telah diproses dan dilabeli sebelumnya. Proses pelatihan ini melibatkan

pemberian *input* data pelatihan ke dalam model dan menyesuaikan bobot internal model secara iteratif berdasarkan fungsi kerugian (*loss function*) dan algoritma optimasi yang dipilih.

## 3.6 Evaluasi

Setelah tahap pelatihan model klasifikasi rampung, langkah berikutnya melibatkan penilaian performa dari tiap model. Penilaian tersebut dimaksudkan untuk menentukan tingkat keakuratan model dalam mengidentifikasi sentimen pada data yang belum pernah ditemui sebelumnya. Penilaian ini dilakukan dengan memanfaatkan data uji yang sudah melalui proses pra-pemrosesan.

## 4. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan data *tweet* dari media sosial X yang diperoleh melalui teknik *crawling*, dengan target pengumpulan sebanyak 10.000 data. Cuplikan hasil *crawling* disajikan

ID	Tweet	Polaritas
20191111_000001	MBG	Positif
20191111_000002	MBG	Positif
20191111_000003	MBG	Positif
20191111_000004	MBG	Positif
20191111_000005	MBG	Positif
20191111_000006	MBG	Positif
20191111_000007	MBG	Positif
20191111_000008	MBG	Positif
20191111_000009	MBG	Positif
20191111_000010	MBG	Positif
20191111_000011	MBG	Positif
20191111_000012	MBG	Positif
20191111_000013	MBG	Positif
20191111_000014	MBG	Positif
20191111_000015	MBG	Positif
20191111_000016	MBG	Positif
20191111_000017	MBG	Positif
20191111_000018	MBG	Positif
20191111_000019	MBG	Positif
20191111_000020	MBG	Positif
20191111_000021	MBG	Positif
20191111_000022	MBG	Positif
20191111_000023	MBG	Positif
20191111_000024	MBG	Positif
20191111_000025	MBG	Positif
20191111_000026	MBG	Positif
20191111_000027	MBG	Positif
20191111_000028	MBG	Positif
20191111_000029	MBG	Positif
20191111_000030	MBG	Positif
20191111_000031	MBG	Positif
20191111_000032	MBG	Positif
20191111_000033	MBG	Positif
20191111_000034	MBG	Positif
20191111_000035	MBG	Positif
20191111_000036	MBG	Positif
20191111_000037	MBG	Positif
20191111_000038	MBG	Positif
20191111_000039	MBG	Positif
20191111_000040	MBG	Positif
20191111_000041	MBG	Positif
20191111_000042	MBG	Positif
20191111_000043	MBG	Positif
20191111_000044	MBG	Positif
20191111_000045	MBG	Positif
20191111_000046	MBG	Positif
20191111_000047	MBG	Positif
20191111_000048	MBG	Positif
20191111_000049	MBG	Positif
20191111_000050	MBG	Positif
20191111_000051	MBG	Positif
20191111_000052	MBG	Positif
20191111_000053	MBG	Positif
20191111_000054	MBG	Positif
20191111_000055	MBG	Positif
20191111_000056	MBG	Positif
20191111_000057	MBG	Positif
20191111_000058	MBG	Positif
20191111_000059	MBG	Positif
20191111_000060	MBG	Positif
20191111_000061	MBG	Positif
20191111_000062	MBG	Positif
20191111_000063	MBG	Positif
20191111_000064	MBG	Positif
20191111_000065	MBG	Positif
20191111_000066	MBG	Positif
20191111_000067	MBG	Positif
20191111_000068	MBG	Positif
20191111_000069	MBG	Positif
20191111_000070	MBG	Positif
20191111_000071	MBG	Positif
20191111_000072	MBG	Positif
20191111_000073	MBG	Positif
20191111_000074	MBG	Positif
20191111_000075	MBG	Positif
20191111_000076	MBG	Positif
20191111_000077	MBG	Positif
20191111_000078	MBG	Positif
20191111_000079	MBG	Positif
20191111_000080	MBG	Positif
20191111_000081	MBG	Positif
20191111_000082	MBG	Positif
20191111_000083	MBG	Positif
20191111_000084	MBG	Positif
20191111_000085	MBG	Positif
20191111_000086	MBG	Positif
20191111_000087	MBG	Positif
20191111_000088	MBG	Positif
20191111_000089	MBG	Positif
20191111_000090	MBG	Positif
20191111_000091	MBG	Positif
20191111_000092	MBG	Positif
20191111_000093	MBG	Positif
20191111_000094	MBG	Positif
20191111_000095	MBG	Positif
20191111_000096	MBG	Positif
20191111_000097	MBG	Positif
20191111_000098	MBG	Positif
20191111_000099	MBG	Positif
20191111_000100	MBG	Positif
20191111_000101	MBG	Positif
20191111_000102	MBG	Positif
20191111_000103	MBG	Positif
20191111_000104	MBG	Positif
20191111_000105	MBG	Positif
20191111_000106	MBG	Positif
20191111_000107	MBG	Positif
