

BAB II TINJAUAN PUSTAKA

2.1 Program Makan Bergizi Gratis (MBG)

Sebagai kebijakan strategis berskala nasional, Program Makan Bergizi Gratis (MBG) digagas Pemerintah Indonesia sebagai langkah transformatif untuk mengangkat derajat kesehatan sekaligus kualitas hidup masyarakat. Pada masa kepemimpinan Presiden Prabowo Subianto, kebijakan ini bahkan resmi ditetapkan sebagai agenda prioritas dalam peta jalan pembangunan nasional, sejalan dengan pandangan bahwa pemenuhan gizi merupakan fondasi utama pembangunan sumber daya manusia (Pratama & Wibowo, 2024).

2.1.1 Landasan dan Tujuan Strategis

Lebih dari sekadar menyalurkan bantuan pangan, pelaksanaan MBG menyimpan dimensi tujuan yang jauh lebih luas. Berlandaskan visi "Indonesia Emas 2045", terdapat sejumlah tantangan mendasar yang coba dijawab lewat program ini, yakni:

1. Penurunan Angka *Stunting*. Sebagai penghambat besar bagi produktivitas sumber daya manusia Indonesia, persoalan tengkes (*stunting*) diupayakan dicegah sejak dini melalui intervensi gizi kepada ibu hamil, ibu menyusui, dan balita sebuah langkah agar tumbuh kembang fisik dan kognitif anak dapat berlangsung optimal (Faidh et al., 2024).
2. Peningkatan Kualitas Pendidikan. Karena asupan nutrisi yang memadai terbukti berkaitan erat dengan kemampuan kognitif, siswa dengan gizi seimbang cenderung lebih fokus dan mudah menyerap materi pelajaran; melalui jalur inilah program diharapkan turut menekan angka putus sekolah sekaligus mendongkrak prestasi akademik (Pratama & Wibowo, 2024).
3. Ketahanan Pangan dan Ekonomi Lokal. Model *local sourcing* yang diadopsi MBG menyerap bahan pangan dari hasil pertanian, peternakan, dan tangkapan

nelayan setempat melahirkan ekosistem ekonomi sirkular yang turut memberdayakan UMKM di sekitar sekolah maupun pusat distribusi (Lestari & Hartono, 2024).

2.1.2 Sasaran dan Target Penerima

Dengan sasaran utama kelompok rentan yang tengah berada pada fase pertumbuhan atau tahap krusial perkembangan biologis, program ini bersifat inklusif dan mencakup:

1. Siswa Jenjang Dasar hingga Menengah, meliputi anak-anak yang menempuh pendidikan mulai dari PAUD, SD, SMP, sampai SMA/SMK.
2. Anak Usia Balita, agar masa emas (*golden age*) mereka terpenuhi kebutuhan proteinnya secara memadai.
3. Ibu Hamil dan Menyusui, sebagai langkah penting untuk mencegah kekurangan gizi kronis sejak masa kandungan (Pratama & Wibowo, 2024).

2.1.3 Tantangan dan Respons Publik

Sebagai kebijakan berskala masif, berbagai kendala operasional tak terhindarkan dalam pelaksanaan MBG mulai dari logistik distribusi ke wilayah 3T (Terdepan, Terluar, Tertinggal), standar keamanan pangan, hingga kebutuhan anggaran negara yang tidak sedikit. Besarnya dampak dan alokasi dana yang menyertainya pun turut memicu perbincangan publik yang intens, terutama di platform digital seperti X (Twitter).

Tanggapan warganet terpecah ke dalam beberapa kelompok: mulai dari dukungan penuh atas manfaat sosialnya, hingga kekhawatiran seputar transparansi dan keberlanjutan fiskal (Ryandi, Pratiwi, & Sari, 2025). Karena itulah menelaah respons masyarakat menjadi krusial bagi pemerintah, terutama untuk melakukan evaluasi kebijakan secara *real-time* dan berbasis data.

