

BAB III METODOLOGI PENELITIAN

3.1 Desain Penelitian

Penelitian ini menggunakan desain kuantitatif berbasis text mining untuk menganalisis dan membandingkan kinerja algoritma *Support Vector Machine* dan *Naïve Bayes* dalam mengklasifikasikan sentimen publik terhadap Program Makan Bergizi Gratis di media sosial X. Opini publik yang berbentuk teks pendek diubah menjadi data numerik agar dapat diolah secara sistematis, dengan alur yang mengikuti kerangka penelitian mulai dari perumusan masalah sampai evaluasi model.

Penelitian bersifat komparatif karena *Support Vector Machine* dan *Naïve Bayes* diuji pada dataset cuitan yang sama. Setiap cuitan yang relevan dipraproses, kemudian direpresentasikan menggunakan pembobotan *Term Frequency Inverse Document Frequency* sehingga membentuk vektor fitur yang menjadi masukan bagi model untuk mempelajari hubungan antara kata dan kelas sentimen positif, negatif, dan netral. Kinerja kedua algoritma dinilai berdasarkan metrik evaluasi yang dihitung dari hasil prediksi pada data uji.

Rancangan penelitian mengikuti urutan kerja yang terstruktur. Data tweet (cuitan) dikumpulkan dari media sosial X dengan topik Program Makan Bergizi Gratis, kemudian diproses melalui pembersihan teks, *case folding*, *tokenizing*, *stopword removal*, dan *stemming* bahasa Indonesia. Hasil pra pemrosesan diubah menjadi fitur numerik dengan TF IDF, lalu digunakan dalam pelatihan model

Support Vector Machine dan *Naïve Bayes* pada data latih yang dibagi dengan menjaga proporsi kelas sentimen.

Tahap penutup desain penelitian berada pada evaluasi dan analisis hasil. Metrik akurasi, presisi, recall, dan F1 score dihitung dari hasil prediksi kedua model terhadap data uji untuk menilai efektivitas dan konsistensi klasifikasi sentimen publik di media sosial X. Hasil evaluasi kemudian dihubungkan kembali dengan tujuan dan rumusan masalah, sehingga desain penelitian memberikan gambaran yang ringkas mengenai alur kerja dan cara penelitian menjawab pertanyaan utama yang diajukan.

3.2 Variabel Penelitian

Tabel 3.1 Tabel Variabel Penelitian

Jenis Variabel	Nama Variabel	Definisi Operasional	Bentuk Data	Sumber Data
Variabel bebas	Representasi fitur teks	Nilai bobot istilah yang dihitung dengan <i>Term Frequency Inverse Document Frequency</i> untuk setiap cuitan	Vektor numerik hasil pembobotan TF IDF untuk setiap dokumen teks	Cuitan tentang Program Makan Bergizi Gratis di media sosial X
Variabel terikat	Kelas sentimen publik	Kategori sentimen yang menunjukkan kecenderungan opini terhadap Program Makan Bergizi Gratis	Label kategorik dengan tiga kelas sentimen, yaitu positif, negatif, dan netral	Pelabelan sentimen pada dataset cuitan

Variabel metode klasifikasi	Algoritma <i>Support Vector Machine</i> dan <i>Naïve Bayes</i>	Pendekatan klasifikasi yang digunakan untuk memetakan vektor fitur teks ke kelas sentimen pada dataset yang sama	Model klasifikasi yang menerima vektor TF IDF sebagai masukan dan menghasilkan prediksi kelas sentimen	Proses pemodelan berbasis <i>machine learning</i> pada dataset cuitan
-----------------------------	--	--	--	---

Penelitian ini menggunakan variabel yang diturunkan dari karakteristik dataset cuitan dan alur kerangka penelitian. Variabel bebas berupa representasi fitur teks yang diperoleh dari cuitan mengenai Program Makan Bergizi Gratis di media sosial X yang dibentuk menggunakan pembobotan *Term Frequency Inverse Document Frequency*, sehingga setiap cuitan dinyatakan sebagai vektor numerik yang memuat bobot istilah dalam kosakata yang digunakan.

Variabel terikat berupa kelas sentimen publik yang dilekatkan pada setiap cuitan dan dibagi menjadi tiga kategori, yaitu positif, negatif, dan netral. Aspek klasifikasi direpresentasikan melalui pemilihan algoritma *Support Vector Machine* dan *Naïve Bayes* yang menerima vektor fitur yang sama sebagai variabel bebas dan menghasilkan prediksi kelas sentimen sebagai variabel terikat, sehingga perbedaan kinerja yang muncul dapat dikaitkan dengan karakteristik masing masing algoritma.

3.3 Pengumpulan Data

Pengumpulan data dalam penelitian ini dilakukan dengan memanfaatkan Platform X (sebelumnya dikenal sebagai Twitter) sebagai sumber data utama karena platform tersebut banyak digunakan masyarakat untuk menyampaikan opini, pandangan, serta respons terhadap kebijakan publik secara terbuka dan real-time.

Data diperoleh melalui X Application Programming Interface (X API) versi 2 sebagai antarmuka resmi yang disediakan platform X untuk mengakses data publik sesuai ketentuan yang berlaku. Penggunaan X API v2 memungkinkan peneliti menarik data komentar atau tweet secara terstruktur berdasarkan kata kunci, rentang waktu, dan kriteria tertentu.

Data yang digunakan merupakan data primer berupa tweet publik yang membahas Program Makan Bergizi Gratis, dengan pembatasan bahwa data hanya diambil dari akun publik dan tidak mencakup akun privat atau konten yang dibatasi aksesnya. Pengambilan data dilakukan dengan proses penarikan (crawling) tweet pada rentang waktu 6 Januari 2025 sampai 20 Desember 2025. Pada tahap proposal digunakan 50 data tweet sebagai dataset awal untuk melakukan perancangan sistem dan pengujian awal metode klasifikasi. Pada tahap penelitian selanjutnya jumlah data akan ditingkatkan untuk memperoleh hasil analisis yang lebih representatif.