20191111_000108	MBG	Positif
20191111_000109	MBG	Positif
20191111_000110	MBG	Positif
20191111_000111	MBG	Positif
20191111_000112	MBG	Positif
20191111_000113	MBG	Positif
20191111_000114	MBG	Positif
20191111_000115	MBG	Positif
20191111_000116	MBG	Positif
20191111_000117	MBG	Positif
20191111_000118	MBG	Positif
20191111_000119	MBG	Positif
20191111_000120	MBG	Positif
20191111_000121	MBG	Positif
20191111_000122	MBG	Positif
20191111_000123	MBG	Positif
20191111_000124	MBG	Positif
20191111_000125	MBG	Positif
20191111_000126	MBG	Positif
20191111_000127	MBG	Positif
20191111_000128	MBG	Positif
20191111_000129	MBG	Positif
20191111_000130	MBG	Positif
20191111_000131	MBG	Positif
20191111_000132	MBG	Positif
20191111_000133	MBG	Positif
20191111_000134	MBG	Positif
20191111_000135	MBG	Positif
20191111_000136	MBG	Positif
20191111_000137	MBG	Positif
20191111_000138	MBG	Positif
20191111_000139	MBG	Positif
20191111_000140	MBG	Positif
20191111_000141	MBG	Positif
20191111_000142	MBG	Positif
20191111_000143	MBG	Positif
20191111_000144	MBG	Positif
20191111_000145	MBG	Positif
20191111_000146	MBG	Positif
20191111_000147	MBG	Positif
20191111_000148	MBG	Positif
20191111_000149	MBG	Positif
20191111_000150	MBG	Positif
20191111_000151	MBG	Positif
20191111_000152	MBG	Positif
20191111_000153	MBG	Positif
20191111_000154	MBG	Positif
20191111_000155	MBG	Positif
20191111_000156	MBG	Positif
20191111_000157	MBG	Positif
20191111_000158	MBG	Positif
20191111_000159	MBG	Positif
20191111_000160	MBG	Positif
20191111_000161	MBG	Positif
20191111_000162	MBG	Positif
20191111_000163	MBG	Positif
20191111_000164	MBG	Positif
20191111_000165	MBG	Positif
20191111_000166	MBG	Positif
20191111_000167	MBG	Positif
20191111_000168	MBG	Positif
20191111_000169	MBG	Positif
20191111_000170	MBG	Positif
20191111_000171	MBG	Positif
20191111_000172	MBG	Positif
20191111_000173	MBG	Positif
20191111_000174	MBG	Positif
20191111_000175	MBG	Positif
20191111_000176	MBG	Positif
20191111_000177	MBG	Positif
20191111_000178	MBG	Positif
20191111_000179	MBG	Positif
20191111_000180	MBG	Positif
20191111_000181	MBG	Positif
20191111_000182	MBG	Positif
20191111_000183	MBG	Positif
20191111_000184	MBG	Positif
20191111_000185	MBG	Positif
20191111_000186	MBG	Positif
20191111_000187	MBG	Positif
20191111_000188	MBG	Positif
20191111_000189	MBG	Positif
20191111_000190	MBG	Positif
20191111_000191	MBG	Positif
20191111_000192	MBG	Positif
20191111_000193	MBG	Positif
20191111_000194	MBG	Positif
20191111_000195	MBG	Positif
20191111_000196	MBG	Positif
20191111_000197	MBG	Positif
20191111_000198	MBG	Positif
20191111_000199	MBG	Positif
20191111_000200	MBG	Positif
20191111_000201	MBG	Positif
20191111_000202	MBG	Positif
20191111_000203	MBG	Positif
20191111_000204	MBG	Positif
20191111_000205	MBG	Positif
20191111_000206	MBG	Positif
20191111_000207	MBG	Positif
20191111_000208	MBG	Positif
20191111_000209	MBG	Positif
20191111_000210	MBG	Positif
20191111_000211	MBG	Positif
20191111_000212	MBG	Positif
20191111_000213	MBG	Positif
20191111_000214	MBG	Positif
20191111_000215	MBG	Positif
20191111_000216	MBG	Positif
20191111_000217	MBG	Positif
20191111_000218	MBG	Positif
20191111_000219	MBG	Positif
20191111_000220	MBG	Positif
20191111_000221	MBG	Positif
20191111_000222	MBG	Positif
20191111_000223	MBG	Positif
20191111_000224	MBG	Positif
20191111_000225	MBG	Positif
20191111_000226	MBG	Positif
20191111_000227	MBG	Positif
20191111_000228	MBG	Positif
20191111_000229	MBG	Positif
20191111_000230	MBG	Positif
20191111_000231	MBG	Positif
20191111_000232	MBG	Positif
20191111_000233	MBG	Positif
20191111_000234	MBG	Positif
20191111_000235	MBG	Positif
20191111_000236	MBG	Positif
20191111_000237	MBG	Positif
20191111_000238	MBG	Positif
20191111_000239	MBG	Positif
20191111_000240	MBG	Positif
20191111_000241	MBG	Positif
20191111_000242	MBG	Positif
20191111_000243	MBG	Positif
20191111_000244	MBG	Positif
20191111_000245	MBG	Positif
2019111		

