

ANALISIS PERBANDINGAN NAIVE BAYES DAN SVM DALAM KLASIFIKASI GENDER DI PLATFORM TWITTER

Ridzky Putra Dwitama^{1*}, Irving Vitra Papatungan²

^{1,2}Universitas Islam Indonesia, Indonesia

*e-mail korespondensi: 21523151@students.uii.ac.id

Abstrak: The emergence of social media has generated large volumes of textual data that can be analyzed to understand user behavior. This study presents a comparative analysis of two text classification algorithms, Naive Bayes and Support Vector Machine (SVM), to determine gender from user comments on social media platform X (formerly Twitter). Gender is used as a classification label due to its important role in identifying interaction patterns, content preferences, and user segmentation. The dataset was obtained via web scraping and preprocessed through text cleaning, abbreviation transformation, and TF-IDF-based feature extraction. Various data sizes (1000, 3000, 5000) and split ratios (70:30 and 80:20) were used to evaluate both algorithms. Initial validation used 10-fold Cross Validation to ensure data consistency before the main testing phase. The results show that SVM outperforms Naive Bayes in accuracy, precision, recall, and F1-score on larger datasets, while Naive Bayes performs consistently on smaller datasets. These findings influence the selection of suitable classification methods for analyzing social media comments and hopefully will made contribution to content moderation systems, gender-based sentiment analysis, and gender bias detection.

Kata Kunci: Machine Learning, Classification, Social Media, Naive Bayes, Support Vector Machine

Abstract: Munculnya media sosial telah menghasilkan sejumlah besar data tekstual yang dapat dianalisis untuk memahami perilaku pengguna. Studi ini menyajikan analisis komparatif dari dua algoritma klasifikasi teks, Naive Bayes dan Support Vector Machine (SVM), untuk menentukan gender dari komentar pengguna di platform media sosial X (sebelumnya Twitter). gender digunakan sebagai label klasifikasi karena perannya yang penting dalam mengidentifikasi pola interaksi, preferensi konten, dan segmentasi pengguna. Kumpulan data diperoleh melalui web scraping dan diproses terlebih dahulu melalui pembersihan teks, transformasi singkatan, dan ekstraksi fitur berbasis TF-IDF. Berbagai ukuran data (1000, 3000, 5000) dan rasio split (70:30 dan 80:20) digunakan untuk mengevaluasi kedua algoritma tersebut. Validasi awal menggunakan 10-fold Cross Validation untuk memastikan konsistensi data sebelum fase pengujian utama. Hasilnya menunjukkan bahwa SVM mengungguli Naive Bayes dalam accuracy, precision, recall, dan F1-score pada dataset yang lebih besar, sementara Naive Bayes terus mempertahankan kualitasnya pada dataset yang lebih kecil. sementara Naive Bayes bekerja secara konsisten pada kumpulan data yang lebih kecil. Penelitian ini mempengaruhi pemilihan metode klasifikasi yang sesuai untuk menganalisis komentar media sosial dan diharapkan dapat memberikan kontribusi pada sistem moderasi konten, analisis sentimen berbasis gender, dan deteksi bias gender.

Keywords: Pembelajaran Mesin, Klasifikasi, Media Sosial, Naive Bayes, Support Vector Machine

PENDAHULUAN

Perkembangan dalam bidang teknologi informasi dan komunikasi pada masa kini telah mendorong peningkatan yang signifikan dalam jumlah pelanggan yang berminat untuk mengakses media sosial. Media sosial tidak hanya digunakan sebagai sarana hiburan, tetapi juga telah berkembang menjadi alat penting dalam komunikasi sosial, pendidikan, serta strategi pemasaran di berbagai sektor (Nursansini & Armiani, 2023; Yuanita Dwi Hartanto et al., 2023). Platform X (sebelumnya dikenal sebagai Twitter) merupakan salah satu media sosial utama yang banyak digunakan untuk berbagi perspektif, pengalaman, dan merespons isu-isu publik secara cepat dan luas. Berbeda dengan Instagram atau Facebook yang lebih berorientasi pada visual dan lebih tertutup, X (Twitter) dipilih karena karakteristik utamanya yang berbasis pada teks, sehingga lebih sesuai dengan fokus penelitian ini yang mengklasifikasikan komentar pengguna dalam bentuk tulisan, serta lebih menyediakan data teks yang bersifat publik dan lebih mudah diakses untuk penelitian dan analisis bahasa. Berdasarkan data dari We Are Social & Metawater 2025, pengguna media sosial twitter di dunia mencapai 586 juta pengguna dengan Indonesia menduduki peringkat ke-4 dengan 25,16 juta pengguna. Besarnya volume komentar yang dihasilkan membuka peluang untuk menganalisis perilaku digital, termasuk identifikasi demografis seperti jenis kelamin. Namun, kompleksitas bahasa yang digunakan menjadi tantangan tersendiri dalam proses analisis dan klasifikasi.

Relevansi klasifikasi gender berdasarkan komentar di media sosial, khususnya platform X (sebelumnya Twitter), meningkat dalam berbagai konteks, seperti personalisasi layanan, penelitian tentang *user behavior*, dan moderasi konten digital. Namun, metode ini terhambat oleh sejumlah tantangan signifikan. Prosedur ekstraksi teks informasi memiliki tantangan tersendiri karena beragamnya bahasa, penggunaan kata-kata informal, singkatan, dan emoji. Selain itu, konteks komentar media sosial sering kali ambigu, dan biasanya singkat dan tidak teratur, yang mempersulit interpretasinya yang akurat. Keakuratan model juga terganggu oleh distribusi data yang tidak teratur antara jenis kelamin jika tidak ditangani dengan benar. Untuk menangani tantangan teks yang ambigu, pendek, dan tidak baku, penelitian ini menerapkan tahapan *preprocessing* yang meliputi normalisasi kata tidak formal, penghapusan simbol, emoji, karakter yang tidak relevan dan mengubah singkatan. Selain itu, diterapkan teknik TF-IDF untuk mengekstraksi fitur penting dari teks, sehingga dapat membantu merepresentasikan

informasi penting dari teks yang strukturnya tidak konsisten dan konteks terbatas. Dalam menjunjung tinggi integritas dalam penelitian, data dalam penelitian ini bersumber dari akun publik dan menghindari pengambilan informasi sensitif dari akun pengguna. Proses anotasi atau *labelling* gender dilakukan secara manual guna menghindari potensi bias serta menjaga privasi pengguna. Tantangan-tantangan ini memerlukan pengembangan metode klasifikasi yang dapat memahami dan menyesuaikan dengan karakteristik unik teks media sosial. Akibatnya, studi perbandingan yang komprehensif diperlukan untuk mengidentifikasi teknik klasifikasi yang paling efektif dan dapat diandalkan untuk mengatasi berbagai tantangan ini dalam konteks klasifikasi gender.