Secara teknis, penarikan data dilakukan menggunakan skrip pemrograman melalui X API v2 dengan memasukkan kata kunci dan frasa yang relevan seperti “makan bergizi gratis”, “program makan gratis”, serta variasi kata kunci lain yang merujuk pada program tersebut. Adapun kriteria data meliputi tweet yang berasal dari akun publik, mengandung kata kunci terkait topik penelitian, berada pada rentang waktu yang ditetapkan, dan ditulis dalam bahasa Indonesia; sementara tweet yang tidak relevan, duplikat, atau tidak memiliki konteks opini yang jelas dikeluarkan dari dataset.

Proses pengumpulan data juga memperhatikan kebijakan penggunaan data platform X, di mana data yang diambil hanya berupa konten publik dan digunakan

semata-mata untuk kepentingan akademik, serta identitas pengguna seperti nama akun atau informasi personal tidak ditampilkan guna menjaga etika penelitian dan privasi. Hasil akhir tahap ini berupa kumpulan tweet publik yang relevan dengan topik penelitian, yang selanjutnya digunakan pada tahap pelabelan data (manual coding sentimen) sebelum dilakukan pra-pemrosesan teks dan pemodelan klasifikasi sentimen menggunakan Support Vector Machine dan Naïve Bayes.

3.4 Instrumen dan Alat Penelitian

Penelitian ini menggunakan X Application Programming Interface (X API) versi 2 untuk mengumpulkan data tweet (cuitan) dari platform media sosial X, khususnya tweet yang relevan dengan *Program Makan Bergizi Gratis*. Data yang dikumpulkan kemudian dianalisis menggunakan algoritma *Support Vector Machine* (SVM) dan *Naïve Bayes* (NB) untuk mengklasifikasikan sentimen publik.

2.4.1 Alat Pengumpulan Data

Alat yang digunakan untuk pengumpulan data adalah X API v2 dengan pustaka *Tweepy*.

Tabel 3.1 Alat Pengumpulan Data

Langkah	Deskripsi
Autentikasi API	Menggunakan API key dan access token untuk autentikasi dan mendapatkan akses data dari platform X.
Pengumpulan Data Cuitan	Menggunakan API untuk mengumpulkan cuitan yang mengandung kata kunci dan hashtag terkait Program Makan Bergizi Gratis, seperti #MakanBergizi, #GiziGratis, dan lainnya.
Pengumpulan Metadata	Metadata yang dikumpulkan meliputi waktu unggahan cuitan, dan jumlah interaksi (likes, retweets, komentar).
Penyaringan Data	Cuitan yang tidak relevan atau tidak terkait dengan topik penelitian akan disaring dan tidak dimasukkan dalam dataset.

3.4.2 Proses Prapemrosesan Data Text

Setelah data terkumpul, langkah selanjutnya adalah prapemrosesan data teks. Tahapan ini bertujuan untuk memastikan data yang dikumpulkan dapat diproses dengan benar dan siap untuk analisis.

Tabel 2.3 Tahapan Prapemrosesan Text

Tahapan Prapemrosesan	Keterangan
Case Folding	Mengubah semua teks menjadi huruf kecil untuk menghindari perbedaan yang tidak relevan antara huruf besar dan kecil.
Tokenisasi	Memecah teks menjadi kata-kata atau token untuk analisis lebih lanjut.
Stopword Removal	Menghapus kata-kata yang tidak memiliki makna penting (seperti "dan", "atau", "yang", dll).
Stemming	Mengubah kata-kata ke bentuk dasarnya (misalnya "berlari" menjadi "lari").
Normalisasi Karakter	Menstandarkan simbol atau karakter yang tidak baku, seperti emotikon atau singkatan yang tidak konsisten.

3.4.3 Representasi Fitur

Setelah teks dipraproses, langkah berikutnya adalah mengubah teks menjadi representasi numerik. Representasi ini memungkinkan model machine learning untuk memproses dan menganalisis data lebih lanjut. *TF-IDF* digunakan untuk mengukur pentingnya setiap kata dalam konteks dokumen tertentu.

Tabel 3.3 Metode Representasi Fitur

Metode Representasi Fitur	Keterangan
TF-IDF (Term Frequency-Inverse Document Frequency)	Menghitung bobot setiap kata dengan memperhitungkan frekuensi kata dalam dokumen serta seberapa jarang kata tersebut muncul di seluruh dataset.

3.4.4 Kevalidan dan Keandalan

Instrumen yang digunakan dalam penelitian ini diuji untuk memastikan kevalidan dan keandalan.

Table 3.4 Tabel Kevalidan dan Keandalan Instrumen

Aspek	Keterangan
Kevalidan Data	Memastikan bahwa data yang dikumpulkan benar-benar relevan dengan topik yang sedang dianalisis. Penggunaan kata kunci dan hashtag yang tepat memastikan relevansi data.
Keandalan Data	Data dikumpulkan melalui proses otomatis menggunakan API X yang dapat diulang untuk mendapatkan hasil yang konsisten.
Penyaringan Cuitan	Cuitan yang tidak relevan atau tidak mengandung topik kebijakan akan disaring dengan menggunakan filter berdasarkan kata kunci yang relevan.

3.4.5 Penggunaan X API v2

Tabel 3.5 Tabel Penggunaan X API v2

Proses Penggunaan API	Keterangan
Autentikasi dan Akses API	Menggunakan API key dan access token untuk autentikasi dan mengakses data publik dari platform X.
Pencarian Cuitan dengan Kata Kunci	API digunakan untuk mencari cuitan dengan kata kunci terkait seperti #MakanBergizi atau #GiziGratis atau #MBG.
Penyimpanan Data	Data disimpan dalam format JSON yang mencakup teks cuitan, metadata (waktu, lokasi, interaksi), dan ID pengguna.

Dengan menggunakan X API v2 , instrumen ini memungkinkan pengumpulan data secara efisien dan otomatis, serta memastikan relevansi dengan topik kebijakan yang dianalisis. Data yang terkumpul kemudian akan diproses untuk analisis sentimen dengan menggunakan algoritma machine learning seperti SVM dan Naïve Bayes.

