

**ANALISIS KOMPARATIF METODE *NAIVE BAYES* DAN  
SUPPORT VECTOR MACHINE (SVM) UNTUK  
KLASIFIKASI GENDER BERDASARKAN  
KOMENTAR PADA PLATFORM  
X (TWITTER)**



Disusun Oleh:

N a m a : Ridzky Putra Dwitama  
NIM : 21523151

**PROGRAM STUDI INFORMATIKA – PROGRAM SARJANA  
FAKULTAS TEKNOLOGI INDUSTRI UNIVERSITAS ISLAM INDONESIA  
2025**

HALAMAN PENGESAHAN DOSEN PEMBIMBING


**ANALISIS KOMPARATIF METODE *NAIVE BAYES* DAN  
SUPPORT VECTOR MACHINE (SVM) UNTUK  
KLASIFIKASI GENDER BERDASARKAN  
KOMENTAR PADAPLATFORM  
X (TWITTER)**

**TUGAS AKHIR**



Yogyakarta, 21 Juli 2025

Pembimbing,

  
Irving Vitra Paputungan, S.T., M.Sc., Ph.D.

## HALAMAN PENGESAHAN DOSEN PENGUJI

# ANALISIS KOMPARATIF METODE *NAIVE BAYES* DAN SUPPORT VECTOR MACHINE (SVM) UNTUK KLASIFIKASI GENDER BERDASARKAN KOMENTAR PADAPLATFORM X (TWITTER)

## TUGAS AKHIR

Telah dipertahankan di depan sidang penguji sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer dari Program Studi Informatika – Program Sarjana di Fakultas Teknologi Industri Universitas Islam Indonesia

Yogyakarta, 27 Agustus 2025

Tim Penguji

Irving Vitra Paputungan, S.T., M.Sc., Ph.D.

08/09/2025

Anggota 1

Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D.

Anggota 2

Rahadian Kurniawan, S.Kom., M.Kom.

Mengetahui,

Ketua Program Studi Informatika – Program Sarjana

Fakultas Teknologi Industri

Universitas Islam Indonesia



Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D.

## HALAMAN PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini:

Nama : Ridzky Putra Dwitama

NIM : 21523151

Tugas akhir dengan judul:

### **ANALISIS KOMPARATIF METODE *NAIVE BAYES* DAN SUPPORT VECTOR MACHINE (SVM) UNTUK KLASIFIKASI GENDER BERDASARKAN KOMENTAR PADAPLATFORM X (TWITTER)**

Menyatakan bahwa seluruh komponen dan isi dalam tugas akhir ini adalah hasil karya saya sendiri. Apabila di kemudian hari terbukti ada beberapa bagian dari karya ini adalah bukan hasil karya sendiri, tugas akhir yang diajukan sebagai hasil karya sendiri ini siap ditarik kembali dan siap menanggung risiko dan konsekuensi apapun.

Demikian surat pernyataan ini dibuat, semoga dapat dipergunakan sebagaimana mestinya.

Yogyakarta, 23 Juli 2025



Ridzky Putra Dwitama

## **HALAMAN PERSEMBAHAN**

Karya ini saya persembahkan untuk kedua orang tua saya yang selalu memberikan doa, dukungan, dan kasih sayang tanpa henti di setiap langkah kehidupan. Saya juga menyampaikan terima kasih kepada teman-teman yang telah menjadi sumber semangat dan pengingat untuk terus maju. Tak lupa, penghargaan saya tujukan kepada para peneliti dan praktisi teknologi yang terus mengembangkan ilmu dalam bidang pemrosesan bahasa alami dan kecerdasan buatan. Semoga karya sederhana ini dapat menjadi bagian dari kontribusi kecil dalam menjembatani pemahaman antara manusia dan mesin melalui bahasa.

## **HALAMAN MOTO**

"Barangsiapa menempuh suatu jalan untuk mencari ilmu, Allah akan memudahkan baginya jalan menuju surga."  
(HR. Muslim, no 2699)

Sometimes we have to go deep inside ourselves to solve our problems  
-Patrick Star

## KATA PENGANTAR

**Assalamualaikum Warahmatullahi Wabarakatuh.**

*Alhamdulillah rabbil 'alamin*, puji syukur penulis panjatkan ke hadirat Allah SWT, Tuhan semesta alam atas segala rahmat, taufik, dan hidayah-Nya yang tak terhingga. Berkat limpahan rahmat dan karunia-Nya, penulis dapat menyelesaikan tugas akhir ini dengan baik dan lancar. Shalawat serta salam senantiasa tercurah kepada Nabi Muhammad SAW, yang telah membimbing umat manusia menuju jalan yang penuh dengan ilmu dan kebenaran.

Dalam proses penyusunan tugas akhir ini hingga selesai tentu tidak lepas dari dukungan, bantuan, dan bimbingan berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis menyampaikan ucapan terimakasih yang mendalam kepada:

1. Allah SWT yang senantiasa memberikan rahmat dan karunia dalam setiap langkah kehidupan penulis, sejak lahir hingga akhir hayat kelak.
2. Kedua orang tua tercinta atas kasih sayang, doa, serta dukungan yang tiada henti sehingga penulis dapat menyelesaikan studi ini.
3. Kakak penulis yang terus memberikan semangat.
4. Prof. Fathul Wahid, S.T., M.Sc., Ph.D., selaku Rektor Universitas Islam Indonesia.
5. Dhomas Hatta Fudholi, S.T., M.Eng., Ph.D., selaku Ketua Program Studi Informatika Program Sarjana Fakultas Teknologi Industri UII.
6. Irving Vitra Paputungan, S.T., M.Sc., Ph.D., selaku dosen pembimbing tugas akhir, atas bimbingan, arahan, dan ilmunya selama proses penelitian ini.
7. Seluruh dosen Program Studi Informatika yang telah berbagi ilmu dan pengalaman yang sangat berharga selama masa studi.
8. Teman-teman mahasiswa Informatika angkatan 21 yang senantiasa menemani dari awal hingga akhir perkuliahan, khususnya teman-teman grup penuh berkah yang tidak bisa saya sebutkan satu persatu.
9. Serta semua pihak yang telah membantu namun tidak dapat disebutkan satu per satu.

Penulis menyadari sepenuhnya bahwa tugas akhir ini masih jauh dari kata sempurna. Oleh karena itu, segala bentuk kritik dan saran yang bersifat membangun sangat diharapkan penulis demi perbaikan di masa yang akan datang.

Akhir kata, penulis berharap karya ini dapat memberikan manfaat, kontribusi positif, dan menjadi referensi yang berguna dalam pengembangan ilmu, khususnya di bidang analisis data dan klasifikasi berbasis teks. Semoga tulisan ini dapat membuka ruang diskusi, menjadi acuan awal bagi penelitian lanjutan, serta menginspirasi pembaca yang memiliki ketertarikan pada

topik serupa. Penulis juga memohon maaf apabila terdapat kekurangan dalam penyusunan tugas akhir ini. Semoga karya ini dapat menjadi pijakan awal untuk penelitian lanjutan yang lebih baik di masa mendatang

*Wassalamu'alaikum Wr. Wb.*

Yogyakarta, 23 Juli 2025

A handwritten signature in dark ink, featuring a large, stylized initial 'R' followed by a series of connected loops and a long, sweeping horizontal stroke extending to the right.

Ridzky Putra Dwitama

## SARI

Media sosial X (sebelumnya Twitter) merupakan salah satu platform yang banyak digunakan oleh masyarakat untuk menyampaikan opini dalam bentuk komentar teks. Komentar-komentar ini tidak hanya mencerminkan pandangan pengguna, tetapi juga menyimpan informasi yang berpotensi untuk mengenali karakteristik demografis, seperti gender. Dalam konteks tersebut, penelitian ini bertujuan untuk membangun dan membandingkan dua model klasifikasi teks, yaitu Naïve Bayes dan Support Vector Machine (SVM), dalam mengklasifikasikan gender berdasarkan komentar pengguna di media sosial X.

Penelitian ini menggunakan pendekatan pembelajaran mesin dengan memanfaatkan teknik ekstraksi fitur TF-IDF terhadap data komentar yang diperoleh melalui web scraping. Proses evaluasi dilakukan terhadap tiga skenario jumlah data (1000, 3000, dan 5000 komentar), dengan dua variasi rasio pembagian data latih dan uji (70:30 dan 80:20), serta beberapa konfigurasi hyperparameter untuk masing-masing model. Kinerja kedua model diukur menggunakan empat metrik utama, yaitu akurasi, precision, recall, dan F1-score.

Hasil penelitian menunjukkan bahwa SVM secara konsisten menghasilkan performa yang lebih tinggi dibandingkan Naïve Bayes dalam seluruh skenario pengujian, khususnya pada dataset berukuran besar. Meskipun Naïve Bayes memiliki keunggulan dari sisi efisiensi komputasi, SVM menunjukkan kemampuan generalisasi yang lebih kuat serta stabilitas klasifikasi yang lebih baik. Dengan demikian, SVM menjadi pilihan yang lebih tepat untuk klasifikasi gender berbasis komentar teks ketika akurasi menjadi prioritas utama. Penelitian ini diharapkan dapat memberikan kontribusi bagi pengembangan sistem klasifikasi berbasis teks dalam berbagai domain, seperti analisis media sosial, pemasaran digital berbasis gender, serta sistem moderasi konten berbasis pengguna.

Kata Kunci: Naïve Bayes, Support Vector Machine, klasifikasi gender, komentar media sosial, pembelajaran mesin, klasifikasi teks.

## GLOSARIUM

|                                      |                                                                                                                                                     |
|--------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|
| Akurasi (Accuracy)                   | Ukuran yang menunjukkan seberapa sering model membuat prediksi yang benar terhadap total prediksi yang dilakukan.                                   |
| Alpha ( $\alpha$ )                   | Parameter smoothing dalam algoritma Naïve Bayes yang digunakan untuk menghindari pembagian dengan nol dan menangani fitur yang jarang muncul.       |
| Bigram                               | Kombinasi dari dua kata berurutan dalam teks. Dalam ekstraksi fitur, digunakan untuk menangkap konteks yang tidak bisa ditangkap oleh kata tunggal. |
| C (Regularisasi)                     | Parameter dalam SVM yang mengatur keseimbangan antara margin keputusan yang luas dan tingkat kesalahan klasifikasi.                                 |
| F1-Score                             | Rata-rata harmonik dari precision dan recall, digunakan untuk mengevaluasi performa model ketika terdapat ketidakseimbangan antar kelas.            |
| Feature Extraction (Ekstraksi Fitur) | Proses mengubah data teks mentah menjadi representasi numerik yang dapat digunakan oleh algoritma pembelajaran mesin.                               |
| Learning Curve                       | Grafik yang menggambarkan hubungan antara jumlah data pelatihan dan performa model, digunakan untuk mendeteksi overfitting atau underfitting.       |
| Machine Learning                     | Cabang kecerdasan buatan yang memungkinkan sistem belajar dari data untuk membuat prediksi atau keputusan tanpa pemrograman eksplisit.              |
| Naive Bayes                          | Algoritma klasifikasi berbasis probabilitas yang mengasumsikan independensi antar fitur. Efisien untuk teks pendek dan dataset besar.               |
| Precision                            | Metrik evaluasi yang mengukur proporsi prediksi positif yang benar dari seluruh prediksi positif yang dihasilkan model.                             |
| Recall                               | Metrik yang mengukur seberapa banyak data positif yang berhasil diklasifikasikan dengan benar oleh model.                                           |
| SVM (Support Vector Machine)         | Algoritma pembelajaran mesin yang mencari hyperplane optimal untuk memisahkan data ke dalam dua kelas. Efektif untuk data berdimensi tinggi.        |
| Document Frequency)                  | Proses memecah teks menjadi unit kecil seperti kata atau frasa untuk keperluan analisis lebih lanjut.                                               |
| Tokenisasi                           | Kata tunggal yang diambil sebagai satuan terkecil dalam representasi teks,                                                                          |
| Unigram                              | biasanya digunakan bersama bigram untuk memberikan konteks tambahan.                                                                                |

## DAFTAR ISI

|                                                                                 |      |
|---------------------------------------------------------------------------------|------|
| HALAMAN JUDUL .....                                                             | i    |
| HALAMAN PENGESAHAN DOSEN PEMBIMBING.....                                        | ii   |
| HALAMAN PENGESAHAN DOSEN PENGUJI.....                                           | iii  |
| HALAMAN PERNYATAAN KEASLIAN TUGAS AKHIR .....                                   | iv   |
| HALAMAN PERSEMBAHAN .....                                                       | v    |
| HALAMAN MOTO .....                                                              | vi   |
| KATA PENGANTAR .....                                                            | vii  |
| SARI.....                                                                       | ix   |
| GLOSARIUM.....                                                                  | x    |
| DAFTAR ISI.....                                                                 | xi   |
| DAFTAR TABEL.....                                                               | xiii |
| DAFTAR GAMBAR.....                                                              | xiv  |
| BAB I PENDAHULUAN.....                                                          | 15   |
| 1.1 Latar Belakang.....                                                         | 15   |
| 1.2 Rumusan Masalah dan Pertanyaan Penelitian.....                              | 19   |
| 1.3 Batasan Masalah.....                                                        | 20   |
| 1.4 Tujuan Penelitian.....                                                      | 21   |
| 1.5 Manfaat Penelitian.....                                                     | 21   |
| 1.6 Metodologi Penelitian.....                                                  | 22   |
| 1.7 Sistematika Laporan.....                                                    | 24   |
| BAB II KAJIAN PUSTAKA .....                                                     | 25   |
| 2.1 Tantangan dalam Klasifikasi Gender pada Media Sosial .....                  | 25   |
| 2.2 Metode Klasifikasi Gender yang Pernah Diterapkan.....                       | 27   |
| 2.3 Alasan Pemilihan Metode Naive Bayes dan SVM dalam Analisis Komparatif ..... | 29   |
| 2.4 Metode Klasifikasi yang Digunakan.....                                      | 30   |
| BAB III METODE PENELITIAN .....                                                 | 33   |
| 3.1 Pengumpulan Data .....                                                      | 33   |
| 3.2 Preprocessing Data.....                                                     | 36   |
| 1. Import Library .....                                                         | 37   |
| 2. Load Dataset .....                                                           | 38   |
| 3. Cleaning Data.....                                                           | 38   |

|                                   |                                                         |    |
|-----------------------------------|---------------------------------------------------------|----|
| 4.                                | Penambahan Parameter .....                              | 39 |
| 5.                                | Feature Extraction.....                                 | 40 |
| 6.                                | Pembagian data .....                                    | 41 |
| 3.3                               | Implementasi Model Naïve Bayes .....                    | 42 |
| 3.4                               | Implementasi Model SVM (Support Vector Machine).....    | 44 |
| 3.5                               | Evaluasi Model.....                                     | 46 |
| 3.6                               | Komparasi Hasil.....                                    | 47 |
| 3.7                               | Rencana Skenario Pengujian.....                         | 48 |
| BAB IV HASIL DAN PEMBAHASAN ..... |                                                         | 50 |
| 4.1                               | Proses Evaluasi Model .....                             | 50 |
| 4.2                               | Pelatihan dan Pengujian Model (Training & Testing)..... | 50 |
| 4.3                               | Evaluasi Model.....                                     | 51 |
| 4.4                               | Visualisasi dan Interpretasi Hasil Pengujian.....       | 55 |
| 4.5                               | Analisis Hasil .....                                    | 58 |
| BAB V KESIMPULAN DAN SARAN.....   |                                                         | 62 |
| 5.1                               | Kesimpulan.....                                         | 62 |
| 5.2                               | Limitasi Batasan.....                                   | 63 |
| 5.3                               | Saran .....                                             | 63 |
| DAFTAR PUSTAKA .....              |                                                         | 65 |

## DAFTAR TABEL

|                                                            |    |
|------------------------------------------------------------|----|
| Tabel 2.1 Metode yang Pernah Diterapkan Klasifikasi.....   | 27 |
| Tabel 3.1 Hasil Proses Labelling Data.....                 | 34 |
| Tabel 3.2 Visualisasi Pengumpulan Dataset Final.....       | 36 |
| Tabel 3.3 Visualisasi Sebelum dan Sesudah Dibersihkan..... | 39 |
| Tabel 3.4 Visualisasi Parameter Jumlah Kata.....           | 40 |
| Tabel 4.1 Evaluasi Model Naive Bayes Rasio Data 70:30..... | 51 |
| Tabel 4.2 Evaluasi Model Naive Bayes Rasio Data 80:20..... | 52 |
| Tabel 4.3 Evaluasi Model SVM Rasio Data 70:30.....         | 52 |
| Tabel 4.4 Evaluasi Model SVM Rasio Data 80:20.....         | 53 |
| Tabel 4.5 Evaluasi Model Terbaik Rasio Data 70:30.....     | 54 |
| Tabel 4.6 Evaluasi Model Terbaik Rasio Data 80:20.....     | 54 |