mencakup penghapusan *username*, *hashtag*, *retweet*, serta URL, yang sering kali muncul tetapi tidak memberikan kontribusi terhadap pemahaman makna teks. Proses cleaning dapat dilihat pada Gambar 4.

```
def clean_text(text):
    text = text.lower() # Casefolding
    text = re.sub(r'\n', ' ', text) # Remove newline
    text = re.sub(r'\\', ' ', text) # Hapus backslash
    text = re.sub(r'@\w+', ' ', text) # Hapus mention (@user)
    text = re.sub(r'https://\S+', ' ', text) # Hapus URL
    text = re.sub(r'[!@#\$%^&_+=~`|}{;:,.<>?]{A-Za-z0-9]+', ' ', text) # Hapus hashtag
    text = re.sub(r'[\x00-\x2F]+', ' ', text) # Hapus non-ASCII (emoji)
    text = re.sub(r'[0-9]+', ' ', text) # Hapus angka
    text = text.translate(str.maketrans(' ', ' ', string.punctuation)) # Hapus tanda baca
    text = text.strip() # Hapus spasi kosong di awal/akhir
    text = re.sub(r'\s+', ' ', text) # Ganti multi-spasi dengan satu spasi
    text = re.sub(r'\b\w{1}\b', ' ', text) # Hapus karakter tunggal
    return text
df['clean_text'] = df['full_text'].apply(clean_text)
```

Gambar 4. Fungsi *cleaning*

b. *Stopword* : Pada tahap ini, elemen linguistik seperti konjungsi (misalnya "dan", "atau"), preposisi (seperti "di", "ke", "dari"), serta kata ganti (seperti "saya", "kamu") dihapus dari teks. Penghapusan *stopwords* bertujuan untuk meningkatkan akurasi model dengan memastikan bahwa hanya kata-kata bermakna yang digunakan dalam analisis, sehingga teks yang diolah menjadi lebih fokus dan informatif. Proses stopword disajikan pada Gambar 5.

```
stop_words = set(stopwords.words('indonesian'))
additional_stopwords = ("apakah", "makan", "bergizi", "gratis")
stop_words.update(additional_stopwords)

def remove_stopwords(text):
    return ' '.join([word for word in text.split() if word not in stop_words])
df['clean_text'] = df['clean_text'].apply(remove_stopwords)
```

Gambar 6. Fungsi *stopword*

c. *Lemmatization* : pada tahap ini, proses lemmatization mengubah setiap kata dalam teks ke bentuk dasarnya. Misalnya, kata-kata seperti "bermain", "bermain-main", dan "dimainkan" akan direduksi menjadi bentuk dasar "main". Proses *lemmatization* disajikan pada Gambar 6.

```
# Lemmatizing
factory = StemmerFactory()
stemmer = factory.create_stemmer()

def lemmatize(text):
    return ' '.join([stemmer.stem(word) for word in text.split()])
df['clean_text'] = df['clean_text'].apply(lemmatize)
```

Gambar 7. Fungsi *lemmatization*

Setelah *preprocessing* selesai, langkah berikutnya adalah pelabelan data berdasarkan sentimen. Data akan dibagi menjadi dua kelas utama, yaitu "positif" dan "negatif", dengan menggunakan pendekatan berbasis *lexicon*.