3.5 Prapemrosesan

Pra-pemrosesan teks merupakan tahapan awal yang sangat penting dalam penelitian analisis sentimen berbasis teks, khususnya pada data media sosial yang bersifat tidak terstruktur. Data tweet yang diperoleh dari platform X umumnya mengandung berbagai unsur non-linguistik seperti tanda baca berlebihan, tautan, mention, hashtag, serta variasi bahasa informal yang dapat mengganggu proses pembelajaran model. Oleh karena itu, pra-pemrosesan dilakukan untuk membersihkan, menormalkan, dan mempersiapkan data teks agar layak digunakan dalam proses ekstraksi fitur menggunakan TF-IDF dan pemodelan klasifikasi sentimen. Dalam penelitian ini, pra-pemrosesan diterapkan pada seluruh tweet yang telah dikumpulkan dan diseleksi relevansinya, dengan tujuan mengurangi noise, memperjelas kata-kata penting, serta meningkatkan konsistensi representasi teks.

2.5.1 Pelabelan Data

Sebelum dilakukan tahap pembersihan teks (text cleaning), penelitian ini terlebih dahulu melaksanakan pelabelan data sentimen terhadap seluruh tweet yang telah dikumpulkan. Pelabelan data adalah proses pemberian label sentimen pada setiap cuitan (tweet) yang menjadi unit analisis. Pada penelitian ini, pelabelan dilakukan secara manual (human annotation) oleh peneliti dengan membaca cuitan secara menyeluruh, kemudian menetapkan label berdasarkan kecenderungan opini/sikap yang disampaikan pengguna terhadap Program Makan Bergizi Gratis (MBG), baik berupa dukungan, kritik, maupun pernyataan informatif tanpa muatan emosional yang dominan.

Pelabelan manual dipilih karena karakter teks media sosial sering memuat bahasa tidak baku, singkatan, penekanan dengan huruf kapital, serta gaya sindiran/sarkasme. Dengan pelabelan manual, peneliti dapat menangkap konteks dan maksud utama dari cuitan sehingga label lebih representatif sebagai kelas target pada tahap pemodelan.

Tabel 3.6 Pedoman Pelabelan Data Sentimen

Label	Definisi operasional (inti makna)	Indikator umum (contoh)	Aturan keputusan cepat
Positif	Dukungan/apresiasi/harapan baik terhadap MBG; termasuk kritik konstruktif bila maksud utama tetap mendukung	“setuju”, “bagus”, “mantap”, “dukung”, “lanjutkan”, “membantu”, “semoga berhasil”, “bermanfaat”	Jika ada kritik namun narasi dominan mendukung/solutif → Positif
Netral	Informatif/deskriptif/pertanyaan tanpa penilaian dominan; tidak jelas mendukung atau menolak	“info...”, “menurut...”, “berdasarkan...”, pertanyaan faktual (kapan/di mana/berapa)	Jika tidak ada evaluasi (pujian/keluhan) yang jelas atau terlalu ambigu → Netral
Negatif	Penolakan/kritik/ketidakpercayaan/pesimisme terhadap MBG; termasuk sarkasme yang menyerang program	“tidak efektif”, “rawan korupsi”, “percuma”, “gagal”, “mandek”, “ngapain”, “bahaya”, “basi”	Jika dominan menolak/menyalahkan/curiga; atau ada negasi/sarkasme yang mengunci polaritas → Negatif

Keterangan : Tabel ini berisi pedoman pelabelan sentimen cuitan MBG (Positif, Netral, Negatif). Definisi, indikator, dan aturan keputusan digunakan agar pelabelan manual konsisten dan minim subjektivitas. Label sentimen selanjutnya dikodekan

ke dalam bentuk numerik (misalnya Negatif=0, Netral=1, Positif=2) untuk memudahkan proses pengolahan data, pelatihan model, dan evaluasi pada algoritma klasifikasi.

Berikut ini adalah tabel yang menunjukkan distribusi label sentimen pada dataset cuitan MBG sebanyak 50 data.

Tabel 3.7 Distribusi Label Sentimen pada Dataset Pilot (n=50)

Label	Jumlah	Persentase
Positif	32	64,0%
Negatif	11	22,0%
Netral	7	14,0%
Total	50	100%

Keterangan : Tabel ini menunjukkan distribusi kelas pada dataset pilot yang digunakan untuk uji kelayakan metode pada tahap proposal. Tabel menunjukkan Mayoritas data berlabel Positif (32; 64,0%), diikuti Negatif (11; 22,0%) dan Netral (7; 14,0%), sehingga dapat disimpulkan kecenderungan sentimen dalam dataset lebih dominan positif.

3.5.2 Pembersihan Teks (Text Cleaning)

Tahap pertama dalam pra-pemrosesan teks adalah pembersihan teks (text cleaning). Pada tahap ini, elemen-elemen yang tidak memiliki kontribusi terhadap makna sentimen dihilangkan, seperti URL, mention akun pengguna (@username), simbol hashtag (#), angka yang tidak relevan, serta tanda baca dan karakter khusus. Pembersihan ini bertujuan untuk mengurangi noise pada data sehingga model dapat lebih fokus pada kata-kata yang merepresentasikan opini masyarakat terhadap Program Makan Bergizi Gratis.

Tabel 3.8 Hasil Pembersihan Teks

Tweet Asli	Hasil Pembersihan Teks
Ketika banjir datang, MBG nggak berhenti! 52 SPPG Aceh distribusikan 185 RIBU paket Makan Bergizi Gratis langsung ke korban bencana. Ini baru namanya Kerja Nyata di saat genting! 👉❤️#LanjutkanMBG	Ketika banjir datang MBG nggak berhenti 52 SPPG Aceh distribusikan 185 RIBU paket Makan Bergizi Gratis langsung ke korban bencana Ini baru namanya Kerja Nyata di saat genting LanjutkanMBG

3.5.3 Case Folding

Case folding merupakan proses mengubah seluruh teks menjadi huruf kecil (lowercase). Tujuan dari proses ini adalah untuk menyamakan bentuk kata sehingga tidak terjadi perbedaan makna akibat penggunaan huruf kapital.

Tabel 3.9 Hasil Case Folding

Sebelum Case Folding	Sesudah Case Folding
Tolong Pak , diperketat Pengawasannya agar tidak terjadi lagi kasus siswa siswi yang keracunan di Sukoharjo kalau tidak Salah gara gara makan Makanan Bergizi Gratis, tolong kalo bisa menu serta standar gizinya ditentukan dari Pusat..hati2 dengan tikus yg suka cuan korbankan anak2	tolong diperketat pengawasannya siswa siswi keracunan sukoharjo salah gara gara makan makanan bergizi gratis tolong kalo menu standar gizinya ditentukan pusathati tikus yg suka cuan korbankan anak

3.5.4 Tokenisasi (Tokenizing)

Tokenisasi merupakan proses pemecahan teks menjadi unit-unit kata (token). Setiap kalimat pada kolom Pembersihan Teks dipecah menjadi daftar kata yang kemudian disimpan dalam kolom Tokens. Tahap ini bertujuan untuk memudahkan proses pengolahan teks selanjutnya, seperti penghapusan stopword dan stemming.

