

# **PENDETEKSIAN UJARAN SEKSISME PADA PLATFORM X DENGAN ALGORITMA MACHINE LEARNING TRADISIONAL**

**Hasyim Al Fattah; Endang Wahyu Pamungkas**  
**Prodi Teknik Informatika, Fakultas Komunikasi dan Informatika, Universitas Muhammadiyah Surakarta**

## **Abstrak**

Studi ini mengeksplorasi dampak internet dan media sosial di Indonesia, dengan fokus pada Twitter sebagai platform populer, khususnya terkait ujaran seksisme terhadap Nadin Amizah. Penelitian ini menggunakan metode supervised learning dengan algoritma Support Vector Machine (SVM) dan Naïve Bayes untuk menganalisis data Twitter berbahasa Indonesia. Data yang digunakan berjumlah 1622 tweet, dikumpulkan antara tanggal 25 September hingga 11 Oktober 2023. Setelah proses preprocessing, jumlah data yang digunakan untuk analisis sentimen adalah 1474 tweet. Hasil analisis menunjukkan bahwa 82.56% (1217 tweet) memiliki label positif atau tidak seksis dan 17.44% (257 tweet) memiliki label negatif. Algoritma SVM mencapai akurasi sebesar 80.36%, sementara algoritma Naïve Bayes mencapai akurasi sebesar 68.62%. Tujuan utama penelitian ini adalah untuk memahami dampak ujaran seksisme dan melakukan prediksi serta analisis sentimen terhadap topik tersebut. Hasil dari analisis ini memberikan pemahaman yang lebih mendalam mengenai penggunaan teknik machine learning dalam konteks deteksi ujaran seksisme, serta menyediakan dasar bagi keputusan berkelanjutan dalam mengatasi masalah ujaran seksisme di media sosial.

**Kata Kunci:** Ujaran Seksisme, Twitter, SVM, Naïve Bayes.

## **Abstract**

This study explores the impact of the internet and social media in Indonesia, with a focus on Twitter as a popular platform, specifically regarding sexist speech against Nadin Amizah. This study uses supervised learning methods with Support Vector Machine (SVM) and Naïve Bayes algorithms to analyze Indonesian Twitter data. The data used amounted to 1622 tweets, collected between September 25 and October 11, 2023. After preprocessing, the amount of data used for sentiment analysis was 1474 tweets. The analysis results show that 82.56% (1217 tweets) have positive or non-sexist labels and 17.44% (257 tweets) have negative labels. The SVM algorithm achieved an accuracy of 80.36%, while the Naïve Bayes algorithm achieved an accuracy of 68.62%. The main objective of this research is to understand the impact of sexist speech and perform prediction and sentiment analysis on the topic. The results of this analysis provide a deeper understanding of the use of machine learning techniques in the context of sexism speech detection, and provide a basis for sustainable decisions in addressing the problem of sexism speech on social media.

**Keywords:** Sexism, Twitter, SVM, Naïve Bayes.

## 1. PENDAHULUAN

Berdasarkan data Badan Pusat Statistik, Indonesia merupakan negara dengan penduduk terbanyak ke-4 di dunia dengan populasi penduduk mencapai 278,69 juta jiwa pada pertengahan tahun 2023. Dikutip dari laporan We Are Social, jumlah pengguna internet di Indonesia mencapai 213 juta orang per Januari 2023, Jumlah ini setara 77% dari total penduduk di Indonesia. Salah satu media sosial yang digemari oleh netizen Indonesia yaitu Twitter atau sekarang berubah nama menjadi X. Sebanyak 14,75 juta jiwa pengguna Twitter di Indonesia, jumlah ini menempatkan Indonesia di urutan ke-6 pengguna Twitter terbanyak di dunia. Twitter di Indonesia merupakan platform media sosial yang populer di mana masyarakat aktif berinteraksi. Hal ini menjadikan Twitter sebagai sumber big data yang signifikan yang dapat dianalisis untuk memverifikasi kebenaran berita atau informasi yang sedang populer atau sedang ramai dibicarakan oleh pengguna Twitter di Indonesia (Legowo, 2023).

Dengan berkembangnya internet, teknologi informasi dan media sosial dapat memberikan kemudahan dalam berkomunikasi, perkembangan ini juga dapat membawa dampak perubahan terhadap perilaku manusia dalam berinteraksi (Santoso et al., 2023). Namun, peningkatan media sosial juga dapat memunculkan masalah baru, seperti ujaran seksisme terhadap perempuan. Ujaran seksisme di media sosial dapat memiliki dampak negatif yang signifikan, termasuk menyebabkan diskriminasi, dampak psikologis, dan pengaruh terhadap Kesehatan fisik (Septiawan, 2023).

