

**KLASIFIKASI SENTIMEN TERHADAP PROGRAM MAKAN BERGIZI
GRATIS MENGGUNAKAN METODE *LOGISTIC REGRESSION***

SKRIPSI

Oleh :
MOH. DAWUD
NIM. 210605110131



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**KLASIFIKASI SENTIMEN TERHADAP PROGRAM MAKAN BERGIZI
GRATIS MENGGUNAKAN METODE *LOGISTIC REGRESSION***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
MOH. DAWUD
NIM. 210605110131

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN


KLASIFIKASI SENTIMEN TERHADAP PROGRAM MAKAN BERGIZI GRATIS MENGGUNAKAN METODE *LOGISTIC REGRESSION*

SKRIPSI

Oleh :
MOH. DAWUD
NIM. 210605110131

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 21 Oktober 2025

Pembimbing I,


Prof. Dr. Suhartono S.Si M.Kom
NIP. 19680519 200312 1 001

Pembimbing II,


A'la Syauqi, M.Kom
NIP. 19771201 200801 1 007

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M.Kom
NIP. 19841010 201903 1 012

HALAMAN PENGESAHAN

KLASIFIKASI SENTIMEN TERHADAP PROGRAM MAKAN BERGIZI GRATIS MENGGUNAKAN METODE *LOGISTIC REGRESSION*

SKRIPSI

Oleh :
MOH. DAWUD
NIM. 210605110131



Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 11 Desember 2025

Susunan Dewan Penguji

Ketua Penguji	: <u>Dr. Irwan Budi Santoso, M.Kom</u> NIP. 19770103 201101 1 004
Anggota Penguji I	: <u>Khadijah F.H. Holle, M.Kom</u> NIP. 19900626 202203 2 002
Anggota Penguji II	: <u>Prof. Dr. Suhartono S.Si M.Kom</u> NIP. 19680519 200312 1 001
Anggota Penguji III	: <u>A'la Syauqi, M.Kom</u> NIP. 19771201 200801 1 007

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Supriyono, M.Kom
NIP. 19841010 201903 1 012

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Moh Dawud
NIM : 210605110131
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Klasifikasi Sentimen terhadap Program Makan Bergizi Gratis Menggunakan Metode *Logistic Regression*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 8 Desember 2025
Yang membuat pernyataan,



Moh. Dawud
NIM. 210605110131

MOTTO

“Selalu Bersyukur.”

HALAMAN PERSEMBAHAN

Dengan segala rasa syukur, penulis mempersembahkan karya ini kepada:

Keluarga
Atas segala doa dan dukungan

Dosen
Atas ilmu dan bimbingannya selama masa studi.

Teman
Yang selalu menemani dalam setiap perjalanan studi.

KATA PENGANTAR

Puji syukur penulis panjatkan kehadiran Allah SWT atas segala rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Klasifikasi Sentimen terhadap Program Makan Bergizi Gratis Menggunakan Metode *Logistic Regression*” dengan baik.

Penyusunan skripsi ini tidak terlepas dari bimbingan, dukungan, serta doa dari berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Prof. Dr. Hj. Ilfi Nur Diana, M.Si, CAHRM, CRMP selaku Rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Dr. Agus Mulyono M.Kes selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Supriyono, M.Kom selaku Kepala Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Prof. Dr. Suhartono S.Si M.Kom, A’la Syauqi, M.Kom selaku Dosen Pembimbing I dan II atas bimbingan, arahan, dan motivasi yang sangat berarti bagi penulis.
5. Dr. Irwan Budi Santoso, M.Kom, Khadijah Fahmi Hayati Holle, M.Kom selaku Dosen Penguji I dan II atas masukan dan saran yang membangun.
6. Ibu Hani Nurhayati, M.T, selaku Dosen Wali atas arahan dan bimbingannya selama masa studi.
7. Segenap dosen dan staf akademik Program Studi Teknik Informatika atas ilmu yang diberikan selama masa studi.

8. Keluarga atas dukungan dan doa yang tiada henti.
9. Saudara Teknik Informatika khususnya ASTER 21 yang telah menjadi bagian dari perjalanan akademik serta senantiasa saling mendukung.
10. Seluruh pihak yang tidak dapat penulis sebutkan satu per satu atas bantuannya selama masa studi berlangsung.

Penulis menyadari bahwa penyusunan skripsi ini masih terdapat kekurangan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan untuk perbaikan di masa mendatang. Besar harapan penulis agar skripsi ini dapat memberikan manfaat serta wawasan bagi pembaca.

Malang, 8 Desember 2025

Penulis

DAFTAR ISI

HALAMAN PENGANTAR	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iii
PERNYATAAN KEASLIAN TULISAN.....	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR GAMBAR	xii
DAFTAR TABEL	xiii
ABSTRAK.....	xiv
ABSTRACT	xv
الملخص.....	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	5
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA.....	8
2.1 Penelitian Terkait.....	8
2.2 Klasifikasi Sentimen.....	11
2.3 Program Makan Bergizi Gratis	13
2.4 <i>Term Frequency-Inverse Document Frequency (TFIDF)</i>	14
2.5 <i>Logistic Regression</i>	15
BAB III METODE PENELITIAN.....	16
3.1 Pengumpulan Data.....	16
3.2 Labelisasi Data.....	17
3.3 Desain Sistem	18
3.4 <i>Preprocessing</i>	20
3.4.1 <i>Cleansing</i>	21
3.4.2 <i>Case Folding</i>	22
3.4.3 <i>Tokenizing</i>	22
3.4.4 <i>Normalization</i>	23
3.4.5 <i>Stopwords Removal</i>	23
3.4.6 <i>Stemming</i>	24
3.5 Pembobotan	24
3.5.1 <i>Term Frequency (TF)</i>	25
3.5.2 <i>Inverse Document Frequency (IDF)</i>	25
3.5.3 <i>Term Frequency-Inverse Document Frequency (TFIDF)</i>	26
3.6 Model Klasifikasi (<i>Logistic Regression</i>)	27
3.7 Evaluasi	33
3.7.1 <i>Confusion Matrix</i>	33
3.7.2 Akurasi	34
3.7.3 <i>Precision</i>	35
3.7.4 <i>Recall</i>	35
3.7.5 <i>F1-Score</i>	36

3.7.6 Skenario Pengujian.....	36
BAB IV HASIL DAN PEMBAHASAN	39
4.1 Uji Coba.....	39
4.2 Hasil Uji Coba	40
4.2.1 Hasil Uji Coba 1	41
4.2.2 Hasil Uji Coba 2	48
4.2.3 Hasil Uji Coba 3	51
4.3 Pembahasan	53
4.4 Integrasi Penelitian dengan Islam.....	57
BAB V KESIMPULAN DAN SARAN.....	61
5.1 Kesimpulan	61
5.2 Saran	62
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 3. 1 Visualisasi Distribusi Dataset Setelah Labelisasi.....	18
Gambar 3. 2 Desain Sistem.....	19
Gambar 3. 3 Flowchart Model Klasifikasi Multinomial Logistic Regression	28
Gambar 4. 1 Confution Matrix Untuk Rasio 60:40	42
Gambar 4. 2 Confution Matrix Untuk Rasio 70:30	43
Gambar 4. 3 Confution Matrix Untuk Rasio 80:20	45
Gambar 4. 4 Confution Matrix Untuk Rasio 90:10	46
Gambar 4. 5 Confution Matrix Untuk Penggunaan Class Weighting.....	49

DAFTAR TABEL

Tabel 3. 1 Data Sampel	16
Tabel 3. 2 Data Sampel yang Telah Berlabel	17
Tabel 3. 3 Proses Cleansing	21
Tabel 3. 4 Proses Case Folding	22
Tabel 3. 5 Proses Tokenizing	22
Tabel 3. 6 Proses <i>Normalization</i>	23
Tabel 3. 7 Proses Stopwords Removal	24
Tabel 3. 8 Proses Stemming	24
Tabel 3. 9 Proses Term Frequency	25
Tabel 3. 10 Confusion Matrix	34
Tabel 3. 11 Skenario Pengujian	36
Tabel 4. 1 Hasil Akhir Bobot pada Uji Coba Pembagian Data (60:40)	41
Tabel 4. 2 Hasil Akhir Bias pada Uji Coba Pembagian Data (60:40)	41
Tabel 4. 3 Hasil Akhir Bobot pada Uji Coba Pembagian Data (70:30)	43
Tabel 4. 4 Hasil Akhir Bias pada Uji Coba Pembagian Data (70:30)	43
Tabel 4. 5 Hasil Akhir Bobot pada Uji Coba Pembagian Data (80:20)	44
Tabel 4. 6 Hasil Akhir Bias pada Uji Coba Pembagian Data (80:20)	44
Tabel 4. 7 Hasil Akhir Bobot pada Uji Coba Pembagian Data (90:10)	46
Tabel 4. 8 Hasil Akhir Bias pada Uji Coba Pembagian Data (90:10)	46
Tabel 4. 9 Perbandingan Hasil Uji Coba 1	47
Tabel 4. 10 Hasil Akhir Bobot pada Uji Coba Penggunaan Class Weighting	48
Tabel 4. 11 Hasil Akhir Bias pada Uji Coba Penggunaan Class Weighting	48
Tabel 4. 12 Perbandingan Hasil Uji Coba 2	49
Tabel 4. 13 Perbandingan Hasil Uji Coba 3	51

ABSTRAK

Dawud, Moh. 2025. **Klasifikasi Sentimen terhadap Program Makan Bergizi Gratis Menggunakan Metode *Logistic Regression***. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Suhartono S.Si M.Kom (II) A'la Syauqi, M.Kom.

Kata Kunci: Klasifikasi, Makan Bergizi Gratis, *Logistic Regression*, Sentimen.

Tingginya prevalensi *stunting* di Indonesia memotivasi pemerintah untuk meluncurkan Program Makan Bergizi Gratis (MBG) sebagai kebijakan untuk mengatasi masalah gizi buruk pada anak-anak. Meskipun program ini ditujukan untuk meningkatkan kualitas gizi masyarakat, tingkat penerimaan publik terhadap MBG masih perlu dievaluasi. Untuk memahami respons masyarakat, penelitian ini melakukan klasifikasi sentimen terhadap wacana MBG pada platform media sosial X. Penelitian ini bertujuan memetakan sentimen publik menggunakan algoritma *Logistic Regression*. Data yang digunakan terdiri dari 1.134 tweet berbahasa Indonesia yang dikumpulkan pada Desember 2024 dengan kata kunci “makan bergizi gratis”. Data direpresentasikan menggunakan teknik pembobotan kata TF-IDF. Eksperimen dilakukan menggunakan empat rasio pembagian data (60:40, 70:30, 80:20, dan 90:10), penerapan *class weighting*, serta variasi *learning rate* (0.1, 0.01, dan 0.001). Hasil terbaik diperoleh pada rasio 60:40 dengan penerapan *class weighting* dan *learning rate* 0.001, menghasilkan akurasi 74,88%, *precision* 70,98%, *recall* 69,35%, serta *F1-score* 69,59%. Temuan ini menunjukkan bahwa *Logistic Regression* dapat digunakan secara efektif untuk memetakan sentimen publik dan memberikan wawasan yang relevan dalam evaluasi kebijakan Program Makan Bergizi Gratis.

ABSTRACT

Dawud, Moh. 2025. **Sentiment Classification of the Free Nutritious Meal Program Using Logistic Regression Method**. Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Maulana Malik Ibrahim State Islamic University, Malang. Promoter: (I) Prof. Dr. Suhartono S.Si M.Kom (II) A'la Syauqi, M.Kom.

Keywords: Classification, Free Nutritious Meal, Logistic Regression, Sentiment.

The high prevalence of stunting in Indonesia has motivated the government to launch the Free Nutritious Meal (MBG) Program as a policy intervention to address child malnutrition. Although the program aims to improve the nutritional status of the population, public acceptance of MBG remains uncertain. To assess societal responses, this study conducts sentiment classification on public discourse regarding MBG on the social media platform X. The objective of this research is to map public sentiment using the Logistic Regression algorithm. The dataset consists of 1,134 Indonesian-language tweets collected in December 2024 using the keyword “makan bergizi gratis.” The data were represented using the TF-IDF word-weighting technique. Experiments were carried out using four data-splitting ratios (60:40, 70:30, 80:20, and 90:10), the application of class weighting, and variations of learning rates (0.1, 0.01, and 0.001). The best performance was achieved using the 60:40 ratio with class weighting and a learning rate of 0.001, yielding an accuracy of 74.88%, precision of 70.98%, recall of 69.35%, and an F1-score of 69.59%. These findings demonstrate that Logistic Regression is an effective method for mapping public sentiment and provides valuable insights for evaluating the Free Nutritious Meal policy.

الملخص

.داوود، محمد. 2025. تصنيف المشاعر تجاه برنامج الطعام المغذي المجاني باستخدام طريقة الانحدار اللوجستي. رسالة تخرج
:برنامج دراسات تقنية المعلومات، كلية العلوم والتكنولوجيا، جامعة إسلامية نيجيريا مولانا مالك إبراهيم مالانج. المشرف
البروفيسور الدكتور سهارتونو س.س.إ.، ماجستير في الكمبيوتر (2) علا شوقي، ماجستير في الكمبيوتر (1).

الكلمات المفتاحية: التصنيف، الطعام المغذي المجاني، الانحدار اللوجستي، المشاعر

إن الانتشار المرتفع للتقزم (*stunting*) في إندونيسيا حفّز الحكومة على إطلاق برنامج "الوجبة المغذية المجانية" (MBG) كسياسة لمعالجة مشكلة سوء التغذية لدى الأطفال. وعلى الرغم من أن هذا البرنامج يهدف إلى تحسين الجودة الغذائية للمجتمع، إلا أن مستوى القبول العام لبرنامج MBG لا يزال بحاجة إلى تقييم. ولفهم استجابة المجتمع، أجرى هذا البحث تصنيفاً للمشاعر تجاه خطاب برنامج MBG على منصة التواصل الاجتماعي "إكس" (X) بهدف رسم خريطة للمشاعر العامة باستخدام خوارزمية الانحدار اللوجستي (*Logistic Regression*). تتكون البيانات المستخدمة من 1,134 تغريدة باللغة الإندونيسية تم جمعها في ديسمبر 2024 باستخدام الكلمات المفتاحية "makan bergizi gratis"، وتم تمثيلها باستخدام تقنية ترجيح الكلمات TF-IDF. تم إجراء التجربة باستخدام أربع نسب لتقسيم البيانات (60:40، 70:30، 80:20، و 90:10)، وتطبيق ترجيح الفئة (*class weighting*)، بالإضافة إلى تنويع معدل التعلم (0.1، 0.01، و 0.001). وقد تم الحصول على أفضل النتائج عند نسبة تقسيم 60:40 مع تطبيق ترجيح الفئة ومعدل تعلم 0.001، مما أسفر عن دقة (*accuracy*) بنسبة 74.88%، وضبط (*precision*) بنسبة 70.98%، واستدعاء (*recall*) بنسبة 69.35%، ودرجة (*f1-score*) بنسبة 69.59%. تشير هذه النتائج إلى أنه يمكن استخدام الانحدار اللوجستي بفعالية لرسم خريطة للمشاعر العامة وتوفير رؤى ذات صلة في تقييم سياسة برنامج الوجبة المغذية المجانية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Stunting adalah keadaan tubuh pendek akibat kekurangan gizi kronis pada usia anak-anak dikarenakan ketidakcukupan asupan nutrisi (Rahmadhita, 2020). Masalah tersebut masih menjadi masalah dan juga tantangan yang serius di Indonesia yang menghambat upaya negara dalam mencapai cita-cita mencerdaskan kehidupan bangsa. Berdasarkan Survei Status Gizi Nasional (SSGI) 2022, prevalensi *stunting* di negara ini mencapai 21,6 persen. Permasalahan gizi menjadi salah satu faktor penghambat negara Indonesia maju. *Stunting* tidak hanya memiliki dampak pada kesehatan fisik dan mental anak, tetapi juga dapat mengurangi potensi produktivitas dan kualitas sumber daya manusia di masa depan (Dewey & Begum, 2011).