Tabel 3.10 Hasil Tokenisasi

Pembersihan Teks	Tokens
Tolong Pak diperketat Pengawasannya agar tidak terjadi lagi kasus siswa siswi yang keracunan di Sukoharjo kalau tidak Salah gara gara makan Makanan Bergizi Gratis tolong kalo bisa menu serta standar gizinya ditentukan dari Pusathati2 dengan tikus yg suka cuan korbakan anak2	[‘tolong’, ‘pak’, ‘diperketat’, ‘pengawasannya’, ‘agar’, ‘tidak’, ‘terjadi’, ‘lagi’, ‘kasus’, ‘siswa’, ‘siswi’, ‘yang’, ‘keracunan’, ‘di’, ‘sukoharjo’, ‘kalau’, ‘tidak’, ‘salah’, ‘gara’, ‘gara’, ‘makan’, ‘makanan’, ‘bergizi’, ‘gratis’, ‘tolong’, ‘kalo’, ‘bisa’, ‘menu’, ‘serta’, ‘standar’, ‘gizinya’, ‘ditentukan’, ‘dari’, ‘pusathati2’, ‘dengan’, ‘tikus’, ‘yg’, ‘suka’, ‘cuan’, ‘korbakan’, ‘anak2’]

3.5.5 Penghapusan Kata Umum (Stopword Removal)

Stopword removal merupakan proses penghapusan kata-kata umum yang sering muncul namun tidak memiliki pengaruh signifikan terhadap penentuan sentimen, seperti *yang*, *dan*, *di*, *itu*, *ke*, dan *dari*. Pada penelitian ini, stopword removal dilakukan menggunakan daftar stopword Bahasa Indonesia. Proses ini bertujuan untuk mengurangi noise pada data dan meningkatkan fokus terhadap kata-kata yang mengandung makna sentimen.

Tabel 3.11 Hasil Stopword Removal

Tokens Sebelum	Tokens Sesudah
['tolong', 'pak', 'diperketat', 'pengawasannya', 'agar', 'tidak', 'terjadi', 'lagi', 'kasus', 'siswa', 'siswi', 'yang', 'keracunan', 'di', 'sukoharjo', 'kalau', 'tidak', 'salah', 'gara', 'gara', 'makan', 'makanan', 'bergizi', 'gratis', 'tolong', 'kalo', 'bisa', 'menu', 'serta', 'standar', 'gizinya', 'ditentukan', 'dari',	Tolong , diperketat Pengawasannya siswa siswi keracunan Sukoharjo Salah gara gara makan Makanan Bergizi Gratis , tolong kalo menu standar gizinya ditentukan Pusat .. hati2 tikus yg suka cuan korbakan anak2

'pusathati2', 'dengan', 'tikus', 'yg', 'suka', 'cuan', 'korbankan', 'anak2']	
--	--

3.5.6 Stemming

Stemming merupakan proses mengubah kata menjadi bentuk dasarnya. Dalam penelitian ini, proses stemming dilakukan menggunakan algoritma stemming Bahasa Indonesia, sehingga kata-kata berimbuhan dapat dikembalikan ke bentuk dasar. Tahap ini bertujuan untuk mengurangi variasi kata yang memiliki makna sama dan meningkatkan efektivitas proses klasifikasi.

Tabel 3.12 Hasil Stemming

Token Setelah Stopword Removal	Token Setelah Stemming
Tolong , diperketat Pengawasannya siswa siswi keracunan Sukoharjo Salah gara gara makan Makanan Bergizi Gratis , tolong kalo menu standar gizinya ditentukan Pusat .. hati2 tikus yg suka cuan korbankan anak2	tolong , diperketat pengawasannya siswa siswi keracunan sukoharjo salah gara gara makan makanan bergizi grati , tolong kalo menu standar gizinya ditentukan pusat .. hati2 tiku yg suka cuan korbankan anak2

2.6 Representasi Fitur Menggunakan TF-IDF

Setelah tahap pra-pemrosesan, data teks diubah menjadi fitur numerik menggunakan TF-IDF (Term Frequency–Inverse Document Frequency) yaitu pembobotan istilah berdasarkan frekuensi kemunculan dalam dokumen (TF) dan tingkat keunikan pada korpus (IDF). Pembentukan fitur dilakukan dengan fit pada data latih dan transform pada data uji menggunakan vektorisasi yang sama untuk mencegah *data leakage*. Matriks TF-IDF yang dihasilkan selanjutnya digunakan sebagai input klasifikasi SVM dan Naïve Bayes.

Tabel 3.13 Representasi TF-IDF

Text	mbg	program	anak	gratis	makan	gizi
mbg makan gizi gratis makan basi gratis...	0.122	0.000	0.000	0.358	0.292	0.150
program makan gizi gratis mbg program unggul presiden prabowo subianto...	0.091	0.159	0.079	0.067	0.054	0.112

Keterangan Tabel:

- Nilai **0.000** menunjukkan fitur/kata tersebut tidak muncul pada dokumen terkait (atau bobotnya menjadi 0).
- Nilai TF-IDF tertinggi menandakan kata paling representatif pada dokumen tersebut
- Tabel ini merupakan contoh hasil ekstraksi fitur TF-IDF, bukan keseluruhan dataset

Tabel 3.14 menampilkan contoh representasi TF-IDF pada data sentimen Program Makan Bergizi Gratis (MBG). Setiap dokumen direpresentasikan sebagai vektor numerik berdasarkan bobot kata yang dihitung menggunakan TF-IDF. Representasi fitur ini selanjutnya digunakan sebagai masukan pada proses klasifikasi menggunakan algoritma Support Vector Machine (SVM) dan Naïve Bayes.