2.2 Analisis Sentimen

Sebagai cabang kajian dalam *Natural Language Processing* (NLP), linguistik komputasional, dan *text mining*, analisis sentimen yang kerap disebut pula *opinion mining* berupaya mengungkap opini, sentimen, penilaian, sikap, maupun emosi seseorang terhadap entitas, peristiwa, atau topik tertentu (Liu, 2022). Di tengah arus transformasi digital, kajian ini menjelma menjadi instrumen penting untuk menggali informasi subjektif dari tumpukan data tekstual tidak terstruktur dalam skala besar.

2.2.1 Level Analisis Sentimen

Bergantung pada seberapa dalam informasi yang hendak digali, analisis sentimen secara garis besar dapat diterapkan pada beberapa level abstraksi berikut (Liu, 2022; Ryandi, Pratiwi, & Sari, 2025):

1. Tingkat Dokumen (*Document Level*), yaitu menilai apakah keseluruhan isi dokumen atau paragraf secara umum mencerminkan sentimen positif, negatif, atau netral.
2. Tingkat Kalimat (*Sentence Level*), yang menetapkan polaritas sentimen per kalimat dan biasanya turut memilah kalimat objektif (fakta) dari kalimat subjektif (opini).
3. Tingkat Aspek (*Aspect/Feature Level*), level paling rinci yang memfokuskan analisis pada opini terhadap aspek spesifik suatu entitas. Pada Program Makan Bergizi Gratis misalnya, aspek yang dapat dinilai antara lain "kualitas makanan", "distribusi", atau "anggaran".

2.2.2 Polaritas Sentimen

Mengklasifikasikan polaritas opini menjadi sasaran utama analisis sentimen, dan untuk kebijakan publik semacam Program Makan Bergizi Gratis (MBG), pengelompokan tersebut umumnya terbagi ke dalam tiga kategori berikut (Mauliza & Sipayung, 2024):

1. Positif, yang mencerminkan dukungan, rasa puas, atau harapan baik atas keberlanjutan program.
2. Negatif, yang mencerminkan kritik, kekhawatiran, ketidakpuasan, atau penolakan terhadap pelaksanaan kebijakan.
3. Netral, berupa pernyataan faktual, pemberitaan tanpa opini pribadi, atau kalimat tanpa muatan emosi yang jelas.

2.2.3 Relevansi dalam Kebijakan Publik

Dibandingkan survei konvensional yang menyita waktu dan biaya besar, penerapan analisis sentimen pada data media sosial memberi keuntungan strategis tersendiri bagi pengambil kebijakan, sebab mampu menangkap "suara masyarakat" secara cepat dan apa adanya karena bersumber dari perbincangan organik di ruang digital (Siregar et al., 2023).

Berbekal teknik *machine learning* semacam *Naïve Bayes* atau *Support Vector Machine* (SVM), volume data teks yang besar pun dapat diklasifikasikan secara otomatis untuk mengenali kecenderungan reaksi publik terhadap isu-isu sensitif (Lestari & Hartono, 2024), sehingga instansi terkait dapat melakukan mitigasi isu atau perbaikan layanan berdasarkan persepsi riil di lapangan (Ryandi, Pratiwi, & Sari, 2025).

2.3 Machine Learning

Sebagai salah satu cabang utama Kecerdasan Buatan (*Artificial Intelligence*), *Machine Learning* (ML) atau Pembelajaran Mesin berfokus pada pengembangan algoritma dan model statistik agar sistem komputer sanggup menjalankan tugas tertentu tanpa instruksi pemrograman yang eksplisit. Ini berbeda dari pemrograman konvensional berbasis aturan (*rule-based*), yang mengharuskan manusia mendefinisikan setiap logika keputusan; *Machine Learning* justru membangun model matematis berdasarkan pola inferensi yang dipelajari dari data sampel (Sarker, 2021).