Menyadari pentingnya isu ini, pasangan calon presiden Prabowo Subianto dan Gibran Rakabuming Raka menjanjikan program Makan Bergizi Gratis (MBG) pada tahun 2023 sebagai salah satu janji kampanye untuk mengatasi masalah gizi buruk yang masih menjadi tantangan serius di negara ini. Karena pasangan tersebut telah memenangkan pemilihan presiden 2024, janji tersebut akan dijadikan sebagai salah satu program selama masa periode kepemimpinannya. Program ini memiliki tujuan untuk meningkatkan sumber daya manusia melalui perbaikan gizi sehingga dapat menciptakan generasi penerus dalam rangka mewujudkan cita-cita Indonesia Emas 2045 (Kemenko PMK,).

Keberhasilan program MBG sangat bergantung pada dukungan dan partisipasi masyarakat. Pemahaman publik terhadap MBG, baik dalam segi manfaat maupun tantangannya, akan sangat memengaruhi implementasi dan keberlanjutan program. Dalam Islam, pentingnya menjaga amanah dalam menjalankan janji tercermin dalam firman Allah pada QS. Al-Mu'minun (23): 8:

وَالَّذِينَ هُمْ لِأَمْتِنِهِمْ وَعَهْدِهِمْ رَاعُونَ ﴿٨﴾

“Dan (sungguh beruntung) orang yang memelihara amanat-amanat dan janjinya,” (Q.S Al-Mu'minun: 8).

Menurut tafsir Ibnu Katsir, ayat ini menunjukkan sifat orang-orang yang beriman, yaitu memelihara amanah yang telah diberikan kepada mereka, baik amanah kepada Allah, seperti menjalankan perintah-Nya, maupun amanah kepada manusia, seperti menunaikan janji dan tanggung jawab. Amanah merupakan karakteristik orang beriman yang akan membawa keberkahan dalam kehidupan, baik individu maupun masyarakat. Dengan demikian, amanah dalam konteks program MBG adalah janji pemerintah kepada masyarakat yang harus dijalankan dan dipelihara dengan penuh tanggung jawab agar memperoleh kepercayaan masyarakat yang tinggi, sehingga kinerja pada program tersebut berjalan lancar dan mendapat citra yang baik dimata publik. Oleh karena itu, penting untuk dilakukan pemahaman terkait bagaimana pandangan masyarakat terhadap suatu program (Riyanto & Kovalenko, 2023).

Salah satu cara untuk menjaga amanah tersebut untuk memahami persepsi masyarakat terhadap program yang dijalankan, dapat dilakukan dengan memahami bagaimana persepsi masyarakat di media sosial seperti X. Media sosial X atau biasa

dikenal dengan Twitter, menjadi salah satu platform dimana masyarakat berekspresi atau menyuarakan pendapat mereka termasuk dalam hal kebijakan publik (Emeraldien et al., 2019). Dengan ini, media sosial X memberikan peluang besar untuk mengumpulkan opini publik dengan cepat dan dalam jumlah yang sangat besar. Dalam konteks kebijakan MBG, penting bagi pemerintah untuk memahami sentimen masyarakat terhadap program ini. Mengingat potensi besar yang dimiliki oleh Twitter dalam mengumpulkan opini publik, klasifikasi sentimen terhadap tweet yang memiliki kaitan dengan program Makan Bergizi Gratis menjadi langkah penting untuk memahami pandangan masyarakat secara lebih mendalam.

Klasifikasi sentimen merupakan salah satu cara untuk mengidentifikasi pandangan masyarakat terhadap suatu kebijakan. Dalam hal ini, untuk memahami reaksi publik terhadap program Makan Bergizi Gratis (MBG), klasifikasi sentimen memiliki peran penting dalam menjelaskan gambaran yang lebih jelas terhadap opini yang berkembang. Dalam Islam, pentingnya mendengarkan berbagai pendapat dan memilih yang terbaik di antara mereka tercermin dalam Surat Az-Zumar ayat 18, yang berbunyi:

الَّذِينَ يَسْمِعُونَ الْقَوْلَ فَيَتَّبِعُونَ أَحْسَنَهُ ۚ أُولَٰئِكَ الَّذِينَ هَدَاهُمُ اللَّهُ وَأُولَٰئِكَ هُمُ الْآلِبَابُ ﴿١٨﴾

“Yang mendengarkan perkataan, lalu mengikuti apa yang paling baik di antaranya. Mereka itulah orang-orang yang telah diberi Allah petunjuk, dan mereka itulah orang-orang yang mempunyai akal.” (QS. Az-Zumar: 18)

Tafsir Imam Fakhruddin Ar-Razi menjelaskan bahwa ayat ini merujuk pada orang-orang yang memiliki kemampuan untuk bernalar secara mendalam dan

memilih informasi dengan bijaksana. Mereka adalah individu yang mampu mendengarkan berbagai pendapat dengan hati terbuka, menyaring nasihat, dan mengambil hikmah dari pengalaman orang lain. Sikap ini mencerminkan kemampuan untuk menganalisis dan mengevaluasi berbagai pandangan secara kritis, selektif, dan objektif. Prinsip ini sangat relevan dalam konteks klasifikasi sentimen, dimana sistem klasifikasi harus mampu mendengarkan berbagai pendapat atau pandangan yang disampaikan oleh masyarakat lewat media sosial, kemudian memilih dan mengklasifikasikan sentimen yang paling relevan dan akurat. Dalam hal ini, klasifikasi sentimen dapat digunakan untuk mengetahui bagaimana reaksi masyarakat terhadap program MBG dengan lebih cepat dan juga efisien, dibandingkan dengan cara manual. Seiring berkembangnya teknologi dalam melakukan klasifikasi sentimen, *machine learning* dapat dijadikan sebagai metode yang efisien dan mampu melakukan klasifikasi teks dengan tingkat akurasi yang tinggi dalam mengklasifikasikan sentimen positif, netral dan negatif yang disampaikan oleh masyarakat berupa opini tentang pandangan mereka. Klasifikasi sentimen menggunakan *machine learning* yang berfungsi untuk melakukan analisa data dalam jumlah besar yang sulit dikelola jika dilakukan secara manual (Nugroho, 2024).

Pada penelitian yang dilakukan oleh Ash Shiddicky dan Surya Agustian pada tahun 2022 menunjukkan bahwa *Logistic Regression* terbukti mampu melakukan klasifikasi terhadap kebijakan vaksinasi COVID-19 dan menghasilkan akurasi yang lebih tinggi, yaitu 67% dibandingkan dengan metode lain, seperti *Naïve Bayes*, *Support Vector Machine* (SVM), bahkan *Long Short-Term Memory*

(LSTM). Pada penelitian yang dilakukan Huseyn Hasanli dan Samir Rustamov pada tahun 2020 yang berjudul “*Sentiment Analysis of Azerbaijani tweets Using Logistic Regression, Naive Bayes and SVM*”, menunjukkan bahwa *Logistic Regression* mampu mengklasifikasikan sentimen pada *tweet-tweet* dengan akurasi sebesar 93%.

Berdasarkan latar belakang yang telah dipaparkan, penelitian ini bertujuan untuk melakukan klasifikasi sentimen publik di media sosial X terkait Program Makan Bergizi Gratis (MBG) dengan menggunakan metode *machine learning* yang dapat menganalisis sentimen masyarakat secara otomatis. Salah satu metode *machine learning* yang digunakan dalam penelitian ini adalah *Logistic Regression*, sebagaimana telah dibuktikan dalam penelitian-penelitian sebelumnya. Klasifikasi sentimen ini bertujuan untuk mengidentifikasi pandangan masyarakat terhadap kebijakan tersebut, baik yang bersifat positif, netral maupun negatif. Penelitian ini akan mengkaji performa *Logistic Regression* dalam melakukan klasifikasi sentimen terhadap kebijakan tersebut, baik yang bersifat positif, netral maupun negatif.

1.2 Rumusan Masalah

Bagaimana performa metode *Logistic Regression* dalam mengklasifikasikan sentimen publik terhadap Program Makan Bergizi Gratis berdasarkan tingkat akurasi, *precision*, *recall*, dan *f1-score*?

1.3 Batasan Masalah

Batasan Untuk memastikan fokus dan keterbatasan dalam penelitian ini, beberapa batasan perlu ditetapkan agar dapat dilakukan secara terarah dan terukur. Berikut batasan masalah yang digunakan pada penelitian ini:

1. Penelitian ini menggunakan data sebanyak 1134 yang berasal dari media sosial X berupa *tweets* yang diambil pada tanggal 1 Desember hingga 31 Desember 2024 dengan kata kunci “makan bergizi gratis”.
2. Bahasa pada data yang digunakan, dibatasi dalam bahasa Indonesia.
3. Fokus Penelitian terbatas pada performa model *Logistic Regression* berdasarkan akurasi, *precision*, *recall*, dan *f1-score*.
4. Penelitian ini melakukan klasifikasi sentimen yang dibagi menjadi tiga kelas, yaitu: sentimen positif, negatif, dan netral.

1.4 Tujuan Penelitian

Tujuan Penelitian ini adalah mengetahui performa metode *Logistic Regression* dalam melakukan klasifikasi sentimen publik terhadap Program Makan Bergizi Gratis berdasarkan tingkat akurasi, *precision*, *recall*, dan *f1-score*.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan kontribusi dan manfaat sebagai berikut:

- a. Memberikan informasi kepada pemerintah tentang persepsi publik terhadap program Makan Bergizi Gratis berdasarkan data yang dijadikan data *training*,

sehingga dapat dijadikan sebagai bahan evaluasi dalam meningkatkan implementasi program.

- b. Memberikan referensi bagi penelitian selanjutnya dalam konteks klasifikasi sentimen publik dalam menggunakan metode *Logistic Regression* untuk evaluasi kebijakan publik.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Klasifikasi sentimen menggunakan metode *Logistic Regression* telah banyak diterapkan untuk memahami sentimen publik terhadap berbagai isu sosial, kebijakan public maupun produk konsumen. Dengan demikian penelitian-penelitian sebelumnya dapat dijadikan sebagai panduan dalam membantu melaksanakan penelitian.

Penelitian oleh Elsa Triningsih dkk. (2025), melakukan analisis sentimen dari masyarakat terhadap Program Makan Bergizi Gratis yang diluncurkan oleh pemerintah. Penelitian ini menggunakan algoritma *Support Vector Machine* (SVM) dan Random Forest untuk menganalisis data tweet yang telah melalui proses pre-processing dan pembobotan menggunakan TFIDF. Sentimen dikategorikan menjadi 3 kelas, yaitu sentimen positif, negatif, dan netral. Hasil penelitian menunjukkan algoritma SVM dapat memberikan performa terbaik dengan nilai akurasi sebesar 85,74%, *precision* sebesar 85,92%, *recall* sebesar 85,74%, dan *F1-Score* yang sangat tinggi, mengungguli Random Forest yang hanya mencapai akurasi 81,53%. Penelitian ini menunjukkan bahwa SVM dengan kernel RBF lebih unggul dibandingkan dengan *Random Forest*. Selain itu, penelitian ini juga menyimpulkan bahwa mayoritas masyarakat memberikan sentimen negatif terhadap program ini, dengan kekhawatiran utama terkait pengelolaan biaya anggaran dan dampaknya pada beberapa sektor, terutama pendidikan.

Penelitian oleh Rahmatullah dkk. (2025) melakukan analisis sentimen dari masyarakat terhadap program Makan Bergizi Gratis menggunakan algoritma *Naive Bayes*. Penelitian ini mengumpulkan data dari 1.470 komentar yang diposting di platform YouTube Sekretariat Negara. Sentimen dikategorikan menjadi positif dan negatif, dengan hasil evaluasi menunjukkan algoritma Naive Bayes dapat memberikan tingkat akurasi sebesar 84,69% dan recall sebesar 53,73%. Penelitian ini menunjukkan bahwa sentimen negatif memiliki persentase total terbesar daripada sentimen yang lain, dengan 1209 komentar diklasifikasikan sebagai negatif dan hanya 31 komentar yang diklasifikasikan sebagai positif. Hasil ini memberikan indikasi bahwa meskipun program Makan Bergizi Gratis mendapatkan perhatian, sebagian besar respons masyarakat cenderung negatif, terkait dengan masalah pengelolaan dan efektivitas program.

Penelitian oleh Riwanto dkk. (2025) menganalisis sentimen dari masyarakat terhadap Program Makan Bergizi Gratis melalui komentar YouTube menggunakan algoritma *Support Vector Machine* (SVM). Dataset yang digunakan, terdiri dari 4.170 komentar yang telah melalui tahap *preprocessing* dan data *splitting*. Hasil evaluasi menunjukkan bahwa model SVM memberikan akurasi sebesar 84%, dengan precision untuk sentimen negatif mencapai 82%, *recall* 72%, dan *F1-score* 77%. Sementara itu, untuk sentimen positif, *precision* mencapai 85%, *recall* 91%, dan *F1-score* 88%. Secara keseluruhan, model lebih efektif dalam mengklasifikasikan sentimen positif dibandingkan dengan sentimen negatif, meskipun masih terdapat potensi untuk meningkatkan performa dalam mengklasifikasikan sentimen negatif. Penelitian ini menunjukkan bahwa model

SVM dapat secara efektif digunakan dalam melakukan analisis atau klasifikasi sentimen terhadap komentar YouTube terkait program Makan Bergizi Gratis.

Selain penelitian yang berkaitan dengan kebijakan program Makan Bergizi Gratis (MBG), terdapat juga beberapa penelitian mengenai Logistic Regression yang masih berkaitan dengan analisis sentimen. Penelitian oleh Maulana dkk, (2023) yang melakukan analisis sentimen mengenai ulasan aplikasi Gojek di Google Play Store menggunakan metode *Logistic Regression*, *Multinomial Naïve Bayes*, SVM, dan K-NN. Data ulasan dikategorikan menjadi sentimen positif dan negatif. Hasil evaluasi menunjukkan bahwa akurasi, *recall* dan *precision* secara berturut-turut yaitu 82.45%, 82.49%, 82.45%, dan 82.43%. Sedangkan K-NN merupakan metode yang memiliki skor paling rendah pada penelitian ini, dengan akurasi, *recall*, dan *precision* secara berturut-turut yaitu 52,28%, 59,43%, 93, 52%, dan 65,65%. Hasil penelitian ini menunjukkan bahwa metode *Logistic Regression* cocok untuk digunakan dalam melakukan klasifikasi terhadap ulasan positif dan negatif.

Penelitian lain yang dilakukan oleh Imamah dan Rachman, (2020) meneliti sentimen terhadap tweet yang terkait dengan tweet mengenai Covid-19 untuk menjelaskan dampaknya terhadap kesehatan mental sebagaimana tercermin dalam opini publik di platform media sosial Twitter. Data yang digunakan pada penelitian tersebut adalah tweet terkait Covid-19 yang dikumpulkan pada 30 April 2020, dengan total 355.384 *tweet*. Dalam analisis ini, metode yang digunakan untuk klasifikasi sentimen adalah *Logistic Regression*. Hasil evaluasi menunjukkan bahwa akurasi hasil klasifikasi sentimen *tweet* Covid-19 mencapai 94,71%, yang

menandakan performa yang sangat baik dalam menganalisis sentimen publik terkait situasi pandemi dan dampaknya terhadap kondisi mental masyarakat.

Tabel 2. 1 Penelitian Terkait

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian
1.	(Elsa Triningsih et al., 2025)	<i>Analisis Sentimen Terhadap Program Makan Bergizi Gratis Menggunakan Algoritma Machine Learning Pada Sosial Media X</i>	Support Vector Machine (SVM), Random Forest	Akurasi tertinggi didapatkan oleh model SVM sebesar 85,74%.
2.	(Rahmatullah et al., 2025)	<i>Sentimen Analisis Makan Bergizi Gratis Menggunakan Algoritma Naive Bayes</i>	Naïve Bayes	Hasil menunjukkan bahwa <i>Naive Bayes</i> mencapai tingkat akurasi 84,69%.
3.	(Riwanto et al., 2025)	<i>Analisis Sentimen Komentar Youtube Terkait Penerapan Makan Bergizi Gratis Menggunakan Model Algoritma SVM</i>	SVM	Hasil menunjukkan bahwa akurasi yang didapatkan oleh SVM dengan performa skor sebesar 84%.
4.	(Ash Shiddicky & Surya Agustian, 2022)	<i>Analisis sentimen Masyarakat terhadap kebijakan vaksinasi covid-19 pada media sosial twitter menggunakan metode Logistic Regression</i>	<i>Logistic Regression, Naive Bayes, SVM, dan LSTM</i>	Hasil menunjukkan bahwa <i>Logistic Regression</i> terbukti memperoleh nilai akurasi dan <i>f1-score</i> lebih baik dari metode-metode lainnya. Nilai akurasi dan <i>f1-score</i> yang didapat masing-masing adalah 67% dan 60%.
5.	(Imamah & Rachman, 2020)	<i>Twitter Sentiment Analysis of Covid-19 Using Term Weighting TF-IDF and Logistic Regresion</i>	TFIDF dan <i>Logistic Regression</i>	Hasil menunjukkan bahwa metode <i>Logistic Regression</i> memperoleh akurasi sebesar 94.71%.