3.7 Penerapan Algoritma

Penelitian ini menggunakan dua algoritma klasifikasi yaitu Support Vector Machine dan Naïve Bayes untuk mengklasifikasikan sentimen teks. Kedua model diimplementasikan menggunakan data hasil preprocessing dan representasi fitur TF-IDF. Sebelum penerapan algoritma klasifikasi dilakukan, dataset yang telah melalui tahap prapemrosesan dan representasi fitur menggunakan Term Frequency–

Inverse Document Frequency (TF-IDF) terlebih dahulu dibagi menjadi data latih (training data) dan data uji (testing data). Pembagian data ini bertujuan untuk memastikan bahwa proses pelatihan model dan pengujian kinerja algoritma dilakukan secara terpisah dan objektif, sehingga hasil evaluasi yang diperoleh dapat mencerminkan kemampuan generalisasi model.

Pada tahap proposal digunakan dataset awal (pilot dataset) sebanyak 50 data yang berfungsi sebagai dasar pengujian awal metode klasifikasi sebelum penggunaan dataset utama pada tahap penelitian selanjutnya. Yang dibagi menjadi 40 data latih (80%) dan 10 data uji (20%) dengan rasio 40:10. Data latih digunakan sebagai dasar pembelajaran model, sedangkan data uji digunakan untuk mengevaluasi kinerja model setelah proses pelatihan. Selain itu, pembagian data dilakukan dengan tetap menjaga proporsi kelas sentimen positif, negatif, dan netral agar tidak terjadi bias kelas pada proses klasifikasi. Ringkasan pembagian data dan distribusi kelas sentimen disajikan pada tabel berikut.

Tabel 3.14 Pembagian Data Latih dan Data Uji pada Dataset Pilot (n=50)

Jenis Data	Jumlah Data	Persentase
Data Latih (Training)	40	80,00%
Data Uji (Testing)	10	20,00%
Total	50	100%

Keterangan: Dataset dibagi menggunakan rasio 40:10 antara data latih dan data uji.

Pembagian data ini digunakan untuk evaluasi awal pada dataset pilot. Evaluasi final dilakukan pada dataset utama.

Tabel 3.15 Data Training

No	gizi	mbg	makan	program	gratis	makan gizi	L
39	0,088323	0,071617	0,085941	0	0	0	0
14	0	0,053778	0	0	0	0	0
49	0,07238	0,058689	0,070428	0	0,086244	0,089025	2
34	0,230622	0	0,074801	0,072812	0,091599	0,094552	2
9	0	0,077887	0	0	0	0	1
33	0	0,060766	0,07292	0	0	0	2
20	0	0,062341	0	0,072821	0	0	1
45	0,110982	0,08999	0,215978	0,105118	0,13224	0,136504	2
5	0	0	0,082833	0,080631	0,101435	0	0
24	0,110396	0,089515	0	0,209126	0	0	2
1	0,112274	0	0,109247	0	0,06689	0,069047	2
43	0,066215	0,053691	0	0,062717	0	0	2
23	0,183612	0	0,119107	0,11594	0,145855	0,150558	2
13	0,105771	0	0	0,100183	0	0	2
27	0	0,102624	0	0,119877	0	0	2
28	0	0	0,132479	0,128957	0,162231	0	2
50	0,129046	0	0,062783	0,061114	0,076882	0,079361	2
35	0,070842	0	0,068932	0,067099	0,084412	0,087134	2
10	0,092262	0	0,089773	0	0,219869	0,113479	2
6	0	0,079987	0,095986	0	0	0	1
17	0	0,057423	0	0,067076	0	0	2
26	0,11823	0,095867	0	0	0	0	2
31	0,111872	0,090711	0,054427	0,158941	0,06665	0,068799	2
38	0	0,039217	0	0,045809	0	0	1
44	0,071331	0,057839	0,069407	0	0	0,087735	2
4	0	0,071836	0	0	0	0	0
37	0,109609	0,088877	0,106653	0,103818	0,130605	0,134816	2
40	0	0,100789	0	0	0	0	2
29	0,122175	0,049533	0,05944	0,05786	0,072789	0,075136	2
18	0	0,161897	0	0,094557	0	0	2
41	0	0,047584	0	0,055583	0	0	0
47	0,105168	0,085276	0	0	0	0	2
11	0,108799	0,04411	0,052933	0,051525	0	0,06691	1
8	0,150191	0,121782	0,292281	0	0,35792	0,18473	0
32	0	0,05191	0	0,121273	0	0	0
21	0,060793	0,049294	0,118308	0,057581	0,072438	0,074774	2
46	0,062215	0,100895	0,060538	0,058928	0	0	2
3	0	0	0,065331	0,063594	0,080003	0	0
15	0	0,038573	0,046288	0	0	0	2

30	0	0,21956	0	0	0	0	0
----	---	---------	---	---	---	---	---

Keterangan:

Tabel ini berisi data training hasil ekstraksi fitur TF-IDF (ditampilkan hanya sebagian fitur). Nilai pada setiap kolom fitur menunjukkan bobot TF-IDF, sedangkan nilai 0 berarti kata/frasa tidak muncul pada dokumen tersebut. Kolom L adalah label sentimen yang telah dikodekan ke numerik (mis. Negatif=0, Netral=1, Positif=2).

Tabel 3.16 Data Testing

No	gizi	mbg	makan	program	gratis	makan gizi	L
22	0	0,328039	0	0,191593	0	0	0
36	0	0	0,29925434	0,1456493	0,3664597	0	2
12	0	0,066082	0	0,0771907	0	0	1
19	0	0,1082	0	0,12639	0	0	1
2	0,24227	0	0	0,2294663	0	0	2
48	0	0,10576	0	0,1235396	0	0	2
16	0,15449	0	0,15032334	0,146327	0,1840823	0,1900173	2
42	0,28579	0,115865	0,13903903	0,1353427	0,1702638	0,1757533	2
7	0,36486	0	0,23667789	0	0	0,1495872	0
25	0	0,116255	0	0	0	0	2

Keterangan:

Tabel ini menampilkan data testing yang telah direpresentasikan menggunakan fitur TF-IDF (hanya sebagian fitur ditampilkan). Nilai pada setiap kolom menunjukkan bobot TF-IDF kata/frasa pada dokumen, sedangkan 0 berarti fitur tersebut tidak muncul. Kolom L merupakan label sentimen dalam bentuk numerik (mis. Negatif=0, Netral=1, Positif=2) yang digunakan untuk evaluasi kinerja model pada data uji.