Metode ini menerapkan daftar kata tertentu sebagai acuan dalam menentukan polaritas sentimen, di mana kata-kata yang memiliki konotasi positif dikategorikan sebagai sentimen positif, sedangkan kata-kata yang mengandung makna negatif dimasukkan ke dalam kategori

```
def get_sentiment(text):
    words = text.split()
    pos_count = sum(1 for word in words if word in positive_words)
    neg_count = sum(1 for word in words if word in negative_words)
    if pos_count > neg_count:
        return 1 # Positif
    elif neg_count > pos_count:
        return 0 # Negatif
    else:
        return -1 # Netral
```

negatif. Proses ini bertujuan untuk menyusun data secara sistematis agar dapat digunakan secara optimal dalam analisis sentimen, sehingga memungkinkan model untuk mengidentifikasi pola opini publik dengan lebih akurat dan terstruktur.

Gambar 5. Tahap pelabelan

Setelah proses pelabelan dilakukan, langkah selanjutnya adalah menerapkan tahap tokenisasi dan *padding*. Tokenisasi berfungsi untuk memecah teks menjadi unit-unit yang lebih kecil seperti kata atau token, sementara *padding* digunakan untuk menyeragamkan panjang input agar sesuai dengan kebutuhan model. Dengan urutan ini, data yang telah dilabeli dapat diproses lebih lanjut dalam bentuk yang terstruktur dan siap untuk dimasukkan ke dalam model pembelajaran mesin atau *deep learning*. Pendekatan ini memastikan setiap entri teks memiliki representasi yang konsisten, baik dari sisi panjang maupun format, sehingga mendukung proses pelatihan model secara efisien. Proses tokenisasi dan *padding* disajikan pada Gambar 8.

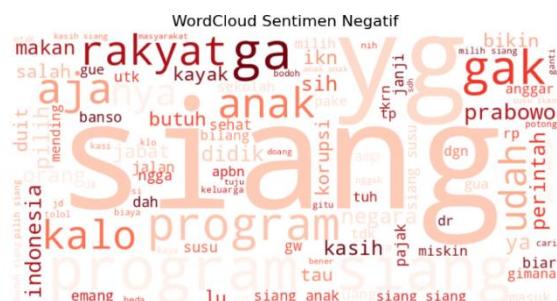
```
MAX_NUM_WORDS = 5000
MAX_SEQUENCE_LENGTH = 100

tokenizer = Tokenizer(num_words=MAX_NUM_WORDS, oov_token=<OOV>)
tokenizer.fit_on_texts(df['clean_text'])
```

Gambar 8. Tokenisasi dan *padding*



Gambar 9. *Wordcloud* sentimen positif



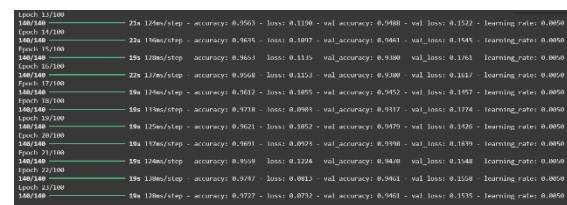
Gambar 10. Wordcloud sentimen negatif

Diagram *wordcloud* memvisualisasikan kata-kata kunci dari sentimen positif dan negatif dengan ukuran huruf yang mencerminkan frekuensi kemunculan masing-masing kata. Pada Gambar 8. tampak bahwa kata-kata seperti dukung, bijak, dan janji mendominasi *wordcloud* sentimen positif, menandakan bahwa kata-kata tersebut paling sering digunakan dalam ulasan bernada positif. Sementara itu, Gambar 9. memperlihatkan *wordcloud* sentimen negatif, di mana kata-kata seperti gak, korupsi, dan mending muncul sebagai yang paling menonjol, mencerminkan kecenderungan ekspresi negatif dari opini masyarakat. Visualisasi ini membantu memberikan gambaran umum terhadap persepsi publik yang tertangkap dalam teks.