2.2 Klasifikasi Sentimen

Klasifikasi sentimen juga dikenal sebagai analisis sentimen (Zhang, 2021).

Klasifikasi sentimen merupakan studi yang menganalisis opini, pandangan, dan sikap sentimental yang ditampilkan orang dalam teks. Analisis ini memiliki tujuan untuk memahami suatu teks, apakah kalimat tersebut termasuk kategori tertentu seperti positif, negatif, atau netral. Analisis ini memiliki relevansi yang signifikan

di berbagai bidang, termasuk bisnis dan politik. Dalam dunia bisnis, klasifikasi sentimen sering digunakan untuk mengukur kepuasan konsumen terhadap suatu produk atau layanan tertentu. (Liu, 2012). Sehingga, dalam ranah kebijakan publik, metode ini digunakan untuk menganalisis sentimen publik yang berlaku terhadap kebijakan pemerintah. Dengan melakukan pemanfaatan data dari media sosial, atau blog, pemerintah dapat menggunakan metode seperti analisis sentimen untuk memperoleh interpretasi tentang penerimaan kebijakan oleh masyarakat, sehingga memperoleh wawasan yang lebih mendalam baik sebelum maupun sesudah implementasi dilakukan.

Dalam analisis sentimen, berbagai algoritma pembelajaran mesin seperti *Bernoulli Naïve Bayes*, *Support Vector Machine (SVM)*, dan *Logistic Regression* telah digunakan untuk mengklasifikasikan sentimen publik dengan akurasi yang tinggi (Dirgantara et al., 2024). Algoritma-algoritma yang mempelajari pola dari dataset berlabel akan melalui preprocessing, sehingga hasil klasifikasi menjadi lebih akurat meskipun menghadapi data yang kompleks dan tidak terstruktur (Sutranggono, 2022). Untuk meningkatkan akurasi sentimen, teks diubah menjadi format numerik melalui teknik pembobotan kata seperti TFIDF dan langkah-langkah preprocessing seperti penghilangan stopwords dan stemming (Widyasanti et al., 2018; Hakim, 2021). Teknik-teknik ini membantu algoritma dalam memahami makna kontekstual dan relevansi kata dalam sebuah kalimat, sehingga meningkatkan performa model dalam mengklasifikasikan sentimen.

2.3 Program Makan Bergizi Gratis

Program Makan Bergizi Gratis (MBG) adalah salah satu program utama yang telah diinisiasi oleh Presiden Prabowo Subianto dan Wakil Presiden Gibran Rakabuming Raka dalam kampanye Pilpres 2024. Program ini memiliki tujuan untuk meningkatkan mutu pendidikan melalui perbaikan gizi sehingga dapat menciptakan generasi penerus dalam rangka mewujudkan cita-cita Indonesia Emas 2024 (Kemenko PMK). Stunting yang disebabkan oleh kekurangan gizi pada seribu hari pertama kehidupan atau disingkat 1000 PHK, menjadi masalah serius yang memengaruhi perkembangan fisik maupun kognitif anak-anak di Indonesia (Pujiastuti, 2022). Program MBG ini diharapkan dapat memperbaiki status gizi anak-anak dan remaja, meningkatkan kualitas hidup, serta mendukung tumbuh kembang mereka dengan menyediakan akses pangan bergizi yang merata di seluruh Indonesia. Dengan memberikan gizi yang cukup pada periode ini, diharapkan dapat mencegah gangguan tumbuh kembang yang berpengaruh pada kualitas SDM di masa depan.

Program MBG yang dilaksanakan mulai Januari 2025 ditargetkan akan menjangkau sekitar 19,47 juta jiwa. Anggaran yang dialokasikan bernilai sebesar Rp71 triliun dalam APBN 2025, diharapkan dapat berjalan sesuai dengan arah tujuan program tersebut (Kemensetneg, 2024). Dana ini digunakan untuk memastikan bahwa pangan bergizi dapat dijangkau oleh masyarakat, terutama di daerah-daerah seperti daerah terpencil.

2.4 *Term Frequency-Inverse Document Frequency (TFIDF)*

Term Frequency-Inverse Document Frequency (TFIDF) adalah metode yang berfungsi sebagai pembobotan kata. Metode ini menentukan bobot sebuah kata dengan mempertimbangkan frekuensi kemunculannya dalam dokumen dan seberapa jarang kata tersebut ditemukan dalam dokumen lain. TFIDF menggabungkan dua elemen utama, yaitu *Term Frequency (TF)* dan *Inverse Document Frequency (IDF)*. TF menunjukkan frekuensi munculnya suatu kata dalam sebuah dokumen dibandingkan dengan total jumlah kata di dokumen tersebut. Semakin sering suatu kata muncul, semakin tinggi nilai TF. Sementara itu, IDF memberikan bobot lebih besar pada kata-kata yang jarang muncul di keseluruhan kumpulan dokumen, karena kata-kata tersebut dinilai lebih informatif. Sebaliknya, kata-kata umum yang banyak ditemukan di hampir semua dokumen akan memperoleh nilai IDF yang rendah (Septian et al., 2019).

Dalam berbagai penelitian, TFIDF sering digunakan untuk memberikan bobot pada kata-kata yang relevan terkait dalam analisis tekstual, termasuk domain seperti analisis sentimen dan klasifikasi teks. Teknik ini memungkinkan model pembelajaran mesin untuk dapat memprioritaskan kata-kata yang mengandung informasi penting, serta mengabaikan kata-kata yang tidak signifikan. Selain itu, teknik ini juga berkontribusi pada reduksi dimensi data, sehingga meningkatkan efisiensi dan efektivitas proses pelatihan model dengan mengurangi kompleksitas fitur yang tidak diperlukan (Yadla & Rao, 2020).

2.5 Logistic Regression

Logistic Regression merupakan salah satu metode yang umum dipakai dalam dalam klasifikasi sentimen teks. Metode ini sering digunakan untuk memprediksi variabel dependen yang bersifat kategoris, khususnya untuk klasifikasi dengan dua kelas, seperti sentimen positif dan negatif. *Logistic Regression* bekerja dengan menganalisis hubungan antara variabel predictor (Ranganathan et al., 2017).

Logistic Regression menggunakan fungsi logistik untuk memetakan nilai prediksi menjadi probabilitas antara 0 dan 1. Jika probabilitas tersebut sama besar atau lebih besar dari 0,5, maka prediksi kelasnya adalah 1 (misalnya, sentimen positif), sedangkan jika kurang dari 0,5, maka prediksi kelasnya adalah 0 (misalnya, sentimen negatif). Dengan pendekatan ini, *Logistic Regression* dapat memetakan data menjadi kelas yang diinginkan dan memberikan interpretasi yang jelas mengenai pengaruh dari masing-masing fitur.

Namun, untuk kasus klasifikasi dengan lebih dari dua kelas, seperti halnya yang digunakan dalam penelitian ini, yaitu *Multinomial Logistic Regression*. Berbeda dengan *Logistic Regression* yang mengklasifikasikan sentimen dalam 2 kelas, *Multinomial Logistic Regression* dapat mengklasifikasikan lebih dari dua kategori kelas (Jurafsky & Martin, 2024). Proses ini memetakan probabilitas untuk masing-masing kelas dalam konteks kategorikal yang lebih kompleks. Misalnya, jika terdapat tiga kelas (kelas A, B, dan C), model akan menghitung peluang untuk setiap kelas, kemudian kelas dengan nilai probabilitas paling tinggi ditetapkan sebagai prediksinya.

BAB III

METODE PENELITIAN

3.1 Pengumpulan Data

Pengumpulan data dalam penelitian ini menggunakan *Tweet Harvest* dengan memanfaatkan *auth token* media sosial X. *Tweet Harvest* melakukan penarikan data berupa *tweet* dari platform media sosial X (sebelumnya Twitter) dengan kata kunci "makan bergizi gratis" dan juga mendeteksi bahasa yang digunakan pada data tersebut. Data yang dikumpulkan adalah data terdeteksi dalam bahasa Indonesia. Proses ini memperoleh sebanyak 1134 data dengan mengambil variabel yang dibutuhkan yakni "*full_text*". Data tersebut diambil mulai pada tanggal 1 sampai 31 Desember 2024. Pemilihan platform media sosial X juga didasarkan pada prevalensinya sebagai saluran komunikasi dalam mengekspresikan pendapat dan sikap yang banyak digunakan oleh masyarakat untuk membahas isu-isu berbagai topik (Emeraldien et al., 2019).

Berikut data sampel yang telah diperoleh pada Tabel 3.1:

Tabel 3. 1 Data Sampel

No	full_text
1	Program Makan Bergizi Gratis sebagai Akses Makan Bergizi bagi Anak Bangsa #PresidenPrabowo
2	@DS_yantie Astaga. Sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis
3	ga butuh makan bergizi gratis yang gak seberapa itu
4	@asumsico Makan bergizi gratis adalah PENGHINAAN bagi masyarakat karena negara menganggap masyarakat TAK MAMPU MEMBERIKAN MAKANAN YANG BERGIZI untuk anaknya...
5	Dengan program makan bergizi gratis Pak Prabowo bantu siswa Indonesia belajar lebih fokus! #IndonesiaEmas #ProgramPresiden #PresidenPrabowo #MakanSiangGratis #KesehatanGratisUntukSemua

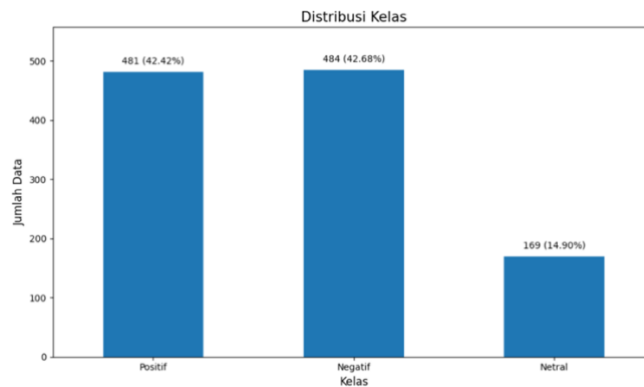
3.2 Labelisasi Data

Karena data yang diperoleh dari platform media sosial X tidak memiliki label sentimen, maka perlu dilakukan langkah labelisasi yang dilakukan secara manual. Labelisasi merupakan proses penting dalam pembuatan dataset yang digunakan untuk pelatihan model klasifikasi. Data latih merupakan salah satu bagian yang penting pada suatu proses klasifikasi (Akbi & Rosyadi, 2018). Dalam penelitian ini, label yang digunakan untuk mengategorikan *tweet* adalah positif, negatif dan netral. *Tweet* yang mengandung pandangan yang mendukung atau menyarankan Program Makan Bergizi gratis diberi label "positif", sedangkan *tweet* yang mengkritik atau meragukan program tersebut diberi label "negatif". Sementara itu, *tweet* yang tidak menunjukkan sentimen jelas atau lebih bersifat netral, seperti yang memberikan informasi tanpa menunjukkan dukungan atau penolakan, diberi label "netral". Setelah labelisasi manual dilakukan, diperlukan validasi data yang dilakukan oleh seorang dosen bahasa Indonesia bernama Rifqi Rohmanul Khakim M.Pd. Penggunaan ahli bahasa bertujuan sebagai validator label yang akan melabeli *tweet-tweet* berdasarkan tiga sentimen yaitu positif, negatif dan netral. Berikut data sampel yang telah dilabeli dan divalidasi pada Tabel 3.2:

Tabel 3. 2 Data Sampel yang Telah Berlabel

No	full_text	label
1	Program Makan Bergizi Gratis sebagai Akses Makan Bergizi bagi Anak Bangsa #PresidenPrabowo	Positif
2	@DS_yantie Astaga. Sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis	Negatif
3	ga butuh makan bergizi gratis yang gak seberapa itu	Negatif
4	@asumsico Makan bergizi gratis adalah PENGHINAAN bagi masyarakat karena negara menganggap masyarakat TAK MAMPU MEMBERIKAN MAKANAN YANG BERGIZI untuk anaknya...	Negatif
5	Dengan program makan bergizi gratis Pak Prabowo bantu siswa Indonesia belajar lebih fokus! #IndonesiaEmas #ProgramPresiden #PresidenPrabowo #MakanSiangGratis #KesehatanGratisUntukSemua	Positif

Berikut Gambar 3.1 yang menampilkan visualisasi hasil dari labelisasi pada dataset:

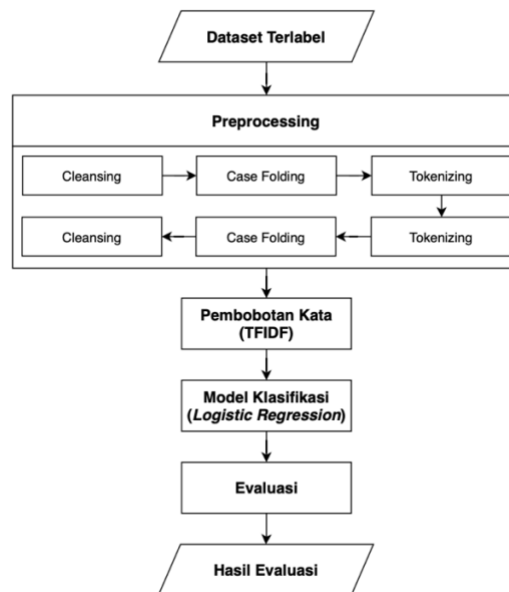


Gambar 3. 1 Visualisasi Distribusi Dataset Setelah Labelisasi

Visualisasi distribusi kelas pada dataset ini menunjukkan ketidakseimbangan yang jelas antara kelas-kelas sentimen. Kelas positif (42.42%) dan negatif (42.68%) memiliki jumlah data yang hampir seimbang, namun kelas netral hanya terdiri dari 169 data (14.90%). Hal ini mengindikasikan bahwa jumlah kelas netral lebih rendah dibanding dengan kelas positif maupun negatif, yang dapat mempengaruhi kinerja model klasifikasi dalam mendeteksi sentimen netral secara akurat.

3.3 Desain Sistem

Pada desain sistem ini menggambarkan tahapan-tahapan proses dari sistem yang akan dilakukan dalam penelitian ini.



Gambar 3. 2 Desain Sistem

Pada Gambar 3.1, dijelaskan bahwa desain sistem penelitian ini terdiri dari beberapa tahapan proses yang saling berkesinambungan. Data yang telah dikumpulkan dan diberi labelisasi akan diproses melalui tahapan *preprocessing* dengan beberapa tahap didalamnya, seperti *cleansing*, *case folding*, *tokenizing*, *normalization*, *stopwords removal*, dan *stemming*. Hal ini bertujuan agar proses pengolahan data lebih mudah (Norman & Mahendra, 2024). Selanjutnya, teks yang telah melalui tahap praproses dikonversi menjadi numerik menggunakan metode TF-IDF, sehingga model dapat mengenali pentingnya kata-kata terhadap suatu konteks tertentu (Hanani, 2023). Setelah itu, model *logistic Regression* dilatih untuk melakukan klasifikasi sentimen dalam *tweet* menjadi dua kategori, positif atau negatif. Evaluasi kinerja model dilakukan untuk mengukur akurasi dan efektivitasnya menggunakan metrik seperti akurasi, *precision*, *recall*, dan *F1-score*.

Hasil dari evaluasi model ini kemudian digunakan untuk melakukan klasifikasi sentimen masyarakat terhadap program Makan Bergizi Gratis.