## DAFTAR GAMBAR

|                                                                                   |    |
|-----------------------------------------------------------------------------------|----|
| Gambar 1.1 Statistik 8 Negara dengan Pengguna X (Twitter) Terbanyak di Dunia..... | 16 |
| Gambar 1.2 Evolusi Logo Perusahaan Twitter hingga menjadi X.....                  | 17 |
| Gambar 1.3 Distribusi Gender Pengguna X (Twitter).....                            | 18 |
| Gambar 1.4 Diagram Penelitian secara umum .....                                   | 22 |
| Gambar 3.1 Langkah Penelitian Analisis Komparatif.....                            | 36 |
| Gambar 3.2 Langkah Preprocessing Data .....                                       | 37 |
| Gambar 4.1 Confusion Matrix Model Terbaik Rasio Data 70:30 .....                  | 55 |
| Gambar 4.2 Confusion Matrix Model Terbaik 3000 Data .....                         | 56 |
| Gambar 4.4 Grouped Bar Chart Model Terbaik Rasio Data 70:30 .....                 | 57 |
| Gambar 4.5 Grouped Bar Chart Model Terbaik Rasio Data 80:20 .....                 | 57 |


## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Di era digital saat ini, media sosial telah menjadi bagian integral dari kehidupan manusia. Platform seperti Facebook, Instagram, dan X (Twitter) telah mengubah cara individu berinteraksi, membentuk opini, dan menyebarkan informasi secara global. Media sosial bukan lagi sekadar tempat berkomunikasi, melainkan ruang publik baru yang memungkinkan partisipasi sosial, budaya, bahkan politik dalam skala luas dan real-time. Berdasarkan laporan We Are Social & Meltwater (2025), jumlah pengguna media sosial global telah mencapai 5,24 miliar, dengan jumlah pengguna di Indonesia sendiri berjumlah 143 juta pengguna aktif. Hal ini menunjukkan potensi besar media sosial sebagai sumber data digital dalam menganalisis perilaku, opini, dan karakteristik demografis masyarakat, mengingat peranannya yang semakin signifikan dalam interaksi sosial daring (Onikoyi, Nnamoko, & Korkontzelos, 2023) serta kemampuannya menyediakan data yang kaya untuk keperluan analitik berbasis perilaku (Vashisth & Meehan, 2020).


Di antara berbagai platform media sosial yang tersedia, X (sebelumnya dikenal sebagai Twitter) menempati posisi penting sebagai ruang diskusi publik yang dinamis. Karakteristik X yang berbasis teks dan bersifat terbuka menjadikannya sumber data yang sangat potensial untuk penelitian, terutama dalam menganalisis opini atau respons terhadap isu-isu sosial secara real-time. Tidak seperti platform visual seperti Instagram atau yang lebih tertutup seperti Facebook, X memungkinkan pengguna untuk mengekspresikan pandangan secara langsung dalam bentuk komentar, percakapan, dan tren melalui tagar. Dengan mayoritas interaksi pengguna yang bersifat publik serta tingginya volume data teks yang dihasilkan setiap harinya, X menawarkan potensi besar sebagai sumber data terbuka yang relevan dalam eksplorasi perilaku digital dan studi berbasis teks (Onikoyi, Nnamoko, & Korkontzelos, 2023) (Vashisth & Meehan, 2020).



Gambar 1.1 Statistik 8 Negara dengan Pengguna X (Twitter) Terbanyak di Dunia

Sumber: We Are Social & Meltwater (2025)

X telah berkembang dari layanan microblogging menjadi platform multifungsi yang mencakup komunikasi, diskusi publik, hingga transaksi digital. Dengan jumlah mencapai 586 juta pengguna aktif bulanan secara global, termasuk 25.2 juta pengguna dari Indonesia sebagai negara dengan pengguna X terbanyak ke-4 di dunia (We are Social & Meltwater, 2025) dan negara lainnya yang memiliki pengguna twitter terbanyak di dunia ditunjukkan pada gambar 1.1. X menjadi medium penting dalam penyebaran informasi dan dinamika opini publik. Teks komentar yang dihasilkan pada platform ini bersifat tidak terstruktur namun mengandung informasi yang kaya mengenai perilaku dan preferensi pengguna (Vashisth & Meehan, 2020). Selain itu, karakter X sebagai jejaring sosial berbasis teks dengan batasan panjang pesan mendorong gaya komunikasi yang ringkas namun tetap ekspresif (Jintawatsakoon & Poonsawat, 2023). Jumlah pengguna yang masif tersebut mencerminkan keragaman pola komunikasi, termasuk perbedaan karakteristik berdasarkan gender, yang menjadikan X relevan sebagai objek kajian dalam penelitian berbasis teks sosial. Platform media sosial X, sebelumnya dikenal sebagai Twitter, awalnya memiliki logo burung biru hingga tahun 2023 ketika diakuisisi Elon Musk, yang kemudian mengubah nama dan logonya menjadi huruf X dengan latar hitam. Gambar 1.2 menunjukkan evolusi logo tersebut dari awal hingga kini.




Gambar 1.2 Evolusi Logo Perusahaan Twitter hingga menjadi X

Sumber: Phillipe H (2023)

Salah satu fitur utama yang menjadi sumber data penting di X adalah kolom komentar. Komentar-komentar ini mencerminkan secara langsung persepsi, emosi, dan sudut pandang pengguna terhadap suatu isu yang tengah berkembang. Dengan ratusan juta komentar yang diunggah setiap harinya, platform ini menyimpan potensi besar untuk dianalisis dalam memahami pola komunikasi digital, khususnya yang berkaitan dengan atribut sosial seperti gender. Penelitian menunjukkan bahwa analisis komentar dapat mengungkap pola kebahasaan tertentu yang berkorelasi dengan jenis kelamin pengguna, sehingga memungkinkan prediksi gender berdasarkan gaya bahasa dan pilihan kosa kata yang digunakan (Onikoyi, Nnamoko, & Korkontzelos, 2023). Lebih lanjut, karena banyak pengguna media sosial memilih untuk tidak menampilkan identitas asli mereka, termasuk jenis kelamin, maka diperlukan pendekatan berbasis data yang dapat mengenali atribut tersebut secara tidak langsung melalui teks (Vashisth & Meehan, 2020).

Gender menjadi salah satu variabel penting dalam studi komunikasi digital karena perbedaan gaya bahasa dan pendekatan komunikasi antara laki-laki dan perempuan telah diidentifikasi dalam berbagai studi, termasuk oleh Pew Research Center (2023). Misalnya, laki-laki cenderung menggunakan bahasa yang lebih lugas, faktual, dan teknis, sedangkan perempuan lebih sering menggunakan ekspresi emosional dan gaya bahasa yang empatik. Dalam konteks digital, perbedaan ini dapat dimanfaatkan untuk berbagai keperluan, seperti menyusun strategi pemasaran yang lebih tepat sasaran, merancang sistem moderasi konten otomatis yang peka terhadap konteks, serta meningkatkan kualitas interaksi pengguna. Informasi mengenai gender pengguna juga sangat berharga di sektor lain, seperti dalam

investigasi hukum dan analisis perilaku daring, terutama untuk mendeteksi potensi risiko atau kebutuhan spesifik berdasarkan jenis kelamin (Jintawatsakoon & Poonsawat, 2023). Klasifikasi gender dari komentar media sosial dapat dilakukan melalui pendekatan text classification berbasis machine learning. Proses ini mencakup beberapa tahap: preprocessing teks (seperti tokenisasi, stopwords removal, dan stemming), ekstraksi fitur (misalnya TF-IDF atau n-gram), dan pemodelan menggunakan algoritma pembelajaran mesin. Tantangan dalam proses ini terletak pada karakteristik bahasa yang informal, banyaknya singkatan, serta struktur kalimat yang tidak baku.



Gambar 1.3 Distribusi Gender Pengguna X (Twitter)

Sumber: Datareportal (2025)

Berdasarkan Gambar 1.3 dari Datareportal (2025), X memiliki komposisi gender yang menunjukkan bahwa pengguna laki-laki mendominasi dengan 61%, sementara perempuan mencapai 39%. Selain itu, Dalam statistik jumlah pengguna twitter di seluruh dunia, Indonesia menjadi negara ke-4 pengguna akun twitter di dunia sebanyak 24 juta yang menggunakan media sosial Twitter.

Dua metode machine learning yang lazim digunakan dalam klasifikasi teks adalah Naive Bayes dan Support Vector Machine (SVM). Naive Bayes dikenal karena pendekatannya yang sederhana namun efisien dalam memproses data teks berdimensi tinggi, sementara SVM unggul dalam memisahkan data yang kompleks serta mampu menangani kasus non-linear dengan baik. Kedua metode ini telah banyak diterapkan dalam studi klasifikasi teks di media

sosial, termasuk untuk memprediksi gender pengguna berdasarkan komentar mereka (Onikoyi, Nnamoko, & Korkontzelos, 2023) (Vashisth & Meehan, 2020). Masing-masing algoritma memiliki karakteristik dan keunggulan tersendiri, sehingga performa klasifikasinya dapat berbeda secara signifikan tergantung pada sifat dan struktur data yang digunakan.

Penelitian ini bertujuan untuk melakukan klasifikasi gender pada komentar pengguna X (sebelumnya Twitter) dengan memanfaatkan dua metode machine learning yang populer, yaitu Naive Bayes dan Support Vector Machine (SVM). Fokus utama penelitian ini adalah melakukan analisis komparatif terhadap performa kedua metode dalam konteks data sosial media yang bersifat tidak terstruktur. Pemilihan kedua algoritma tersebut didasarkan pada karakteristiknya yang saling melengkapi. Naive Bayes dikenal efisien dalam menangani data teks berdimensi tinggi dengan pendekatan probabilistik sederhana, sementara SVM mampu mengklasifikasikan data secara akurat melalui pemisahan linear maupun non-linear (Jintawatsakoon & Poonsawat, 2023) (Styawati, Isnain, Hendrastuty, & Andraini, 2021).

Analisis komparatif ini penting dilakukan mengingat performa setiap algoritma sangat dipengaruhi oleh struktur data, teknik ekstraksi fitur, serta kompleksitas representasi teks yang digunakan (Vashisth & Meehan, 2020). Studi terdahulu menunjukkan bahwa belum banyak penelitian yang secara khusus membandingkan efektivitas kedua metode ini dalam klasifikasi komentar sosial media, terutama pada kasus identifikasi gender, meskipun topik ini memiliki potensi kontribusi besar dalam bidang forensik digital, pemasaran, dan moderasi konten (Jintawatsakoon & Poonsawat, 2023). Oleh karena itu, melalui evaluasi kuantitatif terhadap akurasi dan metrik performa lainnya, penelitian ini diharapkan dapat memberikan gambaran yang lebih komprehensif terkait metode mana yang lebih optimal digunakan untuk klasifikasi gender berbasis komentar digital.

## 1.2 Rumusan Masalah dan Pertanyaan Penelitian

a. Penelitian ini dilandasi oleh masalah utama seperti:

1. Bagaimana proses klasifikasi gender dapat dilakukan berdasarkan komentar pengguna di media sosial X yang bersifat tidak terstruktur?
2. Bagaimana perbandingan kinerja algoritma Naive Bayes dan Support Vector Machine (SVM) dalam tugas klasifikasi gender berdasarkan metrik evaluasi seperti akurasi, presisi, recall, dan F1-score?

b. Pertanyaan Penelitian

Bagaimana kinerja algoritma Naive Bayes dan SVM dapat dibandingkan dalam mengklasifikasikan gender pengguna, dan metode manakah yang menunjukkan performa paling optimal untuk kasus tersebut?

### 1.3 Batasan Masalah

Untuk menjaga fokus dan kedalaman analisis, penelitian ini dibatasi pada ruang lingkup tertentu yang selaras dengan tujuan utama, yaitu melakukan analisis komparatif antara metode Naive Bayes dan Support Vector Machine (SVM) dalam klasifikasi gender berbasis komentar pengguna di media sosial X. Batasan penelitian dirinci sebagai berikut:

a. Sumber Data

Data yang digunakan berupa komentar teks dari platform X yang dikumpulkan melalui teknik web scraping. Pengambilan data dilakukan dalam periode tertentu untuk menjaga relevansi konteks dan representasi gaya komunikasi pengguna pada waktu tersebut.

b. Kategori Klasifikasi

Penelitian membatasi kategori gender pada dua kelas, yaitu laki-laki dan perempuan. Pembatasan ini ditetapkan untuk menyederhanakan ruang lingkup analisis dan memastikan hasil klasifikasi dapat diinterpretasikan secara jelas dalam konteks perbedaan gaya komunikasi antar gender.

c. Metode Machine Learning

Fokus penelitian hanya mencakup dua algoritma pembelajaran mesin yang umum digunakan dalam klasifikasi teks, yaitu Naive Bayes dan Support Vector Machine (SVM). Pemilihan kedua metode ini didasarkan pada rekam jejaknya dalam literatur terdahulu, terutama dalam pemrosesan data teks yang tidak terstruktur seperti komentar media sosial.

d. Evaluasi Kinerja Model

Kinerja model dikaji berdasarkan empat metrik utama: akurasi, presisi, recall, dan F1-score. Evaluasi ini bertujuan untuk memberikan gambaran menyeluruh terhadap performa masing-masing metode, serta untuk menentukan mana di antara keduanya yang lebih optimal dalam konteks klasifikasi gender berbasis teks di media sosial X.

#### 1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk menjawab pertanyaan penelitian dan mencapai fokus penelitian yang telah ditetapkan. Secara khusus, tujuan dari penelitian ini adalah:

- a. Menggunakan metode Naive Bayes dan Support Vector Machine (SVM) dalam tugas klasifikasi gender berbasis teks dari komentar yang diperoleh di platform media sosial X.
- b. Menganalisis performa kedua metode ini dengan menggunakan matriks evaluasi seperti akurasi, presisi, recall, dan F1-score. Analisis ini bertujuan untuk mendapatkan wawasan mengenai kekuatan dan kelemahan masing-masing metode dalam konteks klasifikasi gender.
- c. Membandingkan efektivitas dan efisiensi Naive Bayes dengan SVM untuk menentukan metode yang paling sesuai dalam klasifikasi gender di komentar media sosial X.

#### 1.5 Manfaat Penelitian


Penelitian ini tidak hanya berfokus pada pencapaian tujuan akademis tetapi juga memberikan manfaat yang lebih luas, sebagai berikut:

- a. Secara akademis, penelitian ini diharapkan dapat menambah khazanah literatur di bidang ilmu data dan pemrosesan bahasa alami (NLP), khususnya mengenai penerapan dan evaluasi algoritma klasifikasi dalam konteks analisis gender berbasis teks di media sosial.
- b. Secara praktis, hasil penelitian ini dapat dijadikan rujukan dalam pengembangan sistem klasifikasi gender yang lebih adaptif dan efisien, yang berguna dalam berbagai bidang seperti pemasaran digital, pengembangan sistem rekomendasi, analisis perilaku konsumen, hingga moderasi konten berbasis demografis.

Dengan batasan yang jelas, tujuan yang terarah, dan manfaat yang konkret, penelitian ini diharapkan tidak hanya berkontribusi pada penyelesaian permasalahan yang diangkat, tetapi juga memberikan dampak nyata bagi pengembangan teknologi analitik berbasis media sosial.