Dalam proses pelatihan model, data dibagi dengan perbandingan 80% untuk pelatihan dan 20% untuk pengujian. Evaluasi model dilakukan dengan memanfaatkan *callback*, salah satunya yaitu *EarlyStopping* yang menghentikan pelatihan secara otomatis jika tidak terjadi peningkatan akurasi validasi selama 10 *epoch* berturut-turut. Selain itu, diterapkan pula *ReduceLROnPlateau* untuk menurunkan laju pembelajaran secara otomatis hingga 50% apabila *val\_loss* tidak menunjukkan perbaikan dalam 5 *epoch*. Model dilatih menggunakan fungsi *model.fit()* dengan

maksimal 100 *epoch*, ukuran *batch* 32, dan validasi dilakukan pada setiap siklus pelatihan.

Hasil pelatihan menunjukkan bahwa performa terbaik dicapai pada *epoch* ke-23, dengan akurasi sebesar 0.9727 dan *loss* sebesar 0.0732 pada data pelatihan, serta *val\_accuracy* sebesar 0.9461 dan *val\_loss* sebesar 0.1535 pada data validasi. Adapun *learning rate* pada saat itu tercatat sebesar 0.0050, sebagaimana ditampilkan pada Gambar 11.



Gambar 11. Pelatihan

Tahap berikut setelah pelatihan adalah melakukan pengujian kinerja model melalui metrik *precision*, *recall*, *f1-score*, dan *support*. Ringkasan hasil evaluasi model GRU dapat dilihat pada Tabel 2.

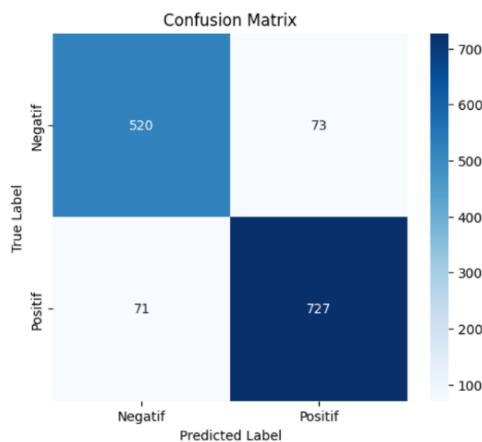
Tabel 2. Evaluasi model GRU

sentimen	precision	recall	F1-score	support
Negatif	0.88	0.88	0.88	593
Positif	0.91	0.91	0.91	798

Dari Tabel 2. Terlihat model GRU memiliki kinerja yang relatif seimbang dalam mengklasifikasikan kedua kategori sentimen. Untuk sentimen negatif, presisi yang diperoleh adalah 0.88, yang berarti bahwa 88% dari *tweet* yang diprediksi sebagai negatif oleh model memang benar-benar negatif. Nilai *recall* untuk sentimen negatif juga berada pada angka yang sama, yaitu 0.88, menunjukkan bahwa model berhasil mengidentifikasi 88% dari seluruh *tweet* negatif dalam data pengujian. Hal ini menghasilkan *f1-score* yang konsisten sebesar 0.88. Jumlah *tweet* yang termasuk dalam kelas negatif pada data pengujian adalah sebanyak 593.

Sementara itu, performa model GRU dalam mengklasifikasikan sentimen positif juga menunjukkan hasil yang baik. Presisi untuk kelas positif tercatat sebesar 0.91, artinya 91%

dari *tweet* yang diprediksi sebagai positif oleh model memang benar-benar positif. *Recall* untuk kelas ini juga tinggi, yaitu sebesar 0.91, yang berarti model mampu mengenali 91% dari seluruh *tweet* positif yang ada. Dengan demikian, *f1-score* untuk sentimen positif pun mencapai nilai 0.91. Jumlah *tweet* yang termasuk dalam kelas positif pada data pengujian adalah sebanyak 798, sedikit lebih banyak dibandingkan kelas negatif.



Gambar 12. Confusion matrix

Sementara itu, *confusion matrix* yang terlihat pada Gambar 12. menunjukkan bahwa angka *True Negative* mencapai 520, yang berarti ada 520 sampel dari kategori negatif yang berhasil diklasifikasikan secara tepat. *False Positive* tercatat sebanyak 73, yaitu jumlah sampel dari kategori negatif yang keliru dianggap sebagai positif. *False Negative* tercatat 71, yang merupakan jumlah sampel dari kategori positif yang salah dikategorikan sebagai negatif. Adapun *True Positive* berjumlah 727, yang menandakan bahwa 727 sampel dari kategori positif diklasifikasikan dengan benar.