3.4 *Preprocessing*

Preprocessing data merupakan tahapan yang sangat penting dalam pemrosesan data teks. Hal ini dikarenakan dapat meningkatkan kualitas dan performa model klasifikasi. Tanpa *preprocessing* yang tepat, data teks mentah cenderung mengandung banyak noise yang dapat mengganggu kinerja model. Oleh karena itu, tahapan ini sangat diperlukan untuk memastikan bahwa data dapat diproses dengan lebih optimal.

Penelitian ini memanfaatkan data dalam bentuk tweet yang dikumpulkan dari platform media sosial X. Dataset yang diambil memiliki karakteristik berupa teks tidak terstruktur yang mengandung bahasa informal, slang, dan singkatan yang umum ditemukan dan muncul di media sosial pada umumnya. Selain itu, *tweet* juga sering kali mengandung elemen-elemen khas media sosial X seperti *hashtag* (#) dan *mention* (@) yang memberikan konteks tambahan, namun tidak relevan untuk klasifikasi sentimen. Data ini juga memiliki panjang teks yang bervariasi, dari *tweet* yang singkat hingga yang lebih panjang, yang perlu diproses dengan hati-hati untuk memperoleh informasi yang lebih terstruktur. Karena karakteristik-karakteristik ini, *preprocessing* menjadi sangat krusial untuk menghilangkan bagian-bagian yang tidak diperlukan serta memastikan data berada dalam kondisi yang sesuai untuk digunakan pada model klasifikasi. Beberapa langkah yang dilakukan dalam *preprocessing* termasuk pembersihan teks (*cleansing*) untuk menghapus elemen-elemen seperti URL, *mention* dan *hashtag*, serta normalisasi untuk menyamakan

variasi kata yang terdapat dalam teks. Tokenisasi diterapkan untuk membagi teks menjadi unit-unit kecil yang lebih mudah diproses, sedangkan *stopwords* yang tidak berpengaruh besar terhadap penentuan sentimen dibuang. Proses-proses ini akan meningkatkan kualitas data, mengurangi *noise* dan menjadikan model untuk bekerja dengan lebih efisien dan akurat dalam mengklasifikasikan sentimen terhadap program MBG.

3.4.1 *Cleansing*

Langkah pertama dalam preprocessing adalah pembersihan teks (*cleansing*). Langkah tersebut bertujuan untuk menghilangkan elemen-elemen yang tidak diperlukan atau berpotensi mengganggu proses klasifikasi. Dalam konteks data teks media sosial, *tweet* atau pesan sering kali mengandung *URL*, *mention* (@) dan *hashtag* (#) yang tidak memberikan peran penting dalam klasifikasi sentimen. Oleh karena itu, elemen-elemen tersebut dihapus menggunakan teknik *regular expression* (*regex*). Menghapus informasi yang tidak perlu dan menjadikan data sesuai dengan yang diinginkan membuat proses pengolahan data latih lebih mudah (Norman & Mahendra, 2024). Berikut Tabel 3.3 yang merupakan contoh proses *cleansing*:

Tabel 3. 3 Proses Cleansing

Tahap	Teks
Sebelum cleansing	@DS_yantie Astaga. Sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis
Setelah cleansing	Astaga. Sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis

3.4.2 Case Folding

Setelah teks dibersihkan, langkah selanjutnya adalah *case folding*, yaitu proses mengubah karakter-karakter huruf besar atau kapital dalam teks menjadi huruf kecil (*lowercase*) sehingga menjadi bentuk yang seragam (Ash Shiddicky & Surya Agustian, 2022). Proses ini untuk menyamakan kata yang memiliki bentuk kapitalisasi berbeda tetapi memiliki makna yang sama. Misalnya, "Dukung" dan "dukung" dianggap sebagai kata yang sama. Berikut Tabel 3.4 yang merupakan contoh proses *case folding*:

Tabel 3. 4 Proses *Case Folding*

Tahap	Teks
Sebelum case folding	Astaga. Sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis
Setelah case folding	astaga sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis

3.4.3 Tokenizing

Setelah tahap *case folding*, teks kemudian dipecah menjadi unit-unit kecil yang disebut token. Token tersebut biasanya berupa kata atau frasa. Proses tersebut disebut *tokenizing*. Tujuan dari *tokenizing* adalah untuk melakukan eksplorasi kata-kata dalam sebuah kalimat untuk keperluan analisis lebih lanjut (Savitri et al., 2021). Pada tahapan *preprocessing* ini, tokenisasi berfungsi untuk memisahkan kata-kata yang saling terhubung dengan tanda baca dan karakter khusus. Berikut Tabel 3.5 yang merupakan contoh proses *tokenizing*:

Tabel 3. 5 Proses Tokenizing

Tahap	Teks
Sebelum tokenisasi	astaga. sebenarnya makan bergizi gratis itu gak efektif daripada makan gratis mending sekolah gratis
Setelah tokenisasi	['astaga', 'sebenarnya', 'makan', 'bergizi', 'gratis', 'itu', 'gak', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']

3.4.4 Normalization

Setelah tokenisasi, tahap berikutnya adalah normalisasi. Normalisasi berfungsi untuk mengganti kata-kata berupa singkatan menjadi bentuk yang sesuai atau berbentuk slang menjadi bentuk yang lebih standar dan mudah dipahami. Normalisasi dilakukan dengan mengganti beberapa kata yang sering dipakai dalam proses interaksi sehari-hari di media sosial, seperti “lu” menjadi “kamu”, “gak” menjadi “tidak”, atau “tp” menjadi “tapi”. Proses ini juga bertujuan untuk meningkatkan keseragaman pada *preprocessing* di setiap teks (Ahuja et al., 2019).

Berikut Tabel 3.6 yang merupakan contoh proses *normalization*:

Tabel 3. 6 Proses *Normalization*

Tahap	Token
Sebelum normalisasi	['astaga', 'sebenarnya', 'makan', 'bergizi', 'gratis', 'itu', 'gak', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']
Setelah normalisasi	['astaga', 'sebenarnya', 'makan', 'bergizi', 'gratis', 'itu', 'tidak', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']

3.4.5 Stopwords Removal

Setelah normalisasi, tahap selanjutnya adalah *stopwords removal*, yaitu menghilangkan kata-kata umum pada teks yang tidak memberikan makna penting bagi proses klasifikasi sentimen, seperti “dan”, “atau”, dan sejenisnya (Nuzul Hikmah et al., 2022). Daftar stopwords yang digunakan, bersumber dari pustaka NLTK. Penghapusan *stopwords* dapat membantu model klasifikasi untuk fokus pada kata-kata yang benar-benar relevan dalam konteks klasifikasi sentimen. Berikut Tabel 3.7 yang merupakan contoh proses *stopwords removal*:

Tabel 3. 7 Proses Stopwords Removal

Tahap	Teks
Sebelum stopwords removal	['astaga', 'sebenarnya', 'makan', 'bergizi', 'gratis', 'itu', 'tidak', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']
Setelah stopwords removal	['astaga', 'sebenarnya', 'makan', 'bergizi', 'gratis', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']

3.4.6 Stemming

Langkah terakhir dalam tahap *preprocessing* adalah *stemming*, yakni bertujuan untuk mengurangi kata-kata berimbuhan ke bentuk dasarnya. Misalnya, kata "mendukung" menjadi "dukung", dan "menganggap" akan diproses menjadi bentuk dasar "anggap". Stemming ini akan proses dengan menggunakan pustaka Sastrawi khusus untuk bahasa Indonesia, yang membantu dalam menangani berbagai bentuk kata dalam teks. Berikut Tabel 3.8 yang merupakan contoh proses *stemming*:

Tabel 3. 8 Proses Stemming

Tahap	Teks
Sebelum stemming	['astaga', 'sebenarnya', 'makan', 'bergizi', 'gratis', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']
Setelah stemming	['astaga', benar, 'makan', 'gizi', 'gratis', 'tidak', 'efektif', 'daripada', 'makan', 'gratis', 'mending', 'sekolah', 'gratis']

3.5 Pembobotan

Pembobotan kata merupakan salah satu langkah memiliki peran penting dalam proses klasifikasi sentimen yang berfungsi untuk mengurangi dimensi data dengan menyusun data teks yang tidak terstruktur sehingga dapat diklasifikasikan menggunakan algoritma *machine learning* (Nurhaliza Agustina et al., 2024). Salah satu metode pada pembobotan kata yang paling sering digunakan ialah TF-IDF. Metode ini bertujuan untuk mengukur seberapa penting suatu kata dalam sebuah

dokumen, serta memperhitungkan sejauh mana kata tersebut spesifik atau umum di seluruh koleksi dokumen (Septian et al., 2019). TFIDF mampu menyaring kata-kata yang bersifat umum dan kurang informatif, membuat model mampu lebih fokus mengenali kata-kata yang benar-benar penting dalam konteks dokumen.

3.5.1 Term Frequency (TF)

Tahap *Term Frequency* (TF) mengevaluasi frekuensi kemunculan suatu kata dalam sebuah dokumen. Kata yang bermunculan lebih sering akan memperoleh nilai TF yang lebih tinggi. Berikut Persamaan 3.1 yang digunakan untuk menghitung nilai Term Frequency (TF):

$$TF_{(t,d)} = \frac{\text{Jumlah kemunculan kata } (t) \text{ dalam dokumen } (d)}{\text{Jumlah total kata } (t) \text{ dalam dokumen } (d)} \quad 3.1$$

Berikut adalah Tabel 3.9 merupakan contoh perhitungan TF untuk kata "program" pada lima dokumen setelah melalui proses *preprocessing*:

Tabel 3. 9 Proses Term Frequency

Dokumen	Jumlah Total Kata	Frekuensi "program"	Nilai TF
1	11	1	1/11
2	13	0	0/13
3	7	0	0/7
4	18	0	0/18
5	13	1	1/13

3.5.2 Inverse Document Frequency (IDF)

Inverse Document Frequency (IDF) berfungsi sebagai metrik untuk mengukur distinsi atau seberapa jarang sebuah kata korpus teks. Kata yang frekuensi kemunculannya lebih rendah di seluruh korpus akan memiliki nilai IDF

yang lebih tinggi, sebaliknya kata yang frekuensi kemunculannya lebih tinggi, akan memiliki nilai IDF yang lebih rendah. Berikut Persamaan 3.2 yang digunakan untuk menghitung nilai *Inverse Document Frequency* (IDF):

$$IDF_{(t)} = \log\left(\frac{N}{DF_{(t)}}\right) \quad 3.2$$

Keterangan:

N : Jumlah total dokumen dalam koleksi
 $DF_{(t)}$: Jumlah dokumen yang memuat kata (t)

Berikut contoh perhitungan $IDF_{(t)}$ untuk kata “program” yang diterapkan melalui rumus pada Persamaan 3.2

$$IDF_{(program)} = \log\left(\frac{5}{2}\right)$$

$$IDF_{(program)} = 0.3979$$

3.5.3 *Term Frequency-Inverse Document Frequency* (TFIDF)

Setelah TF dan IDF, langkah selanjutnya ialah mengalikan nilai TF dengan IDF untuk setiap kata dalam dokumen. Nilai TFIDF menunjukkan pentingnya kata dalam dokumen tertentu. Berikut Persamaan 3. 3 merupakan rumus untuk menghitung nilai TFIDF dengan cara mengalikan antara nilai TF dan IDF.

$$TF\ IDF_{(t,d)} = TF_{(t,d)} \times IDF_{(t)} \quad 3.3$$

Keterangan:

$TF_{(t,d)}$: Frekuensi kata (t) dalam dokumen (d)
 $IDF_{(t)}$: Rasio antara jumlah total dokumen dengan jumlah dokumen yang mengandung kata (t)

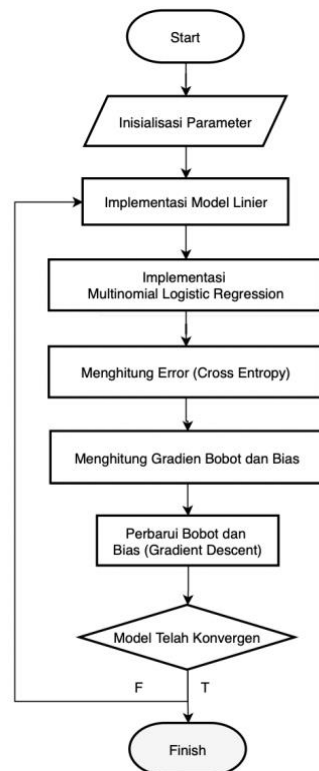
Sehingga nilai TF-IDF pada kata “program” di dokumen 1 dapat dihitung menggunakan Persamaan 3.3 sebagai berikut:

$$TF\ IDf_{(program,1)} = \frac{1}{11} \times 0.3979$$

$$TF\ IDf_{(program,1)} = 0.036$$

3.6 Model Klasifikasi (*Logistic Regression*)

Model klasifikasi merupakan salah satu teknik dalam pembelajaran mesin yang berfungsi memprediksi label atau kategori suatu data berdasarkan fitur-fitur yang dimilikinya. Dalam klasifikasi multi-kelas, model digunakan untuk mengelompokkan data ke dalam lebih dari dua kelas yang berbeda, misalnya dalam klasifikasi sentimen yang dapat mencakup kelas positif, negatif, dan netral. Model ini lebih kompleks dibandingkan dengan *Logistic Regression biner* karena dapat menangani lebih dari dua kelas. Berikut ini adalah *flowchart* yang menggambarkan langkah-langkah utama dalam implementasi *Multinomial Logistic Regression* (MLR).



Gambar 3. 3 *Flowchart Model Klasifikasi Multinomial Logistic Regression*

Berdasarkan Gambar 3.3, model ini berawal dari inisialisasi parameter, dimana nilai awal untuk bobot dan bias model ditetapkan dengan nilai nol (0). Setelah parameter diinisialisasi, langkah berikutnya adalah implementasi model linier, yang berfungsi untuk memodelkan hubungan antara fitur input yang diperoleh dari TFIDF dan *output* berupa nilai kontinu. Dengan menggunakan model regresi linier ini, model kemudian dapat mengonversi *output* yang dihasilkan menjadi probabilitas untuk setiap kelas menggunakan *Multinomial Logistic Regression*, yang merupakan perluasan dari model *Logistic Regression* untuk masalah klasifikasi multi-kelas.

Dalam model *linier*, hubungan antara fitur input x_1, x_2, \dots, x_n dan *output* y dimodelkan sebagai fungsi linear. Berikut Persamaan 3.4 terkait model *linier*:

$$t_k = \beta_{0k} + \beta_{1k}x_1 + \beta_{2k}x_2 + \dots + \beta_{nk}x_n \quad 3.4$$

Keterangan :

t_k	: Nilai linear untuk kelas k
β_{0k}	: Intercept atau bias untuk kelas k
$\beta_{1k}, \beta_{2k}, \dots, \beta_{nk}$: Koefisien bobot untuk fitur x_1, x_2, \dots, x_n pada kelas k
x_1, x_2, \dots, x_n	: Fitur input

Model ini menghasilkan nilai t_k untuk setiap kelas k_1 , yang bisa lebih kecil dari 0 atau lebih besar dari 1. Namun, kita membutuhkan output dalam rentang antara 0 dan 1 untuk masalah klasifikasi probabilistik.

Sama seperti dalam regresi logistik biner, *log odds* juga digunakan dalam model Multinomial *Logistic Regression*. Pada regresi logistik biner, kita menghitung logaritma dari rasio peluang (*odds ratio*) untuk kelas positif terhadap kelas negatif. Dalam model multinomial, log odds dihitung untuk setiap kelas terhadap kelas referensi (biasanya kelas terakhir, K). *Log odds* untuk kelas k terhadap kelas K dihitung dengan Persamaan 3.5:

$$\ln \left(\frac{P(y = k|x)}{P(y = K|x)} \right) = t_k \quad 3.5$$

Keterangan :

y	: Variabel target/kategori
k	: Salah satu kelas, dengan $k = 1, 2, \dots, K - 1$
K	: Kelas referensi
x	: Variabel fitur / vektor input
$P(y = k x)$: Probabilitas bahwa kelas adalah k , diberikan x
t_k	: Skor/logit untuk kelas k

Untuk mengonversi output regresi linier t_k ke dalam rentang probabilitas 0 dan 1, kita menggunakan multinomial *Logistic Regression*. Multinomial *Logistic Regression* mengubah hasil logit menjadi probabilitas dalam rentang antara 0 dan 1. Hal ini dapat didefinisikan sebagai berikut pada Persamaan 3.6:

$$P_k(x) = \frac{e^{t_k}}{\sum_{j=0}^{K-1} e^{t_j}} \quad 3.6$$

Keterangan :

$P_k(x)$: Probabilitas kelas k untuk sampel x
 K : Jumlah kelas yang ada
 t_k : Nilai linear untuk kelas k
 e^{t_k} : Eksponensial dari t_k

Dengan ini, kita dapat menghubungkan model linear t_k dengan probabilitas $P_k(x)$. Probabilitas untuk kelas k diberikan oleh rumus di atas. Sedangkan probabilitas untuk kelas lainnya dapat diperoleh dengan metode perhitungan yang sama, di mana probabilitas untuk kelas negatif (atau kelas lainnya) adalah komplement dari probabilitas kelas positif.