### 1.6 Metodologi Penelitian

Metodologi Penelitian terdiri dari tahapan penelitian secara umum dari perencanaan awal hingga selesai keseluruhan. Langkah-langkah tersebut ditampilkan pada gambar 1.4 yang meliputi:



Gambar 1.4 Diagram Penelitian secara umum

Kajian literatur dilakukan untuk memahami penerapan metode naive bayes dan svm untuk klasifikasi gender berdasarkan komentar pada twitter untuk nanti dianalisis guna membandingkan performa. Literatur yang dipelajari mencakup:

- a. Putri, Enri, & Sari. (2020) yang mengkaji terkait analisis pelecehan seksual dengan tujuan mengklasifikasikan jenis pelecehan dari tweet dengan menggunakan naive bayes sebagai metodenya.
- b. Angelina dkk. (2023) yang membahas tentang analisis sentimen dari pengguna platform Twitter dari kasus konser K-pop dengan menggunakan metode Support Vector Machine (SVM).
- c. Mubarak dkk. (2023) yang membahas tentang analisis efektivitas data tweet dan deskripsi akun dalam mengklasifikasikan gender pengguna twitter dengan CNN dengan menunjukkan penggunaan kombinasi data dan deskripsi menghasilkan akurasi tinggi.
- d. Zakia dkk. (2020) yang melakukan eksplorasi tentang klasifikasi jenis kelamin pengguna twitter dari tweet dengan dua metode, yaitu BM25 dan KNN untuk menghasilkan performa baik dari pengukuran *accuracy*, *precision*, *recall*, dan *F1-score*.
- e. Ramli & Sibaroni (2022) yang mengkaji terkait klasifikasi dari topik dengan menggunakan fitur ekspansi Word2Vec secara signifikan meningkatkan performa klasifikasi.

- f. Sa'Diah dkk. (2024) yang membahas penggunaan metode Long Short-Term Memory (LSTM) dalam kasus klasifikasi gender dari analisis teks.

a) Pengumpulan Data

Data yang digunakan dalam penelitian ini dikumpulkan dari platform X (Twitter) yang dilakukan dengan teknik tweet-harvest. Teks komentar yang dikumpulkan mencakup berbagai topic atau tren yang sedang panas, rentang waktu tertentu dengan gaya penulisan yang berbeda-beda melihat dari perkembangan zaman yang bertujuan supaya model dapat mengenali pola komentar untuk nanti ditentukan kelas gender nya.

b) Preprocessing Data

Tahap preprocessing yaitu, pembersihan dan pengolahan data untuk memastikan kualitas dan validitas data yang digunakan untuk implementasi model. Proses ini meliputi input data teks dari file CSV, lalu pembersihan teks dilakukan untuk menghapus elemen yang tidak diperlukan seperti emoji, tak, tokenisasi, penghapusan stopwords, stemming. Penghitungan metrik tambahan yaitu jumlah kata dilakukan untuk memastikan data yang bagus untuk nanti dimodelkan. Pengubahan singkatan untuk menambah kualitas komentar. Preprocessing ini bertujuan supaya data sudah bersih dan siap untuk dilatih ke model naive bayes dan svm. Setelah perhitungan metrik, sebelum model di implementasikan, dilakukan pembagian data atau split data dengan rasio 70:30 dan 80:20 untuk kedua model.

c) Implementasi Model

Model naive bayes dibangun untuk menentukan probabilitas dari teks untuk nanti ditentukan gendernya, yang memungkinkan beberapa kata yang sering muncul pada gender tertentu dapat ditentukan gendernya ketika ada data baru nantinya. Sedangkan model svm dibangun dengan menentukan hyperplane dari fitur ekstraksi teks yang kemudian diubah menjadi vektor untuk menentukan gender. Setelah kedua model dikembangkan, evaluasi model dilakukan untuk menilai performa masing-masing model berdasarkan metrik yang ditentukan.

d) Analisis Komparasi Hasil

Setelah model diimplementasikan, dilakukan analisis komparasi untuk membandingkan performa kedua model dalam mengklasifikasikan gender berdasarkan komentar. Model naive bayes dibandingkan dengan model svm untuk menilai kualitas performa dalam klasifikasi gender. Komparasi ini bertujuan untuk memastikan model yang dikembangkan tidak hanya mampu menghasilkan akurasi yang bagus namun juga

kinerja yang baik antar sesama model sehingga dapat dilihat kelemahan dan kelebihan masing-masing metode dalam evaluasi model masing-masing, sehingga dapat menjadi referensi yang lebih detail dan mendalam untuk pengembangan klasifikasi gender kedepannya.

e) Menulis Laporan

Setelah seluruh proses penelitian selesai dilakukan, laporan penelitian disusun untuk mendokumentasikan keseluruhan proses dari awal hingga perolehan hasil selama penelitian dilakukan. Dengan menyusun laporan yang sistematis, diharapkan dapat menjadi wawasan mendalam bagi pengembangan lebih lanjut dalam bidang klasifikasi gender pada machine learning di masa mendatang.

## 1.7 Sistematika Laporan

a. BAB I – PENDAHULUAN

Bab ini memaparkan latar belakang penelitian, rumusan masalah dan pertanyaan penelitian, rumusan masalah, tujuan penelitian, manfaat penelitian, metodologi penelitian dan sistematika penulisan laporan secara keseluruhan.

b. BAB II - KAJIAN PUSTAKA

Bab ini membahas teori-teori yang mendukung penelitian, termasuk klasifikasi teks dan tantangannya, algoritma Naive Bayes dan Support Vector Machine (SVM), serta penelitian-penelitian sebelumnya yang relevan.

c. BAB III - METODOLOGI PENELITIAN

Bab ini menjelaskan mengenai tahapan dan metodologi yang digunakan dalam penelitian, mulai dari pengumpulan data, preprocessing teks, ekstraksi fitur, pelatihan model, evaluasi performa, visualisasi dan skenario pengujian.

d. BAB IV - HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil implementasi dan evaluasi model klasifikasi gender menggunakan Naive Bayes dan SVM. Disertakan pula analisis perbandingan performa kedua model berdasarkan metrik evaluasi, visualisasi hasil pengujian serta analisis komparatif hasil.

e. BAB V – KESIMPULAN

Bab ini menjelaskan kesimpulan dari hasil penelitian serta saran untuk pengembangan dan penelitian selanjutnya, baik dari segi pendekatan, algoritma, maupun perluasan ruang lingkup studi.

## **BAB II**

### **KAJIAN PUSTAKA**

Pada Bab Kajian Pustaka ini, akan dibahas penelitian terdahulu yang relevan dengan penerapan metode *Naive Bayes* dan SVM (*Support Vector Machine*) dalam kasus klasifikasi gender berdasarkan komentar X (Twitter) beserta metode lain yang berkaitan. Kajian Pustaka bertujuan untuk memberi gambaran mengenai bagaimana metode *Naive Bayes* dan SVM (*Support Vector Machine*) dapat diimplementasikan dalam klasifikasi gender berdasarkan komentar serta memberikan solusi yang diberikan dalam penelitian ini, yaitu membandingkan metode *Naive Bayes* dan SVM untuk menilai performa dalam mengklasifikasikan gender secara akurat.

Bagian ini membahas berbagai penelitian terdahulu yang berkaitan dengan penggunaan metode *Naive Bayes* dan Support Vector Machine (SVM) dalam klasifikasi gender berdasarkan komentar di platform Twitter. Penelitian-penelitian tersebut menjadi dasar untuk memahami perkembangan pendekatan klasifikasi teks dalam konteks permasalahan gender. Selain itu, kajian ini juga akan mengidentifikasi tantangan utama dalam klasifikasi gender berbasis komentar, serta mengelompokkan penelitian terdahulu ke dalam beberapa kategori yang relevan dengan topik penelitian ini yaitu metode yang pernah diterapkan dalam penerapan klasifikasi gender berdasarkan komentar serta kelemahan dan keunggulannya.

Dengan memahami tantangan serta karakteristik dari masing-masing metode, penelitian ini melakukan perbandingan untuk menilai kesesuaian *Naive Bayes* dan SVM dalam menyelesaikan permasalahan klasifikasi gender berdasarkan teks komentar. Pemilihan metode didasarkan pada tingkat relevansi dan kemampuan metode dalam mengatasi kompleksitas data komentar dan tantangan masalah yang dihadapi.

#### **2.1 Tantangan dalam Klasifikasi Gender pada Media Sosial**

Klasifikasi gender berdasarkan komentar di media sosial menghadirkan berbagai tantangan yang signifikan, terutama karena karakteristik data yang tidak terstruktur, bervariasi, dan sering kali tidak seimbang antar kelas. Platform seperti X (Twitter) menyediakan data teks dalam jumlah besar yang bersifat informal dan dinamis, sehingga memerlukan pendekatan klasifikasi yang adaptif dan efektif. Beberapa tantangan utama dalam konteks ini yang dihadapi adalah sebagai berikut:

a. Variasi bahasa dan penggunaan istilah

Platform media sosial seperti X (Twitter) sering kali dipenuhi oleh komentar yang menggunakan bahasa informal, singkatan, istilah gaul, serta simbol atau emoji. Keragaman ini menciptakan kompleksitas dalam pemrosesan bahasa alami, karena makna sebuah kata atau frasa dapat berubah tergantung konteks dan gaya penulisan pengguna. Oleh karena itu, metode klasifikasi yang diterapkan harus mampu mengakomodasi variasi bahasa ini melalui pre-processing yang efektif dan representasi fitur teks yang adaptif.

b. Ketidakseimbangan data

Dalam klasifikasi gender, distribusi data yang tidak seimbang menjadi tantangan serius, di mana jumlah data dari satu gender lebih dominan dibandingkan dengan yang lainnya. Contoh seperti jumlah komentar dari pengguna pria lebih banyak dibandingkan komentar dari pengguna wanita. Ketidakseimbangan ini dapat menyebabkan model klasifikasi yang bias terhadap kelas mayoritas, sehingga dibutuhkan metode yang mampu mempertahankan performa pada kondisi distribusi data yang tidak merata serta *Undersampling* untuk menghapus kelas mayoritas supaya keseimbangan data antar kelas gender tetap terjaga.

c. Fitur yang terbatas

Komentar di media sosial khususnya X (Twitter) umumnya singkat, ringkas, dan tidak terstruktur dengan baik, yang menyebabkan kesulitan dalam proses ekstraksi fitur yang digunakan untuk meningkatkan kualitas model. Untuk mengatasi hal ini, digunakan Teknik representasi text seperti TF-IDF (*Term Frequency-Inverse Document Frequency*), yang dapat membantu mengekstraksi fitur penting dari teks pendek dan meningkatkan kualitas model klasifikasi.

d. Ambiguitas Konteks

Komentar-komentar di media sosial khususnya Twitter sering kali mengandung ambiguitas, dimana maknanya bisa sangat bergantung pada konteks penggunaannya. Sebuah komentar yang terlihat netral dapat memiliki konotasi gender tertentu, tergantung siapa yang menulis dan dalam konteks apa komentar itu dibuat. Tantangan ini menuntut penggunaan metode klasifikasi yang mampu menangkap hubungan antar fitur teks secara efektif.

Berdasarkan tantangan klasifikasi di atas, metode klasifikasi diatas harus mampu beradaptasi dengan variasi linguistik yang beragam, tahan terhadap ketidakseimbangan data, mampu menangkap pola dari teks pendek, dan sensitif terhadap konteks ambigu.

## 2.2 Metode Klasifikasi Gender yang Pernah Diterapkan

Tabel 2.1 Metode yang Pernah Diterapkan Klasifikasi

| Metode                                                                                               | Keunggulan                                                                                                            | Kelemahan                                                                                                                                   |
|------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------|
| <i>Naive Bayes</i><br>(Putri, Enri, & Sari, 2020)                                                    | - Efisien dalam pelatihan dan mampu menangani data teks pendek dan data yang tidak seimbang dengan probabilitas prior | - Kurang efektif jika data terlalu kompleks dan saat fitur saling berinteraksi, sehingga dapat mengurangi akurasi model                     |
| <i>Support Vector Machine (SVM)</i><br>(Angelina, Hayati, & Dwilestari, 2023)                        | - Efektif dalam menangani data teks dengan dimensi yang tinggi dan relasi fitur yang kompleks                         | - Rentan terjadi overfitting tanpa tuning parameter yang tepat dan membutuhkan waktu pelatihan lebih lama apabila ukuran data semakin besar |
| <i>Convolutional Neural Network (CNN)</i><br>(Mubarak, Faisal, Kartini, Nugrahadhi, & Saragih, 2023) | - Mampu mengekstraksi fitur penting dari teks besar dan kompleks.                                                     | - Memerlukan sumber daya komputasi yang tinggi dan sangat bergantung pada kualitas data input.                                              |
| <i>K-Nearest Neighbor (KNN)</i><br>(Zakia, Indriati, & Marji, 2020)                                  | -Mampu bekerja dengan baik pada data yang tidak terdistribusi secara normal.                                          | - Waktu komputasi meningkat ketika jumlah data besar, dan sangat sensitif terhadap <i>noise</i> ,                                           |
| <i>Random Forest</i><br>(Ramli & Sibaroni, 2022)                                                     | - Dapat menangani data yang tidak seimbang, dan menjaga keseimbangan antar kelas.                                     | - Rentas <i>overfitting</i> pada dataset kecil dan memerlukan banyak sumber daya komputasi.                                                 |
| <i>Long Short- Term Memory (LSTM)</i><br>(Sa'diah, et al., 2024)                                     | - Mampu menangani urutan teks panjang dan menyimpan informasi jangka panjang.                                         | - Membutuhkan data pelatihan besar serta sumber daya komputasi tinggi dan kurang efisien untuk teks pendek                                  |

Berikut merupakan ringkasan dari penelitian yang relevan dari tabel 2.1 sebagai berikut:

a. Naive Bayes

*Naive Bayes* merupakan berbasis probabilistik yang banyak digunakan dalam berbagai kasus termasuk klasifikasi teks karena efisien dan relatif mudah diterapkan. Dalam penelitian yang dilakukan Putri dkk. (2020), metode Naive Bayes digunakan untuk mengklasifikasikan tweet bertema pelecehan seksual dan memperoleh performa yang baik dengan berbagai rasio data meskipun data tidak seimbang. Metode ini cocok untuk teks pendek dan skenario dengan keterbatasan sumber daya, namun kurang efektif ketika fitur dalam data saling berinteraksi secara kompleks.

b. Support Vector Machine (SVM)

SVM dikenal unggul dalam menangani data berdimensi tinggi dan relasi antar fitur. Angelina et al. (2023) menggunakan SVM untuk analisis sentimen pada konser K-Pop dan memperoleh akurasi 76,64% dari 841 tweet. Metode ini menunjukkan kinerja yang lebih optimal seiring meningkatnya jumlah data, terutama jika dilakukan tuning parameter seperti nilai C dan kernel. Kelemahannya terletak pada kebutuhan waktu pelatihan yang relatif lama dan sumber daya komputasi yang lebih besar.

c. Convolutional Neural Networks (CNN)

CNN merupakan salah satu metode deep learning yang efektif dalam mengekstraksi fitur dari teks. Mubarak et al. (2023) menunjukkan bahwa penggabungan data tweet dan deskripsi akun dengan CNN dapat meningkatkan akurasi klasifikasi gender. Meskipun memiliki potensi besar, CNN tidak digunakan dalam penelitian ini karena membutuhkan infrastruktur komputasi tinggi dan waktu pelatihan yang lebih lama, sehingga kurang efisien untuk klasifikasi komentar pendek di Twitter.

d. K-Nearest Neighbors (KNN) dan Random Forest

Kedua metode ini cukup populer dalam klasifikasi berbasis teks. Zakia et al. (2020) menggunakan KNN untuk klasifikasi gender dan mendapatkan akurasi rata-rata 68,6% dengan F1-score sebesar 69,34%. Sementara itu, Ramli dan Sibaroni (2022) menggunakan Random Forest dan Word2Vec untuk klasifikasi topik, dengan hasil akurasi melebihi 90%. KNN memiliki kelemahan pada efisiensi saat data besar, dan Random Forest cenderung overfitting pada dataset kecil.

e. Long Short-Term Memory (LSTM)

LSTM merupakan metode yang mampu memproses data sekuensial dengan mempertahankan konteks informasi dalam jangka waktu panjang. Penelitian oleh Sa'diah et al. (2024) menunjukkan bahwa kombinasi FastText dan LSTM menghasilkan akurasi tinggi dalam klasifikasi gender. Namun, metode ini memerlukan jumlah data besar dan daya komputasi tinggi, sehingga belum digunakan dalam penelitian ini yang berfokus pada efisiensi dan penanganan komentar pendek.