Machine Learning menjadi elemen vital di era yang serba digerakkan oleh data (*data-driven era*), berkat kesanggupannya menangani kerumitan sekaligus volume data yang besar. Bukan sekadar menghafal data, sistem ML mampu melakukan generalisasi beradaptasi dan menghasilkan prediksi akurat terhadap data baru yang belum pernah dijumpai sebelumnya sebuah kemampuan yang sangat relevan untuk mengolah data teks dinamis dan tidak terstruktur, seperti opini publik di media sosial mengenai kebijakan pemerintah (Géron, 2022).

2.3.1 Pendekatan Supervised Learning

Algoritma *Machine Learning* dapat dikelompokkan ke dalam beberapa kategori berdasarkan cara kerjanya, dan penelitian ini secara khusus mengadopsi pendekatan *Supervised Learning* (Pembelajaran Terawasi), yang menurut Campesato (2021) merupakan metode di mana algoritma dilatih menggunakan dataset dengan label input maupun output yang jelas.

Pada analisis sentimen terhadap Program Makan Bergizi Gratis (MBG), proses tersebut melibatkan pasangan data berupa teks komentar masyarakat sebagai input dan label sentimen (Positif, Negatif, atau Netral) sebagai output. Intinya, *Supervised Learning* mempelajari fungsi pemetaan (f) dari variabel input (x) menuju variabel output (y) dengan galat seminimal mungkin, sehingga model mampu memprediksi label sentimen (y) secara otomatis begitu diberi data komentar baru (x) (Bonaccorso, 2021).

2.3.2 Tahapan Proses Machine Learning

Penerapan *Machine Learning* pada klasifikasi teks tidak berlangsung seketika, melainkan melalui rangkaian tahapan sistematis. Mengacu kerangka kerja standar industri menurut Huyen (2022), tahapan tersebut mencakup:

1. Pengumpulan Data (*Data Collection*), yaitu menghimpun data mentah dari sumbernya, misalnya Kaggle atau media sosial.

2. Pra-pemrosesan (*Preprocessing*), yang menyaring data dari *noise* agar siap diproses lebih lanjut.
3. Ekstraksi Fitur (*Feature Extraction*): karena algoritma matematis tidak bisa memproses teks mentah secara langsung, tahap ini mengonversi data teks ke bentuk representasi numerik (vektor) yang dapat dibaca mesin.
4. Pelatihan Model (*Model Training*), tempat algoritma seperti *Naïve Bayes* atau SVM mencari pola paling optimal untuk membedakan satu kelas sentimen dari kelas lainnya.
5. Evaluasi (*Evaluation*), yaitu mengukur performa model memakai data uji terpisah untuk memastikan model tidak sekadar menghafal data latih namun gagal menangani data baru (*overfitting*).

Berkat pendekatan ini, sistem mampu mengenali nuansa bahasa secara otomatis kata "sejahtera" misalnya cenderung berlabel positif, sementara "boros" cenderung berlabel negatif berdasarkan probabilitas statistik yang telah dipelajari selama tahap pelatihan (Liu, 2022).

2.4 Natural Language Processing (NLP)

Sebagai disiplin ilmu yang berupaya menjembatani kesenjangan komunikasi antara manusia dan komputer, *Natural Language Processing* (NLP) atau Pemrosesan Bahasa Alami menjadi jawaban atas satu persoalan mendasar: manusia berkomunikasi memakai bahasa alami yang kaya struktur, ambiguitas, dan konteks (termasuk Bahasa Indonesia), sedangkan komputer pada dasarnya hanya mengenal instruksi biner dan numerik. NLP-lah yang menyediakan kerangka komputasi agar mesin dapat membaca, memahami, dan mengolah bahasa manusia secara bermakna (Aggarwal, 2021).