Pemilihan teknik *Naive Bayes* dan *Support Vector Machine* (SVM) dalam penelitian ini didasarkan pada kesesuaian fitur masing-masing algoritma dengan masalah klasifikasi gender berdasarkan komentar teks pada sumber media sosial. *Naive Bayes* diakui karena kemampuannya dalam mengelola teks pendek dan distribusi data yang tidak seimbang secara efektif dengan menggunakan pendekatan probabilistik yang mudah dipahami dan ampuh. Di sisi lain, SVM mampu menetapkan batasan optimal di area fitur yang rumit dan mampu mengelola data berdimensi tinggi, sehingga cocok untuk representasi struktur linguistik berbagai komentar media sosial. Meskipun terdapat algoritma lain seperti *Random Forest*, CNN yang banyak dipakai dalam klasifikasi teks, Penelitian ini memilih *Naive Bayes* dan SVM karena efisien menangani teks pendek, dan sesuai untuk literatur yang dikaji dengan data terbatas. Tujuan dari penelitian ini adalah untuk memberikan pemahaman yang komprehensif tentang efektivitas masing-masing metode dalam konteks klasifikasi teks dengan membandingkan dua pendekatan yang secara konseptual berbeda. Pengukuran *accuracy*, *precision*, *recall*, dan *F1-score* diimplementasikan untuk menilai kinerja kedua algoritma secara objektif dan komprehensif.

Beberapa penelitian sebelumnya telah menyelidiki klasifikasi gender berbasis teks menggunakan berbagai teknik pembelajaran mesin, seperti SVM dan *naive bayes*. Penelitian yang dilakukan oleh Naufal et al. (2023) membandingkan klasifikasi *cyberbullying* di media sosial menggunakan *Naive Bayes*, SVM, dan *Random Forest*. Hasilnya menunjukkan bahwa SVM adalah yang paling efektif dalam menghasilkan kinerja berkualitas tinggi untuk kumpulan data besar. Penelitian lain yang dilakukan oleh Mubarok et al. (2023) mencapai akurasi tertinggi sebesar 94,50% untuk klasifikasi gender

menggunakan data Twitter, memanfaatkan teknik CNN dan word2vec. Ini dicapai dengan menggabungkan data tweet dan deskripsi. Namun, beberapa penelitian yang secara eksplisit membandingkan kinerja kedua pendekatan pada kumpulan data komentar X (Twitter) dalam kondisi volume data dan rasio pembagian data yang bervariasi masih kurang. Ini menandakan bahwa penelitian lanjutan diperlukan.

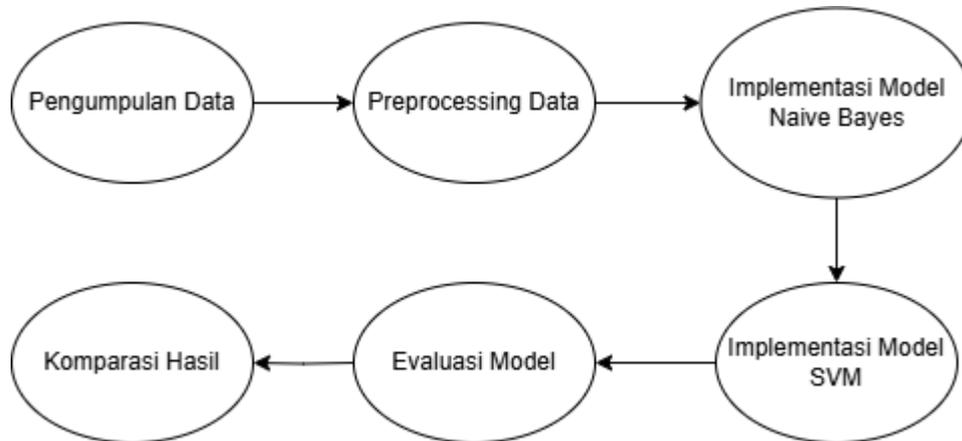
Selain skenario klasifikasi gender, *Naive Bayes* dan SVM serta metode lainnya (CNN, KNN, atau Random Forest) telah banyak digunakan dalam berbagai studi kategorisasi teks lainnya. Menurut penelitian yang dilakukan oleh Iqbal et al. (2022) algoritma *Naive Bayes* dapat diterapkan dalam berbagai skenario klasifikasi, seperti analisis data serangan jaringan komputer. Analisis sentimen kasus K-POP dilakukan dengan menggunakan pendekatan SVM dalam studi lain yang dilakukan oleh Dessy Angelina et al. (2023) melakukan analisis sentimen dengan kasus K-POP menggunakan metode SVM dan *tools RapidMiner*. Dengan menggunakan empat algoritma yaitu *Decision Tree*, *Random Forest*, *Naive Bayes*, dan KNN Rahayu et al. (2023) melakukan penelitian untuk mengklasifikasikan tweet pengguna yang merupakan responden. *Random Forest* mencapai akurasi tertinggi sebesar 96%, sedangkan kinerja *Naive Bayes* lebih rendah daripada teknik lainnya. Meskipun sering digunakan dalam klasifikasi teks, kemanjuran *Naive Bayes* dan SVM dipengaruhi secara signifikan oleh konteks dan fitur data.