Melalui perbandingan ini, terlihat bahwa tidak semua metode cocok diterapkan dalam konteks data komentar media sosial. Oleh karena itu, seleksi metode harus mempertimbangkan kesesuaian dengan tantangan yang telah dijelaskan sebelumnya. Pada bagian berikutnya, akan dibahas lebih lanjut mengenai alasan pemilihan metode Naive Bayes dan SVM sebagai pendekatan utama dalam penelitian ini, berdasarkan kelayakan dan relevansinya terhadap karakteristik data yang digunakan.

### 2.3 Alasan Pemilihan Metode Naive Bayes dan SVM dalam Analisis Komparatif

Berdasarkan tantangan-tantangan yang telah diidentifikasi dan perbandingan terhadap berbagai metode yang relevan, penelitian ini memilih metode Naive Bayes dan Support Vector Machine (SVM) sebagai dua metode yang layak di komparasikan dalam penelitian ini. Pemilihan ini tidak didasarkan pada prediksi hasil eksperimen atau kemudahan implementasi, melainkan pada kesesuaian karakteristik kedua metode dalam merespons konteks dan kompleksitas data yang digunakan. Berikut alasan mengapa metode naive bayes dan SVM menjadi metode yang digunakan untuk analisis komparasi dalam penelitian ini:

a. Penyesuaian Karakteristik Data

Naive Bayes memiliki keunggulan dalam mengolah data teks pendek dan tidak seimbang. Metode ini bekerja dengan prinsip probabilistik sederhana namun efektif dalam menangani distribusi kelas yang timpang. Sementara itu, SVM cocok digunakan pada data teks dengan jumlah fitur yang banyak dan hubungan antar kata yang kompleks, seperti komentar yang telah diubah ke dalam bentuk vektor menggunakan teknik TF-IDF.

b. Kemampuan Menangani Tantangan Tekstual

Naive Bayes memiliki kelebihan dalam mengatasi variasi kata yang tidak teratur atau beragam, karena ia bekerja berdasarkan frekuensi kata. Sedangkan SVM mampu memisahkan data dengan lebih tegas dan akurat, terutama saat data memiliki banyak fitur yang saling berkaitan. Kemampuan ini penting untuk menangani komentar-komentar yang ambigu atau memiliki makna yang tergantung konteks.

c. Penyesuaian Sumber Daya dan Waktu

Naive Bayes dikenal efisien dalam hal waktu pelatihan dan penggunaan memori, menjadikannya cocok untuk eksperimen awal atau sistem dengan keterbatasan sumber daya. Sebaliknya, SVM membutuhkan sumber daya komputasi lebih besar, tetapi memberikan performa klasifikasi yang lebih stabil dan akurat pada dataset berukuran besar. Kombinasi ini memungkinkan penelitian untuk menilai trade-off antara efisiensi dan efektivitas model klasifikasi teks.

d. Pendekatan Komparatif

Tujuan utama dari penelitian ini adalah membandingkan dua pendekatan klasifikasi yang secara konsep berbeda namun sama-sama relevan terhadap tantangan yang dihadapi. Naive Bayes mewakili pendekatan berbasis probabilitas yang adaptif terhadap teks singkat dan tidak seimbang, sedangkan SVM mewakili pendekatan margin-based yang kuat terhadap struktur fitur kompleks. Evaluasi akan dilakukan dengan mengukur performa kedua metode menggunakan metrik akurasi, precision, recall, dan F1-score, untuk menilai efektivitas masing-masing secara obyektif dan menyeluruh. Dengan membandingkan keduanya, diharapkan bisa memberikan gambaran yang seimbang tentang kelebihan dan kekurangan masing-masing metode untuk tugas klasifikasi gender berbasis komentar di media sosial.

## 2.4 Metode Klasifikasi yang Digunakan

a. Metode Naive Bayes

*Naive Bayes* merupakan salah satu metode klasifikasi berbasis Teorema Bayes dan probabilistik yang didasarkan pada teorema Bayes. Metode ini mengasumsikan bahwa setiap fitur pada data bersifat saling independen satu sama lain. Meskipun asumsi ini jarang terpenuhi dalam data nyata, Naive Bayes tetap menunjukkan performa yang baik, terutama dalam tugas klasifikasi teks seperti pada penelitian ini yang mengklasifikasikan gender berdasarkan komentar di media sosial.

Secara matematis, Teorema Bayes dirumuskan pada persamaan (2.1) yaitu:

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)} \quad (2.1)$$

1.  $P(C|X)$  adalah probabilitas Kelas  $C$  (misalnya laki-laki atau perempuan) diberikan fitur  $X$ ,
2.  $P(X|C)$  adalah probabilitas fitur  $X$  muncul pada kelas  $C$ ,
3.  $P(C)$  adalah probabilitas prior dari kelas  $C$ ,

4.  $P(X)$  adalah probabilitas dari fitur  $X$  secara umum.

Metode ini bekerja dengan menghitung kemungkinan suatu data masuk ke dalam kelas tertentu berdasarkan frekuensi kemunculan kata atau fitur. Hal ini membuat Naive Bayes efektif dalam menangani data teks pendek, karena tidak memerlukan pemrosesan fitur yang terlalu kompleks. Selain itu, metode ini cukup tangguh terhadap data yang tidak seimbang, karena klasifikasi dilakukan berdasarkan probabilitas relatif terhadap masing-masing kelas.

Dalam praktik klasifikasi teks, seperti dalam penelitian ini, proses penerapan Teorema Bayes mencakup perhitungan probabilitas awal (prior) dari setiap kelas, probabilitas kemunculan kata dalam masing-masing kelas (kondisional), dan akhirnya perhitungan probabilitas gabungan untuk menentukan kelas dengan kemungkinan terbesar. Kelas yang memiliki nilai probabilitas tertinggi akan dipilih sebagai hasil klasifikasi. Proses ini berjalan secara efisien bahkan ketika jumlah fitur sangat banyak, menjadikan Naive Bayes sangat cocok digunakan pada data teks seperti komentar media sosial.

Naive Bayes dianggap relevan karena mampu mengakomodasi noise dalam teks dan tetap memberikan hasil yang stabil pada data berukuran kecil hingga sedang. Namun, kekurangan utamanya terletak pada ketidakmampuannya menangani interaksi antar fitur yang kompleks, yang sering kali muncul dalam data sosial media, karena model ini menganggap fitur tidak saling bergantung satu sama lain. Oleh karena itu, meskipun efektif dan efisien, model ini memiliki keterbatasan dalam mengekspresikan hubungan semantik atau konteks antar kata dalam teks yang lebih panjang.

#### b. Metode Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan algoritma supervised learning yang banyak digunakan untuk tugas klasifikasi maupun regresi. Konsep utama dari SVM adalah mencari sebuah hyperplane atau bidang pemisah optimal yang memisahkan dua kelas data dalam ruang fitur. Hyperplane ini dibentuk sedemikian rupa sehingga margin dimaksimalkan. Dengan margin yang besar, SVM cenderung memiliki generalisasi yang lebih baik terhadap data baru.

Secara matematis pada persamaan (2.2), fungsi tujuan dari SVM adalah :

$$\min_{w,b} \frac{1}{2} |w|^2 \quad (2.2)$$

Dengan kendala persamaan (2.3):

$$y_i(w \cdot x_i + b) \geq 1, \forall i \quad (2.3)$$

di mana:

1.  $w$  adalah vektor bobot,
2.  $b$  adalah bias,
3.  $x_i$  adalah data ke- $i$ ,
4.  $y_i$  adalah label kelas data ke- $i$ , dengan nilai -1 atau 1.

Tujuan dari fungsi ini adalah mencari nilai  $w$  dan  $b$  yang memaksimalkan margin sambil tetap mempertahankan klasifikasi yang benar terhadap seluruh data pelatihan. Dalam konteks klasifikasi teks, seperti komentar pada media sosial, SVM bekerja dengan cara mengubah teks menjadi vektor numerik, misalnya menggunakan metode TF-IDF. Karena teks memiliki dimensi fitur yang sangat tinggi, SVM menjadi algoritma yang cocok digunakan karena kemampuannya dalam menangani data berdimensi besar secara efisien. Selain itu, SVM dikenal stabil performanya saat digunakan dalam dataset yang kompleks dan jumlah data yang besar.


SVM klasik bekerja dengan data yang dapat dipisahkan secara linear, namun banyak data, seperti komentar media sosial yang ambigu, tidak dapat dipisahkan dengan garis lurus. Untuk mengatasi hal ini, digunakan konsep soft margin, yang menambahkan toleransi terhadap kesalahan klasifikasi selama pelatihan, memungkinkan SVM membentuk hyperplane yang optimal meskipun ada titik data yang tidak dapat dipisahkan dengan sempurna. Selain itu, SVM juga mendukung kernel trick, yang memproyeksikan data ke ruang berdimensi lebih tinggi, sehingga data yang tidak linier dapat dipisahkan. Berbagai jenis kernel, seperti linear kernel, polynomial kernel, dan radial basis function (RBF), dapat disesuaikan dengan karakteristik data untuk memperoleh hasil klasifikasi yang lebih baik.

Berdasarkan karakteristik tersebut, SVM dipandang mampu menghadapi tantangan klasifikasi komentar media sosial, seperti interaksi kompleks antar fitur dan konteks makna yang ambigu. Keunggulan lainnya adalah kestabilan performa ketika ukuran data diperbesar dan ketika digunakan pada data berdimensi tinggi. Namun, kelemahan dari SVM terletak pada waktu pelatihan yang relatif lebih lama dan kebutuhan akan tuning parameter seperti  $C$  dan jenis kernel, yang jika tidak dilakukan secara optimal dapat memengaruhi akurasi klasifikasi.

### BAB III

#### METODE PENELITIAN

Pada bab ini akan dijabarkan langkah dari analisis komparatif metode naive bayes dan SVM (Support Vector Machine) untuk melakukan klasifikasi gender berdasarkan komentar pada platform X (twitter) yang bertujuan untuk menganalisis perbandingan performa kedua model dari metode Naive Bayes dan SVM berdasarkan kriteria yang ada. Penelitian ini memiliki beberapa langkah yaitu 1) Pengumpulan Data, 2) Pre-processing Data, 3), Implementasi Model Naive Bayes dan 4) Implementasi Model SVM (Support Vector Machine), 5) Evaluasi Model 6) Komparasi Hasil. Langkah Penelitian ditunjukkan pada gambar 3.1.



Gambar 3.1 Langkah Penelitian Analisis Komparatif

#### 3.1 Pengumpulan Data

Data pada penelitian ini diperoleh dari platform media sosial X (Twitter) pada rentang waktu 1 September 2024 hingga 13 April 2025. Selama periode tersebut, terkumpul 11.488 komentar dari total 26 topik atau kata kunci dengan atribut yang terdiri atas teks komentar, username, tanggal pembuatan tweet, topik komentar, serta ID. Topik komentar yang dihimpun mencakup peristiwa-peristiwa yang sedang menjadi perhatian publik pada periode tersebut dengan gaya bahasa yang berbeda-beda, yaitu:

- a. Politik yang menunjukkan kondisi pemerintahan di Indonesia, masalah korupsi dan sebagainya yang berkaitan.
- b. Hiburan yang berfokus pada artis atau figur publik.
- c. Olahraga dengan fokus pada Timnas Indonesia.
- d. Budaya dengan melihat kasus rumah makan Padang.

- e. Hak Asasi Manusia (HAM) yang fokusnya pada isu genosida di Gaza dan Palestina.

Pengumpulan data dilakukan menggunakan metode tweet-harvest, yang merupakan teknik web scraping dari Twitter berdasarkan kata kunci dan rentang data yang ingin dikumpulkan. Langkah-langkah dalam proses tweet-harvest meliputi input token otentikasi, yaitu token akses unik dari Twitter yang digunakan untuk mengotorisasi permintaan data. Setelah itu, dilakukan instalasi beberapa alat pendukung seperti Pandas, Node.js, dan tweet-harvest. Setelah instalasi selesai, proses scraping dimulai dengan menentukan nama file yang akan menyimpan data komentar, kata kunci yang berkaitan dengan topik atau hashtag, rentang tanggal dan bahasa, serta rentang data yang ingin diambil. Setelah proses scraping selesai, data yang diperoleh disimpan dalam format CSV dalam bentuk mentah. Sebelum data digunakan untuk analisis lebih lanjut, dilakukan pelabelan manual terhadap data berdasarkan atribut yang relevan dengan tujuan penelitian.

Untuk menjaga validitas data, hanya komentar yang diambil dari akun pengguna yang memiliki deskripsi gender yang jelas. Kriteria validasi gender mencakup foto profil, username, dan bio akun, yang ketiganya harus konsisten merepresentasikan gender pengguna. Contohnya, akun dengan nama laki-laki, foto profil laki-laki, dan biodata yang sesuai akan dimasukkan ke dataset. Proses ini mengacu pada penelitian (Sa'diah, et al., 2024) yang menggabungkan informasi akun dan tweet dalam mengklasifikasikan gender. Jika informasi pada salah satu atribut tersebut (username, foto profil, atau deskripsi akun) tidak sesuai, maka akun tersebut akan di hapus sehingga hanya akun yang ketiga atributnya sesuai yang dapat masuk ke dalam dataset final.

Contoh hasil proses labelling data yang berdasarkan dari atribut pengguna akun X (Twitter) ditampilkan pada tabel 3.1:

Tabel 3.1 Hasil Proses Labelling Data

| No | Username   | Biodata Akun                                                             | Foto Profil                                                                          | Label Gender |
|----|------------|--------------------------------------------------------------------------|--------------------------------------------------------------------------------------|--------------|
| 1  | mairanabia | Turn to Allah before you return to Allah                                 |  | Perempuan    |
| 3  | sentereus  | Madridista isinya cuma; Opini, Sedikit Humor, dan Suara untuk Perubahan. |  | Laki-Laki    |

Proses validasi data dilakukan untuk memastikan bahwa penentuan gender pada dataset adalah akurat dan dapat dipercaya. Validasi ini dilakukan melalui Proses anotasi dilakukan oleh dua annotator independen (peneliti utama dan rekan annotator), dengan masing-masing memvalidasi seluruh 11.488 komentar untuk meminimalkan bias dan meningkatkan reliabilitas.

Selain itu, dilakukan filterisasi tambahan untuk menghapus akun yang tidak relevan, meliputi:

- a. Akun yang teridentifikasi sebagai akun berita (general, olahraga, podcast maupun media).
- b. Akun yang dikelola oleh orang lain dengan tujuan untuk komunitas seperti fanbase artis maupun pemain bola dan akun parodi.
- c. Akun dengan komentar mengandung konten dewasa, promosi barang dagangan, atau judi online.
- d. Akun yang sudah nonaktif atau di banned karena *Community guidelines*.

Perlu diperhatikan bahwa data yang terkumpul bersifat acak, sehingga satu akun bisa memiliki satu atau lebih tweet di dalam dataset yang dimana hal ini menyebabkan kemungkinan dominasi opini dari akun tertentu menjadi rendah atau terkontrol karena sebagian besar akun hanya terkumpul satu komentar.