NLP berperan sentral sebagai mekanisme *preprocessing* pada penelitian analisis sentimen terhadap Program Makan Bergizi Gratis (MBG), mengingat data opini masyarakat yang diambil dari media sosial umumnya tidak terstruktur (*unstructured data*) dan sarat derau (*noise*), singkatan tidak baku, simbol, serta

variasi ejaan. Tanpa campur tangan NLP, algoritma klasifikasi seperti *Naïve Bayes* atau SVM akan kesulitan menemukan pola akurat akibat tingginya variasi fitur yang tidak relevan sebagaimana ditegaskan Vajjala et al. (2021), keberhasilan model *machine learning* pada data teks sangat bergantung pada kualitas tahap NLP ini, tempat data mentah diubah menjadi format terstruktur yang lebih bersih.

2.4.1 Tahapan Preprocessing Teks

Agar data tekstual mentah dapat diubah menjadi representasi fitur yang optimal, penelitian ini menjalankan serangkaian tahapan standar dalam alur (*pipeline*) NLP berikut:

1. *Case folding*, yaitu tahap penyeragaman format huruf pada dokumen agar konsisten biasanya diubah ke huruf kecil (*lowercase*) dengan tujuan memangkas dimensi fitur lewat penghapusan perbedaan yang tidak memengaruhi makna semantik. Tanpa tahap ini, kata "Gizi", "GIZI", dan "gizi" dalam opini tentang MBG akan dianggap tiga fitur terpisah oleh komputer; *case folding* menyatukan ketiganya menjadi satu token "gizi", sehingga frekuensi kemunculannya dapat dihitung secara akurat (Liu, 2022).
2. Tokenisasi memecah kalimat atau paragraf menjadi unit-unit terkecil yang disebut token, baik berupa kata, angka, maupun tanda baca. Pada analisis sentimen, proses ini memisahkan rangkaian karakter menjadi entitas kata yang berdiri sendiri kalimat "Program MBG sangat bermanfaat", misalnya, akan terurai menjadi daftar token ["Program", "MBG", "sangat", "bermanfaat"]. Menurut Khurana et al. (2023), ketepatan tokenisasi sangat penting sebab kekeliruan pemisahan kata dapat mengubah makna kalimat sekaligus memengaruhi bobot TF-IDF pada tahap berikutnya.
3. Sebagai tahap seleksi fitur, *Filtering (Stopword Removal)* membuang kata-kata berfrekuensi tinggi namun minim atau bahkan nihil muatan sentimen (*low-level information*), yang lazim disebut *stopwords* dalam Bahasa Indonesia, contohnya adalah kata hubung dan kata depan seperti "dan", "yang", "di", "ke", "dari". Penghapusan kata-kata tersebut penting untuk memperkecil ukuran

dataset dan mengarahkan fokus algoritma pada kata kunci (*keywords*) yang benar-benar sarat muatan sentimen, seperti "enak", "sehat", "kacau", atau "mahal" (Hidayatullah et al., 2021).

4. *Stemming* adalah proses morfologis yang mengembalikan kata berimbuhan (afiks) ke bentuk dasarnya (*root word*) sebuah tahap yang cukup menantang mengingat struktur morfologi Bahasa Indonesia mencakup awalan (prefiks), akhiran (sufiks), sisipan (infiks), dan gabungan (konfiks).

Tujuannya adalah menyatukan berbagai variasi kata yang berakar makna sama; kata "membagikan", "dibagikan", dan "pembagian" dalam konteks distribusi makanan MBG, misalnya, sama-sama berakar pada kata "bagi". Tanpa stemming, ketiganya akan diperlakukan sebagai fitur berlainan oleh algoritma, sedangkan dengan stemming variasi tersebut dipadatkan menjadi satu fitur "bagi" saja, sehingga kepadatan fitur dan akurasi klasifikasi turut meningkat (Sarkar, 2021). Untuk memastikan ketepatan pengembalian ke kata dasar, penelitian ini memakai algoritma stemming yang disesuaikan dengan kaidah morfologi Bahasa Indonesia, seperti Sastrawi.