3.7.1 Penerapan Algoritma Support Vector Machine (SVM)

Setelah proses pembagian data dilakukan, tahap selanjutnya adalah penerapan algoritma Support Vector Machine (SVM) untuk klasifikasi sentimen. SVM digunakan untuk mengklasifikasikan sentimen berdasarkan fitur teks yang telah direpresentasikan dalam bentuk vektor TF-IDF. Algoritma ini bekerja dengan membangun batas keputusan (decision boundary) yang optimal untuk memisahkan kelas-kelas sentimen pada ruang fitur berdimensi tinggi, sehingga mampu menghasilkan model dengan kemampuan generalisasi yang baik. Parameter yang digunakan dalam penelitian ini adalah kernel linier dan parameter c , pemilihan kernel linear didasarkan pada karakteristik data teks yang memiliki dimensi tinggi dan sparsity yang besar. Parameter C (regularization parameter) digunakan untuk mengontrol keseimbangan antara margin yang besar dan kesalahan klasifikasi. Kita akan menggunakan data testing pada tabel 3.17 untuk menguji performa model SVM. Berikut ini langkah – langkah perhitungan manual pada SVM :

A. Untuk Linear SVM, prediksi dilakukan dengan menghitung:

$$\text{score}(c) = w_c \cdot x + b_c$$

x = vektor TF-IDF data testing (fitur yang sama)

w_c, b_c = parameter model hasil training untuk kelas c

Karena punya 3 kelas, implementasi umum adalah One-vs-Rest (OvR):

Ada 3 pasang (w, b) : untuk Negatif, Netral, Positif

Prediksi = kelas dengan score terbesar

B. Ambil 1 baris data testing untuk pengujian

No	gizi	mbg	makan	program	gratis	makan gizi	...	L
16	0,15449	0	0,15032334	0,146327	0,1840823	0,1900173		2

C. Perhitungan untuk kelas positif (2)

$$b_{pos} = 0,071819$$

w_{pos} : mbg $-0,784452$; gizi $0,517734$; makan gizi $0,299019$; program $0,140406$; gratis $-0,018422$; makan $-0,009499$

Hitung kontribusi ($w \cdot x$):

$$\text{mbg: } (-0,784452)(0) = 0$$

$$\text{gizi: } (0,517734)(0,15449) = 0,079984726$$

$$\text{makan gizi: } (0,299019)(0,1900173) = 0,056818783$$

$$\text{program: } (0,140406)(0,146327) = 0,020545189$$

$$\text{gratis: } (-0,018422)(0,1840823) = -0,003391164$$

$$\text{makan: } (-0,009499)(0,15032334) = -0,001427921$$

Jumlah:

$$\sum(w \cdot x) = 0,152529612$$

Tambah intercept:

$$\text{score(Positif)} = 0,152529612 + 0,071819174 = 0,224348786$$

D. Perhitungan Kelas Negatif (0)

$$b_{neg} = -0,408293$$

w_{neg} : mbg $0,994148$; gizi $-0,432879$; makan gizi $-0,341181$; gratis $0,322243$; makan $0,140548$; program $-0,130420$

Kontribusi :

$$\text{mbg: } (0,994148)(0) = 0$$

$$\text{gizi: } (-0,432879)(0,15449) = -0,066875477$$

$$\text{makan gizi: } (-0,341181)(0,1900173) = -0,064830292$$

$$\text{gratis: } (0,322243)(0,1840823) = 0,059319233$$

$$\text{makan: } (0,140548)(0,15032334) = 0,021127645$$

$$\text{program: } (-0,130420)(0,146327) = -0,019083967$$

Jumlah:

$$\sum(w \cdot x) = -0,070342859$$

Tambah intercept:

$$\text{score(Negatif)} = -0,070342859 - 0,408293495 = -0,478636354$$

E. Perhitungan Kelas Netral (1)

$$b_{net} = -0,574747$$

$$w_{net}: \text{ gratis } -0,400721; \text{ gizi } -0,232170; \text{ makan } -0,212270; \text{ mbg } -0,166459; \text{ program } -0,115826; \text{ makan gizi } -0,053944$$

Kontribusi :

$$\text{gratis: } (-0,400721)(0,1840823) = -0,073765643$$

$$\text{gizi: } (-0,232170)(0,15449) = -0,035867943$$

$$\text{makan: } (-0,212270)(0,15032334) = -0,031909135$$

$$\text{mbg: } (-0,166459)(0) = 0$$

$$\text{program: } (-0,115826)(0,146327) = -0,016948471$$

$$\text{makan gizi: } (-0,053944)(0,1900173) = -0,010250293$$

Jumlah:

$$\sum(w \cdot x) = -0,168741486$$

Tambah intercept:

$$\text{score(Netral)} = -0,168741486 - 0,574747229 = -0,743488716$$

F. Keputusan Prediksi (argmax skor)

Bandingkan skor:

Positif: 0,224348786

Negatif: -0,478636354

Netral: -0,743488716

Skor terbesar adalah Positif, sehingga prediksi SVM (berdasarkan 6 fitur cuplikan) adalah:

$$\hat{y} = \text{Positif (2)}$$

Hasil pengujian bernilai positif yang artinya sama dengan data latih dengan label bernilai positif (2), ini meunjukkan bahwa prediksi sesuai

3.7.2 Penerapan Algoritma Naïve Bayes

Sebagai pembanding, algoritma Multinomial Naïve Bayes (NB) diterapkan menggunakan dataset dan representasi fitur yang sama. Naïve Bayes merupakan metode klasifikasi probabilistik yang menentukan kelas suatu dokumen berdasarkan distribusi kemunculan fitur dengan asumsi independensi antar fitur. Penggunaan input TF-IDF yang sama bertujuan agar perbandingan kinerja antara SVM dan Naïve Bayes dapat dilakukan secara objektif. Parameter yang digunakan pada penelitian ini adalah Laplace smoothing, penggunaan laplace smoothing bertujuan untuk menghindari probabilitas nol pada fitur yang tidak muncul dalam

data latih, sehingga model tetap dapat melakukan prediksi dengan stabil. Berikut ini langkah – langkah perhitungan manual pada Naïve Bayes :