Dataset akhir disimpan dalam format CSV dengan data yang telah divalidasi dan memuat kolom atribut yang relevan dengan penelitian ini. Setelah melalui proses filterisasi, sebanyak 2.148 komentar dieliminasi dari total 11.488 komentar awal. Rincian eliminasi tersebut meliputi 940 komentar yang berasal dari akun berita, 528 komentar yang teridentifikasi sebagai akun bot, spam, atau akun yang dikelola oleh pihak ketiga (misalnya fanbase atau komunitas), serta sisanya merupakan akun yang memuat konten penjualan produk, konten dewasa, dan perjudian daring. Dengan demikian, dataset akhir yang digunakan untuk tahap preprocessing berjumlah 9.340 komentar, terdiri atas 4.972 komentar yang diidentifikasi berasal dari pengguna laki-laki dan 4.368 komentar yang diidentifikasi berasal dari pengguna perempuan. Visualisasi distribusi dataset akhir ditunjukkan pada Tabel 3.2 sebagai berikut:

Tabel 3.2 Visualisasi Pengumpulan Dataset Final

| ID   | Username     | Gender    | Dates_tweet | Tweet_Teks                                                                                                                                                                                                                                                                                                | Topic  |
|------|--------------|-----------|-------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------|
| 1035 | AvatarAang73 | Laki-Laki | 1-Nov-24    | @IKMpusat Suruh aja para perantau Minang yg makan di sana... Aroma arogansi rasis dan melawan takdir Allah atas rejeki manusia... Tinggalkan RM Padang ganti makan di Warteg Soto Lamongan soto Madura Coto Makassar Warung Khas Jatim Gudeg sate Madura warung Sunda.                                    | Minang |
| 1038 | HabsimAnwaru | Laki-Laki | 1-Nov-24    | @tagarabak @ubegebel Ya betul itu faktanya. Sy kuliah di Bdg 1 kontrakan dg penghuni total 9 6 dr Sumbar. Tahu apa yg diomongkan? sll mmbangga2kan smua hal trkait Minang. Explicit merasa suku paling baik dibanding yg lain. Ya Alloh ampe males kl berteman sm org Minang. Maaf tp itu nyata sy alami. | Minang |


Penjelasan kolom-kolom dalam label adalah sebagai berikut:

- ID : Kode unik dari tiap dataset komentar pengguna
- Username : Nama dari pengguna akun Twitter
- Gender : Komponen penting untuk fokus penelitian ini yang akan diklasifikasikan
- Dates\_tweet : Tanggal Tweet dibuat
- Tweet\_teks : Teks komentar twitter
- Topic : komponen dari komentar twitter yang menunjukkan tren atau hastag dari komentar yang dibuat

### 3.2 Preprocessing Data

Data yang sudah terkumpul akan dibersihkan dengan tujuan agar data yang akan digunakan oleh model bersih, terstruktur dan dapat dianalisis. Proses Preprocessing data dilakukan menggunakan platform Google Colab dengan Langkah-langkah preprocessing sebagai berikut. Cleaning data terdiri dari stopwords removal, stemming, tokenisasi, mengubah singkatan dan penghapusan angka,emoji, simbol dan tanda baca. Feature Extraction mengubah

data text menjadi format untuk model machine learning dengan metode TF- IDF. Setelah Feature Extraction, dilakukan pembagian data menjadi data pelatihan dan data pengujian. Gambar 3.2 menunjukkan diagram Langkah Preprocessing data.



Gambar 3.2 Langkah Preprocessing Data

Berikut penjelasan langkah-langkah preprocessing data:

a. Import Library

library digunakan untuk mendukung proses preprocessing dan persiapan data sebelum pemodelan. Library pandas dimanfaatkan untuk memuat, membaca, dan mengelola dataset dalam bentuk DataFrame. NumPy digunakan sebagai pendukung manipulasi data numerik yang dibutuhkan selama pemrosesan teks. re (regular expression) berfungsi untuk melakukan pembersihan teks dari karakter yang tidak relevan, seperti simbol, angka, atau tanda baca tertentu. NLTK (Natural Language Toolkit) digunakan untuk proses tokenisasi (word\_tokenize), penghapusan stopwords dengan daftar kata umum dalam bahasa Indonesia, serta mendukung proses unduhan sumber daya (stopwords, punkt, dan punkt\_tab) yang diperlukan dalam tahap tokenisasi. Sastrawi

digunakan sebagai stemmer bahasa Indonesia untuk mengubah kata menjadi bentuk dasarnya. Selain itu, scikit-learn berperan dalam ekstraksi fitur menggunakan TfidfVectorizer serta pembagian dataset melalui train\_test\_split. Library tambahan seperti SingkatanConverter digunakan untuk konversi singkatan menjadi kata lengkap agar teks lebih seragam.

b. Load Dataset

Data yang sudah dikumpulkan dan disusun dalam file CSV akan diunggah ke google colab lalu di load menggunakan library pandas dengan fungsi `pd.read_csv()`.

c. Cleaning Data

Pembersihan data dilakukan untuk memastikan data yang akan dianalisis rapi, tidak ada kesalahan, dan sesuai format. Berikut merupakan langkah-langkah dari cleaning data:

1. Case Folding

Case folding dilakukan untuk menyamakan bentuk teks dengan mengubah seluruh huruf menjadi huruf kecil (lowercase). Langkah ini bertujuan untuk mengatasi inkonsistensi penggunaan huruf kapital dan huruf kecil dalam penulisan komentar yang dapat mengganggu analisis teks. Data komentar yang memiliki penulisan dengan huruf kapital berlebihan (misalnya seluruh kata menggunakan caps lock) akan diubah menjadi bentuk standar agar lebih rapi dan seragam (Magnolia, Nurhopipah, & Kusuma, 2023) (Styawati, Isnain, Hendrastuty, & Andraini, 2021). Contoh “Bismillah Jaga kesehatan Jaga pola makan Semoga puasa Ramadhan nya lancar dan shalat Tarawih nya nyaman” jadi “bismillah jaga kesehatan jaga pola makan semoga puasa ramadhan nya lancar dan shalat tarawih nya nyaman”

2. Penghapusan Angka, Simbol, Tanda Baca, dan Emoji

Tanda baca dan simbol seperti “@,” “#” sering kali tidak relevan untuk analisis dan hanya membuat data berantakan. Penghapusan emoji juga dilakukan karena membuat data berantakan. Angka yang biasa terdapat pada tweet dihapus guna merapikan data.

3. Tokenisasi

Setelah teks dibersihkan dari angka, simbol, tanda baca, dan emoji selanjutnya dilakukan tokenisasi untuk memecah teks menjadi unit kata (token) menggunakan metode *word tokenization*. Contoh nya “Setan merah dulu punya legenda Ole Gunnar solskjaer Merah putih sekarang punya calon legenda Ole Romeny” menjadi “[‘setan’, ‘merah’, ‘dulu’, ‘punya’, ‘legenda’, ‘ole’, ‘gunnar’, ‘solskjaer’, ‘merah’, ‘putih’, ‘sekarang’, ‘punya’, ‘calon’, ‘legenda’, ‘ole’, ‘romeny’]”. Tokenisasi berfungsi untuk memecah komentar menjadi kata-kata terpisah dengan mengidentifikasi pemisah berupa spasi dalam teks, sehingga setiap komentar dapat diuraikan menjadi unit kata yang lebih kecil (Styawati, Isnain, Hendrastuty, & Andraini,

2021). Proses ini penting untuk memudahkan penghitungan jumlah kata per komentar, mendukung ekstraksi fitur seperti TF-IDF, menangkap konteks kata saat diproses oleh model.

#### 4. Menghapus Stopwords

Stopwords removal atau menghapus stopwords merupakan proses menghapus kata-kata umum yang terdapat dalam daftar stopwords (Styawati, Isnain, Hendrastuty, & Andraini, 2021). Stopwords sendiri merupakan kata-kata umum seperti "dan," "yang," atau "the" yang sering muncul tetapi tidak terlalu penting untuk analisis. Menghapusnya membantu fokus pada kata-kata yang lebih bermakna.

#### 5. Stemming

Stemming adalah proses mengubah setiap kata dalam data teks menjadi bentuk dasarnya dengan menghilangkan imbuhan awalan maupun akhiran (Styawati, Isnain, Hendrastuty, & Andraini, 2021). Tahapan ini juga berfungsi untuk menyaring kata-kata yang mengandung konjungsi, kata ganti, atau preposisi, sehingga diperoleh kata inti yang lebih sederhana (Magnolia, Nurhopipah, & Kusuma, 2023). Contohnya, kata "bermain" akan diubah menjadi "main". Proses stemming dilakukan untuk mengurangi kompleksitas teks dan membantu model fokus pada kata-kata utama yang relevan dalam proses klasifikasi gender.

Visualisasi sebelum dan sesudah dibersihkan ditampilkan pada Tabel 3.3 :

Tabel 3.3 Visualisasi Sebelum dan Sesudah Dibersihkan

| ID   | Username     | Teks Sebelum Dibersihkan                                                                                                                                                                                    | Teks Sesudah Dibersihkan                                                                                                                                     |
|------|--------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1035 | AvatarAang73 | @IKMpusat Suruh aja para perantau Minang yg makan di sana... Aroma arogansi rasis dan melawan takdir Allah atas rejeki manusia... Tinggalkan RM Padang ganti makan di Warteg Soto Lamongan soto Madura Coto | suruh aja perantau minang yg makan aroma arogansi rasi melawan takdir allah rejeki manusia tinggalkan rm padang ganti makan warteg soto lamongan soto madura |

#### d. Mengubah Singkatan

Penanganan bahasa informal, termasuk singkatan dan bahasa gaul, menjadi aspek penting dalam pemrosesan tweet karena sering kali memuat ekspresi singkat atau istilah khusus (Melhem, Abdi, & Meziane, 2024). Proses konversi singkatan diterapkan untuk mengganti kata-kata yang menggunakan bentuk singkatan menjadi bentuk lengkap atau baku sebelum analisis lanjutan dilakukan. Misalnya, kata "sy" diubah menjadi "saya" dan "rm" menjadi "rumah makan". Pada tahap ini digunakan sebuah kamus singkatan

(kamus\_singkatan.csv) yang berisi pasangan singkatan dan kata aslinya. Setiap komentar diproses dengan cara memecah teks menjadi potongan kata, kemudian masing-masing kata dibandingkan dengan kamus tersebut menggunakan SingkatanConverter. Langkah ini bertujuan untuk meningkatkan konsistensi data teks serta mengurangi risiko kesalahan klasifikasi pada model Naive Bayes dan Support Vector Machine.

e. Penambahan Parameter

Setiap teks komentar yang diekstraksi akan ditambahkan jumlah kata dengan kriteria yaitu lebih dari 10 kata sehingga kata yang kurang dari jumlah tersebut akan dihapus. Jumlah kata ini dihitung setelah teks dibersihkan. Berikut visualisasi sebelum dan sesudah ditambahkan parameter jumlah kata. Kriteria parameter kurang dari 10 kata sudah dilakukan oleh (Tang, et al., 2024) yang melakukan preprocessing menggunakan NLP dengan menghapus review yang kurang dari 10 kata karena komentar pendek tidak memiliki konten yang substansial. Contoh hasil visual data yang sudah ditambahkan parameter jumlah kata ditunjukkan pada tabel 3.4.

Tabel 3.4 Visualisasi Parameter Jumlah Kata

| ID   | Username  | Teks Sebelum Dibersihkan                                                                                                                                                                             | Teks Sesudah Dibersihkan                                                                                                                                                                                | Jumlah Kata |
|------|-----------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------|
| 2507 | ikaprmtsr | ceritanya beli lauk ayam bakar nasi padang masnya bungku ayam plastik bene tru liat tuh ayamnya bolakbalik tadaaaa nemu telur lalat ku kasih tau masnya aja kalo telur lalat langsung diganti masnya | ceritanya beli lauk ayam bakar nasi padang masnya bungku ayam plastik bene tru liat tuh ayamnya bolakbalik tadaaaa temu telur lalat ku kasih tahu masnya saja kalau telur lalat langsung diganti masnya | 32          |

f. Feature Extraction

Setelah Proses Cleaning data, langkah selanjutnya adalah ekstraksi fitur menggunakan teknik TF-IDF (*Term Frequency-Inverse Document Frequency*). Teknik ini mengubah data teks menjadi representasi numerik dengan memberikan bobot pada setiap kata berdasarkan frekuensi kemunculannya dalam dokumen. Pendekatan ini memungkinkan model untuk lebih fokus pada kata-kata yang relevan dalam membedakan kategori gender. Proses ekstraksi fitur menggunakan TfidfVectorizer dari library dengan parameter utama yang digunakan sebagai berikut:

1. Nilai n-gram: Menggunakan pasangan nilai (1,2), yang mencakup unigram (kata tunggal) dan bigram (kombinasi dua kata). Pendekatan ini memungkinkan model untuk menangkap konteks kata yang sering muncul dalam teks.
2. Jumlah fitur maksimum: Jumlah fitur yang digunakan dibatasi hingga 5000 kata atau kombinasi kata dengan bobot tertinggi. Batasan ini diterapkan melalui parameter `max_features`, yang diatur dengan nilai 5000, untuk memastikan bahwa fitur yang paling relevan diprioritaskan dalam analisis, meningkatkan efisiensi dan akurasi pemrosesan data teks.

Proses ekstraksi fitur menggunakan TF-IDF meliputi dua langkah utama:

1. Fit and Transform: Proses `fit_transform` digunakan untuk mengidentifikasi seluruh kata atau n-gram dalam teks dan menghitung bobot TF-IDF. Hasil dari proses ini adalah matriks yang berbentuk vektor numerik.
2. Konversi ke DataFrame: Matriks hasil ekstraksi TF-IDF kemudian dikonversi menjadi DataFrame, dengan kolom yang sesuai dengan kata atau n-gram yang teridentifikasi. Langkah ini mempermudah integrasi fitur dengan data lainnya dalam tahap analisis lebih lanjut.

Fitur-fitur yang diperoleh dari ekstraksi TF-IDF ini selanjutnya digunakan sebagai input untuk model Naive Bayes dan SVM. Matriks numerik yang dihasilkan memungkinkan model untuk menganalisis pola bahasa dalam teks komentar dan membuat klasifikasi gender berdasarkan pola-pola tersebut.

g. Pembagian data

Dalam penelitian ini, data yang diperoleh dari komentar media sosial dibagi menjadi dua subset: data pelatihan dan data pengujian, dengan pembagian rasio 80:20 dan 70:30. Pembagian ini mengacu pada penelitian yang dilakukan oleh (Putri & Raharja, 2023) yang menyatakan bahwa “Proses pemisahan data latih dan data uji dilakukan secara acak untuk menjaga proporsi yang seimbang antara kelas-kelas tersebut”. Berdasarkan rekomendasi tersebut, 80% dari data digunakan untuk pelatihan dan 20% untuk pengujian serta pembagian lain yaitu 70% untuk pelatihan dan 30% untuk pengujian. Pembagian data dengan rasio ini bertujuan untuk menjaga keseimbangan antar kelas serta mengurangi kemungkinan terjadinya overfitting, sehingga menghasilkan hasil yang lebih relevan.

Pembagian data dilakukan dengan menerapkan teknik stratifikasi, yang memastikan distribusi gender antara data pelatihan dan data pengujian tetap seimbang. Hal ini memungkinkan model untuk belajar dari representasi yang proporsional, yang sangat penting agar model dapat mempelajari pola-pola pada setiap kelas dengan tepat dan menghindari

adanya bias terhadap salah satu kelas.

Untuk menjamin bahwa hasil pengujian mencerminkan kinerja model yang sesungguhnya, langkah-langkah pencegahan data leakage (kebocoran data) dilakukan. Data leakage merujuk pada situasi di mana informasi dari data pengujian bocor ke dalam proses pelatihan, yang dapat mempengaruhi hasil evaluasi model. Beberapa langkah pencegahan data leakage yang diterapkan adalah:

- a. Preprocessing Terpisah: Semua proses preprocessing, seperti ekstraksi fitur menggunakan TF-IDF, dilakukan hanya pada data pelatihan. Parameter yang diperoleh dari proses tersebut kemudian diterapkan pada data pengujian untuk memastikan tidak ada informasi dari data pengujian yang digunakan dalam pelatihan.
- b. Penggunaan fungsi `train_test_split`: Pembagian data dilakukan menggunakan fungsi `train_test_split` dari library `sklearn`, dengan parameter `stratify` untuk memastikan distribusi gender tetap konsisten antara data pelatihan dan pengujian.

Setelah seluruh tahapan preprocessing selesai diterapkan, diperoleh dataset akhir sebanyak 5.275 data komentar yang telah melalui proses. Dari total data tersebut, distribusi kelas menunjukkan adanya 2.819 komentar yang dikategorikan sebagai laki-laki dan 2.456 komentar yang dikategorikan sebagai perempuan. Namun, untuk menjaga keseimbangan antar kelas maka dilakukan penghapusan kelas yang dominan yaitu laki-laki sehingga jumlah datanya sama dengan gender perempuan. Hal ini dilakukan supaya meminimalisir kesalahan dalam proses klasifikasi data.

### 3.3 Implementasi Model Naïve Bayes

#### a. Pelatihan Model

Setelah melalui proses pembagian data dalam preprocessing, pada tahap ini model Naive Bayes dilatih dengan data pelatihan yang berisi teks komentar pengguna twitter yang diekstraksi menggunakan teknik TF-IDF. Data pelatihan ini mencakup komentar-komentar yang telah diberi label berdasarkan kategori gender, yaitu laki-laki dan perempuan. Tujuan pelatihan model naive bayes adalah agar model naive bayes dapat mempelajari probabilitas kemunculan kata tertentu pada masing-masing kategori gender.