2.5 TF-IDF (Term Frequency-Inverse Document Frequency)

Setelah melewati tahap *preprocessing*, data teks perlu dikonversi menjadi bentuk numerik agar dapat diolah algoritma *machine learning*. Salah satu metode ekstraksi fitur yang paling banyak dipakai dan terbukti efektif dalam analisis sentimen untuk keperluan ini adalah *Term Frequency-Inverse Document Frequency* (TF-IDF), yang memberi bobot statistik pada setiap kata guna menunjukkan seberapa penting kata tersebut dalam sebuah dokumen dibandingkan seluruh korpus (Mauliza & Sipayung, 2024).

2.5.1 Komponen TF-IDF

Dua konsep perhitungan bobot berikut membentuk TF-IDF:

1. *Term Frequency* (TF), yang mengukur seberapa sering sebuah kata (t) muncul dalam suatu dokumen (d) logikanya, semakin kerap kata itu muncul, semakin kuat pula kata tersebut merepresentasikan isi dokumennya.
2. *Inverse Document Frequency* (IDF), yang berperan menurunkan bobot kata-kata yang terlalu sering muncul di banyak dokumen (misalnya kata umum yang lolos dari stopwords removal). Sebaliknya, kata yang unik atau jarang dijumpai di dokumen lain akan diberi bobot tinggi karena dianggap memiliki daya pembeda kuat antar kelas sentimen (Siregar et al., 2023).

2.5.2 Perhitungan Matematis

Bobot TF-IDF (W) secara matematis diperoleh dari perkalian nilai TF dengan nilai IDF, dengan rumus umum sebagai berikut:

$$W_{d,t} = TF_{d,t} \times \log \left(\frac{N}{df_t} \right)$$

Dimana:

- $W_{d,t}$: Bobot kata t dalam dokumen d .
- $TF_{d,t}$: Frekuensi kemunculan kata t dalam dokumen d .
- N : Total seluruh dokumen dalam korpus.
- df_t : Jumlah dokumen yang mengandung kata t (Ryandi, Pratiwi, & Sari, 2025).

2.5.3 Keunggulan TF-IDF dalam Analisis Sentimen

Kata-kata seperti "efektif", "bangga", atau "kecewa" mungkin tidak muncul di setiap dokumen, namun memiliki bobot IDF tinggi dan di sinilah TF-IDF sangat membantu menonjolkan kata-kata bermuatan sentimen kuat pada analisis sentimen Program Makan Bergizi Gratis (MBG). Kondisi ini pada gilirannya membantu model klasifikasi seperti *Naïve Bayes* atau SVM lebih terfokus pada kata-kata kunci

tersebut ketika menentukan apakah sebuah komentar di media sosial X bersifat positif atau negatif (Siregar et al., 2023).

2.6 Naïve Bayes Classifier

Berkat kesederhanaan dan efisiensinya, *Naïve Bayes Classifier* menjadi salah satu algoritma pembelajaran mesin yang populer untuk klasifikasi teks. Algoritma ini bertumpu pada Teorema Bayes yang dipadukan dengan asumsi "naif" yakni setiap fitur (dalam hal ini kata) pada dokumen dianggap independen satu sama lain, sehingga kemunculan sebuah kata dianggap tidak dipengaruhi oleh kata lain dalam kalimat yang sama (Mauliza & Sipayung, 2024).

2.6.1 Prinsip Teorema Bayes

Prinsip dasarnya adalah menghitung probabilitas kemunculan suatu kelas (misalnya sentimen positif atau negatif) berdasarkan fitur-fitur pada data uji, yang secara matematis dirumuskan lewat Teorema Bayes berikut:

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)}$$

Dimana:

- $P(C|X)$: Probabilitas posterior dari kelas C (target) diberikan prediktor X (fitur).
- $P(C)$: Probabilitas prior dari kelas tersebut.
- $P(X|C)$: *Likelihood*, yaitu probabilitas prediktor diberikan kelasnya.
- $P(X)$: Probabilitas prior dari prediktor.