Kita menggunakan data uji yang sama pada perhitungan manual model algoritma sebelumnya

No	gizi	mbg	makan	program	gratis	makan gizi	...	L
16	0,15449	0	0,15032334	0,146327	0,1840823	0,1900173		2

A. Menghitung Prior Kelas dari data training 40 data

Jumlah kelas pada training: Negatif=9, Netral=5, Positif=26

$$P(0) = \frac{9}{40} = 0,225 \Rightarrow \log P(0) = -1,491655$$

$$P(1) = \frac{5}{40} = 0,125 \Rightarrow \log P(1) = -2,079442$$

$$P(2) = \frac{26}{40} = 0,65 \Rightarrow \log P(2) = -0,430783$$

B. Likelihood (log) per fitur dari model Naïve Bayes

Skor (log-posterior tak ternormalisasi) dihitung dengan:

$$score(c) = \log P(c) + \sum_i x_i \cdot \log P(fitur_i | c)$$

Tabel 3.17 Tabel Kontribusi 6 fitur

Fitur	x	logP(f Neg)	x·logP (Neg)	logP(f Net)	x·logP (Net)	logP(f Pos)	x·logP (Pos)
mbg	0,00000 0	-4,816967	0,00000 0	- 5,037216	0,00000 0	- 4,455052	0,00000 0
progra m	0,14632 7	-5,032033	- 0,73632 2	- 5,145165	- 0,75287 7	- 4,372444	- 0,63980 7
gizi	0,15449 0	-5,096571	- 0,78736 9	- 5,199902	- 0,80333 3	- 4,230106	- 0,65350 9

makan	0,15032 3	-4,887581	- 0,73471 7	- 5,163480	- 0,77619 1	- 4,415053	- 0,66368 5
gratis	0,18408 2	-4,879118	- 0,89815 9	- 5,302301	- 0,97606 0	- 4,464780	- 0,82188 7
makan gizi	0,19001 7	-5,310484	- 1,00908 4	- 5,237534	- 0,99522 2	- 4,528097	- 0,86041 7

Jumlah kontribusi ($\sum x \cdot \log P$) dari 6 fitur:

$$\Sigma Neg = -4,165652$$

$$\Sigma Net = -4,303683$$

$$\Sigma Pos = -3,639305$$

C. Menghitung Skor Tiap Kelas

$$\begin{aligned} score(0) &= \log P(0) + \Sigma Neg = -1,491655 + (-4,165652) \\ &= -5,657307 \end{aligned}$$

$$\begin{aligned} score(1) &= \log P(1) + \Sigma Net = -2,079442 + (-4,303683) \\ &= -6,383125 \end{aligned}$$

$$\begin{aligned} score(2) &= \log P(2) + \Sigma Pos = -0,430783 + (-3,639305) \\ &= -4,070088 \end{aligned}$$

D. Keputusan Prediksi

Skor terbesar (paling mendekati 0) adalah kelas 2 (Positif), sehingga:

$$\hat{y} = \arg \max (score) = 2 \text{ (Positif)}$$

Hasil prediksi Naïve Bayes untuk data uji menghasilkan positif, ini menunjukkan bahwa prediksi sesuai

3.8 Teknik Evaluasi Machine Learning

Teknik evaluasi digunakan untuk menilai kinerja algoritma Support Vector Machine (SVM) dan Naïve Bayes (NB) dalam mengklasifikasikan sentimen publik terhadap Program Makan Bergizi Gratis di media sosial X. Evaluasi dilakukan dengan membandingkan label hasil prediksi model pada data uji (*testing data*) dengan label sentimen sebenarnya, sehingga dapat diketahui tingkat ketepatan dan konsistensi model dalam melakukan klasifikasi.

3.8.1 Evaluasi Model *Support Vector Machine* (SVM)

Kinerja model SVM dievaluasi berdasarkan data uji yang telah diklasifikasikan sebelumnya. Evaluasi dilakukan menggunakan metrik Akurasi (*Accuracy*), Presisi (*Precision*), Recall (*Sensitivity*), dan F1 Score. Berikut ini adalah Confusion Matrix berdasarkan hasil prediksi.

Tabel 3.18 Tabel Confusion Matrix Support Vector Machine

Aktual	Prediction		
	Positif	Negatif	Netral
Positif	6 TP	1 FN	2 FN
Negatif	1 FP	1 TN	0 FN
Netral	2 FP	1 FN	0 TN

Keterangan :

1. Positif aktual, model memprediksi Positif dengan benar sebanyak 6 kali (TP), tetapi salah memprediksi sebagai Negatif sebanyak 1 kali (FN) dan Netral sebanyak 2 kali (FN).
2. Negatif aktual, model salah memprediksi sebagai Positif sebanyak 1 kali (FP), benar memprediksi sebagai Negatif sebanyak 1 kali (TN), dan salah memprediksi sebagai Netral sebanyak 0 kali.

- Netral aktual, model salah memprediksi sebagai Positif sebanyak 2 kali (FP), salah memprediksi sebagai Negatif sebanyak 1 kali (FN), dan benar memprediksi sebagai Netral sebanyak 0 kali (TN)

Berikut ini adalah akurasi, presisi, recall dan F1-Score :

- Akurasi (Accuracy)

Akurasi mengukur proporsi prediksi yang benar dari total prediksi yang dibuat oleh model.

$$\begin{aligned} \text{Akurasi} &= \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Total Prediksi}} \\ &= \frac{7}{22} = 0,3182 = 31,82\% \end{aligned}$$

- Presisi (Precision)

Precision mengukur ketepatan model dalam mengklasifikasikan sentimen positif. Precision dihitung dengan rumus:

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}}$$

Presisi Kelas Positif

$$\text{Presisi (P)} = \frac{TP}{TP+FP} = \frac{6}{6+1} = \frac{6}{7} = 0,9$$

Presisi Kelas Negatif

$$\text{Presisi (Neg)} = \frac{TP}{TP+FP} = \frac{1}{1+0} = \frac{1}{1} = 1$$

Presisi Kelas Netral

$$\text{Presisi (Net)} = \frac{TP}{TP+FP} = \frac{0}{0+0} = \frac{0}{2} = 0$$

- Recall

Recall mengukur kemampuan model dalam mengidentifikasi semua sentimen positif. Recall dihitung dengan rumus:

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

Recall Kelas Positif

$$\text{Recall (P)} = \frac{TP}{TP+FN} = \frac{6}{6+0} = \frac{6}{6} = 1$$

Recall Kelas Negatif

$$\text{Recall (Neg)} = \frac{TP}{TP+FN} = \frac{1}{1+1} = \frac{1}{2} = 0,5$$

Recall Kelas Netral

$$\text{Recall (Net)} = \frac{TP}{TP+FN} = \frac{0}{0+2} = \frac{0}{2} = 0$$

4. F1-Score

F1-Score adalah rata-rata harmonis antara precision dan recall, yang memberikan gambaran seimbang tentang kinerja model. F1-Score dihitung dengan rumus:

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

F1-Score Kelas Positif

$$\text{F1-Score (P)} = 2 \times \frac{0,6 \times 1}{0,6 + 1} = 2 \times \frac{0,6}{1,6} = 0,75$$

F1-Score Kelas Negatif

$$\text{F1-Score (Neg)} = 2 \times \frac{1 \times 0,5}{1 + 0,5} = 2 \times \frac{0,5}{1,5} = 0,67$$

F1-Score Kelas Netral

$$\text{F1-Score (Net)} = 2 \times \frac{0 \times 0}{0 + 0} = 2 \times \frac{0}{0} = 0$$

3.8.2 Evaluasi Model Naïve bayes

Sekarang kita mengevaluasi kinerja model *Naïve Bayes*, evaluasi dilakukan menggunakan metrik Akurasi (*Accuracy*), Presisi (*Precision*), Recall (*Sensitivity*), dan F1 Score. Berikut ini adalah Confusion Matrix berdasarkan hasil prediksi.

Tabel 3.19 Tabel Confusion Matrix Naïve Bayes

Aktual	Prediction		
	Positif	Negatif	Netral
Positif	6 TP	2 FN	2 FN
Negatif	0 FP	0 TN	0 FN
Netral	0 FP	0 FN	0 TN

Keterangan :

1. Positif aktual, model memprediksi Positif dengan benar sebanyak 6 kali (TP), tetapi salah memprediksi sebagai Negatif sebanyak 2 kali (FN) dan Netral sebanyak 2 kali (FN).
2. Negatif aktual, model tidak pernah salah memprediksi sebagai Positif (FP), memprediksi Negatif dengan benar sebanyak 0 kali (TN), dan tidak ada FN.
3. Netral aktual, model tidak pernah salah memprediksi sebagai Positif atau Negatif (FP/FN), dan tidak ada prediksi yang benar untuk kategori ini (TN).

Berikut ini adalah akurasi, presisi, recall dan F1-Score :

1. Akurasi (*Accuracy*)

Akurasi mengukur proporsi prediksi yang benar dari total prediksi yang dibuat oleh model.

$$\begin{aligned} \text{Akurasi} &= \frac{\text{Jumlah Prediksi Benar}}{\text{Jumlah Total Prediksi}} \\ &= \frac{6}{22} = 0,2727 = 27,27\% \end{aligned}$$

2. Presisi (Precision)

Precision mengukur ketepatan model dalam mengklasifikasikan sentimen positif. Precision dihitung dengan rumus:

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}}$$

Presisi Kelas Positif

$$\text{Presisi (P)} = \frac{TP}{TP+FP} = \frac{6}{6+0} = \frac{6}{6} = 1$$

Presisi Kelas Negatif

$$\text{Presisi (Neg)} = \frac{TP}{TP+FP} = \frac{0}{0+0} = \frac{0}{0} = 0$$

Presisi Kelas Netral

$$\text{Presisi (Net)} = \frac{TP}{TP+FP} = \frac{0}{0+0} = \frac{0}{0} = 0$$

3. Recall

Recall mengukur kemampuan model dalam mengidentifikasi semua sentimen positif. Recall dihitung dengan rumus:

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

Recall Kelas Positif

$$\text{Recall (P)} = \frac{TP}{TP+FN} = \frac{6}{6+0} = \frac{6}{6} = 1$$

Recall Kelas Negatif

$$\text{Recall (Neg)} = \frac{TP}{TP+FN} = \frac{0}{0+2} = \frac{0}{2} = 0$$

Recall Kelas Netral

$$\text{Recall (Net)} = \frac{TP}{TP+FN} = \frac{0}{0+2} = \frac{0}{2} = 0$$

4. F1-Score

F1-Score adalah rata-rata harmonis antara precision dan recall, yang memberikan gambaran seimbang tentang kinerja model. F1-Score dihitung dengan rumus:

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

F1-Score Kelas Positif

$$\text{F1-Score (P)} = 2 \times \frac{1 \times 1}{1 + 1} = 2 \times \frac{1}{2} = 1$$

F1-Score Kelas Negatif

$$\text{F1-Score (Neg)} = 2 \times \frac{0 \times 0}{0 + 0} = 2 \times \frac{0}{0} = 0$$

F1-Score Kelas Netral

$$\text{F1-Score (Net)} = 2 \times \frac{0 \times 0}{0 + 0} = 2 \times \frac{0}{0} = 0$$

3.8.4 Validasi Model

Validasi model merupakan tahapan penting dalam penelitian machine learning untuk memastikan bahwa model yang dibangun memiliki kemampuan generalisasi yang baik terhadap data yang belum pernah digunakan pada proses pelatihan. Pada penelitian ini, validasi model dilakukan menggunakan metode Stratified 10-Fold Cross Validation sebagai strategi evaluasi performa model.

Metode 10-Fold Cross Validation membagi dataset ke dalam sepuluh bagian (fold) dengan ukuran yang relatif sama. Pada setiap iterasi, sembilan fold (90%) digunakan sebagai data latih (training), sedangkan satu fold (10%) digunakan sebagai data uji (testing). Proses ini dilakukan sebanyak sepuluh kali sehingga

setiap bagian data memperoleh kesempatan menjadi data uji satu kali. Nilai performa akhir model diperoleh dari rata-rata hasil evaluasi pada seluruh fold.

Pendekatan stratified digunakan untuk menjaga proporsi distribusi kelas sentimen, yaitu positif, negatif, dan netral, pada setiap fold tetap seimbang sesuai dengan distribusi dataset keseluruhan sehingga dapat mengurangi bias evaluasi akibat ketidakseimbangan data.