Proses Pelatihan model naive bayes melalui beberapa langkah dan rumus formulasi sebagai berikut:

### 1. Probabilitas Prior

Probabilitas prior untuk setiap kelas (gender yang meliputi laki-laki dan perempuan) dihitung pada persamaan (3.1) :

$$P(C_k) = \frac{N}{Nk} \quad (3.1)$$

1.  $P(C_k)$  adalah probabilitas prior untuk kelas  $k$  (laki-laki atau perempuan).
2.  $Nk$  adalah jumlah data dalam kelas  $k$
3.  $N$  adalah total jumlah data.

### 2. Probabilitas Kondisional

Probabilitas kemunculan kata  $w$  dalam kelas  $C_k$  dihitung menggunakan rumus pada persamaan (3.2) :

$$P(w | C_k) = \frac{N_{w,k} + 1}{Nk + V} \quad (3.2)$$

Dimana:

1.  $P(w|C_k)$  adalah probabilitas kata  $w$  muncul dalam kelas  $C_k$ ,
  2.  $N_{w,k}$  adalah jumlah kemunculan kata  $w$  dalam kelas  $k$
  3.  $V$  adalah jumlah total kata unik.
- ### 3. Prediksi Kelas

Untuk memprediksi kelas dari sebuah komentar baru, model menghitung probabilitas posterior untuk setiap kelas menggunakan persamaan (3.3) :

$$P(C_k | w_1, w_2, \dots, w_m) \propto P(C_k) \prod_{i=1}^m P(w_i | C_k) \quad (3.3)$$

Kelas dengan probabilitas tertinggi akan dipilih sebagai prediksi.

Proses pelatihan ini menggunakan distribusi Multinomial Naive Bayes dengan variasi hyperparameter alpha (0.1, 0.5, dan 1.0) karena data yang digunakan bersifat diskrit (berupa frekuensi kata dalam teks) dan variasi alpha untuk melihat pengaruh smoothing terhadap performa model. Setelah model selesai dilatih, ia dapat memprediksi kategori gender pada data yang belum pernah dilihat sebelumnya, berdasarkan pola yang telah dipelajari dari data pelatihan. Setelah proses pelatihan, model siap untuk melakukan prediksi berdasarkan data yang sebelumnya tidak dilihat.

## b. Pengujian Model

Setelah pelatihan selesai, tahap selanjutnya adalah pengujian model menggunakan data pengujian. Data pengujian ini berisi komentar-komentar yang belum pernah dilihat oleh model selama pelatihan. Pada tahap pengujian, model Naive Bayes akan melakukan prediksi mengenai gender berdasarkan teks komentar yang ada dalam dataset pengujian. Hasil prediksi yang diperoleh kemudian dibandingkan dengan label yang sebenarnya untuk menghitung berbagai metrik evaluasi yang digunakan untuk menilai kinerja model. Metrik evaluasi tersebut antara lain meliputi *accuracy*, *precision*, *recall*, dan *F1-score*.

## 3.4 Implementasi Model SVM (Support Vector Machine)

### a. Pemilihan Kernel

Pada implementasi metode SVM, pemilihan kernel merupakan langkah penting yang menentukan bagaimana model memisahkan data dalam ruang fitur. Terdapat beberapa jenis kernel yang dapat digunakan dalam SVM, di antaranya adalah kernel linear, polynomial, dan Radial Basis Function (RBF). Pada penelitian ini, kernel yang digunakan adalah kernel linear, karena data yang digunakan cenderung memiliki distribusi yang tidak kompleks dan dapat dipisahkan secara linear. Selain itu, kernel linear lebih efisien digunakan pada data berbentuk teks, di mana pola hubungan antara fitur dan kategori (gender dalam hal ini) dapat ditemukan melalui garis pemisah yang sederhana. Pemilihan kernel linear memungkinkan model untuk memisahkan dua kelas (laki-laki dan perempuan) dengan cara yang lebih langsung dan cepat. Fungsi Kernel dapat dirumuskan sebagai  $K(x_i, x_j)$ . Untuk kernel linear yang digunakan pada penelitian ini, fungsi kernelnya dinyatakan sebagai  $K(x_i, x_j) = x_i \cdot x_j$ .

### b. Pelatihan Model

Seperti pada Naive Bayes, Pelatihan model SVM dilakukan menggunakan data pelatihan yang telah diekstraksi sebelumnya. Pada tahap ini, SVM berusaha untuk menemukan hyperplane yang dapat memisahkan data berdasarkan kategori gender. Hyperplane ini berfungsi sebagai pembatas yang membedakan data dari dua kelas: laki-laki dan perempuan.

Proses Pelatihan model dalam SVM melalui beberapa langkah dan rumus formulasi sebagai berikut:

### 1. Definisi Hyperplane

Hyperplane dalam ruang fitur  $R^n$  dapat dinyatakan dengan persamaan (3.4):

$$w \cdot x + b = 0 \quad (3.4)$$

di mana:

1.  $w$  adalah vektor bobot (weight vector).
2.  $x$  adalah vektor fitur dari data.
3.  $b$  adalah bias (intercept).

### 2. Margin

Margin adalah jarak antara hyperplane dan titik data terdekat dari masing-masing kelas. Margin dapat dinyatakan pada persamaan (3.5):

$$Margin = \frac{2}{||w||} \quad (3.5)$$

### 3. Fungsi Tujuan

SVM bertujuan untuk memaksimalkan margin sambil meminimalkan kesalahan klasifikasi. Fungsi tujuan dapat dinyatakan pada persamaan (3.6):

$$Min \frac{1}{2} ||w||^2 \quad (3.6)$$

Dengan kendala persamaan (3.7):

$$y_i (w \cdot x_i + b) \geq 1 \quad \forall i \quad (3.7)$$

di mana  $y_i$  adalah label kelas dari data  $x_i$  (1 untuk laki-laki, -1 untuk perempuan).

### c. Optimasi Parameter

Setelah melakukan pelatihan model, dilakukan optimasi parameter untuk meningkatkan akurasi model. Proses optimasi dapat dilakukan menggunakan metode *Langrange multipliers* untuk mengubah kendala menjadi fungsi tujuan yang dapat dioptimalkan. Salah satu parameter penting yang perlu dioptimasi adalah  $C$  (Complexity). Parameter  $C$  mengontrol trade-off antara kesalahan klasifikasi dan lebar margin yang dapat diterima oleh model. Nilai  $C$  yang tinggi akan memaksa model untuk meminimalkan kesalahan klasifikasi, tetapi hal ini bisa menyebabkan model menjadi overfitting, yaitu model terlalu spesifik terhadap data pelatihan dan kurang dapat menggeneralisasi ke data baru. Sebaliknya, nilai  $C$  yang rendah dapat menyebabkan underfitting, di mana model

tidak cukup fleksibel dalam memisahkan kelas dengan baik, karena terlalu memperbesar margin dan mengabaikan beberapa kesalahan klasifikasi. Oleh karena itu, pemilihan nilai  $C$  yang optimal sangat penting untuk mencapai keseimbangan yang tepat antara akurasi dan generalisasi model.

#### d. Pengujian Model

Setelah model SVM dilatih dan parameter dioptimasi, tahap selanjutnya adalah pengujian model menggunakan data pengujian yang sama dengan data yang digunakan pada model Naive Bayes. Pada tahap ini, model akan memprediksi gender berdasarkan teks komentar dalam dataset pengujian, dan hasil prediksi akan dibandingkan dengan label sebenarnya untuk mengevaluasi kinerja model. Metrik evaluasi seperti accuracy, precision, recall, dan F1-score akan digunakan untuk mengukur seberapa baik model SVM dalam melakukan klasifikasi data.

### 3.5 Evaluasi Model

Setelah implementasi kedua model, evaluasi dilakukan untuk menilai performa model menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* mengukur proporsi prediksi yang benar dari total prediksi yang dibuat oleh model. *Accuracy* memberikan gambaran umum tentang seberapa baik model dalam mengklasifikasikan data, baik untuk kelas positif maupun negatif. Rumus *accuracy* secara umum dapat dituliskan dalam persamaan (3.8):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+F} \quad (3.8)$$

Precision mengukur proporsi prediksi positif yang benar dari seluruh prediksi positif yang dihasilkan oleh model. Precision penting untuk menghindari kesalahan positif (False Positive) yang dapat berdampak signifikan. Rumus Precision secara umum dapat ditulis dalam persamaan (3.9) :

$$Precision = \frac{TP}{TP+FP} \quad (3.9)$$

Recall mengukur proporsi data positif yang berhasil diklasifikasikan dengan benar oleh model. Recall menjadi penting dalam situasi di mana kesalahan negatif (False Negative) harus diminimaliskan. Rumus Recall secara umum dapat ditulis dalam persamaan (3.10) :

$$Recall = \frac{TP}{TP+FN} \quad (3.10)$$

F1-Score merupakan rata-rata harmonis antara precision dan recall, memberikan keseimbangan antara kedua metrik tersebut, terutama pada dataset dengan distribusi kelas yang tidak seimbang. Rumus F1-Score secara umum dalam persamaan (3.11) :

$$F1-Score = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.11)$$

Dalam menganalisis kesalahan klasifikasi dengan lebih rinci, digunakan confusion matrix yang terdiri dari empat kategori berikut:

- a. True Positive (TP): Data positif yang diklasifikasikan dengan benar sebagai positif.
- b. True Negative (TN): Data negatif yang diklasifikasikan dengan benar sebagai negatif.
- c. False Positive (FP): Data negatif yang salah diklasifikasikan sebagai positif.
- d. False Negative (FN): Data positif yang diklasifikasikan sebagai negatif.

Selain evaluasi pada data pengujian, validasi silang juga dilakukan menggunakan metode 10-Fold Cross-Validation. Proses ini bertujuan untuk memastikan bahwa hasil evaluasi model konsisten pada berbagai subset data. Validasi silang membantu mengurangi bias dalam evaluasi dan memastikan bahwa hasil yang diperoleh lebih representatif terhadap keseluruhan dataset. Prosedur validasi silang melibatkan pembagian dataset menjadi sepuluh bagian yang kurang lebih sama besar. Pada setiap iterasi, sembilan bagian digunakan sebagai data pelatihan, dan satu bagian sebagai data pengujian. Proses ini diulang sepuluh kali, sehingga setiap bagian digunakan sekali sebagai data pengujian. Hasil evaluasi dari sepuluh iterasi tersebut kemudian dirata-rata untuk memberikan gambaran menyeluruh tentang kinerja model.

### 3.6 Komparasi Hasil

Setelah Evaluasi model dilakukan, selanjutnya adalah membandingkan hasil kedua model, yaitu Naive Bayes dan SVM, berdasarkan metrik evaluasi yang telah dihitung sebelumnya. Metrik yang digunakan untuk perbandingan antara lain: accuracy, precision, recall, dan F1-score. Metrik- metrik ini akan memberikan gambaran yang lebih jelas tentang kelebihan dan kekurangan masing- masing model dalam mengklasifikasikan gender berdasarkan teks komentar di X (Twitter).

Hasil komparasi antara kedua model (Naive Bayes dan SVM) dapat divisualisasikan untuk mempermudah analisis dan pemahaman. Salah satu metode visualisasi yang digunakan adalah Grouped Bar Chart, di mana setiap metrik evaluasi seperti akurasi, precision, recall, dan F1-score ditampilkan sebagai kelompok batang untuk masing-masing model. Selain itu, Confusion matrix yang dapat mengidentifikasi jenis kesalahan klasifikasi yang dilakukan oleh model. Misalnya, jika model menghasilkan lebih banyak False Positive, ini menunjukkan

bahwa model sering keliru dalam mengklasifikasikan data negatif sebagai positif. Dengan cara ini, perbandingan performa kedua model dapat dilakukan secara mudah dan jelas, memungkinkan identifikasi model dengan performa terbaik untuk setiap metrik.

Perbandingan ini tidak hanya berguna untuk memahami kekuatan relatif Naive Bayes dan SVM dalam konteks dataset yang digunakan, tetapi juga memiliki aplikasi praktis dalam moderasi komentar di platform media sosial. Model yang lebih unggul dalam klasifikasi gender dapat diterapkan untuk mengelompokkan komentar berdasarkan gender, yang dapat membantu dalam analisis sentimen gender atau pendeteksi bias gender di media sosial. Selain itu, perbandingan ini memberikan wawasan mengenai efisiensi penggunaan kedua model dalam lingkungan produksi, terutama dalam hal waktu pelatihan dan kompleksitas data, serta bagaimana kedua model mengatasi masalah overfitting atau underfitting seiring bertambahnya ukuran data pelatihan.

### 3.7 Rencana Skenario Pengujian

Penelitian ini bertujuan untuk mengkomparasi kinerja dua model klasifikasi, yaitu Naïve Bayes dan Support Vector Machine (SVM), dalam mengklasifikasikan gender berdasarkan komentar dari media sosial X (Twitter). Pengujian dilakukan dengan menggunakan data yang sudah di preprocessing. Tujuan utama dari pengujian ini adalah:

- a. Menilai performa masing-masing model dalam klasifikasi gender, dan
  - b. Membandingkan hasil klasifikasi guna mengetahui kelebihan dan kekurangan dari setiap pendekatan.
1. Parameter model yang digunakan

Model pertama yang digunakan adalah Multinomial Naïve Bayes, yang cocok untuk data teks karena menghitung probabilitas berdasarkan frekuensi kata. Model ini diuji menggunakan parameter smoothing (Alpha) dengan nilai 0.1, 0.5, dan 1.0. Parameter Alpha berfungsi untuk menangani fitur yang jarang muncul; nilai yang lebih kecil menjadikan model lebih sensitif terhadap kata-kata jarang, sedangkan nilai yang lebih besar memberi efek generalisasi yang lebih kuat.

Model kedua adalah Support Vector Machine (SVM) dengan kernel linear. Kernel ini dipilih karena data teks sering kali dapat dipisahkan secara linier dalam ruang fitur. SVM diuji dengan parameter C (Regularisasi), yaitu 0.1, 1, dan 10. Nilai C yang lebih kecil memberikan margin keputusan yang lebih lebar dengan toleransi kesalahan yang lebih tinggi, sedangkan nilai yang lebih besar memaksa model untuk meminimalkan kesalahan klasifikasi.

## 2. Pembagian Dataset

Pengujian dilakukan dalam dua skenario. Skenario pertama adalah pengujian dengan proporsi data yang berbeda, yaitu 70% data untuk pelatihan dan 30% untuk pengujian, serta 80% untuk pelatihan dan 20% untuk pengujian. Tujuannya adalah mengevaluasi pengaruh proporsi data terhadap performa model.

Skenario kedua adalah pengujian berdasarkan ukuran dataset yang berbeda, yaitu 1000, 3000, dan 5000 sampel. Dataset dengan 1000 sampel digunakan untuk melihat performa model pada data terbatas. Ukuran 3000 sampel memberikan gambaran performa pada data sedang, sedangkan 5000 sampel digunakan untuk menguji stabilitas dan konsistensi model pada data yang lebih besar dan beragam.

Pembagian ini mengikuti praktik umum dalam penelitian machine learning untuk menjaga keseimbangan antara data pelatihan dan pengujian, serta memastikan evaluasi model yang lebih akurat. Dengan strategi pengujian ini, penelitian ini diharapkan dapat memberikan analisis yang lebih mendalam terkait efektivitas metode Naïve Bayes dan SVM dalam klasifikasi gender berdasarkan komentar di X (Twitter).

## **BAB IV**

### **HASIL DAN PEMBAHASAN**

#### **4.1 Proses Evaluasi Model**

Bab ini membahas hasil dari eksperimen klasifikasi gender berdasarkan komentar di platform media sosial X (Twitter) menggunakan metode Naïve Bayes dan Support Vector Machine (SVM). Model dievaluasi dengan menjalankan skenario pengujian yang telah dijelaskan pada Bab III untuk memahami bagaimana masing-masing model mengenali pola dalam data serta performa klasifikasinya berdasarkan metrik evaluasi yang digunakan.

Proses evaluasi model terdiri dari tahapan berikut:

- a. Pelatihan Model (Training): Melatih Naïve Bayes dan SVM dengan dataset yang telah diproses.
- b. Pengujian Model (Testing): Menguji model menggunakan data uji yang dipisahkan sebelumnya.
- c. Evaluasi Model: Mengukur performa model menggunakan metrik evaluasi seperti accuracy, precision, recall, dan F1-score.
- d. Analisis Hasil Evaluasi: Membandingkan performa model berdasarkan berbagai skenario pengujian.