2.6.2 Multinomial Naïve Bayes

Multinomial Naïve Bayes adalah varian yang paling umum dipakai untuk keperluan analisis sentimen, sebab memperhitungkan frekuensi kemunculan kata (seperti bobot hasil TF-IDF) dalam dokumen bukan sekadar ada-tidaknya kata

tersebut. Karakteristik inilah yang membuatnya cocok untuk data media sosial X yang cenderung pendek namun repetitif (Saputra, Purnamasari, & Ali, 2024).

2.6.3 Keunggulan *Naïve Bayes* dalam Analisis Sentimen

Terlepas dari asumsi independensi yang terkesan terlalu sederhana ("naif"), algoritma ini tetap menunjukkan performa kuat dalam klasifikasi teks karena beberapa alasan berikut:

1. Kecepatan Komputasi. Dibandingkan SVM, *Naïve Bayes* membutuhkan waktu pelatihan yang jauh lebih singkat, sehingga ideal untuk mengolah data media sosial dalam jumlah besar secara *real-time* (Mauliza & Sipayung, 2024).
2. Kebutuhan Data yang Lebih Sedikit. Algoritma ini tetap bekerja baik meski data pelatihan relatif terbatas, sepanjang distribusi probabilitas tiap kelas terwakili secara memadai (Saputra, Purnamasari, & Ali, 2024).
3. Kemudahan Implementasi. Model matematisnya yang sederhana membuat *Naïve Bayes* kerap dijadikan *baseline* (tolok ukur pembandingan) dalam riset analisis sentimen, sebelum beranjak menguji model yang lebih kompleks (Lestari & Hartono, 2024).

Dalam konteks Program Makan Bergizi Gratis (MBG), kecepatan inilah yang memungkinkan *Naïve Bayes* memetakan pola kata dominan pada sentimen positif maupun negatif dengan cepat, sehingga memberi gambaran awal yang cukup akurat tentang kecenderungan opini publik (Pratama & Wibowo, 2024).

2.7 Support Vector Machine (SVM)

Sebagai salah satu algoritma *supervised learning* yang kuat dan populer, *Support Vector Machine* (SVM) banyak digunakan untuk tugas klasifikasi maupun regresi. Pada analisis sentimen, cara kerjanya adalah mencari *hyperplane* atau bidang pemisah optimal yang mampu memisahkan data dari kelas-kelas berbeda misalnya sentimen positif dan negatif dengan tingkat kesalahan seminimal mungkin (Ramadhan, 2024).

2.7.1 Prinsip Kerja *Hyperplane* dan *Margin*

Prinsip dasarnya adalah mencari garis pemisah (pada ruang dua dimensi) atau bidang pemisah (pada ruang berdimensi tinggi) yang berjarak paling jauh dari titik data terdekat di masing-masing kelas; titik data yang letaknya paling dekat dengan *hyperplane* itulah yang disebut *support vectors*.

Jarak antara *support vectors* kedua kelas disebut *margin*, dan SVM berupaya menjalankan *maximal margin classification* yakni memaksimalkan lebar margin tersebut. Semakin lebar margin yang tercipta, semakin kecil pula peluang kesalahan klasifikasi pada data baru, sehingga model memiliki daya generalisasi yang baik (Susanto, 2024).

2.7.2 Linear dan Non-Linear SVM (Kernel Trick)

Bagi data yang dapat dipisahkan secara linier, SVM cukup memakai fungsi linier sederhana; namun pada data media sosial yang kompleks, kelas-kelasnya kerap tidak dapat dipisahkan secara linier. Untuk mengatasinya, SVM memanfaatkan *Kernel Trick*, yaitu teknik yang memetakan data berdimensi rendah ke ruang fitur berdimensi lebih tinggi, sehingga data yang semula sulit dipisahkan menjadi dapat dibatasi oleh sebuah *hyperplane* (Ryandi, Pratiwi, & Sari, 2025).