Untuk melatih model, kita perlu mengoptimalkan parameter $\beta_{0k}, \beta_{1k}, \dots, \beta_{nk}$ agar probabilitas yang diprediksi $P_k(x)$ sesuai dengan label yang sebenarnya. Misalkan kita memiliki dataset dengan m sampel, dan untuk setiap sampel i , kita memiliki label aktual $y_i \in \{0, 1, 2, \dots, K-1\}$ dan probabilitas yang diprediksi oleh model $p_{ik} = P(y_i = k | x_i)$. Fungsi likelihood untuk seluruh dataset adalah hasil perkalian dari probabilitas yang diprediksi untuk setiap sampel, yang dipangkatkan dengan label aktual. Untuk satu sampel i , jika $y_i = k$, maka kita ingin probabilitas p_{ik} , maka kita ingin probabilitas $1 - p_{ik}$. Berikut Persamaan 3.7 yang merupakan fungsi *likelihood* untuk m sampel:

$$L = \prod_{i=1}^m \prod_{k=0}^{K-1} p_{ik}^{\mathbb{I}(y_i=k)} (1 - p_{ik})^{\mathbb{I}(y_i \neq k)} \quad 3.7$$

Keterangan :

p_{ik} : Probabilitas kelas k yang diprediksi untuk sampel i
 $\mathbb{I}(y_i = k)$: Indikator yang bernilai 1 jika $y_i = k$ dan 0 jika $y_i \neq k$
 y_i : Label aktual untuk sampel i

Untuk menyederhanakan perhitungan, kita sering menggunakan log-likelihood. Log-likelihood adalah logaritma dari fungsi likelihood, yang mengubah perkalian menjadi penjumlahan. *Log-likelihood* ini mengukur seberapa baik probabilitas yang diprediksi oleh model dengan data empiris yang diamati. Berikut Persamaan 3.8 yang merupakan fungsi log-likelihood untuk dataset dengan m sampel:

$$\log L = \prod_{i=1}^m \prod_{k=0}^{K-1} \mathbb{I}(y_i = k) \log(p_{ik}) + (1 - \mathbb{I}(y_i = k)) \log(1 - p_{ik}) \quad 3.8$$

Fungsi *cross-entropy* (atau *log loss*) adalah fungsi *cost* yang digunakan untuk mengukur *error* antara probabilitas prediksi model dan label aslinya. *Cross-entropy* juga dikenal dengan *negative log-likelihood*. *Cross-entropy* sering digunakan *Multinomial Logistic Regression* dan dalam konteks klasifikasi dengan lebih dari dua kelas. Berikut Persamaan 3.9 yang merupakan *cross-entropy* untuk satu sampel i :

$$L_i = - \sum_{k=0}^{K-1} \mathbb{I}(y_i = k) \log(p_{ik}) \quad 3.9$$

Keterangan :

p_{ik} : Probabilitas kelas k yang diprediksi untuk sampel i
 y_i : Label aktual untuk sampel i

Berikut Persamaan 3.10 dari *cross-entropy* untuk seluruh dataset dengan m sampel, yang merupakan rata-rata dari loss per sampel:

$$L = - \frac{1}{m} \sum_{i=1}^m \sum_{k=0}^{K-1} \mathbb{I}(y_i = k) \log(p_{ik}) \quad 3.10$$

Keterangan :

L : *Cross-entropy loss* untuk seluruh dataset

m : Jumlah total sampel dalam dataset

Untuk meminimalkan loss function, digunakan *Gradient Descent*. *Gradient Descent* ialah metode optimisasi yang bertujuan untuk menemukan nilai minimum dari loss function (Aliman et al., 2022). Proses ini dilakukan secara iteratif dengan memperbarui parameter model. Pembaruan parameter dilakukan berdasarkan gradien dari loss function terhadap masing-masing parameter.

Gradien dapat dihitung dengan Persamaan 3.11 dan Persamaan 3.12 berikut untuk parameter β_{jk} dan bias β_{0k} :

$$\frac{\partial L}{\partial \beta_{jk}} = \frac{1}{m} \sum_{i=1}^m (p_{ik} - \mathbb{I}(y_i = k)) x_{ij} \quad 3.11$$

$$\frac{\partial L}{\partial \beta_{0k}} = \frac{1}{m} \sum_{i=1}^m (p_{ik} - \mathbb{I}(y_i = k)) \quad 3.12$$

Keterangan :

x_{ij} : Nilai fitur ke- j untuk sampel ke- i

p_{ik} : Probabilitas kelas k yang diprediksi untuk sampel i

y_i : Label aktual untuk sampel i

Setelah gradien dihitung, parameter β_{jk} dan β_{0k} diperbarui menggunakan rumus seperti pada Persamaan 3.13 dan Persamaan 3.14 sebagai berikut:

$$\beta_{jk} = \beta_{jk} - \eta \frac{\partial L}{\partial \beta_{jk}} \quad 3.13$$

$$\beta_{0k} = \beta_{0k} - \eta \frac{\partial L}{\partial \beta_{0k}} \quad 3.14$$

Keterangan :

β_{jk} : Parameter bobot untuk fitur ke- j pada kelas k

β_{0k} : Parameter bias untuk kelas k

η : Learning rate

Selain itu, untuk menangani ketidakseimbangan kelas dalam dataset, model ini menggunakan *class weights* agar memberikan bobot lebih besar pada kelas dengan jumlah data yang lebih sedikit atau minoritas. Dengan cara ini, model menjadi lebih sensitif terhadap kelas tersebut, yang dapat membantu meningkatkan akurasi model dalam memprediksi kelas yang jarang muncul (Bakirarar & Elhan, 2023).

Proses pelatihan ini diulang untuk sejumlah iterasi sampai perbedaan antara nilai *cross-entropy* pada iterasi sebelumnya dan iterasi berikutnya cukup kecil, sehingga model secara bertahap belajar untuk memperoleh hasil prediksi yang lebih tepat.

3.7 Evaluasi

Evaluasi memanfaatkan *confusion matrix* untuk mengukur kinerja model klasifikasi dengan melihat nilai pada masing-masing kelas yang diprediksi dan kelas yang sebenarnya (Amal, 2023). Dalam penelitian ini, evaluasi model dilakukan untuk menilai kinerja model *Logistic Regression* dalam melakukan klasifikasi sentimen terhadap program Makan Bergizi Gratis.

3.7.1 *Confusion Matrix*

Confusion Matrix merupakan metode evaluasi yang digunakan untuk mengukur keberhasilan suatu model klasifikasi (Amal, 2023). Matriks ini menggambarkan performa kinerja model dalam menghasilkan prediksi yang tepat maupun keliru, yang dikelompokkan ke dalam empat jenis: *True Positives* (TP), *True Negatives* (TN), *False Positives* (FP), dan *False Negatives* (FN) (Norman &

Mahendra, 2024). Setiap klasifikasi menunjukkan kuantitas kejadian yang diprediksi secara akurat atau tidak akurat dalam dua kategori yang ditetapkan.

Berikut Tabel 3.9 yang menunjukkan confusion matrix.

Tabel 3. 10 Confusion Matrix

	Prediksi Positif (1)	Prediksi Negatif (0)
Aktual Positif (1)	<i>True Positives (TP)</i>	<i>False Negatives (FN)</i>
Aktual Negatif (0)	<i>False Positives (FP)</i>	<i>True Negatif (TN)</i>

Keterangan :

TP : Data positif yang diprediksi oleh model dengan benar
TN : Data negatif yang diprediksi oleh model dengan benar
FP : Data negatif diprediksi oleh model sebagai data positif
TN : Data positif diprediksi oleh model sebagai data negatif

3.7.2 Akurasi

Akurasi berfungsi sebagai metrik yang paling mendasar dan umum digunakan untuk mengevaluasi kinerja model. Akurasi dihitung melalui penilaian proporsi prediksi yang dianggap benar (baik *True Positives* maupun *True Negatives*) dalam klasifikasi (Khomsah & Aribowo, 2020). Akurasi dihitung dengan rumus seperti pada Persamaan 3.15.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \quad 3.15$$

Meskipun akurasi dapat menunjukkan seberapa sering model memberikan prediksi yang tepat, metrik ini dapat menyesatkan dalam kasus ketidakseimbangan kelas. Misalnya, jika satu kelas jauh lebih banyak daripada kelas lain, akurasi tinggi

dapat tercapai hanya dengan memprediksi kelas mayoritas, meskipun model tidak memprediksi kelas minoritas dengan baik (Arisandi, 2023).

3.7.3 Precision

Precision mengukur sejauh mana model secara tepat mengidentifikasi data kelas positif (Yoga Siswa, 2023). Nilai ini diperoleh dari perbandingan antara jumlah prediksi positif yang benar (*True Positives*, TP) dengan total prediksi positif yang dihasilkan model (*True Positives* + *False Positives*, FP). Dalam kata lain, *precision* memberi tahu kita seberapa banyak dari hasil prediksi positif yang sebenarnya benar. *Precision* yang memiliki angka persentase tinggi berarti model jarang membuat kesalahan dalam memprediksi kelas positif. *Precision* dihitung dengan rumus seperti pada Persamaan 3.16.

$$Precision = \frac{TP}{TP + FP} \quad 3.16$$

3.7.4 Recall

Recall mengukur kemampuan suatu model dalam mengidentifikasi atau menemukan data positif dari seluruh data positif yang tersedia (Bahtiar et al., 2023). *Recall* dihitung sebagai rasio antara jumlah prediksi positif yang benar (*True Positives*, TP) dan jumlah seluruh contoh positif yang sebenarnya ada dalam data (*True Positives* + *False Negatives*, FN). Dengan kata lain, *recall* memberi tahu seberapa banyak kelas positif yang tidak terlewatkan oleh model. *Recall* yang tinggi berarti model mampu mengidentifikasi hampir semua contoh kelas positif yang ada. *Recall* dihitung dengan rumus seperti pada Persamaan 3.17.

$$Recall = \frac{TP}{TP + FN} \quad 3.17$$

3.7.5 F1-Score

F1-Score adalah skor yang menggabungkan *precision* dan *recall* untuk memberikan penilaian keseluruhan mengenai performa model (Norman & Mahendra, 2024). *F1-Score* dihitung dengan rumus seperti pada Persamaan 3.18.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad 3.18$$

3.7.6 Skenario Pengujian

Dalam penelitian ini, model *Multinomial Logistic Regression* diuji melalui tiga skenario pengujian. Skenario pengujian ini dirancang untuk mengevaluasi pengaruh perbandingan rasio pembagian data, penerapan class weight pada model, serta variasi *learning rate* yang berbeda. Sebagai gambaran lebih jelas mengenai skenario pengujian yang dilakukan, berikut disajikan Tabel 3.11 yang menggambarkan perbandingan antara rasio pembagian data, penerapan class weight, dan variasi *learning rate* yang digunakan dalam penelitian ini.

Tabel 3. 11 Skenario Pengujian

Skenario Pengujian	Parameter yang Diuji	Deskripsi
Uji Coba 1	Rasio pembagian data	60:40, 70:30, 80:20, 90:10
Uji Coba 2	Penerapan <i>class weighting</i>	Dengan dan tanpa <i>class weighting</i>
Uji Coba 3	Variasi <i>learning rate</i>	0.1, 0.01, 0.001

Pengujian pertama bertujuan untuk menentukan akurasi pada setiap rasio *split* data atau pembagian data yang optimal antara data *training* dan data *testing*. Pembagian data antara data latih dan data uji dilakukan dengan 4 rasio perbandingan yang berbeda yakni 90:10, 80:20, 70:30, dan 60:40 (Prasetyo et al., 2024). Data *training* tersebut akan dilakukan latih dengan *learning rate* 0.01. Hasil dari pengujian ini bertujuan untuk memperoleh pemahaman mengenai bagaimana variasi rasio pembagian data dapat mempengaruhi performa model dalam mengklasifikasikan sentimen terhadap program Makan Bergizi Gratis.

Setelah menentukan rasio pembagian data yang optimal dari pengujian pertama, pengujian kedua dilakukan dengan penerapan *class weighting* pada model *Logistic Regression*. Penerapan *class weighting* bertujuan untuk penanganan terjadinya ketidakseimbangan kelas dalam dataset dengan memberikan bobot lebih besar pada kelas minoritas, sehingga model menjadi lebih sensitif terhadap kelas tersebut. *Class weighting* ini dapat membuat hasil performa model menjadi lebih tinggi atas penanganan ketidakseimbangan pada suatu dataset (Bakirarar & Elhan, 2023). Pengujian ini memungkinkan model untuk lebih akurat dalam memprediksi kelas yang kurang terwakili, seperti kelas netral, yang sebelumnya mungkin sulit dikenali oleh model tanpa adanya pembobotan.

Selanjutnya, pengujian model dilakukan uji coba lebih lanjut dengan variasi *learning rate* pada model yang telah diterapkan *class weighting*. *Learning rate* merupakan parameter penting dalam optimasi model yang memengaruhi performa model selama pelatihan (Cynthia et al., 2025). Tiga nilai *learning rate* yang diujikan diantaranya, 0.1, 0.01, dan 0.001. Sebelum dilakukan uji coba ketiga, nilai 0.01

dijadikan sebagai *learning rate* yang digunakan selama pengujian pertama dan kedua. Pengujian ini bertujuan untuk mengetahui apakah variasi *learning rate* berpengaruh secara signifikan terhadap akurasi serta kinerja model dalam mengklasifikasikan sentimen mengenai Program Makan Bergizi Gratis.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Uji Coba

Proses uji coba pada penelitian ini dilakukan untuk mengevaluasi kinerja model *Multinomial Logistic Regression* dalam mengklasifikasikan sentimen dari masyarakat terhadap program Makan Bergizi Gratis. Data yang digunakan dalam uji coba ini diperoleh dari platform media sosial X (sebelumnya Twitter), dengan memanfaatkan *Tweet Harvest* untuk mengekstrak tweet yang relevan dengan kata kunci "makan bergizi gratis". Data yang terkumpul terdiri dari 1134 tweet yang terdeteksi dalam bahasa Indonesia pada periode 1 hingga 31 Desember 2024. Proses pengumpulan data ini memiliki tujuan untuk memperoleh representasi yang representatif dari opini publik yang dibagikan melalui platform media sosial. Setelah data terkumpul, dilakukan labelisasi manual pada tweet yang ada, dengan mengklasifikasikan tweet ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Labelisasi dan validasi data dilakukan oleh seorang ahli bahasa untuk memastikan ketepatan kategori sentimen yang diberikan. Hasil labelisasi data menunjukkan bahwa kelas positif dan negatif masing-masing memiliki distribusi yang hampir seimbang, dengan kelas positif terdiri dari 481 tweet (42.42%) dan kelas negatif berjumlah 484 tweet (42.68%). Sedangkan jumlah kelas netral hanya sebanyak 169 tweet (14.90%).

Pada tahap uji coba ini, dilakukan dua skenario pengujian utama yang telah dilakukan preprocessing yang di dalamnya memiliki beberapa tahapan,

diantaranya, *case-folding*, *tokenizing*, *normalization*, *stopwords removal*, dan *stemming*. Dan dilanjutkan dengan pembobotan kata menggunakan TFIDF. Kemudian, pada skenario pertama dalam menguji rasio pembagian data *training* dan data *testing*, yang dilakukan dengan membagi dataset menjadi beberapa rasio yang berbeda, yaitu 60:40, 70:30, 80:20 dan 90:10. Tujuan dari skenario ini adalah untuk mengetahui pengaruh pembagian data terhadap performa model dalam mengklasifikasikan sentimen pada dataset. Skenario kedua bertujuan untuk mengevaluasi penerapan *class weighting* atau pembobotan kelas pada model, di mana pemberian bobot lebih pada kelas minoritas dilakukan untuk menangani ketidakseimbangan data pada tiap kelas dalam dataset. Dengan demikian, model akan lebih sensitif terhadap kelas yang jarang muncul, yang diharapkan dapat meningkatkan akurasi pada kelas minoritas. Setelah itu, dilanjutkan skenario ketiga dengan pengujian nilai *learning rate* yang berbeda. Skenario ketiga ini bertujuan untuk mengetahui seberapa besar pengaruh *learning rate* terhadap hasil model.