Penelitian ini menyelidiki tantangan dan peluang yang terkait dengan metode *naive bayes* dan SVM yang saling bertentangan dalam klasifikasi gender dari komentar di platform X (Twitter). Selain membandingkan performa kedua metode, penelitian ini mengevaluasi pengaruh perbedaan jumlah data, *hyperparameter* masing-masing metode serta variasi rasio pembagian data untuk mengidentifikasi konsistensi kinerja model klasifikasi. Pemilihan skenario ini disesuaikan untuk mencerminkan skenario pelatihan pada data berskala kecil, menengah, dan tinggi serta mempertimbangkan efisiensi penggunaan sumber daya komputasi. Analisis ini akan membantu dalam pengembangan sistem yang mampu menganalisis teks di media sosial dan akan memberikan kontribusi yang berharga bagi bidang klasifikasi demografis melalui penerapan *machine learning*.

METODE

Dalam artikel ini, kinerja algoritma model *Naive Bayes* dan *Support Vector Machine* (SVM) dalam klasifikasi gender dianalisis menggunakan pendekatan kuantitatif

dengan metode komparatif, seperti yang ditunjukkan oleh komentar pengguna di platform X (Twitter). Tahapan utama proyek ini meliputi pengumpulan data, *pre-processing* data, pengembangan model klasifikasi, evaluasi kinerja, dan analisis komparatif.



Gambar 1. Alur Diagram Metodologi Analisis

Pengumpulan Data

Data untuk penelitian ini diperoleh melalui teknik *tweet-harvest*, yang merupakan metode web scraping pada platform X (Twitter) yang menggunakan kata kunci dan rentang tanggal tertentu. ID pengguna, tanggal tweet, topik, nama pengguna, dan komentar merupakan data yang telah dikumpulkan. Identifikasi gender dilakukan secara manual sesuai dengan publik akun pengguna, yang meliputi nama, foto profil, dan deskripsi akun, mengacu pada penelitian yang dilakukan Sa'diah et al. (2024) yang menggunakan kombinasi informasi profil dan konten tweet. Prosedur pelabelan diselesaikan oleh dua anotator yang berbeda untuk meningkatkan keandalan dan keakuratan data. Kumpulan data akhir hanya terdiri dari komentar yang secara jelas dikaitkan dengan gender. Kumpulan data tersebut kemudian dibersihkan dari data yang tidak memenuhi kriteria validitas. Tindakan ini diambil untuk memastikan bahwa data yang digunakan dalam pelatihan model klasifikasi gender memiliki kualitas, relevansi, dan konsistensi yang tinggi.

Pre-processing

Pre-processing teks merupakan langkah awal untuk memastikan data teks bebas dari gangguan sebelum dianalisis lebih lanjut (Adha et al., 2020). Tahapan *pre-processing* bertujuan untuk meningkatkan kualitas teks sebelum dilakukan pemodelan. Proses ini dilakukan dalam beberapa langkah utama. Pertama, *case folding* mengubah semua

karakter menjadi huruf kecil untuk mencegah adanya pengulangan kata karena perbedaan dalam penulisan huruf kapital. Kedua, tokenisasi memecah teks menjadi kata-kata tunggal supaya lebih mudah dianalisis. Ketiga, penghapusan *stopword* dilakukan untuk menghilangkan kata-kata umum yang tidak memiliki kontribusi penting terhadap klasifikasi, seperti “dan” atau “yang”. Selanjutnya, dilakukan normalisasi terhadap kata-kata tidak baku atau slang menjadi bentuk formal, misalnya “sy” menjadi “saya”. Proses berikutnya adalah *stemming*, yaitu pengembalian kata ke bentuk dasarnya menggunakan algoritma Bahasa Indonesia agar pola bahasa lebih mudah dikenali oleh model. Terakhir, setiap komentar dihitung jumlah katanya, dan hanya teks dengan panjang antara 10 hingga 50 kata yang dipertahankan untuk memastikan kelayakan analisis dan konsistensi dalam dataset.

Feature Extraction

Teks yang telah dipreprocessing sebelumnya diubah menjadi representasi numerik menggunakan metode TF-IDF (*Term Frequency–Inverse Document Frequency*). Metode ini menetapkan nilai yang lebih tinggi untuk istilah yang lebih informatif dengan memberi bobot pada setiap kata dalam kaitannya dengan frekuensinya dalam komentar yang relatif terhadap seluruh korpus. Ekstraksi fitur parameter n-gram (1,2) digunakan untuk menangkap kata tunggal dan pasangan kata. Jumlah fitur dibatasi hingga 5000 untuk menjaga efisiensi. Bentuk matriks numerik dari transformasi TF-IDF diubah menjadi DataFrame untuk tujuan berfungsi sebagai input bagi proses pelatihan model klasifikasi.

Data Split

Pembagian dataset dalam penelitian ini menggunakan strategi rasio ganda 80:20 dan 70:30 untuk data pelatihan dan pengujian, mengacu pada penelitian yang dilakukan oleh (Putri et al., 2023). Untuk mencegah bias kategorisasi, teknik stratifikasi digunakan untuk memastikan distribusi gender yang adil di kedua kelompok data. Untuk menyelidiki dampak volume data pada kinerja model, eksperimen dilakukan dengan tiga ukuran dataset yang berbeda yaitu 1000, 3000, dan 5000 komentar. Langkah-langkah perlindungan terjadi *data leakage* diimplementasikan dengan bantuan pre-processing terpisah dan fungsi `train_test_split` dari *library* sklearn yang memanfaatkan opsi `stratify`. Pendekatan ini bertujuan untuk menyeimbangkan kelas dan mengurangi risiko *overfitting* untuk hasil klasifikasi yang lebih unggul dan representatif.

Pembangunan Model

Model klasifikasi gender diimplementasikan menggunakan dua algoritma (*Support Vector Machine* dan *Multinomial Naive Bayes*). Model *naive bayes* menghitung probabilitas prior setiap kelas gender dan probabilitas kondisional untuk setiap fitur teks saat diterapkan menggunakan pendekatan probabilistik berdasarkan *teorema Bayes*. Analisis *smoothing* pada akurasi klasifikasi digunakan untuk mengoptimalkan kinerja model dengan memvariasikan *hyperparameter alpha* (0,1, 0,5, 1,0). Untuk mengidentifikasi pola distribusi leksikal yang mencerminkan ciri gender dalam teks komentar, representasi TF-IDF dari pustaka yang telah diproses sebelumnya digunakan selama prosedur pelatihan.