2.7.3 Keunggulan SVM dalam Klasifikasi Teks

Sejumlah keunggulan teknis ditawarkan SVM saat diterapkan pada analisis sentimen Program Makan Bergizi Gratis (MBG), di antaranya:

1. Efektif pada Dimensi Tinggi. Meski data teks hasil pemrosesan TF-IDF biasanya memiliki ribuan fitur (kata), SVM terbukti tetap stabil dan efektif bekerja pada jumlah fitur yang sangat banyak (Ramadhan, 2024).
2. Tahan terhadap *Outlier*. Karena penentuan bidang pemisah hanya bergantung pada *support vectors*, SVM relatif tidak mudah terganggu oleh titik data pencilan (*outlier*) yang letaknya jauh dari batas keputusan (Susanto, 2024).

3. Akurasi yang Kompetitif. Sejumlah penelitian bahkan menunjukkan SVM kerap menghasilkan akurasi lebih unggul dibandingkan algoritma klasifikasi tradisional lainnya dalam menangani opini publik yang ambigu di media sosial (Ryandi, Pratiwi, & Sari, 2025).

2.8 Word N-gram dan Character N-gram

N-gram adalah teknik ekstraksi fitur dalam pengolahan teks yang memecah teks menjadi rangkaian sebanyak n unit berurutan, baik berupa kata (*word*) maupun karakter (*character*) tergantung pendekatan yang dipilih. Karena sanggup menangkap konteks lokal suatu teks, teknik ini banyak diterapkan dalam klasifikasi teks dan analisis sentimen (Iriananda et al., 2024).

2.8.1 Word N-gram

Berbasis urutan kata, *Word N-gram* merupakan teknik representasi fitur teks di mana setiap rangkaian n kata berurutan dalam kalimat dianggap sebagai satu fitur. Nilai $n = 1$ disebut *unigram*, $n = 2$ disebut *bigram*, dan $n = 3$ disebut *trigram*. Kalimat "makan bergizi gratis", misalnya, akan menghasilkan unigram {"makan", "bergizi", "gratis"}, bigram {"makan bergizi", "bergizi gratis"}, dan trigram {"makan bergizi gratis"}.

Karena mampu menangkap tak hanya makna kata tunggal tetapi juga konteks frasa dan kalimat pendek yang relevan secara sentimen, perpaduan word N-gram (Unigram + Bigram + Trigram) pada algoritma SVM dengan pembobotan TF-IDF terbukti mendongkrak performa klasifikasi sentimen secara signifikan dibandingkan pemakaian fitur tunggal. Seleksi fitur berbasis N-gram sendiri terbukti mendongkrak akurasi algoritma klasifikasi pada teks berbahasa Indonesia, khususnya pada data ulasan media sosial (Iriananda et al., 2022).

2.8.2 Character N-gram

Berbeda dari word N-gram yang bekerja pada level kata, *Character N-gram* memecah teks berdasarkan rangkaian n karakter (huruf) sehingga bekerja pada level sub-kata. Pendekatan ini memungkinkannya menangkap pola morfologis, imbuhan,

serta variasi penulisan informal yang lazim dijumpai di media sosial (Nugroho, 2021).

Kelebihan utamanya terletak pada kesanggupan menangani kasus *out-of-vocabulary* (OOV), yakni kata-kata yang tidak tercakup dalam kosakata pelatihan fenomena yang sangat lazim pada teks media sosial berbahasa Indonesia akibat maraknya singkatan, bahasa gaul, dan salah eja. Character N-gram bahkan sangat efektif diterapkan pada dataset teks pendek seperti cuitan Twitter/X, karena mampu mengekstrak informasi subkata meski banyak kata tidak baku; penambahannya pada model klasifikasi teks berbahasa Indonesia terbukti mendongkrak akurasi dari 89,67% menjadi 92%, menegaskan nilai tambah pendekatan ini dibandingkan model berbasis kata semata (Nugroho, 2021).