4.2 Hasil Uji Coba

Pada bagian ini, disajikan hasil dari pengujian yang telah dilakukan menggunakan berbagai skenario pembagian data, penerapan *class weighting* dan penerapan variasi *learning rate*. Proses uji coba pertama dilakukan pada rasio pembagian data *training* dan *testing*, yang selanjutnya diikuti oleh pengujian dengan menggunakan penerapan *class weighting* untuk mengatasi ketidakseimbangan kelas. Pada uji coba pertama dan kedua, digunakan *learning rate* sebesar 0.001. Selain melakukan uji coba dengan berbagai rasio pembagian data dan penerapan *class weighting*, juga dilakukan uji coba tambahan dengan

variasi *learning rate* untuk menguji seberapa besar pengaruh *learning rate* terhadap kinerja model.

4.2.1 Hasil Uji Coba 1

Pada uji coba pertama, kami membagi data dengan rasio 60:40 untuk *training* dan *testing*. Sebelum melakukan pembagian data, jumlah total data yang digunakan adalah 1134 data, dengan masing-masing kelas terdiri dari 481 data untuk kelas positif, 484 data untuk kelas negatif, dan 169 data untuk kelas netral. Setelah pembagian data, data *training* yang digunakan berjumlah 680 data, dengan 286 data untuk kelas positif, 302 data untuk kelas negatif, dan 92 data untuk kelas netral, sementara data *testing* berjumlah 454 data, dengan 179 data untuk kelas positif, 198 data untuk kelas negatif, dan 77 data untuk kelas netral.

Setelah proses pelatihan model selesai, diperoleh nilai bobot (*weights*) dan bias akhir sebagaimana ditampilkan pada Tabel 4.1 dan Tabel 4.2. Proses pelatihan mencapai konvergensi pada iterasi ke-158.600, yang menunjukkan bahwa parameter model telah stabil dan siap untuk evaluasi.


Tabel 4. 1 Hasil Akhir Bobot pada Uji Coba Pembagian Data (60:40)

[[-0.07630024 0.11832145 -0.04202121]			
[-0.18118038 0.2657899 -0.08460952]			
[-0.2176902 0.3188819 -0.1011917]			
...			
[-0.09317897 0.1586089 -0.06542994]			
[0. 0. 0.]			
[0. 0. 0.]]			

Tabel 4. 2 Hasil Akhir Bias pada Uji Coba Pembagian Data (60:40)

[-0.16287984 0.76080196 -0.59792212]			
--------------------------------------	--	--	--

Berikut adalah *confusion matrix* yang menunjukkan hasil evaluasi model pada skenario ini:



Gambar 4. 1 *Confusion Matrix* Untuk Rasio 60:40

Berdasarkan Gambar 4.2, hasil evaluasi menunjukkan bahwa model mendapatkan nilai sebagai berikut sebagai berikut:

$$Accuracy = 74.22\%$$

$$Precision = 65.75\%$$

$$Recall = 62.75\%$$

$$F1 - Score = 61.98\%$$

Pada uji coba selanjutnya, kami membagi data dengan rasio 70:30 untuk *training* dan *testing*. Setelah pembagian data, data *training* yang digunakan berjumlah 793 data, dengan 334 data untuk kelas positif, 352 data untuk kelas negatif, dan 107 data untuk kelas netral, sementara data *testing* berjumlah 341 data, dengan 150 data untuk kelas positif, 129 data untuk kelas negatif, dan 62 data untuk kelas netral.

Setelah proses pelatihan model selesai, diperoleh nilai bobot (*weights*) dan bias akhir sebagaimana ditampilkan pada Tabel 4.3 dan Tabel 4.4. Proses pelatihan

mencapai konvergensi pada iterasi ke-160.743, yang menunjukkan bahwa parameter model telah stabil dan siap untuk evaluasi.


Tabel 4. 3 Hasil Akhir Bobot pada Uji Coba Pembagian Data (70:30)

$\begin{bmatrix} -0.06621904 & 0.10650427 & -0.04028523 \\ -0.15750653 & 0.22785517 & -0.07034864 \\ -0.21448263 & 0.30873323 & -0.0942506 \end{bmatrix}$
...
$\begin{bmatrix} -0.08667865 & 0.15042231 & -0.06374366 \\ -0.14674125 & 0.22659356 & -0.0798523 \end{bmatrix}$
$\begin{bmatrix} 0. & 0. & 0. \end{bmatrix}$

Tabel 4. 4 Hasil Akhir Bias pada Uji Coba Pembagian Data (70:30)

$\begin{bmatrix} -0.1969643 & 0.74964824 & -0.55268394 \end{bmatrix}$

Berikut adalah *confusion matrix* yang menunjukkan hasil evaluasi model pada skenario ini:



Gambar 4. 2 *Confusion Matrix* Untuk Rasio 70:30

Berdasarkan Gambar 4.3, hasil evaluasi menunjukkan bahwa model mendapatkan nilai sebagai berikut sebagai berikut:

$$Accuracy = 73.02\%$$

$$Precision = 65.66\%$$

$$Recall = 61.58\%$$

$$F1 - Score = 59.95\%$$

Pada uji coba selanjutnya, kami membagi data dengan rasio 80:20 untuk *training* dan *testing*. Setelah pembagian data, data training yang digunakan berjumlah 907 data, dengan 391 data untuk kelas positif, 392 data untuk kelas negatif, dan 124 data untuk kelas netral, sementara data testing berjumlah 227 data, dengan 90 data untuk kelas positif, 92 data untuk kelas negatif, dan 45 data untuk kelas netral.

Setelah proses pelatihan model selesai, diperoleh nilai bobot (*weights*) dan bias akhir sebagaimana ditampilkan pada Tabel 4.7 dan Tabel 4.8. Proses pelatihan mencapai konvergensi pada iterasi ke-161.589, yang menunjukkan bahwa parameter model telah stabil dan siap untuk evaluasi.


Tabel 4. 5 Hasil Akhir Bobot pada Uji Coba Pembagian Data (80:20)

[-0.05746001 0.09510412 -0.03764411]
[-0.13238375 0.19094005 -0.05855629]
[-0.19351006 0.28004531 -0.08653525]
...
[-0.09006906 0.16444982 -0.07438076]
[-0.12574388 0.1966043 -0.07086042]
[0. 0. 0.]]

Tabel 4. 6 Hasil Akhir Bias pada Uji Coba Pembagian Data (80:20)

[-0.24257557 0.82916129 -0.58658571]

Berikut adalah *confusion matrix* yang menunjukkan hasil evaluasi model pada skenario ini:



Gambar 4. 3 Confution Matrix Untuk Rasio 80:20

Berdasarkan Gambar 4.4, hasil evaluasi menunjukkan bahwa model mendapatkan nilai sebagai berikut sebagai berikut:

$$Accuracy = 70.93\%$$

$$Precision = 63.08\%$$

$$Recall = 61.56\%$$

$$F1 - Score = 59.91\%$$

Pada uji coba selanjutnya, kami membagi data dengan rasio 90:10 untuk *training* dan *testing*. Setelah pembagian data, data *training* yang digunakan berjumlah 1020 data, dengan 440 data untuk kelas positif, 434 data untuk kelas negatif, dan 146 data untuk kelas netral, sementara data testing berjumlah 114 data, dengan 41 data untuk kelas positif, 50 data untuk kelas negatif, dan 23 data untuk kelas netral.

Setelah proses pelatihan model selesai, diperoleh nilai bobot (*weights*) dan bias akhir sebagaimana ditampilkan pada Tabel 4.9 dan Tabel 4.10. Proses pelatihan mencapai konvergensi pada iterasi ke-164.162, yang menunjukkan bahwa parameter model telah stabil dan siap untuk evaluasi.

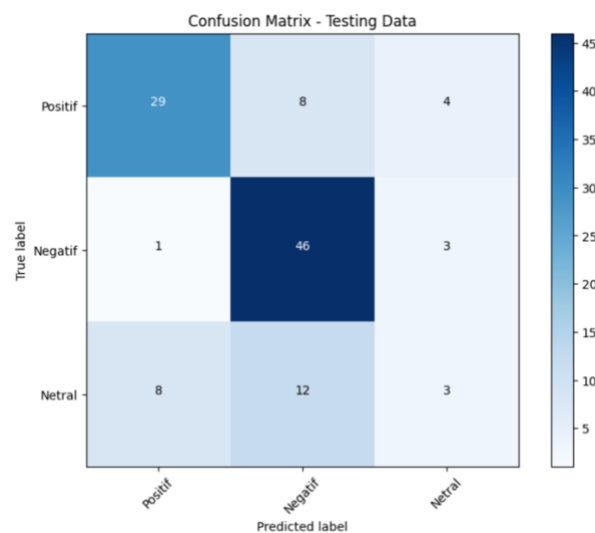
Tabel 4. 7 Hasil Akhir Bobot pada Uji Coba Pembagian Data (90:10)

[[-0.05271147 0.09115863 -0.03844716]
[-0.12374127 0.17307668 -0.04933542]
[-0.17787606 0.25845841 -0.08058235]
...
[-0.08187733 0.15129996 -0.06942263]
[-0.1111321 0.1767204 -0.0655883]
[0. 0. 0.]]

Tabel 4. 8 Hasil Akhir Bias pada Uji Coba Pembagian Data (90:10)

[-0.27914246 0.81375878 -0.53461632]

Berikut adalah *confusion matrix* yang menunjukkan hasil evaluasi model pada skenario ini:



Gambar 4. 4 *Confution Matrix* Untuk Rasio 90:10

Berdasarkan Gambar 4.5, hasil evaluasi menunjukkan bahwa model mendapatkan nilai sebagai berikut sebagai berikut:

$$Accuracy = 68.42\%$$

$$Precision = 58.67\%$$

$$Recall = 58.59\%$$

$$F1 - Score = 56.95\%$$

Tabel 4. 9 Perbandingan Hasil Uji Coba 1

Ratio	Accuracy	Precision	Recall	F1-Score
60:40	74.22%	65.74%	62.74%	62%
70:30	73.02%	65.65%	61.58%	59.96%
80:20	70.92%	63.07%	61.55%	59.92%
90:10	68.42%	58.67%	58.59%	56.95%

Dari Tabel 4.9, dapat dilihat bahwa nilai akurasi menunjukkan konsistensi di semua rasio pembagian data yang diuji. Meskipun terdapat variasi dalam pembagian data, model tetap menghasilkan nilai evaluasi yang hampir identik di setiap skenario. Hal ini menunjukkan bahwa perbedaan rasio pembagian data tidak memberikan dampak signifikan terhadap kinerja model. Dengan demikian, model ini terbukti *robust* terhadap perubahan rasio, dan hasil evaluasi yang konsisten menunjukkan kinerja yang optimal pada berbagai skenario pembagian data. Sehingga, rasio pembagian data yang digunakan dalam uji coba ini diterapkan pada tahap uji coba selanjutnya, yaitu untuk menguji penerapan *class weighting* dalam model yang mana rasio pembagian data yang digunakan adalah rasio pembagian yang menghasilkan nilai akurasi tertinggi.

4.2.2 Hasil Uji Coba 2

Pada uji coba kedua, dilakukan penerapan *class weighting* untuk mengatasi ketidakseimbangan kelas dalam dataset. Setelah proses pelatihan model selesai, diperoleh nilai bobot (*weights*) dan bias akhir sebagaimana ditampilkan pada Tabel 4.10 dan Tabel 4.11. Proses pelatihan mencapai konvergensi pada iterasi ke-160.426, yang menunjukkan bahwa parameter model telah stabil dan siap untuk evaluasi.


Tabel 4. 10 Hasil Akhir Bobot pada Uji Coba Penggunaan *Class Weighting*

[[-0.06145016 0.11772401 -0.05627385]
[-0.13972926 0.24866084 -0.10893158]
[-0.17012096 0.30050209 -0.13038113]
...
[-0.07447045 0.16319804 -0.08872759]
[0. 0. 0.]
[0. 0. 0.]]

Tabel 4. 11 Hasil Akhir Bias pada Uji Coba Penggunaan *Class Weighting*

[-0.27957466 0.61653039 -0.33695573]

Berikut adalah hasil evaluasi model setelah penerapan *class weighting* pada rasio pembagian 60:40 yang didapat dari uji coba 1 dengan rasio dengan akurasi terbaik dibanding lainnya:



Gambar 4. 5 *Confusion Matrix* Untuk Penggunaan *Class Weighting*

Berdasarkan Gambar 4.6, hasil evaluasi menunjukkan bahwa model mendapatkan nilai sebagai berikut sebagai berikut:

$$Accuracy = 76.21\%$$

$$Precision = 70.05\%$$

$$Recall = 68.21\%$$

$$F1 - Score = 68.68\%$$

Berikut adalah tabel perbandingan antara hasil uji coba model dengan dan tanpa penerapan *class weighting* pada rasio pembagian data 60:40:

Tabel 4. 12 Perbandingan Hasil Uji Coba 2

Metriks	Tanpa <i>Class Weighting</i>	Dengan <i>Class Weighting</i>
Accuracy	74.22%	76.21%
Precision	65.74%	70.04%
Recall	62.74%	68.21%
F1-Score	62%	68.68%

Tabel 4.12 menunjukkan perbandingan antara hasil uji coba model dengan dan tanpa penerapan *class weighting* pada rasio pembagian data 60:40. Penerapan *class weighting* berhasil meningkatkan performa model pada semua metrik evaluasi, termasuk akurasi, *precision*, *recall*, dan *F1-score*. Hasil evaluasi menunjukkan bahwa dengan *class weighting*, model mengalami peningkatan signifikan, terutama pada *precision* (dari 65.74% menjadi 70.04%) dan *recall* (dari 62.74% menjadi 68.21%), yang menandakan bahwa *class weighting* efektif dalam mengatasi ketidakseimbangan kelas pada dataset. *F1-Score* juga meningkat dari 62% menjadi 68.68%, menunjukkan keseimbangan yang lebih baik antara *precision* dan *recall*.

Berdasarkan *confusion matrix* yang ditampilkan pada Gambar 4.6, penerapan *class weighting* memberikan dampak yang signifikan terutama pada kelas netral. Sebelum penerapan *class weighting*, kelas netral sering kali terabaikan, dengan 32 *False Negatives* (FN) dan hanya 28 *True Positives* (TP). Namun, setelah penerapan *class weighting*, TP untuk kelas netral meningkat menjadi 28, sementara FN berkurang menjadi 17, yang menandakan bahwa model lebih mampu mengidentifikasi tweet dengan sentimen netral. Sementara itu, kelas positif dan negatif juga mengalami peningkatan kinerja, dengan *True Positives* (TP) untuk kelas positif tetap stabil di 143, dan untuk kelas negatif meningkat menjadi 175. Peningkatan performa pada kelas netral, yang sebelumnya lebih sulit dideteksi, menunjukkan bahwa *class weighting* berhasil memperbaiki keseimbangan kelas, sehingga model menjadi lebih sensitif terhadap kelas yang kurang terwakili tersebut.

4.2.3 Hasil Uji Coba 3

Pada uji coba ketiga, pengujian dilakukan dengan membandingkan tiga nilai *learning rate* yang berbeda, yaitu 0.1, 0.01, dan 0.001, dengan rasio pembagian data 60:40 antara data *training* dan data *testing*, serta penerapan *class weighting*. Tujuan pengujian, digunakan untuk mengukur pengaruh variasi *learning rate* terhadap performa model *Logistic Regression* dalam mengklasifikasikan sentimen dari masyarakat terhadap program Makan Bergizi Gratis. Sebelumnya, pada uji coba kedua, model dengan *learning rate* 0.01 dan juga dilakukan penerapan *class weighting* memberikan hasil evaluasi yang cukup baik dengan akurasi 76.21%, *precision* 70.04%, *recall* 68.21%, dan *F1-score* 68.68%.