Tahap berikutnya adalah melakukan evaluasi terhadap model yang telah dikembangkan, untuk menguji kemampuannya dalam memprediksi sentimen dari ulasan masyarakat. Proses ini bertujuan untuk memastikan bahwa model dapat mengklasifikasikan opini publik secara akurat,



sesuai dengan kategori sentimen yang telah ditetapkan. Hasil evaluasi disajikan pada Gambar 13 dan 14.

Gambar 13. Evaluasi sentimen positif



Gambar 14. Evaluasi sentimen negatif

## 5. KESIMPULAN

Berdasarkan hasil yang diperoleh, dapat dinyatakan bahwa model penelitian ini memiliki tingkat akurasi yang sangat baik, yakni 94%. Angka ini menunjukkan bahwa secara umum, model mampu melakukan klasifikasi sentimen dengan sangat baik dan akurat. Tingkat akurasi tersebut bahkan melebihi performa rata-rata model NLP secara umum, sehingga dapat disimpulkan bahwa model ini lebih efektif dalam memproses dan memprediksi data sentimen secara keseluruhan. Kinerja model juga terlihat sangat baik jika dianalisis berdasarkan masing-masing kelas. Untuk kelas negatif, model mampu mendekripsi data dengan *recall* sebesar 88% dan *precision* sebesar 88% pula. Sementara itu, untuk kelas positif, performa model juga sangat memuaskan dengan nilai *recall* dan *precision* yang sama-sama mencapai 91%. Artinya, model mampu mengidentifikasi data positif dengan akurat, dan prediksi positif yang dihasilkan sebagian besar benar adanya. Secara menyeluruh, penerapan model GRU terbukti efektif dengan capaian yang sesuai dengan target penelitian.

Sebagai tindak lanjut dari penelitian ini, perlu dipertimbangkan pengambilan data sentimen publik dari berbagai *platform* lain, seperti YouTube, Instagram, dan sejenisnya. Selain itu, penambahan jumlah dataset dapat dilakukan untuk meningkatkan kualitas model serta meminimalkan potensi bias. Penggunaan varian lain dari model RNN, seperti LSTM dan BiLSTM, juga relevan karena keduanya dirancang untuk mengolah data sekuensial berbasis teks dan berpotensi menghasilkan

performa yang lebih optimal dalam analisis sentimen.

## UCAPAN TERIMA KASIH

Penulis menyampaikan apresiasinya yang sebesar – besarnya kepada seluruh pihak yang telah memberikan dukungan dan kontribusi selama proses penelitian, sehingga penelitian ini dapat diselesaikan tepat waktu. Bantuan, arahan, serta kerja sama yang diberikan sangat berarti dalam mendukung kelancaran dan keberhasilan penyusunan penelitian ini.