Model SVM diimplementasikan oleh kernel linier yang dirancang untuk mengidentifikasi hiperbidang optimal untuk memaksimalkan margin pemisah antara kelas gender melalui formulasi matematika. Parameter C berfungsi sebagai pengatur yang menyeimbangkan pengoptimalan lebar margin dan minimalisasi kesalahan klasifikasi untuk mencegah *overfitting* dan *underfitting*. Pemilihan kernel linear bergantung pada karakteristik data teks, yang biasanya menunjukkan distribusi fitur yang dapat dipisahkan secara linear dalam ruang vektor. Konstruksi model SVM bertujuan untuk mengoptimalkan fungsi objektif sambil mematuhi batasan setiap set data pelatihan, sehingga menghasilkan model klasifikasi gender dengan tingkat generalisasi tertinggi.

Evaluasi Performa

Performa model dievaluasi menggunakan empat kriteria atau metrik utama yaitu *precision*, *recall*, *accuracy*, dan *F1-score*. *F1-score* adalah rata-rata harmonis presisi dan perolehan kembali, sedangkan *accuracy* adalah persentase prediksi yang benar terhadap semua prediksi yang dibuat. *Precision* adalah *accuracy* prediksi gender, dan *recall* adalah sensitivitas model dalam mengidentifikasi gender tertentu. Implementasi confusion matrix memungkinkan identifikasi bias prediktif model terhadap kelas gender tertentu dengan memfasilitasi analisis terperinci tentang distribusi kesalahan klasifikasi di empat kategori yang meliputi True Positive, True Negative, False Positive, dan False Negative. Pendekatan 5-Fold Cross Validation diimplementasikan untuk memastikan bahwa hasilnya lebih representatif dan konsisten.

Komparasi Hasil

Setelah proses evaluasi performa, dilakukan perbandingan hasil dari kedua model naive bayes dan SVM. Hasil dari semua metrik dalam setiap skenario volume data, pengaturan hyperparameter model, dan rasio pembagian data menjadi dasar perbandingan. Tujuan dari analisis perbandingan ini adalah mengidentifikasi faktor data yang memengaruhi kinerja setiap algoritma dan untuk mengidentifikasi algoritma yang lebih efektif untuk mengklasifikasikan gender berdasarkan komentar media sosial. Hasilnya akan disajikan untuk memudahkan pemahaman setelah evaluasi. Selain confusion matrix, dua jenis grafik bermanfaat untuk visualisasi yaitu grouped bar chart dan learning curve. Grafik ini digunakan untuk menganalisis pembelajaran guna mengidentifikasi bias atau overfitting dalam model. Analisis Komparatif ini berpotensi menjadi sumber daya yang berharga untuk interpretasi komentar di media sosial dan aplikasi lain, seperti analisis sentimen di media sosial dan deteksi bias gender.

HASIL DAN PEMBAHASAN

Hasil

Dataset

Data yang diperoleh dalam penelitian ini dikumpulkan dengan menggunakan pendekatan web scraping dari situs media sosial X (Twitter), dengan penekanan pada komentar-komentar berbahasa Indonesia. Setelah itu, setiap komentar diberi label gender pengguna, yang ditentukan dengan mencari informasi personal pada setiap profil pengguna. Kumpulan data bersih yang terkumpul sejumlah 5000 komentar berlabel gender diperoleh dengan membuang spam dan komentar-komentar yang tidak relevan setelah pemilihan beserta nama pengguna yang tidak sesuai dengan nama pengguna seperti instansi atau perusahaan.

Pre-processing

Untuk meningkatkan kualitas teks, dilakukan Pre-processing pada data yang dikumpulkan. Metode ini meliputi *stemming* untuk mengembalikan kata ke bentuk dasarnya, tokenisasi untuk memecah kalimat menjadi kata per kata, penghapusan stopword untuk menghilangkan kata yang tidak diperlukan, *case folding* untuk standardisasi huruf, dan menormalkan kata-kata yang tidak baku beserta menghapus singkatan pada beberapa kata dalam komentar. Teknik TF-IDF (*Term Frequency-Inverse Document Frequency*) digunakan untuk merepresentasikan teks sebagai vektor numerik

untuk ekstraksi fitur, yang dilakukan setelah proses *preprocessing*. Selain itu, pemisahan data untuk pengujian dan pelatihan terbagi menjadi dua skenario rasio (70:30 dan 80:20), dan jumlah data divariasikan hingga 1000, 3000, dan 5000 komentar untuk memeriksa dampak ukuran dataset pada eksekusi model. Tabel 1 menyediakan contoh representasi teks komentar yang telah dibersihkan dan menampilkan hasil dari langkah *pre-processing* ini.

Tabel 1. Contoh Hasil Teks Pre-processing

Teks komentar sebelum Pre-processing	Teks Komentar setelah Pre-processing
Selamat berpulang ke negeri abadi Eyang Titiek Puspa turut belasungkawa atas berita duka ini.	selamat berpulang negeri abadi eyang titiek puspa belasungkawa berita duka
@idextratime Okelah kita kasih kesempatan sekali lagi di match vs bahrain di match ini 3 poin harga mati kalau gak bisa 3 poin di match ini berarti #KluivertOut #ErickThohirOut gak bisa ditawar lagi	Oke lah kita kasih kesempatan match v bahrain match poin harga mati tidak poin match tidak ditawar

Evaluasi Model

Penelitian ini mengevaluasi klasifikasi gender berdasarkan komentar pengguna media sosial menggunakan dua model klasifikasi yaitu *naive bayes* dan *Support Vector Machine* (SVM). Evaluasi dilakukan dengan menguji berbagai kombinasi jumlah data (1000, 3000, 5000), rasio pembagian data (70:30 dan 80:20), dan nilai *hyperparameter* untuk setiap algoritma. Agar dapat memberikan gambaran menyeluruh mengenai bagaimana performa klasifikasi setiap model, empat kriteria atau matriks evaluasi utama yaitu *accuracy*, *precision*, *recall*, dan *F1-score* digunakan untuk menilai performa model. Hasil evaluasi ditampilkan secara terpisah untuk setiap algoritme.