Berikut Tabel 4. 13 perbandingan hasil uji coba 3:

Tabel 4. 13 Perbandingan Hasil Uji Coba 3

Learning rate	Accuracy	Precision	Recall	F1-Score
0.1	75.99%	69.49%	67.53%	67.95%
0.01	76.21%	70.04%	68.21%	68.68%
0.001	74.88%	70.98%	69.35%	69.59%

Dari Tabel 4. 13, hasil uji coba dapat dilihat bahwa akurasi pada setiap variasi *learning rate* menunjukkan perbedaan yang relatif kecil antara model dengan *learning rate* 0.1, 0.01, dan 0.001. *Learning rate* 0.01 menghasilkan akurasi tertinggi, yaitu 76.21%, diikuti oleh *learning rate* 0.1 dengan 75.99%, dan *learning rate* 0.001 yang sedikit lebih rendah, yaitu 74.88%. Meskipun terdapat sedikit penurunan pada akurasi untuk *learning rate* 0.001, perbedaan ini tidak terlalu signifikan. Hal ini menandakan bahwa model mampu mempertahankan kinerjanya secara konsisten meskipun terjadi perubahan pada nilai *learning rate*. Namun, saat

melihat metrik lain seperti *precision*, *recall*, dan *F1-score*, *learning rate* 0.001 memberikan hasil yang lebih baik, dengan *precision* 70.98% dan *recall* 69.35%, lebih tinggi dibandingkan dengan *learning rate* 0.1 dan 0.01. Ini menunjukkan bahwa *learning rate* 0.001 lebih sensitif dalam mendeteksi sentimen positif dan negatif, meskipun kelas netral tetap menunjukkan *recall* yang lebih rendah dibandingkan dengan kedua *learning rate* lainnya. Berdasarkan hasil ini, dapat disimpulkan bahwa *learning rate* 0.001 lebih optimal untuk model ini dalam hal *precision*, *recall*, dan *F1-score*, meskipun *learning rate* 0.01 memberikan hasil yang hampir setara dalam akurasi.

Pada uji coba ini, *learning rate* yang lebih besar (0.1) menghasilkan akurasi yang hampir setara dengan *learning rate* 0.01, namun dengan *precision* dan *recall* yang lebih rendah. Ini terjadi karena model dengan *learning rate* yang lebih tinggi cenderung melakukan pembaruan parameter yang lebih besar pada setiap iterasi, yang dapat menyebabkan model meleset dari pola-pola yang lebih halus dalam data, seperti yang terdapat pada kelas netral. Sebaliknya, *learning rate* yang lebih kecil (0.001) memberikan sedikit penurunan pada akurasi, tetapi menunjukkan peningkatan yang signifikan dalam *precision* dan *recall*, terutama untuk kelas negatif. Hal ini mengindikasikan bahwa *learning rate* 0.001 lebih cermat dalam mendeteksi sentimen positif dan negatif, serta mengurangi *False Negatives* (FN) secara signifikan. Meskipun kelas netral tetap menjadi tantangan, model dengan *learning rate* 0.001 tetap lebih sensitif dalam mendeteksi pola-pola halus, terutama pada dataset yang lebih kompleks dan tidak seimbang. Secara keseluruhan, meskipun *learning rate* 0.01 memberikan akurasi tertinggi, *learning rate* 0.001

lebih optimal dalam meningkatkan *precision*, *recall*, dan *F1-score*, serta lebih sensitif terhadap pola pada data yang lebih halus. Oleh karena itu, *learning rate* 0.001 dapat dianggap sebagai pilihan yang lebih baik untuk mengoptimalkan kinerja model ini.

4.3 Pembahasan

Pada uji coba pertama, dilakukan pengujian dengan empat rasio pembagian data untuk training dan testing. Total data yang digunakan berjumlah 1134, yang terdiri dari 481 data untuk kelas positif, 484 data untuk kelas negatif, dan 169 data untuk kelas netral. Pembagian data yang dilakukan dengan rasio 60:40, di mana data training mencakup 680 data, yang terdiri dari 286 data untuk kelas positif, 302 data untuk kelas negatif, dan 92 data untuk kelas netral. Sementara itu, data *testing* berjumlah 454 data, yang terdiri dari 179 data untuk kelas positif, 198 data untuk kelas negatif, dan 77 data untuk kelas netral. Berdasarkan *confusion matrix* pada Gambar 4.2, model menghasilkan akurasi sebesar 74.22%, *precision* sebesar 65.74%, *recall* sebesar 62.74%, dan *F1-score* sebesar 62%. Dalam hal ini, model berhasil mengklasifikasikan data positif dan negatif dengan baik, namun kesulitan dalam mengklasifikasikan kelas netral. *False Negative* (FN) pada kelas netral menunjukkan bahwa model cenderung salah memprediksi data netral sebagai negatif atau positif. Hal ini dapat dijelaskan oleh ketidakseimbangan kelas yang ada dalam dataset, di mana kelas netral memiliki proporsi yang lebih kecil dibandingkan kelas positif dan negatif. Meski demikian, model menunjukkan konsistensi performa pada kelas positif dan negatif, dengan *True Positive* (TP) yang tinggi pada kedua kelas tersebut.

Pada uji coba pertama selanjutnya, data dibagi dengan rasio 70:30 untuk *training* dan *testing*. Setelah pembagian, data training berjumlah 793 data, dengan rincian 334 data untuk kelas positif, 352 data untuk kelas negatif, dan 107 data untuk kelas netral, sedangkan data testing berjumlah 341 data, dengan rincian 150 data untuk kelas positif, 129 data untuk kelas negatif, dan 62 data untuk kelas netral. Hasil evaluasi pada *confusion matrix* di Gambar 4.3 menunjukkan bahwa model mendapatkan akurasi sebesar 73.02%, *precision* sebesar 65.65%, *recall* sebesar 61.58%, dan *F1-score* sebesar 59.96%. Meskipun terjadi penurunan pada akurasi dan *precision* dibandingkan dengan uji coba pertama, model masih menunjukkan performa yang cukup baik dalam mengklasifikasikan kelas positif dan negatif. Kelas netral kembali menjadi tantangan, dengan *False Negative* (FN) yang tinggi. Penurunan pada *precision* dan *recall* menunjukkan bahwa rasio pembagian yang lebih besar pada data training tidak serta merta memperbaiki kinerja model, terutama dalam mengidentifikasi kelas netral yang kurang terwakili dalam data.

Pada uji coba pertama selanjutnya, data dibagi dengan rasio 80:20 untuk *training* dan *testing*. Hasil evaluasi berdasarkan *confusion matrix* pada Gambar 4.4 menunjukkan akurasi sebesar 70.92%, *precision* sebesar 63.07%, *recall* sebesar 61.55%, dan *F1-score* sebesar 59.92%. Pada rasio ini, akurasi mengalami penurunan lebih lanjut dibandingkan dengan uji coba sebelumnya. Model masih memiliki kemampuan yang cukup baik untuk mengidentifikasi data positif dan negatif, namun kelas netral kembali menjadi masalah besar dengan tingkat *False Negative* (FN) yang tinggi. Penurunan akurasi menunjukkan bahwa model mulai kesulitan ketika rasio data testing meningkat. Hal ini mungkin disebabkan oleh

jumlah data *training* yang lebih sedikit, sehingga model tidak memiliki cukup informasi untuk menggeneralisasi dengan baik pada data *testing*. Selain itu, kesulitan dalam mengidentifikasi kelas netral menandakan bahwa ketidakseimbangan kelas yang ada di dataset masih mempengaruhi kinerja model secara signifikan.

Pada uji coba pertama selanjutnya, data dibagi dengan rasio 90:10 untuk *training* dan *testing*. Hasil evaluasi berdasarkan *confusion matrix* pada Gambar 4.5 menunjukkan akurasi sebesar 68.42%, *precision* sebesar 58.67%, *recall* sebesar 58.59%, dan *F1-score* sebesar 56.96%. Pada rasio ini, akurasi menurun secara signifikan dibandingkan dengan rasio pembagian lainnya. Hal ini mengindikasikan bahwa dengan data *testing* yang lebih besar, model kesulitan untuk mengklasifikasikan dengan baik. *False Positive* (FP) dan *False Negative* (FN) pada kelas netral masih menjadi masalah utama, mengingat ketidakseimbangan kelas yang ada. Penurunan pada *precision*, *recall*, dan akurasi menandakan bahwa meskipun rasio 90:10 memberikan lebih banyak data testing, model tidak mampu mengidentifikasi pola dengan baik karena kurangnya data *training*. Ini menggarisbawahi pentingnya memilih rasio pembagian yang tepat untuk menjaga keseimbangan antara data *training* dan data *testing*.

Pada uji coba kedua, *class weighting* diterapkan pada rasio pembagian data 60:40, yang sebelumnya menunjukkan hasil terbaik. Evaluasi berdasarkan *confusion matrix* pada Gambar 4.6, menghasilkan akurasi 76.21%, *precision* 70.04%, *recall* 68.21%, dan *F1-score* 68.68%. Penerapan *class weighting* meningkatkan kinerja model secara keseluruhan dibandingkan dengan tanpa *class*

weighting. Pada *confusion matrix* tanpa *class weighting*, model memiliki TP (*True Positive*) yang cukup baik pada kelas positif (144) dan negatif (180), tetapi kurang baik pada kelas netral (13). Setelah penerapan *class weighting*, TP pada kelas positif sedikit menurun (143), namun TP pada kelas negatif juga sedikit menurun (175), namun TP pada kelas netral meningkat signifikan (28). Selain itu, *class weighting* cenderung mengurangi jumlah kesalahan klasifikasi, terlihat dari penurunan nilai FP (*False Positive*) dan FN (*False Negative*) secara keseluruhan, yang pada akhirnya meningkatkan *recall* dan *precision*, terutama pada kelas netral yang sebelumnya bermasalah. Secara khusus, perhatikan bagaimana *class weighting* membantu model untuk lebih akurat mengidentifikasi kelas netral, yang sebelumnya sering salah diklasifikasikan sebagai positif atau negatif (tercermin dari tingginya nilai FP dan FN pada kelas ini sebelum *class weighting*).

Pada uji coba ketiga, Pada uji coba ketiga, dilakukan pengujian dengan tiga nilai *learning rate* yang berbeda, yaitu 0.1, 0.01, dan 0.001, dengan rasio pembagian data 60:40 untuk *training* dan *testing*, serta penerapan *class weighting*. Tujuan dari pengujian ini adalah untuk mengukur pengaruh variasi *learning rate* terhadap performa model *Logistic Regression* dalam mengklasifikasikan sentimen masyarakat terhadap program Makan Bergizi Gratis. Sebelumnya, pada uji coba kedua, model dengan *learning rate* 0.01 dan *class weighting* menghasilkan akurasi 76.21%, *precision* 70.04%, *recall* 68.21%, dan *F1-score* 68.68%.

Pada uji coba dengan *learning rate* 0.001, model mencapai akurasi 74.88%, *precision* 70.98%, *recall* 69.35%, dan *F1-score* 69.59%. Dalam hal ini, TP untuk kelas positif meningkat menjadi 175, dan FN untuk kelas netral sedikit lebih rendah

dibandingkan dengan *learning rate* 0.1. Meskipun akurasi sedikit menurun, *precision* dan *recall* lebih baik pada kelas negatif, dengan TP mencapai 175 dan FN yang lebih rendah. Ini menunjukkan bahwa *learning rate* yang lebih kecil (0.001) membuat model lebih sensitif dalam mendeteksi sentimen negatif, serta memperbaiki keseimbangan antara *precision* dan *recall* untuk kelas negatif.

Namun, meskipun *learning rate* 0.001 memberikan deteksi yang lebih baik pada kelas negatif, kelas netral tetap menjadi tantangan besar, dengan *False Positive* (FP) dan *False Negative* (FN) yang cukup tinggi. Hal ini menunjukkan bahwa meskipun *learning rate* 0.001 memberikan peningkatan pada *precision* dan *recall* untuk kelas positif dan negatif, perbaikan lebih lanjut masih diperlukan untuk mengidentifikasi kelas netral dengan lebih akurat.

4.4 Integrasi Penelitian dengan Islam

Dalam perspektif Islam, pentingnya menjaga keseimbangan dalam kehidupan, termasuk dalam hal penyampaian informasi dan opini publik, dapat dihubungkan dengan prinsip-prinsip etika dan keadilan. Agama Islam sangat menekankan pentingnya kejujuran dalam berbicara, termasuk dalam menyampaikan pendapat melalui media, baik itu media sosial atau platform lainnya. Hal ini dapat dihubungkan dengan penelitian ini yang berfokus pada klasifikasi sentimen masyarakat terhadap program Makan Bergizi Gratis. Islam mengajarkan bahwa dalam menyampaikan sesuatu, kita harus memperhatikan kebenaran dan keadilan, tanpa menyebarkan informasi yang menyesatkan atau tidak akurat.

Dalam konteks ini, model klasifikasi sentimen yang digunakan dalam penelitian, berusaha menggambarkan opini publik secara objektif dan adil, tanpa memihak satu pihak tertentu, sehingga menjaga integritas informasi yang disebarluaskan kepada masyarakat. Hal ini searah dengan prinsip dalam ajaran Islam yang menegaskan pentingnya melakukan verifikasi atas kebenaran suatu informasi sebelum mempercayai maupun menyebarkan, sebagaimana tertulis dalam Surah Al-Hujurat (49:6):

يَا أَيُّهَا الَّذِينَ آمَنُوا إِن جَاءَكُمْ فَاسِقٌ بِنَبَأٍ فَتَبَيَّنُوا أَن تُصِيبُوا قَوْمًا بِجَهَالَةٍ فَتُصْحِحُوا عَلَىٰ مَا فَعَلْتُمْ نُدْمِينَ ﴿٦﴾

"Wahai orang-orang yang beriman, jika seorang fasik datang kepadamu membawa berita penting, maka telitilah kebenarannya agar kamu tidak mencelakakan suatu kaum karena ketidaktahuan(-mu) yang berakibat kamu menyesali perbuatanmu itu."

Ayat ini mengajarkan kepada umat Islam untuk tidak sembarangan menerima dan menyebarkan berita, dan memastikan kebenarannya terlebih dahulu. Dalam konteks penelitian ini, prinsip ini relevan dalam hal menganalisis dan mengklasifikasikan sentimen publik terkait kebijakan atau program pemerintah. Sebelum menyebarkan hasil klasifikasi sentimen, penting untuk memastikan terkait data yang digunakan valid dan tidak menyesatkan, agar tidak merugikan pihak-pihak yang tidak bersalah. Prinsip ini juga berhubungan dengan objektivitas dalam penelitian yang bertujuan untuk menggali opini publik secara adil. Penelitian ini bertujuan agar hasil klasifikasi sentimen dapat mencerminkan pandangan masyarakat dengan jujur dan tidak memihak, sehingga dapat memberikan wawasan yang berguna bagi pengambil kebijakan untuk memperbaiki dan menyempurnakan kebijakan yang ada agar lebih berpihak kepada kebaikan umat.

Selain prinsip keadilan dan kejujuran dalam penyebaran informasi, Islam juga mengajarkan umatnya untuk menjadi umat yang terbaik, yang senantiasa mengajak kepada kebaikan dan mencegah kemungkaran. Surah Ali Imran (3:110) menyatakan:

كُنْتُمْ خَيْرَ أُمَّةٍ أُخْرِجَتْ لِلنَّاسِ تَأْمُرُونَ بِالْمَعْرُوفِ وَتَنْهَوْنَ عَنِ الْمُنْكَرِ وَتُؤْمِنُونَ بِاللَّهِ وَلَوْ آمَنَ أَهْلُ الْكِتَابِ

لَكَانَ خَيْرًا لَّهُمْ مِنْهُمْ الْمُؤْمِنُونَ وَأَكْثَرُهُمُ الْفَاسِقُونَ ﴿١١٠﴾

"Kamu (umat Islam) adalah umat terbaik yang dilahirkan untuk manusia (selama) kamu menyuruh (berbuat) yang makruf, mencegah dari yang mungkar, dan beriman kepada Allah. Seandainya Ahlulkitab beriman, tentulah itu lebih baik bagi mereka. Di antara mereka ada yang beriman dan kebanyakan mereka adalah orang-orang fasik."