#### **4.2 Pelatihan dan Pengujian Model (Training & Testing)**

##### **a. Pelatihan Model (Training)**

Pada tahap ini, model Naïve Bayes dan SVM dilatih menggunakan dataset komentar yang telah diproses melalui tahapan preprocessing seperti case folding, tokenization, stopword removal, stemming, dan ekstraksi fitur menggunakan TF-IDF. Proses pelatihan dilakukan dengan konfigurasi parameter yang telah ditentukan pada Bab III. Setelah pelatihan selesai, model yang telah dilatih diuji pada data uji untuk mengukur kemampuannya dalam mengklasifikasikan gender berdasarkan komentar.

##### **b. Pengujian Model (Testing)**

Setelah proses pelatihan, model diuji menggunakan data uji yang telah dipisahkan sebelumnya untuk mengevaluasi sejauh mana model dapat mengklasifikasikan gender dengan akurat. Pengujian dilakukan sesuai dengan skenario yang telah dijelaskan pada Bab III, yang mencakup:

1. Pengujian dengan berbagai proporsi data latih dan uji (80:20 dan 70:30).
2. Pengujian dengan variasi hiperparameter pada Naïve Bayes ( $\alpha = 0.1, 0.5, 1.0$ ).
3. Pengujian dengan variasi hiperparameter pada SVM ( $C = 0.1, 1, 10$ ).

#### 4.3 Evaluasi Model

Evaluasi model dilakukan untuk mengukur kinerja klasifikasi gender menggunakan dua algoritma yang dibandingkan, yaitu Naïve Bayes dan Support Vector Machine (SVM).

Evaluasi dilakukan dengan empat metrik utama:

- a. Accuracy: Persentase prediksi yang benar dari total data uji.
- b. Precision: Kemampuan model menghindari prediksi positif yang salah.
- c. Recall: Kemampuan model dalam mendeteksi seluruh data positif.
- d. F1-Score: Rata-rata harmonik dari precision dan recall, menggambarkan keseimbangan antara keduanya.

Pengujian dilakukan pada dua rasio pembagian data (80:20 dan 70:30), serta kombinasi nilai hiperparameter masing-masing model. Hasil pengujian disajikan secara ringkas dalam tabel berikut, yang kemudian dianalisis untuk melihat performa optimal dari masing-masing model.

##### a. Evaluasi Model Naive Bayes

Evaluasi model Naive Bayes dilakukan dengan mengubah nilai  $\alpha$  dan rasio data.

Tabel berikut menyajikan performa model:

##### 1. Rasio 70:30

Tabel 4.1 Evaluasi Model Naive Bayes Rasio Data 70:30

| Model       | Accuracy | Precision | Recall | F1-Score |
|-------------|----------|-----------|--------|----------|
| Alpha = 0.1 | 0.6947   | 0.6949    | 0.6947 | 0.6946   |
| Alpha = 0.5 | 0.7089   | 0.709     | 0.7089 | 0.7089   |
| Alpha = 1.0 | 0.7137   | 0.7138    | 0.7137 | 0.7136   |

Berdasarkan tabel 4.1, model Naive Bayes dengan parameter  $\alpha = 1.0$  menunjukkan performa terbaik dengan akurasi 0.7137, precision 0.7138, recall 0.7137, dan F1-score 0.7136. Performa ini lebih tinggi dibandingkan  $\alpha = 0.5$  (0.7089) dan  $\alpha = 0.1$  (0.6947), yang cenderung menghasilkan metrik lebih rendah pada semua aspek. Temuan ini mengindikasikan bahwa penyesuaian smoothing pada  $\alpha$  berpengaruh terhadap stabilitas prediksi, dengan  $\alpha = 1.0$  menjadi nilai yang paling

optimal pada rasio data 70:30 karena memberikan keseimbangan terbaik antara precision dan recall.

## 2. Rasio 80:20

Tabel 4.2 Evaluasi Model Naive Bayes Rasio Data 80:20

| Model       | Accuracy | Precision | Recall | F1-Score |
|-------------|----------|-----------|--------|----------|
| Alpha = 0.1 | 0.7009   | 0.701     | 0.7009 | 0.7008   |
| Alpha = 0.5 | 0.707    | 0.7073    | 0.707  | 0.7069   |
| Alpha = 1.0 | 0.7152   | 0.7154    | 0.7151 | 0.715    |

Berdasarkan tabel 4.2, pola serupa juga ditemukan. Alpha = 1.0 kembali menghasilkan performa tertinggi dengan akurasi 0.7152, precision 0.7154, recall 0.7151, dan F1-score 0.7150. Sementara itu, alpha = 0.5 mencatatkan hasil menengah (sekitar 0.707) dan alpha = 0.1 memiliki nilai terendah pada semua metrik evaluasi (sekitar 0.7009). Hal ini menunjukkan bahwa penggunaan alpha yang terlalu kecil dapat menyebabkan model kurang mampu menangani variasi data, sedangkan alpha = 1.0 konsisten memberikan hasil yang stabil dan optimal baik pada rasio 70:30 maupun 80:20.

## b. Evaluasi Model SVM (Support Vector Machine)

Model SVM diuji dengan parameter regularisasi C dan rasio data. Hasilnya sebagai berikut:

### 1. Rasio Data 70:30

Tabel 4.3 Evaluasi Model SVM Rasio Data 70:30

| Model   | Accuracy | Precision | Recall | F1-Score |
|---------|----------|-----------|--------|----------|
| C = 0.1 | 0.7293   | 0.7295    | 0.7293 | 0.7292   |
| C = 1.0 | 0.7232   | 0.7234    | 0.7232 | 0.7231   |
| C = 10  | 0.6547   | 0.6547    | 0.6547 | 0.6547   |

Berdasarkan Tabel 4.3, model Support Vector Machine (SVM) dengan kernel linear menunjukkan performa terbaik pada parameter regularisasi C = 0.1, dengan akurasi, precision, recall, dan F1-score masing-masing sebesar 0.7293, 0.7295, 0.7293, dan 0.7292. Nilai ini lebih tinggi dibandingkan C = 1.0 yang memiliki metrik akurasi 0.7232, precision 0.7234, recall 0.7232, dan F1-score 0.7231. Sementara itu, C = 10

memberikan performa terendah dengan seluruh metrik berada pada kisaran 0.6547, menunjukkan adanya indikasi overfitting akibat kompleksitas model yang terlalu tinggi. Temuan ini mengindikasikan bahwa pada rasio 70:30, model dengan C yang lebih kecil justru mampu memberikan keseimbangan lebih baik antara kompleksitas dan kemampuan generalisasi.

## 2. Rasio data 80:20

Tabel 4.4 Evaluasi Model SVM Rasio Data 80:20

| Model   | Accuracy | Precision | Recall | F1-Score |
|---------|----------|-----------|--------|----------|
| C = 0.1 | 0.7232   | 0.7235    | 0.7233 | 0.7232   |
| C = 1.0 | 0.7172   | 0.7173    | 0.7172 | 0.7172   |
| C = 10  | 0.6663   | 0.6664    | 0.6663 | 0.6662   |

Berdasarkan Tabel 4.4, pola serupa ditemukan di mana  $C = 0.1$  kembali menghasilkan performa terbaik dengan akurasi 0.7232, precision 0.7235, recall 0.7233, dan F1-score 0.7232. Nilai ini sedikit lebih unggul dibandingkan  $C = 1.0$  yang menunjukkan akurasi 0.7172, precision 0.7173, recall 0.7172, dan F1-score 0.7172. Sama halnya dengan rasio 70:30,  $C = 10$  memperlihatkan performa yang paling rendah pada semua metrik (sekitar 0.6663 – 0.6666). Hal ini menegaskan bahwa penggunaan nilai C yang terlalu besar tidak selalu meningkatkan performa model, melainkan dapat memperburuk kemampuan generalisasi, sedangkan C yang lebih kecil (0.1) pada rasio 80:20 mampu menjaga kestabilan performa dengan baik.

## c. Evaluasi Model Terbaik Naive Bayes dan SVM

Setelah hasil evaluasi dari masing-masing ditampilkan, dilakukan komparasi untuk membandingkan performa kedua model pembanding, yaitu Naive Bayes dan SVM (Support Vector Machine). Komparasi dilakukan dengan membandingkan dua model yang memiliki hasil terbaik berdasarkan parameternya masing-masing dari skenario yang telah diuji. Tabel berikut menyajikan hasil evaluasi model pada data uji:

## 1. Rasio Data 70:30

Tabel 4.5 Evaluasi Model Terbaik Rasio Data 70:30

| Model                        | Hyperparameter | Accuracy | Precision | Recall | F1-Score |
|------------------------------|----------------|----------|-----------|--------|----------|
| Naive Bayes                  | Alpha = 1.0    | 0.7137   | 0.7138    | 0.7137 | 0.7137   |
| SVM (Support Vector Machine) | C = 0.1        | 0.7232   | 0.7294    | 0.7293 | 0.7292   |

## 2. Rasio Data 80:20

Tabel 4.6 Evaluasi Model Terbaik Rasio Data 80:20

| Model                        | Hyperparameter | Accuracy | Precision | Recall | F1-Score |
|------------------------------|----------------|----------|-----------|--------|----------|
| Naive Bayes                  | Alpha = 1.0    | 0.7152   | 0.7154    | 0.7152 | 0.7151   |
| SVM (Support Vector Machine) | C = 0.1        | 0.7232   | 0.7235    | 0.7233 | 0.7232   |

Berdasarkan dari perbandingan evaluasi masing-masing model pada tabel 4.5 dan 4.6, hasil evaluasi menunjukkan bahwa model Support Vector Machine (SVM) secara konsisten memiliki performa yang lebih baik dibandingkan dengan Naïve Bayes pada kedua rasio pembagian data (70:30 dan 80:20). Pada rasio 70:30, SVM dengan parameter  $C = 0.1$  mencapai akurasi 0.7232, precision 0.7294, recall 0.7293, dan F1-score 0.7292, sedikit lebih tinggi dibandingkan dengan Naïve Bayes ( $\alpha = 1.0$ ) yang memperoleh akurasi 0.7137, precision 0.7138, recall 0.7137, dan F1-score 0.7137. Pada rasio 80:20, SVM kembali unggul dengan akurasi 0.7232, precision 0.7235, recall 0.7233, dan F1-score 0.7232, mengungguli Naïve Bayes yang hanya mencapai akurasi 0.7152, precision 0.7154, recall 0.7152, dan F1-score 0.7151.

Secara keseluruhan, performa SVM yang lebih tinggi pada kedua skenario menunjukkan stabilitas model dalam menangani variasi rasio data serta kemampuannya menjaga keseimbangan antar metrik evaluasi. Temuan positifnya, SVM unggul di semua metrik tanpa mengalami degradasi signifikan saat rasio data berubah. Temuan negatifnya, perbedaan performa SVM dan Naïve Bayes relatif kecil (sekitar 1–1.5%), yang mengindikasikan bahwa dengan data dan preprocessing saat ini, kedua model memiliki tingkat kedekatan performa yang cukup tinggi sehingga Naïve Bayes masih dapat menjadi alternatif apabila prioritas utama adalah kecepatan komputasi.


#### 4.4 Visualisasi dan Interpretasi Hasil Pengujian

Guna mempermudah analisis perbandingan kinerja model, hasil evaluasi divisualisasikan menggunakan dua jenis grafik, yaitu Grouped Bar Chart dan Learning Curve. Grouped Bar Chart digunakan untuk membandingkan metrik evaluasi seperti accuracy, precision, recall, dan F1- Score secara berdampingan antara kedua model, sehingga perbedaan performa dapat terlihat dengan jelas. Sementara itu, Learning Curve digunakan untuk menganalisis perubahan akurasi model seiring dengan penambahan jumlah data pelatihan. Grafik ini juga membantu mengidentifikasi apakah model mengalami overfitting atau underfitting. Berikut adalah grafik yang menampilkan tingkat akurasi masing-masing model dalam berbagai skenario:

##### a. Confusion Matrix

Confusion matrix menggambarkan performa klasifikasi model terhadap data aktual. Matriks ini menunjukkan jumlah True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN) dari hasil prediksi.

##### 1. Rasio Data 70:30




Gambar 4.1 Confusion Matrix Model Terbaik Rasio Data 70:30

Gambar 4.1 menampilkan confusion matrix hasil klasifikasi menggunakan dua metode: Naïve Bayes dengan  $\alpha = 1.0$  dan Support Vector Machine (SVM) dengan  $C = 0.1$  pada rasio pembagian 70% data latih dan 30% data uji. Hasil menunjukkan bahwa SVM memberikan prediksi yang lebih akurat dengan jumlah klasifikasi benar (true positive dan true negative) yang lebih tinggi dibandingkan Naïve Bayes. Hal ini terlihat dari nilai diagonal utama yang lebih besar pada SVM, yang menunjukkan kemampuan metode tersebut dalam meminimalkan kesalahan klasifikasi, khususnya pada kelas positif. Sebaliknya, Naïve Bayes menghasilkan

jumlah false positive dan false negative yang lebih tinggi, yang menandakan keterbatasannya dalam mendeteksi pola pada rasio ini.

## 2. Rasio Data 80:20




Gambar 4.2 Confusion Matrix Model Terbaik 3000 Data

Gambar 4.2 menunjukkan confusion matrix pada rasio pembagian 80% data latih dan 20% data uji, dengan Naïve Bayes menggunakan  $\alpha = 1.0$  dan SVM menggunakan  $C = 0.1$ . Sama seperti pada rasio 70:30, SVM kembali menunjukkan performa yang lebih baik dengan jumlah prediksi benar yang lebih tinggi dan kesalahan klasifikasi yang lebih rendah pada kedua kelas (0 dan 1). Naïve Bayes, meskipun tetap dapat memprediksi kedua kelas dengan cukup seimbang, masih mengalami kesulitan dalam mengurangi jumlah false negative pada kelas 1, yang berdampak pada penurunan nilai recall.

Secara keseluruhan, evaluasi confusion matrix pada kedua rasio data menunjukkan bahwa SVM secara konsisten lebih unggul dibandingkan Naïve Bayes. SVM mampu meminimalkan kesalahan klasifikasi dengan false positive yang lebih rendah pada kelas 0 dan false negative yang lebih rendah pada kelas 1. Di sisi lain, Naïve Bayes lebih seimbang dalam mendistribusikan prediksi antar kelas, tetapi akurasi lebih rendah akibat kesalahan klasifikasi yang lebih sering terjadi pada kelas 1.


## b. Grouped Bar Chart

## 1. Rasio Data 70:30



Gambar 4.3 Grouped Bar Chart Model Terbaik Rasio Data 70:30

## 2. Rasio Data 80:20



Gambar 4.4 Grouped Bar Chart Model Terbaik Rasio Data 80:20

Berdasarkan gambar 4.3 dan 4.4, hasil visualisasi grouped bar chart pada kedua rasio data (70:30 dan 80:20) menunjukkan perbandingan kinerja model terbaik Naïve Bayes dan SVM berdasarkan empat metrik evaluasi utama: akurasi, precision, recall, dan F1-score. Pada rasio 70:30, model SVM ( $C=0.1$ ) menunjukkan skor yang sedikit lebih unggul dibandingkan Naïve Bayes ( $\alpha=1.0$ ) pada seluruh metrik dengan selisih sekitar 0,015–0,02. Sementara itu, pada rasio 80:20, selisih performa antara kedua model semakin mengecil dengan perbedaan kurang dari 0,01 di semua metrik, meskipun SVM tetap konsisten lebih baik.

#### 4.5 Analisis Hasil

Berdasarkan hasil evaluasi yang diperoleh dari tabel dan grafik, model Support Vector Machine (SVM) terbukti memiliki performa yang lebih baik dalam mengklasifikasikan gender berdasarkan komentar di media sosial X (Twitter). Dengan tingkat akurasi yang lebih tinggi dalam berbagai skenario pengujian, SVM mampu menjaga keseimbangan antara precision, recall, dan F1-score, sehingga menghasilkan klasifikasi yang lebih akurat.

Untuk memahami lebih dalam mengenai performa masing-masing model berdasarkan berbagai parameter evaluasi, berikut adalah analisis berdasarkan hasil eksperimen:

##### a. Accuracy

*Accuracy* mencerminkan persentase klasifikasi yang benar dari total data uji. Model SVM menunjukkan performa akurasi tertinggi dalam semua skenario pengujian.