Naive Bayes

Tabel 2. Hasil Evaluasi Model Naive Bayes

Rasio Data	Jumlah Data	Hyperparameter (Alpha)	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
70:30	1000	0.1	81.7	81.8	81.7	81.7
		0.5	83	83.1	83	83
		1.0	84	84.1	84	84
	3000	0.1	82.5	82.5	82.5	82.5
		0.5	84	84	84	83.9
		1.0	84.5	84.5	84.5	84.5
	5000	0.1	82.4	82.4	82.4	82.4
		0.5	83.1	83.1	83.1	83.1
		1.0	83.8	83.7	83.8	83.7
80:20	1000	0.1	81	81.3	81	81
		0.5	82.5	82.7	82.5	82.5

Rasio Data	Jumlah Data	Hyperparameter (Alpha)	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
	3000	1.0	83.5	83.7	83.5	83.5
		0.1	83	82.9	83	82.9
		0.5	83.8	83.8	83.8	83.8
	5000	1.0	83.8	83.9	83.8	83.7
		0.1	82	81.9	82	82
		0.5	83.8	84	83.8	84
		1.0	84.2	84.3	84.2	84.2

Pengujian yang dilakukan pada skenario tiga ukuran data dan dua rasio split, hasil evaluasi algoritma *naive bayes* dengan tiga *hyperparameter alpha* yaitu 0,1, 0,5, dan 1,0 ditampilkan pada Tabel 1. Secara umum, model dengan $\alpha = 1,0$ menunjukkan kinerja paling konsisten di semua metrik dengan hasil evaluasi yang cukup tinggi. Model *naive bayes* terbaik ditemukan dalam skenario data 3000 dengan $\alpha = 1,0$ dan rasio 70:30, menghasilkan *accuracy* 84,5%, *precision* 84,5%, *recall* 84,5%, dan *F1-score* 84,5%. Situasi lain yang juga berkinerja cukup baik adalah pada ukuran data 1000 dengan rasio 70:30 dan $\alpha = 1,0$, di mana semua metrik evaluasi tercatat pada 84,5%.

SVM (Support Vector Machine)

Tabel 2. Hasil Evaluasi Model SVM (*Support Vector Machine*)

Rasio Data	Jumlah Data	Hyperparameter (C)	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
70:30	1000	0.1	82	84	82	81.7
		1.0	86.7	86.8	86.7	86.7
		10	83.7	83.8	83.7	83.7
	3000	0.1	83.2	86	83.2	82.7
		1.0	86.7	86.7	86.7	86.7
		10	85.2	85.2	85.2	85.2
	5000	0.1	87.2	87.8	87.2	87.1
		1.0	86.6	86.6	86.5	86.5
		10	82.8	82.7	82.8	82.7
80:20	1000	0.1	77.1	80.5	77.1	76.4
		1.0	86.5	86.8	86.5	86.5
		10	82.5	82.9	82.5	82.5
	3000	0.1	84.8	86.7	84.8	84.5
		1.0	87	87	87	86.9
		10	85.1	85.1	85.1	85.1
	5000	0.1	87.6	88	87.6	87.5
		1.0	86.5	86.5	86.5	86.4
		10	82.2	82.2	82.2	82.1

Kinerja SVM menggunakan tiga variasi parameter C (0,1, 1,0, dan 10) dalam skenario ukuran data dan rasio split yang sama ditunjukkan pada Tabel 2. Temuan

menunjukkan bahwa pada keempat kriteria penilaian $C = 0,1$ secara teratur menghasilkan skor tinggi. Dengan rasio split 80:20 dan $C = 0,1$, model terbaik diperoleh dalam skenario ukuran data 5000, menghasilkan *accuracy* 87,6%, *precision* 88,0%, *recall* 87,6%, dan *F1-score* 87,5%. Lebih lanjut, skenario data 5000 dengan rasio split 70:30 dan $C = 0,1$ juga menghasilkan hasil yang cukup kompetitif, dengan semua metrik mendekati 88%.

Komparasi Model Naive Bayes dan SVM (*Support Vector Machine*)

Untuk memberikan perbandingan langsung antara kedua algoritma, Tabel 3 menyajikan satu hasil terbaik dari masing-masing model berdasarkan seluruh skenario pengujian. Pemilihan model dilakukan dengan mempertimbangkan performa tertinggi dan paling seimbang pada empat kriteria atau matriks evaluasi utama, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Pendekatan ini bertujuan untuk menyoroti kekuatan utama dari masing-masing algoritma dalam kondisi optimalnya.

Tabel 3. Komparasi Hasil Terbaik Naive Bayes dan SVM

Model	Rasio Data	Jumlah Data	Hyperparameter	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)
Naive Bayes	70:30	3000	Alpha = 1.0	84.5	84.5	84.5	84.5
SVM	80:20	5000	C = 0.1	87.6	88	87.6	87.7