## DAFTAR PUSTAKA

- [1] L. Tsabitah *et al.*, “ANALISIS SENTIMEN PROGRAM MAKAN SIANG GRATIS DALAM MENDUKUNG SDGS MENGGUNAKAN NAÏVE BAYES,” *Jurnal Mahasiswa Teknik Informatika*, vol. 9, no. 4, pp. 6288–6294, 2025, [Online]. Available: <https://www.kaggle.com>
- [2] P. Muhammad Jakak and M. Rahman, “Analisis Sentimen Publik Terhadap Program Makan Bergizi Gratis di Instagram Menggunakan Algoritma Support Vector Machine,” *SMARTICS Journal*, vol. 11, no. 1, pp. 14–20, 2025, doi: 10.21067/smartics.v11i1.11852.
- [3] E. I. Saputra, T. Sy. E. Fatdha, Agustin, Junadhi, and M. Khairul Anam, “Klasifikasi Emosi Terhadap Konflik Israel-Palestina Menggunakan Algoritma Gated Recurrent Unit,” *The Indonesian Journal of Computer Science*, vol. 13, no. 4, pp. 6230–6242, Jul. 2024, doi: 10.33022/ijcs.v13i4.4106.
- [4] V. R. Danestriara, E. Setiana, I. Akbar, and T. Hidayah, “Algoritma Gated Recurrent Unit untuk Prediksi Harga Indeks Penutupan Saham LQ45,” *Jurnal Accounting Information System (AIMS)*, vol. 7, no. 1, pp. 1–8, 2024, doi: 10.32627.
- [5] F. Lubis and D. Novianty Sitompul, “Aspect-Based Sentiment Analysis on Hotel Reviews Using Gated Recurrent Unit,” *INCODING: Journal of Informatics and Computer Science Engineering*, vol. 5, no. 1, pp. 75–94, 2025, doi: 10.34007/incoding.v5i1.710.
- [6] Z. Purwanti, P. Studi Sistem Informasi, S. Tinggi Ilmu Komputer Cipta Karya Informatika, K. Jakarta Timur, and D. Khusus Ibukota Jakarta, “Pemodelan Text Mining untuk Analisis Sentimen Terhadap Program Makan Siang Gratis di Media Sosial X Menggunakan Algoritma Support Vector
- [7] Machine (SVM),” *Jurnal Indonesia : Manajemen Informatika dan Komunikasi (JIMIK)*, vol. 5, no. 3, pp. 3065–3079, 2024, [Online]. Available: <https://journal.stmiki.ac.id>
- [8] A. Sitanggang, Y. Umaidah, Y. Umaidah, R. I. Adam, and R. I. Adam, “ANALISIS SENTIMEN MASYARAKAT TERHADAP PROGRAM MAKAN SIANG GRATIS PADA MEDIA SOSIAL X MENGGUNAKAN ALGORITMA NAÏVE BAYES,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, pp. 2755–2762, Aug. 2024, doi: 10.23960/jitet.v12i3.4902.
- [9] D. T. Attaulah and D. Soyusiawaty, “Analisis Sentimen Program Makan Siang Gratis di Twitter/X menggunakan Metode BI-LSTM,” *Edumatic: Jurnal Pendidikan Informatika*, vol. 9, no. 1, pp. 294–303, Apr. 2025, doi: 10.29408/edumatic.v9i1.29725.
- [10] W. Anggriyani and M. Fakhriza, “Analisis Sentimen Program Makan Gratis Pada Media Sosial X Menggunakan Metode NLP,” *Journal of Computer System and Informatics (JoSYC)*, vol. 5, no. 4, pp. 1033–1042, Aug. 2024, doi: 10.47065/josyc.v5i4.5826.
- [11] A. Tholib, N. K. Agusmawati, and F. Khairiyah, “PREDIKSI HARGA EMAS MENGGUNAKAN METODE LSTM DAN GRU,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, pp. 620–627, Aug. 2023, doi: 10.23960/jitet.v11i3.3250.
- [12] K. Danil, “Pengenalan Jenis Kelamin dalam Lingkungan Multiaksen Menggunakan Metode Multi Layer Perceptron (MLP) dan Gated Recurrent Unit (GRU),” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 803–811, May 2024, doi: 10.57152/malcom.v4i3.1323.
- [13] R. Hidayat and D. J. Ratnatingsih, “Analisis Sentimen Program Makanan Bergizi Gratis Menggunakan Algoritma Random Forest dan Naive Bayes,” *Journal of Computing and Informatics Research*, vol. 5, no. 1, pp. 395–400, 2025, doi: 10.47065/comforch.v5i1.2355.
- [14] K. Kevin, M. Enjeli, and A. Wijaya, “Analisis Sentimen Penggunaan Aplikasi Kinemaster Menggunakan Metode Naive Bayes,” *Jurnal Ilmiah Computer Science*, vol. 2, no. 2, pp. 89–98, Jan. 2024, doi: 10.58602/jics.v2i2.24.
- [15] S. Khairunnisa, A. Adiwijaya, and S. Al Faraby, “Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19),” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol.

- 5, no. 2, p. 406, Apr. 2021, doi: 10.30865/mib.v5i2.2835.
- [15] Abd. A. Syam, G. Hardy M, A. Salim, D. F. Surianto, and M. Fajar B, "ANALISIS TEKNIK PREPROCESSING PADA SENTIMEN MASYARAKAT TERKAIT KONFLIK ISRAEL-PALESTINA MENGGUNAKAN SUPPORT VECTOR MACHINE," *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 3, pp. 1464–1472, Aug. 2024, doi: 10.29100/jipi.v9i3.5527.
- [16] Y. Qi and Z. Shabrina, "Sentiment analysis using Twitter data: a comparative application of lexicon- and machine-learning-based approach," *Soc Netw Anal Min*, vol. 13, no. 1, Dec. 2023, doi: 10.1007/s13278-023-01030-x.