1. Pada rasio 70:30, SVM ( $C = 0.1$ ) mencapai akurasi 0.7232, lebih tinggi dibandingkan Naïve Bayes ( $\alpha = 1.0$ ) yang hanya 0.7137, menunjukkan SVM lebih mampu mengenali pola komentar secara umum.
2. Pada rasio 80:20, SVM juga unggul dengan 0.7232, sedangkan Naïve Bayes 0.7152, menandakan keunggulan SVM konsisten di kedua rasio data.

Selisih akurasi antara kedua model tergolong rendah (hanya 0.7–1%), sehingga keunggulan SVM belum memberikan perbedaan signifikan secara praktis, terutama bila diterapkan pada data yang lebih kompleks.

##### b. Precision

*Precision* mengukur seberapa tepat model dalam mengidentifikasi kelas tertentu (positif). SVM menunjukkan keunggulan dalam precision pada semua ukuran dataset.

1. Pada rasio 70:30, SVM mencatat precision 0.7294, lebih baik dari Naïve Bayes (0.7138), yang berarti SVM lebih jarang melakukan kesalahan positif palsu (false positive).
2. Pada rasio 80:20, SVM tetap unggul dengan precision 0.7233, sedangkan Naïve Bayes

0.7154, menandakan konsistensi pada kedua rasio.

Kedua model masih menghasilkan *false positive* yang cukup tinggi (210 untuk SVM dan 218 untuk Naïve Bayes pada rasio 70:30), yang menunjukkan masih banyak komentar netral/ambigu yang salah diprediksi sebagai kelas tertentu.

c. Recall

*Recall* menunjukkan kemampuan model untuk mendeteksi seluruh instance yang benar.

1. Pada rasio 70:30, SVM mencatat recall 0.7293, lebih baik dari Naïve Bayes (0.7137), menunjukkan kemampuan mendeteksi kelas dengan lebih merata.
2. Pada rasio 80:20, SVM kembali unggul dengan recall 0.7235 dibandingkan Naïve Bayes 0.7152, menunjukkan efektivitas model tetap terjaga walaupun data uji lebih sedikit.

Kedua model masih kesulitan mendeteksi kelas dengan atribut gender ambigu, terlihat dari *false negative* yang cukup tinggi (189 pada SVM dan 204 pada Naïve Bayes di rasio 70:30).

d. F1-Score

*F1-score* merupakan metrik gabungan dari precision dan recall. Hasil menunjukkan bahwa SVM memiliki keseimbangan terbaik di antara keduanya.

1. Pada rasio 70:30, SVM memperoleh F1-score 0.7292, mengungguli Naïve Bayes (0.7137), menunjukkan keseimbangan precision dan recall lebih baik.
2. Pada rasio 80:20, SVM mencatat F1-score 0.7232, lebih tinggi dari Naïve Bayes 0.7151, mempertegas keunggulan konsistensinya.

Perbedaan F1-score relatif tipis di kedua rasio data (sekitar 0.7–1%), sehingga keunggulan SVM tidak terlalu dominan dalam skenario yang lebih beragam.

e. Rasio Data

1. Kedua model menunjukkan performa yang relatif seimbang pada rasio 70:30 dan 80:20, tanpa adanya degradasi signifikan.
2. SVM menunjukkan fleksibilitas yang lebih baik terhadap perbedaan rasio data, sedangkan Naïve Bayes tetap stabil meskipun sedikit di bawah SVM.

Rasio 80:20 tidak selalu menghasilkan performa yang lebih baik, meskipun secara teori lebih banyak data latih seharusnya menguatkan model. Hal ini menunjukkan adanya batasan pada kompleksitas data dan informasi gender dalam komentar.

f. Pengaruh Hyperparameter Naive Bayes (alpha)

Naïve Bayes cukup stabil terhadap variasi nilai alpha, dengan performa terbaik biasanya pada  $\alpha = 1.0$ .

1. Performa model Naive bayes relatif stabil pada berbagai nilai alpha dari 0.1, 1.0 dan 0.5. Tetapi, alpha = 1.0 lebih banyak memberikan hasil yang lebih baik dibandingkan alpha lainnya.
2. Perbedaan pada nilai alpha sejatinya tidak menyebabkan perbedaan performa yang signifikan, namun naive bayes sendiri cukup robust terhadap variasi alpha sehingga alpha = 1.0 bisa dijadikan acuan dalam membangun model naive bayes karena konsistensi hasil

Naïve Bayes menunjukkan keterbatasan fleksibilitas hyperparameter, karena meskipun  $\alpha$  diubah, peningkatan performanya tidak signifikan, sehingga model sulit dioptimalkan lebih jauh.

g. Pengaruh Hyperparameter SVM (C)

Nilai parameter C sangat menentukan performa model SVM.

1. Nilai C = 0.1 memberikan performa terbaik di kedua rasio, menunjukkan bahwa regularisasi yang lebih kuat mengurangi overfitting.
2. Nilai C yang sedang (1.0) dan besar (10) menghasilkan performa yang lebih rendah dan kurang stabil. Menunjukkan bahwa dalam membangun model SVM (Support Vector Machine), lebih disarankan menggunakan hyperparameter C = 1.0 yang menjaga keseimbangan kompleksitas dan akurasi model.

SVM membutuhkan penyesuaian C yang tepat; nilai yang terlalu besar atau terlalu kecil dapat menyebabkan ketidakseimbangan antara bias dan variansi.

h. Generalisasi Model

Kemampuan generalisasi menjadi penting untuk mengetahui sejauh mana model dapat diterapkan pada data baru.

1. Naïve Bayes tetap kompetitif dengan waktu pelatihan yang sangat cepat dan hasil yang cukup stabil.
2. SVM lebih mampu menggeneralisasi data baru dengan variasi topik komentar yang beragam.

SVM memerlukan komputasi lebih besar dan waktu latih lebih lama yang bahkan bisa sampai 5 menit lebih untuk pemodelan, sehingga kurang efisien jika dataset diperbesar secara signifikan.

i. Efisiensi dan Kompleksitas Komputasi

Efisiensi komputasi berbeda pada masing-masing model.

1. Naïve Bayes unggul dalam kecepatan pelatihan, sangat cocok untuk skenario real-time atau data streaming.
2. SVM meskipun lebih lambat, memberikan output yang lebih konsisten dan akurat untuk dataset yang sudah terkontrol kualitasnya.

SVM memiliki biaya komputasi tinggi, yang dapat menjadi kendala bila digunakan pada dataset yang jauh lebih besar atau real-time.

j. Kesalahan Klasifikasi (Error)

1. SVM memiliki false negative lebih rendah dibandingkan Naïve Bayes (189 vs 204 pada rasio 70:30).
2. Naïve Bayes tetap menunjukkan prediksi seimbang antar kelas, meskipun akurasi lebih rendah.

Kedua model masih sering salah mengklasifikasikan akun dengan informasi gender ambigu, seperti username netral atau bio kosong.

Dari hasil analisis berikut, dapat disimpulkan bahwa SVM lebih unggul dalam aspek akurasi, precision, recall, dan F1-score secara keseluruhan, meskipun memerlukan waktu dan sumber daya komputasi yang lebih besar. Sebaliknya, Naïve Bayes lebih cepat dan efisien dalam proses pelatihan, tetapi memiliki keterbatasan dalam mengklasifikasikan kategori gender dengan akurasi yang tinggi. Oleh karena itu, pemilihan model perlu disesuaikan dengan karakteristik data serta kebutuhan penelitian yang dilakukan.

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Penelitian ini bertujuan untuk melakukan analisis komparatif terhadap dua algoritma klasifikasi teks yaitu Naive Bayes dan Support Vector Machine (SVM), dalam mengklasifikasikan gender berdasarkan komentar pada platform media sosial X (Twitter). kedua metode memiliki karakteristik dan performa yang berbeda dalam menangani data komentar yang bersifat tidak terstruktur, mengandung variasi bahasa, serta cenderung tidak seimbang antar kelas. Naive Bayes menunjukkan performa yang cukup stabil dengan proses pelatihan yang cepat dan efisien, sementara SVM dengan parameter memberikan performa lebih konsisten pada kedua rasio data (70:30 dan 80:20) dengan nilai akurasi, precision, recall, dan F1-score yang sedikit lebih tinggi dibandingkan Naive Bayes.

Berdasarkan hasil yang diperoleh, SVM terbukti memiliki performa lebih unggul dibandingkan Naive Bayes, dengan selisih yang tidak jauh pada semua matriks evaluasi. SVM mampu memberikan keseimbangan yang lebih baik antara precision dan recall, serta menunjukkan jumlah kesalahan klasifikasi yang lebih rendah, khususnya pada false negative. Namun, perbedaan performa tersebut belum signifikan secara praktis dan kedua model masih memiliki keterbatasan dalam menangani komentar yang pendek atau ambigu. Naive Bayes tetap relevan digunakan karena kecepatan dan efisiensinya, sedangkan SVM lebih direkomendasikan ketika akurasi sedikit lebih tinggi diperlukan dengan kompromi pada waktu dan sumber daya komputasi yang lebih besar. Kedua metode ini dipilih berdasarkan kemampuan masing-masing dalam mengatasi tantangan khas pada data media sosial, seperti fitur terbatas, ketidakseimbangan data, dan ambiguitas konteks. Dengan membandingkan keduanya menggunakan metrik evaluasi seperti accuracy, precision, recall, dan F1-score, penelitian ini berhasil memberikan gambaran yang komprehensif mengenai efektivitas masing-masing metode dalam tugas klasifikasi gender berbasis komentar teks.

Penelitian ini menjawab rumusan masalah yang telah diajukan dan mendukung tujuan utama untuk mengetahui metode klasifikasi yang lebih sesuai dengan karakteristik data sosial media yang digunakan.

## 5.2 Limitasi Batasan

Dalam pelaksanaan penelitian ini, terdapat beberapa keterbatasan yang perlu diperhatikan, antara lain:

- a. Keterbatasan cakupan data: Data yang digunakan hanya berasal dari komentar Twitter dalam bahasa Indonesia, sehingga hasil penelitian belum mencerminkan performa metode pada jenis platform atau bahasa lain.
- b. Karakteristik pengumpulan data: Dataset yang dikumpulkan bersifat acak (random) sehingga jumlah komentar yang dikumpulkan dari setiap akun tidak seragam, dengan sebagian besar akun hanya memberikan satu komentar. Oleh karena itu, penentuan gender lebih banyak didasarkan pada atribut akun seperti username, foto profil, dan bio, bukan pada konsistensi perilaku dari banyak komentar dalam satu akun.
- c. Jumlah dan jenis algoritma: Penelitian ini hanya membandingkan dua algoritma klasifikasi, yakni Naive Bayes dan SVM. Belum ada eksplorasi terhadap metode lanjutan yang dapat menangkap konteks lebih dalam dari teks.
- d. Preprocessing sederhana: Teknik preprocessing yang digunakan masih terbatas pada tahap dasar (tokenisasi, stopwords removal, dan stemming), sehingga belum sepenuhnya menangkap makna konteks dari komentar.
- e. Pengaturan parameter terbatas: Penyesuaian parameter seperti Alpha (Naive Bayes) dan C (SVM) dilakukan secara manual tanpa pendekatan sistematis seperti grid search atau teknik hyperparameter tuning yang lebih canggih.

## 5.3 Saran

Untuk pengembangan penelitian pada masa mendatang, beberapa saran berikut dapat menjadi pertimbangan:

- a. Perluasan dan diversifikasi dataset  
Disarankan menggunakan data dari berbagai platform media sosial, bahasa, atau topik komentar yang berbeda untuk meningkatkan generalisasi model.
- b. Validasi Gender pada tweet dan akun  
Disarankan untuk melakukan validasi gender tidak hanya pada tingkat akun, tetapi juga mempertimbangkan konsistensi perilaku dari beberapa komentar dalam satu akun. Hal ini dapat dilakukan dengan mengumpulkan lebih banyak komentar dari setiap akun atau menerapkan metode verifikasi tambahan, seperti analisis pola bahasa atau interaksi akun, sehingga penentuan gender lebih akurat dan tidak hanya bergantung pada atribut username, foto profil, dan bio.

c. Eksplorasi metode lanjutan

Penelitian selanjutnya dapat mempertimbangkan penggunaan metode seperti LSTM, CNN, atau transformer-based models (seperti BERT) untuk menangkap konteks yang lebih kompleks dalam teks.

d. Peningkatan teknik preprocessing

Penerapan preprocessing dengan menggunakan teknik representasi kata berbasis embedding seperti Word2Vec atau FastText, atau pemanfaatan pre-trained model untuk meningkatkan pemahaman konteks dan makna kata dalam komentar.

e. Optimasi parameter model secara sistematis

Disarankan melakukan tuning parameter menggunakan pendekatan otomatis untuk memperoleh konfigurasi terbaik dan hasil yang lebih optimal dari masing-masing metode tanpa adanya ketergantungan nilai parameter tetap.

## DAFTAR PUSTAKA

- Angelina, D., Hayati, U., & Dwilestari, G. (2023). PENERAPAN METODE SUPPORT VECTOR MACHINE PADA SENTIMEN ANALISIS PENGGUNA TWITTER TERHADAP KONSER KPOP. *KOPERTIP: Jurnal Ilmiah Manajemen Informatika dan Komputer*, VII(01), 14-23.
- Jintawatsakoon, S., & Poonsawat, E. (2023). Gender Classification of Social Network Text Using Natural Language Processing and Machine Learning Approaches. *International Joint Conference on Computer Science and Software Engineering (JCSSE)*, 415-420.
- Magnolia, C., Nurhopipah, A., & Kusuma, B. (2023). Penanganan Imbalanced Dataset untuk Klasifikasi Komentar Program Kampus Merdeka pada Aplikasi Twitter. *Edu Komputika Journal*, 105-113.
- Melhem, W. Y., Abdi, A., & Meziane, F. (2024). Deep Learning Classification of Traffic-Related Tweets: An Advanced Framework Using Deep Learning for Contextual Understanding and Traffic-Related Short Text Classification. *Applied Sciences*, 21.
- Mubarak, A. F., Faisal, R. M., Kartini, D., Nugrahadi, T. D., & Saragih, H. T. (2023). Gender Classification of Twitter Users Using Convolutional Neural Network. *Matrik: Jurnal Manajemen, Teknik Informatika, dan Rekayasa Komputer*, 23(01), 79-92.
- Onikoyi, B., Nnamoko, N., & Korkontzelos, I. (2023). Gender prediction with descriptive textual data using a Machine Learning approach. *NaturalLanguageProcessingJournal*, 1-8.
- Putri, K., & Raharja, A. R. (2023). Implementasi Algoritma Support Vector Machine dalam Klasifikasi Deteksi Depresi dari Postingan pada Media Sosial. *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, 193-202.
- Putri, M. A., Enri, U., & Sari, N. B. (2020). Analisis Algoritma Naive Bayes Classifier untuk Klasifikasi Tweet Pelecehan Seksual dengan #MeToo. *IJCIT (Indonesian Journal on Computer and Information Technology)*, V(2), 126-135.
- Ramli, G. R., & Sibaroni, Y. (2022). Klasifikasi Topik Twitter menggunakan Metode Random Forest dan Fitur Ekspansi Word2Vec. *e-Proceeding of Engineering*, IX(1), 79-92.
- Sa'diah, H., Faisal, R. M., Farmadi, A., Abadi, F., Indriani, F., Alkaff, M., & Abullayev, V. (2024). Gender Classification on Social Media Messages Using fastText-base Feature and Long Short-Term Memory. *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, VI(3), 243-252.
- Styawati, Isnain, R. A., Hendrastuty, N., & Andraini, L. (2021). Comparison of Support Vector

Machine and Naïve Bayes . *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, 6(1), 56-60.

Tang, X., Tian, H., Kong, P., Ezzini, S., Liu, K., Xia, X., . . . Bissyande, T. F. (2024). App review driven collaborative bug finding. *Empirical Software Engineering*, 32.

Vashisth, P., & Meehan, K. (2020). Gender Classification using Twitter Text Data. *31st Irish Signals and Systems Conference (ISSC)*, 1-6.

Zakia, S. A., Indriati, & Marji. (2020). Klasifikasi Jenis Kelamin Pengguna Twitter dengan menggunakan Metode BM25 dan K-Nearest Neighbor (KNN). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, IV(10), 3331-3337.