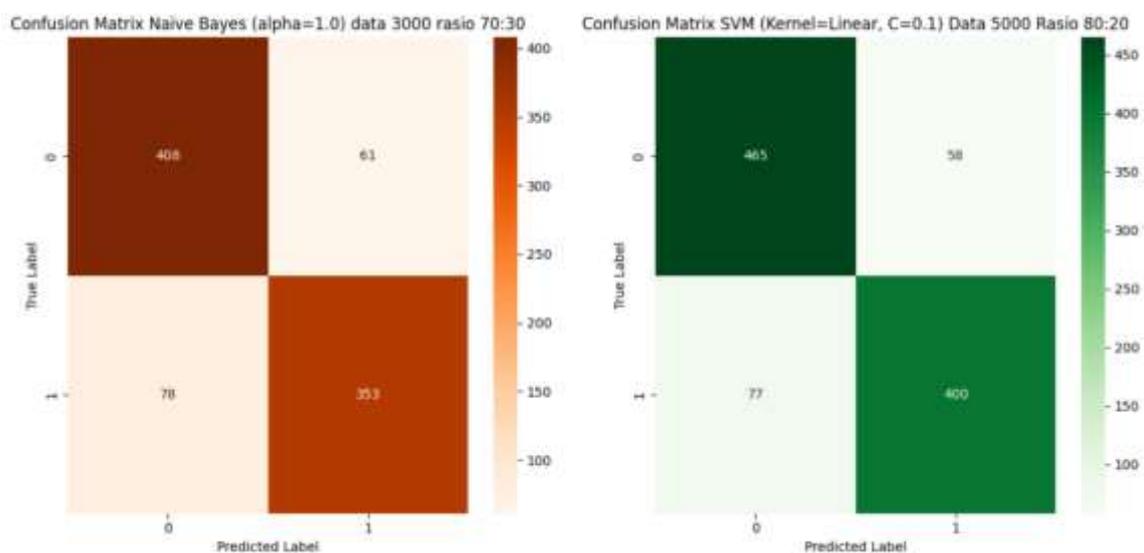
Model *Naive Bayes* menunjukkan kinerja terbaik di antara semua metrik evaluasi sebesar 84,5% berdasarkan hasil evaluasi yang ditunjukkan pada Tabel 3 dalam skenario volume data 3000, rasio split 70:30, dan nilai alpha 1,0. Model SVM dengan parameter $C = 0,1$, di sisi lain, berkinerja terbaik dalam skenario volume data 5000 dan rasio 80:20, menghasilkan skor F1 sebesar 87,7% dan akurasi tertinggi sebesar 88,0%. Temuan ini menyiratkan bahwa SVM memiliki manfaat dalam menangani data yang besar dan rumit dengan tingkat akurasi dan kemampuan klasifikasi yang lebih tinggi secara umum. Sebaliknya, terutama pada data berukuran sedang, *Naive Bayes* terus menunjukkan kinerja yang konsisten dan kompetitif, oleh karena itu memberikan opsi yang efisien dalam situasi klasifikasi dengan sumber daya terbatas. Proses visualisasi dan diskusi lebih lanjut untuk mengeksplorasi fitur dan kinerja setiap algoritma kemudian didasarkan pada dua model terbaik ini.

Visualisasi

Untuk memudahkan pemahaman kinerja kedua model, visualisasi dilakukan dalam bentuk *grouped bar chart*, *confusion matrix*, dan *learning curve*. *Grouped bar chart* digunakan untuk menggambarkan perbandingan empat metrik evaluasi utama

antara model Naive Bayes dan SVM dalam skenario terbaiknya masing-masing. Selanjutnya, *confusion matrix* disajikan untuk menampilkan distribusi klasifikasi yang benar dan salah dari setiap model, sedangkan *learning curve* digunakan untuk mengevaluasi tren kinerja model terhadap peningkatan jumlah data pelatihan. Ketiga visualisasi ini memberikan gambaran menyeluruh tentang kekuatan dan keterbatasan masing-masing algoritma dalam tugas klasifikasi gender berdasarkan komentar media sosial.

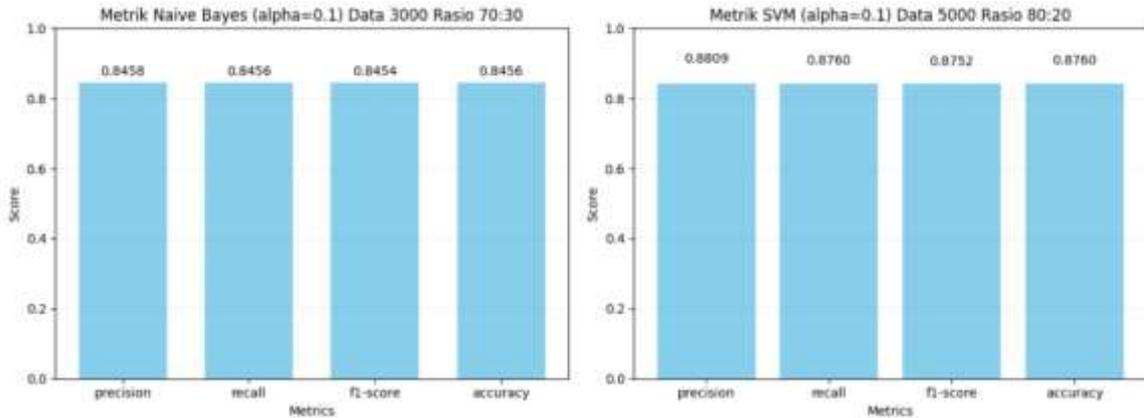
Confusion Matrix



Gambar 2. Confusion Matrix Model Terbaik Naive Bayes dan SVM

Confusion Matrix dari dua model terbaik ditunjukkan pada Gambar 2. Yang ditunjukkan di sebelah kiri adalah matriks kebingungan model Naive Bayes ($\alpha = 1.0$) dengan 3000 data dan rasio 70:30; model SVM ($C = 0.1$) dengan 5000 data dan rasio 80:20 ditunjukkan di sebelah kanan. *Naive Bayes* menghasilkan 408 *True Negative*, 353 *True Positive*, 61 *False Positive*, dan 78 *False Negative* dalam urutan tersebut. SVM, di sisi lain, menghasilkan 465 *true negative*, 400 *true positive*, 58 *false positive*, dan 77 *false negative*. SVM tampaknya memiliki kinerja klasifikasi yang lebih baik tergantung pada temuan-temuan ini dengan jumlah kesalahan yang agak lebih rendah daripada *Naive Bayes*. Meskipun perbedaannya tidak terlalu signifikan, ini mengonfirmasi skor F1 dan kinerja recall SVM yang agak lebih besar. Grafik ini menawarkan bukti yang jelas tentang kapasitas setiap model untuk membedakan kedua kategori gender secara setara.