2.8.3 Kombinasi Word N-gram dan Character N-gram pada SVM

Sebagai strategi yang kian populer dalam riset analisis sentimen teks media sosial, perpaduan word N-gram dan character N-gram memungkinkan model memanfaatkan sekaligus informasi semantik tingkat kata dan informasi morfologis tingkat karakter dalam satu ruang fitur yang terpadu (Iriananda et al., 2024).

Kombinasi tersebut diterapkan pada penelitian ini sebagai strategi ekstraksi fitur pada algoritma SVM, memakai fungsi *TfidfVectorizer* dari pustaka *Scikit-learn* dengan parameter *analyzer* diatur pada nilai 'word' untuk word N-gram dan 'char' atau 'char_wb' untuk character N-gram, serta parameter *ngram_range* yang menentukan rentang nilai *n* yang dipakai. Sebelum dimasukkan ke model SVM untuk pelatihan dan klasifikasi, kedua matriks fitur tersebut terlebih dahulu digabungkan (*concatenated*) (Iriananda et al., 2022).

Lewat penggabungan kedua jenis N-gram ini, model SVM diharapkan mampu mengklasifikasikan sentimen publik terhadap Program Makan Bergizi Gratis dengan lebih akurat, terutama dalam menghadapi ragam gaya penulisan masyarakat Indonesia di media sosial.

2.9 Evaluasi Model

Sebagai tahap akhir yang fundamental dalam penelitian analisis sentimen, evaluasi model berfungsi mengukur sejauh mana algoritma klasifikasi mampu mengenali pola opini masyarakat. Instrumen evaluasi yang paling lazim dipakai dalam riset *machine learning* untuk keperluan ini adalah *Confusion Matrix*, yang menyajikan tabel perbandingan antara nilai aktual (data asli dari lapangan) dan nilai prediksi hasil model (Sari & Nugroho, 2024).

2.9.1 Komponen *Confusion Matrix*

Hasil prediksi dikelompokkan *Confusion Matrix* ke dalam empat kategori utama, yaitu:

1. *True Positive* (TP), yaitu data positif yang berhasil diprediksi secara tepat sebagai positif.
2. *True Negative* (TN), yaitu data negatif yang berhasil diprediksi secara tepat sebagai negatif.
3. *False Positive* (FP), yaitu data negatif yang keliru diprediksi sebagai positif (*Error Tipe I*).
4. *False Negative* (FN), yaitu data positif yang keliru diprediksi sebagai negatif (*Error Tipe II*).

2.9.2 Metrik Evaluasi

Berdasarkan keempat nilai di atas, penelitian ini menggunakan beberapa metrik standar untuk memberikan gambaran performa yang objektif (Sari & Nugroho, 2024; Ryandi, Pratiwi, & Sari, 2025):

1. Akurasi (*Accuracy*): yang mengukur proporsi keseluruhan prediksi tepat baik positif maupun negatif terhadap seluruh data.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Presisi (*Precision*): yang mengukur ketepatan antara data yang diprediksi positif dengan data yang sesungguhnya positif; metrik ini penting untuk menekan kesalahan "salah tuduh" (FP).

$$\text{Precision} = \frac{TP}{TP + FP}$$

3. Recall (Sensitivitas): yang mengukur seberapa berhasil model menemukan kembali seluruh data positif yang sesungguhnya ada di dalam dataset.

$$\text{Recall} = \frac{TP}{TP + FN}$$

4. F1-Score: rata-rata harmonik yang menyeimbangkan nilai Presisi dan *Recall*. Metrik ini sering dianggap lebih representatif dibandingkan akurasi semata, terutama saat terjadi ketidakseimbangan jumlah data (*imbalanced data*) antara sentimen positif dan negatif.

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

Lewat evaluasi inilah peneliti dapat menyimpulkan algoritma mana *Naïve Bayes* atau SVM yang lebih efektif dan andal memetakan respons publik terhadap kebijakan Program Makan Bergizi Gratis (MBG)