Tafsir Ibnu Katsir menjelaskan bahwa ayat ini menyampaikan terkait peran umat Islam sebagai umat yang terbaik, dengan tugas mulia untuk mendorong perbuatan yang baik (*amar ma'ruf*) serta menghindarkan dari hal-hal yang salah (*nahi munkar*). Dalam konteks sosial, tugas ini tidak hanya terbatas pada aspek ibadah pribadi, tetapi juga berperan aktif dalam mempengaruhi kehidupan masyarakat secara luas. Umat Islam tidak hanya diharapkan menjadi penerima kebaikan, tetapi juga menjadi penyebar kebaikan melalui kata-kata, tindakan, dan kebijakan yang mereka dorong.

Prinsip "*amar ma'ruf nahi munkar*" yang terkandung dalam ayat ini mengajarkan bahwa umat Islam harus berperan aktif dalam menyuarakan hal-hal yang bermanfaat dan konstruktif, serta menghindari penyebaran informasi yang dapat merugikan bahkan menyesatkan. Dalam konteks penelitian ini, penggunaan *machine learning* untuk klasifikasi sentimen publik sejalan dengan prinsip Islam

ini, karena bertujuan untuk mendistribusikan informasi yang akurat dan objektif, serta memberikan wawasan yang berguna bagi pengambil kebijakan. Penelitian ini berusaha untuk mengevaluasi dan menggambarkan performa model yang digunakan dalam mengklasifikasikan sentimen publik secara akurat dan adil, tanpa memihak, serta menghindari penyebaran informasi yang salah atau menyesatkan. Dengan demikian, studi ini mampu memberikan sumbangan yang positif dalam menyempurnakan kebijakan yang ada, sesuai dengan prinsip Islam untuk menyebarkan kebaikan dan kebenaran, serta menghindari kesalahan informasi yang bisa merugikan masyarakat.

Selain itu, kita juga diajarkan untuk selalu memegang amanah. Sebagaimana disebutkan dalam hadist berikut:

كُلُّكُمْ رَاعٍ وَكُلُّكُمْ مَسْئُولٌ عَنْ رَعِيَّتِهِ

“Setiap kalian adalah pemimpin dan setiap pemimpin akan dimintai pertanggung jawaban atas yang dipimpinnya. (HR. Bukhori).

Hadist ini mengingatkan bahwa setiap individu yang memiliki tanggung jawab atau posisi dalam masyarakat harus memegang amanah dengan baik, termasuk dalam menyampaikan informasi atau keputusan yang berkaitan dengan masyarakat. Dalam konteks penelitian ini, memastikan bahwa hasil analisis dan kebijakan yang dapat dipertanggungjawabkan adalah bagian dari amanah yang harus dijaga.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil penelitian ini, dapat disimpulkan bahwa metode *Multinomial Logistic Regression* menunjukkan performa yang stabil dalam mengklasifikasikan sentimen publik terhadap Program Makan Bergizi Gratis. Variasi rasio pembagian data (60:40, 70:30, 80:20, dan 90:10) tidak memberikan dampak signifikan terhadap hasil yang diperoleh, dengan rasio 60:40 memperoleh akurasi tertinggi sebesar 74.22%. Penerapan *class weighting* terbukti efektif dalam mengatasi ketidakseimbangan kelas, khususnya pada kelas netral, yang meningkatkan akurasi menjadi 76.21% serta *precision* 70.04%, *recall* 68.21%, dan *F1-score* 68.68%. Pemilihan *learning rate* juga berperan penting, di mana *learning rate* sebesar 0.001 memberikan hasil terbaik secara keseluruhan dengan akurasi 74.88%, *precision* 70.98%, *recall* 69.35%, dan *F1-score* 69.59%, serta peningkatan signifikan pada *precision* dan *recall* untuk kelas negatif. Penelitian ini menunjukkan bahwa metode *Multinomial Logistic Regression*, dengan pemilihan rasio pembagian data yang tepat, penerapan *class weighting* dan pengaturan *learning rate* yang optimal, dapat menghasilkan kinerja yang memadai dalam klasifikasi sentimen publik terhadap program ini. Pendekatan ini juga dapat diterapkan untuk klasifikasi sentimen dalam konteks program-program serupa yang memberikan gambaran jelas terkait persepsi masyarakat terhadap suatu kebijakan atau program tertentu.

5.2 Saran

Berdasarkan hasil penelitian ini, terdapat beberapa saran yang dapat dipertimbangkan untuk meningkatkan kualitas dan akurasi klasifikasi sentimen terhadap program Makan Bergizi Gratis (MBG), baik pada sisi data, *preprocessing*, maupun eksplorasi model lainnya:

1. Penggunaan data yang lebih besar, yang mencakup data yang diperoleh selama atau setelah pelaksanaan program Makan Bergizi Gratis. Hal ini dapat membantu model untuk lebih akurat dalam mengklasifikasikan sentimen yang terkait langsung dengan pelaksanaan program.
2. Melakukan eksplorasi penggunaan teknik pembobotan lain seperti Word2Vec atau GloVe yang dapat menangkap hubungan semantik antar kata dan memberikan representasi vektor yang lebih kaya.
3. Melakukan eksplorasi metode klasifikasi lain yang dapat dijadikan sebagai pembandingan, seperti menerapkan pembelajaran berbasis konteks, yang dapat membantu model dalam memahami makna kata dalam kalimat yang lebih kompleks.

DAFTAR PUSTAKA

- Ahuja, R., Chug, A., Kohli, S., Gupta, S., & Ahuja, P. (2019). The Impact of Features Extraction on the Sentiment Analysis. *Procedia Computer Science*, 152, 341–348. <https://doi.org/10.1016/j.procs.2019.05.008>
- Akbi, D. R., & Rosyadi, A. R. (2018). Analisis Klasterisasi Malware: Evaluasi Data Training Dalam Proses Klasifikasi Malware. *Jurnal ELTIKOM*, 2(2), 58–66. <https://doi.org/10.31961/eltikom.v2i2.88>
- Amal, I. (2023). Perbandingan Pelabelan Otomatis Dan Manual Untuk Analisis Sentimen Terhadap Kenaikan Harga BBM Pertamina Pada Twitter Menggunakan Algoritma Support Vector Machine.
- Arisandi, R. (2023). Perbandingan Model Klasifikasi Random Forest Dengan Resampling dan Tanpa Resampling pada Pasien Penderita Gagal Jantung. *Jurnal Gaussian*, 12(1), 136–145. <https://doi.org/10.14710/j.gauss.12.1.136-145>
- Ash Shiddicky & Surya Agustian. (2022). Analisis Sentimen Masyarakat Terhadap Kebijakan Vaksinasi Covid-19 pada Media Sosial Twitter menggunakan Metode Logistic Regression. *Jurnal CoSciTech (Computer Science and Information Technology)*, 3(2), 99–106. <https://doi.org/10.37859/coscitech.v3i2.3836>
- Bahtiar, S. A. H., Dewa, C. K., & Luthfi, A. (2023). Comparison of Naïve Bayes and Logistic Regression in Sentiment Analysis on Marketplace Reviews Using Rating-Based Labeling. *Journal of Information Systems and Informatics*, 5(3), 915–927. <https://doi.org/10.51519/journalisi.v5i3.539>
- Cynthia, E. P., Saeed, A. H., Eka, M., & Nursalisah, F. (2025). *Pengaruh Parameter Learning Rate terhadap Konvergensi Model Neural Network dalam Proses Pelatihan*. 1(1).
- Dewey, K. G., & Begum, K. (2011). Long-term consequences of stunting in early life. *Maternal & Child Nutrition*, 7(s3), 5–18. <https://doi.org/10.1111/j.1740-8709.2011.00349.x>
- Dirgantara, W., Fairuz Iqbal Maulana, Subairi, & Rahman Arifuddin. (2024). The Performance of Machine Learning Model Bernoulli Naïve Bayes, Support Vector Machine, and Logistic Regression on COVID-19 in Indonesia using

- Sentiment Analysis. *Techné : Jurnal Ilmiah Elektroteknika*, 23(1), 153–162. <https://doi.org/10.31358/techne.v23i1.446>
- Elsa Triningsih, M Afdal, Inggih Permana, & Nesdi Evrilyan Rozanda. (2025). *Building of Informatics, Technology and Science (BITS)*. 6(4).
- Emeraldien, F. Z., Sunarsono, R. J., & Alit, R. (2019). Twitter Sebagai Platform Komunikasi Politik di Indonesia. *Scan : Jurnal Teknologi Informasi dan Komunikasi*, 14(1), 21–30. <https://doi.org/10.33005/scan.v14i1.1457>
- Hanani, A. (2023). Algoritma Term Frequency – Inverse Document Frequency (TF-IDF).
- Imamah, & Rachman, F. H. (2020). Twitter Sentiment Analysis of Covid-19 Using Term Weighting TF-IDF And Logistic Regresion. *2020 6th Information Technology International Seminar (ITIS)*, 238–242. <https://doi.org/10.1109/ITIS50118.2020.9320958>
- Jurafsky, D., & Martin, J. H. (2024). Speech and Language Processing.
- KEMENKO PMK. (2024). Program Makan Bergizi Gratis, Wujudkan SDM Unggul Melalui Perbaikan Gizi | Kementerian Koordinator Bidang Pembangunan Manusia dan Kebudayaan. <https://www.kemenkopmk.go.id/program-makan-bergizi-gratis-wujudkan-sdm-unggul-melalui-perbaikan-gizi>
- Kemensetneg. (2024). *Kementerian Sekretariat Negara Republik Indonesia*. Makan Bergizi Gratis Dan SDM Unggul. https://www.setneg.go.id/baca/index/makan_bergizi_gratis_dan_sdm_unggul
- Khomsah, S., & Aribowo, A. S. (2020). Model Text-Preprocessing Komentar Youtube Dalam Bahasa Indonesia. 4(4).
- Liu, B. (2012). Sentiment Analysis and Opinion Mining. *Morgan & Claypool Publishers*.
- Maulana, A., Inayah Khasnaputri Afifah, Asghafi Mubarrak, Kiagus Rachmat Fauzan, Ardhan Dwintara, & Zen, B. P. (2023). Comparison of Logistic Regression, MultinomialNB, SVM, And K-NN Methods on Sentiment Analysis of Gojek App Reviews on The Google Play Store. *Jurnal Teknik Informatika (Jutif)*, 4(6), 1487–1494. <https://doi.org/10.52436/1.jutif.2023.4.6.863>

- Norman, S. S., & Mahendra, S. (2024). Analisis Sentimen Tingkat Kepuasan Pelanggan Terhadap Layanan Kurir J&T Express Menggunakan Algoritma Support Vector Machine (SVM) Berdasarkan Ulasan Pengguna di Google Playstore. *Jurnal Sains & Teknologi Fakultas Teknik Universitas Darma Persada*, 13(2), 29–36. <https://doi.org/10.70746/jstunsada.v13i2.450>
- Nugroho, A. C. (2024). Klasifikasi Sentimen Dalam Forum Diskusi Mahasiswa: Sebuah Pendekatan Machine Learning. 1.
- Nurhaliza Agustina, C. A., Novita, R., Mustakim, & Rozanda, N. E. (2024). The Implementation of TF-IDF and Word2Vec on Booster Vaccine Sentiment Analysis Using Support Vector Machine Algorithm. *Procedia Computer Science*, 234, 156–163. <https://doi.org/10.1016/j.procs.2024.02.162>
- Nuzul Hikmah, Dyah Ariyanti, & Ferry Agus Pratama. (2022). Implementasi Chatbot Sebagai Virtual Assistant di Universitas Panca Marga Probolinggo menggunakan Metode TF-IDF. *JTIM: Jurnal Teknologi Informasi dan Multimedia*, 4(2), 133–148. <https://doi.org/10.35746/jtim.v4i2.225>
- Pujiastuti, N. E. (2022). *Direktorat Jenderal Pelayanan Kesehatan*. https://yankes.kemkes.go.id/view_artikel/149/cegah-stunting-dengan-makanan-bergizi-seimbang-pada-1000-hari-kehidupan-pertama-anak
- Rahmadhita, K. (2020). Permasalahan Stunting dan Pencegahannya. *Jurnal Ilmiah Kesehatan Sandi Husada*, 11(1), 225–229. <https://doi.org/10.35816/jiskh.v11i1.253>
- Rahmatullah, B., Saputra, S. A., Budiono, P., & Wigandi, D. P. (2025). Sentimen Analisis Makan Bergizi Gratis Menggunakan Algoritma Naive Bayes. *Journal of Information Technology*, 5(1). <https://doi.org/10.46229/jifotech.v5i1.978>
- Ranganathan, P., Pramesh, C. S., & Aggarwal, R. (2017). Common pitfalls in statistical analysis: Logistic regression. *Perspectives in Clinical Research*, 8(3), 148–151. https://doi.org/10.4103/picr.PICR_87_17
- Riwanto, M. H., Ardhiyansyah, P., Adiansyah, R. A., Alfiansyah, A., Waek, G., & Fahlapi, R. (2025). Analisis Sentimen Komentar Youtube Terkait Penerapan Makan Bergizi Gratis Menggunakan Model Algoritma SVM.
- Riyanto, M., & Kovalenko, V. (2023). Partisipasi Masyarakat Menuju Negara Kesejahteraan: Memahami Pentingnya Peran Aktif Masyarakat Dalam

- Mewujudkan Kesejahteraan Bersama. *Jurnal Pembangunan Hukum Indonesia*, 5(2), 374–388. <https://doi.org/10.14710/jphi.v5i2.374-388>
- Saif, H., He, Y., Fernandez, M., & Alani, H. (2016). Contextual semantics for sentiment analysis of Twitter. *Information Processing & Management*, 52(1), 5–19. <https://doi.org/10.1016/j.ipm.2015.01.005>
- Savitri, N. L. P. C., Rahman, R. A., Venyutzky, R., & Rakhmawati, N. A. (2021). Analisis Klasifikasi Sentimen Terhadap Sekolah Daring pada Twitter Menggunakan Supervised Machine Learning. *Jurnal Teknik Informatika dan Sistem Informasi*, 7(1). <https://doi.org/10.28932/jutisi.v7i1.3216>
- Seid, S. & Pooja. (2019). Road Accident Data Analysis: Data Preprocessing for Better Model Building. *Journal of Computational and Theoretical Nanoscience*, 16(9), 4019–4027. <https://doi.org/10.1166/jctn.2019.8288>
- Septian, J. A., Fachrudin, T. M., & Nugroho, A. (2019). Analisis Sentimen Pengguna Twitter Terhadap Polemik Persepakbolaan Indonesia Menggunakan Pembobotan TF-IDF dan K-Nearest Neighbor. *Journal of Intelligent System and Computation*, 1(1), 43–49. <https://doi.org/10.52985/insyst.v1i1.36>
- Sutranggono, A. N. (2022). Klasifikasi Emosi pada Cuitan di Twitter dengan Principal Component Analysis dan Support Vector Machine. *MATHunesa: Jurnal Ilmiah Matematika*, 10(1), 13–20. <https://doi.org/10.26740/mathunesa.v10n1.p13-20>
- Widyasanti, N. K., Darma Putra, I. K. G., & Dwi Rusjyanthi, N. K. (2018). Seleksi Fitur Bobot Kata dengan Metode TFIDF untuk Ringkasan Bahasa Indonesia. *Jurnal Ilmiah Merpati (Menara Penelitian Akademika Teknologi Informasi)*, 119. <https://doi.org/10.24843/JIM.2018.v06.i02.p06>
- Yadla, H. K., & Rao, D. P. P. (2020). Machine Learning Based Text Classifier Centered On TF-IDF Vectoriser. 9(03).
- Yoga Siswa, T. A. (2023). Komparasi Optimasi Chi-Square, CFS, Information Gain dan ANOVA dalam Evaluasi Peningkatan Akurasi Algoritma Klasifikasi Data Performa Akademik Mahasiswa. *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, 18(1), 62. <https://doi.org/10.30872/jim.v18i1.11330>

Zhang, S. (2021). Sentiment Classification of News Text Data Using Intelligent Model. *Frontiers in Psychology*, 12, 758967. <https://doi.org/10.3389/fpsyg.2021.758967>