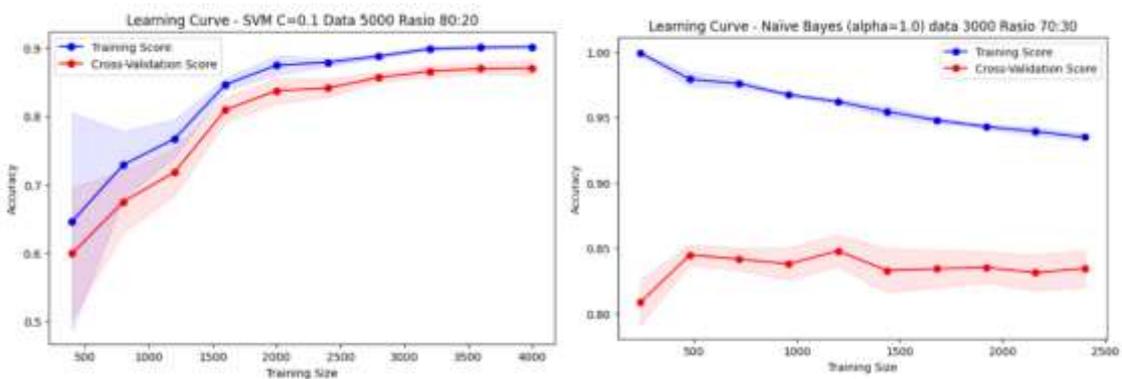
Grouped Bar Chart



Gambar 3. Grouped Bar Chart Model Terbaik Naive Bayes dan SVM

Gambar 3 menampilkan Grouped Bar Chart yang membandingkan kinerja model naive bayes dan Support Vector Machine (SVM) dalam kasus klasifikasi teks. dengan konfigurasi hyperparameter $\alpha = 0,1$. Dengan menggunakan 3000 data dalam rasio 70:30, model naive bayes menghasilkan *F1-score*, *precision*, *recall*, dan *accuracy* sebesar 0.845. Sebanyak 5000 titik data dan rasio 80:20 digunakan untuk menghasilkan *precision* 0,8809, *recall* 0,8760, *F1-score* 0,8752, dan *accuracy* 0,8760 oleh model SVM. SVM mengungguli *naive bayes* dalam setiap metrik. Hal ini menunjukkan bahwa kinerja klasifikasi dapat ditingkatkan dengan meningkatkan volume data dan menerapkan rasio pemisahan yang optimal. Hal ini juga menunjukkan bahwa SVM lebih dapat diandalkan dalam lingkungan pengujian ini.

Learning Curve



Gambar 4. Learning Curve Matrix Model Terbaik Naive Bayes dan SVM

Gambar 4 menampilkan learning curve dari model SVM (kiri) dan Naive Bayes (kanan) pada skenario terbaik masing-masing. untuk model SVM (kiri) dan Naive Bayes (kanan) dalam skenario kasus terbaiknya masing-masing. Dengan $C = 0,1$ dan 5000 data

(rasio 80:20), Curve model SVM menunjukkan peningkatan akurasi yang stabil pada data pelatihan dan validasi saat ukuran data meningkat, dengan celah yang terus menyempit, yang menunjukkan bahwa model dapat digeneralisasi dengan cukup baik. Kurva pembelajaran Naive Bayes ($\alpha = 1,0$) pada 3000 data (rasio 70:30) menunjukkan learning curve yang menurun secara bertahap sementara curve validasi tetap cukup stabil. Ini menunjukkan bahwa model *Naive Bayes* bekerja secara konsisten sejak awal, meskipun tidak menunjukkan peningkatan kinerja yang signifikan seperti SVM saat ukuran data meningkat. Perbedaan pola ini menunjukkan bahwa SVM lebih baik terhadap kuantitas data yang tinggi, sedangkan *Naive Bayes* bekerja lebih baik pada data sedang dengan efisiensi pelatihan yang utuh.

Pembahasan

Hasil penelitian mengindikasikan bahwa algoritma SVM (*Support Vector Machine*) cenderung menunjukkan kinerja yang lebih unggul dibandingkan *Naive Bayes* pada dataset yang besar. Pada dataset dengan 5000 komentar dan rasio 80:20, SVM dengan parameter $C = 0.1$ mencatatkan *accuracy* sebesar 87,6%, *precision* 88%, *recall* 87,6% dan *F1-score* 87,7%, lebih tinggi daripada *Naive Bayes* yang keseluruhan matriksnya mendapat hasil sebesar 84,5% (dengan $\alpha=1.0$) pada jumlah data lebih kecil dan rasio yang berbeda. Hal ini menunjukkan bahwa SVM lebih efisien dalam mengelola data yang besar dan kompleks karena kemampuannya dalam membentuk *hyperplane* yang optimal pada ruang fitur berdimensi tinggi. Sebaliknya, pada dataset yang lebih kecil hingga menengah (1000 dan 3000 komentar), perbedaan kinerja antara *Naive Bayes* dan SVM relatif kecil. Pada rasio 70:30, *Naive Bayes* dengan $\alpha = 1,0$ dengan data 3000 menunjukkan kinerja yang kompetitif dengan akurasi 84,5%, sedangkan SVM dengan $C = 1,0$ pada data 5000 mencapai 87,6%. Hal ini konsisten dengan sifat *Naive Bayes* yang cepat dan sederhana sehingga sangat efisien untuk kumpulan data yang lebih kecil dan tidak memerlukan pemisahan yang rumit antara kelas.

Penelitian yang dilakukan oleh Naufal et al. (2023) mendukung temuan ini, yang menunjukkan bahwa SVM berkinerja terbaik dalam kategorisasi teks berbasis komentar di situs media sosial. Pendukung lain yaitu penelitian oleh Aysha et al. (2021) juga mendukung hasil ini dengan menunjukkan bahwa meskipun kinerja *Naive Bayes* menurun seiring dengan kompleksitas data, ia lebih stabil dan efisien pada kumpulan data kecil. Hasil ini mengonfirmasi pengetahuan bahwa pilihan algoritme klasifikasi harus

memperhitungkan tujuan aplikasi dan ciri data. *Naive Bayes* tetap menjadi opsi terbaik untuk proses klasifikasi cepat dan kumpulan data kecil. Pada kumpulan data besar dan rumit, SVM berkinerja lebih baik untuk studi menyeluruh meskipun demikian.

SIMPULAN

Penelitian ini menggunakan metode komparatif untuk mengevaluasi kinerja model *Naive Bayes* dan *Support Vector Machine* (SVM) dalam klasifikasi gender, seperti yang ditunjukkan oleh komentar pengguna di platform media sosial. Penelitian ini secara efektif menggambarkan perbedaan dalam kemandirian antara kedua metodologi melalui pengumpulan data, *pre-processing* teks, *feature extraction* TF-IDF, data split, implementasi model klasifikasi, dan evaluasi performa. Sementara *Naive Bayes* lebih efisien dalam pelatihan dan menunjukkan kinerja yang konsisten pada kumpulan data sedang, dengan akurasi maksimum 84,5% pada pemisahan data 70:30 dan alfa = 1,0, SVM mengungguli *Naive Bayes* pada kumpulan data besar dengan skor F1-score 87,7% dan akurasi 87,6% pada pemisahan data 80:20 dan parameter C = 0,1. Hasil ini menunjukkan bahwa klasifikasi gender dari komentar media sosial tidak hanya meningkatkan ketepatan prediksi teknis tetapi juga memfasilitasi pengembangan penelitian sosial digital, analisis perilaku pengguna, dan sistem personalisasi layanan. Kompleksitas model dan karakteristik data yang digunakan harus dipertimbangkan saat memilih algoritma klasifikasi, selain tingkat akurasi. Kesimpulan bahwa SVM lebih adaptif terhadap peningkatan ukuran kumpulan data daripada *Naive Bayes* didukung oleh visualisasi kurva pembelajaran, yang menunjukkan peningkatan yang lebih signifikan dalam kinerja SVM saat data ditambahkan. Kesimpulan ini didukung oleh evaluasi metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Secara aplikatif, algoritma *Naive Bayes* banyak diimplementasikan dalam berbagai kasus seperti deteksi spam, analisis sentimen, dan analisis opini pelanggan, terutama dalam konteks komputasi ringan. Di sisi lain, SVM kerap digunakan dalam aplikasi yang memerlukan akurasi tinggi dan fitur kompleks, seperti deteksi penipuan, pengenalan wajah, serta klasifikasi teks dengan dimensi data yang besar. Meskipun demikian, penelitian ini memiliki keterbatasan pada skala data yang digunakan, yang disesuaikan dengan kapasitas dan jangkauan studi. Akibatnya, direkomendasikan agar penelitian di masa mendatang memperluas pengumpulan data ke berbagai platform, menggunakan teknik pembelajaran mendalam seperti LSTM atau

BERT, dan mengeksplorasi strategi klasifikasi berbasis konteks untuk meningkatkan generalisasi dan akurasi model.

DAFTAR RUJUKAN

- Adha, T., Putri, M., Enri, U., & Sari, B. N. (2020). IJCIT (Indonesian Journal on Computer and Information Technology) Analisis Algoritma Naive Bayes Classifier untuk Klasifikasi Tweet Pelecehan Seksual dengan #MeToo. In *IJCIT (Indonesian Journal on Computer and Information Technology)* (Vol. 5, Issue 2). <https://doi.org/https://doi.org/10.31294/ijcit.v5i2.8636>
- Aysha, A., Syed Meeral, M. K., & Bushra, K. M. (2021). A comparative study of detection and classification of emotions on social media using SVM and Naïve bayes techniques. *Advances in Parallel Computing*, 39, 142–149. <https://doi.org/10.3233/APC210134>
- Dessy Angelina, Hayati, U., & Dwilestari, G. (2023). Penerapan Metode Support Vector Machine Pada Sentimen Analisis Pengguna Twitter Terhadap Konser K-Pop. *Kopertip : Jurnal Ilmiah Manajemen Informatika Dan Komputer*, 7(1), 14–23. <https://doi.org/10.32485/kopertip.v7i1.251>
- Iqbal, M., Rohmat Saedudin, Rd., & Fathinuddin, M. (2022). Analisis Perbandingan Akurasi K-Nearest Neighbor Dan Naïve Bayes Untuk Klasifikasi Data Serangan Jaringan Komputer. *EDUSAINTEK: Jurnal Pendidikan, Sains Dan Teknologi*, 9(3), 920–929. <https://doi.org/10.47668/edusaintek.v9i3.611>
- Mubarok, F. A., Reza Faisal, M., Kartini, D., Nugrahadi, D. T., & Saragih, T. H. (2023). Gender Classification of Twitter Users Using Convolutional Neural Network. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 23(1), 79–92. <https://doi.org/10.30812/matrik.v23i1.3318>
- Naufal, M. F., Arifin, T., & Wirjawan, H. (2023). Analisis Perbandingan Tingkat Performa Algoritma SVM, Random Forest, dan Naïve Bayes untuk Klasifikasi Cyberbullying pada Media Sosial. *Jurnal Riset Sistem Informasi Dan Teknik Informatika (JURASIK)*, 8, 82–90. <https://doi.org/https://tunasbangsa.ac.id/ejurnal/index.php/jurasik/article/view/544>
- Nursansini, D. A., & Armiani, A. (2023). PERAN MEDIA SOSIAL MENINGKATKAN PENJUALAN UMKM DI NTB. *EDUSAINTEK: Jurnal Pendidikan, Sains Dan Teknologi*, 11(1), 76–86. <https://doi.org/10.47668/edusaintek.v11i1.1007>
- Putri, K., Raharja, A., Program, A., Informatika, S., Matematika, F., Pengetahuan, I., Universitas Udayana, A., Raya, B. J., Unud, K., Jimbaran, B., & Selatan, K. (2023). Implementasi Algoritma Support Vector Machine dalam Klasifikasi Deteksi Depresi dari Postingan pada Media Sosial. *Jurnal Nasional Teknologi Informasi Dan Aplikasinya*, 2(1). <https://doi.org/https://doi.org/10.24843/JNATIA.2023.v02.i01.p22>
- Rahayu, K., Fitria, V., Septhya, D., Rahmadden, R., & Efrizoni, L. (2023). Klasifikasi Teks untuk Mendeteksi Depresi dan Kecemasan pada Pengguna Twitter Berbasis Machine Learning. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 3(2), 108–114. <https://doi.org/10.57152/malcom.v3i2.780>

Sa'diah, H., Faisal, M. R., Farmadi, A., Abadi, F., Indriani, F., Alkaff, M., & Abullayev, V. (2024). Gender Classification on Social Media Messages Using fastText-base Feature Extraction and Long Short-Term Memory. *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 6(3), 243–252. <https://doi.org/10.35882/jeeemi.v6i3.407>

Yuanita Dwi Hartanto, G., Gouw, J., Junita, J., & Hennyta, V. (2023). HUBUNGAN MEDIA SOSIAL TERHADAP MOTIVASI BELAJAR DAN HASIL BELAJAR MATEMATIKA. *EDUSAINTEK: Jurnal Pendidikan, Sains Dan Teknologi*, 10(3), 907–921. <https://doi.org/10.47668/edusaintek.v10i3.877>