Kekerasan Seksual yang Difasilitasi Teknologi melibatkan berbagai perilaku agresif dan merugikan yang dilakukan melalui teknologi. Penelitian terbaru telah menyoroti bentuk-bentuk kekerasan online seperti kekerasan berbasis gender, pelecehan seksual digital, pelecehan seksual berbasis gambar, dan pemaksaan seksual online. Studi juga menyoroti penyebaran TFSV dan dampak negatifnya pada korban. Literatur yang ada membahas karakteristik korban, pelaku, dan pengamat, yang membantu memahami dan mencegah masalah ini. Namun, penelitian tentang faktor-faktor yang memfasilitasi kekerasan ini masih terbatas. Penelitian ini bertujuan untuk memperluas literatur yang ada dengan mengeksplorasi faktor-faktor yang berkaitan dengan gender dan seksisme yang berkontribusi pada pelepasan moral (Martínez-Bacaicoa et al., 2024).

(Murthy, 2013) menyebutkan dalam bukunya “Twitter: Social Communication in the Twitter Age,” memaparkan Twitter sebagai sebuah alat komunikasi sosial yang dapat digunakan pengguna untuk membagikan pikiran, berita, informasi, dan opini dalam format pesan singkat dan dengan cakupan publik atau selektif. Twitter mempunyai keunggulan sendiri dibandingkan dengan media sosial lainnya, yaitu kecepatan penyampaian informasi dan target yang luas. Selain menjadi alat komunikasi, Twitter juga digunakan untuk berbagai bidang, seperti sebagai alat protes, kampanye politik, dan sumber pembelajaran (Irvani A, 2023). Berbagai ragam gaya komunikasi dapat ditemukan di Twitter, baik berupa komentar positif maupun negatif, kritik, masukan, maupun gurauan yang di dalamnya banyak mengandung sindiran. Inilah alasan yang meyakinkan penulis menggunakan media sosial Twitter sebagai objek penelitian.

Ujaran seksisme merupakan salah satu contoh dari seksisma halus atau subtle sexism yang terdiri dari pernyataan yang memperkuat stereotip gender serta perbedaan status antara perempuan dan laki-laki. Bentuk ujaran ini sering kali tidak disadari oleh banyak individu karena dianggap sebagai kebiasaan berbahasa sehingga tidak terlihat seperti tindakan seksisme (Sulatri, 2021). Umumnya korban dari kasus seperti ini adalah perempuan, meskipun tidak menutup kemungkinan laki-laki juga mengalami hal serupa. Seksisme adalah pandangan dan niat merendahkan perempuan dalam segala aspek keberadaannya, secara eksistensial menyangkut tubuhnya, pemikirannya, perasaannya. Pandangan ini menganggap bahwa perempuan adalah makhluk yang inferior dan boleh diperolok dan dilecehkan (Jannah, 2021).

Penggunaan ujaran seksis kerap digunakan sebagai sarana untuk merendahkan atau memprovokasi individu lain untuk membenci seorang tokoh figur atau suatu organisasi. Hal ini dapat menimbulkan perpecahan, keributan, gangguan psikologi, dan lain-lainnya (Wijaya & Mawardi, 2023). Oleh karena itu mendeteksi ujaran seksisme sangat penting untuk mencegah gangguan terhadap kehidupan sosial individu.

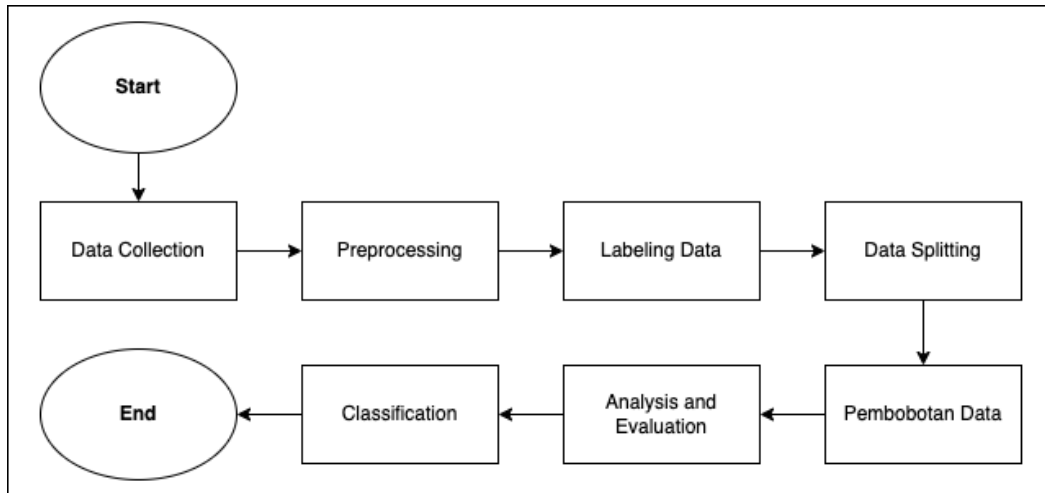
Algoritma machine learning memberikan cara yang efisien untuk mendeteksi ujaran kebencian di platform media sosial, mengurangi kebutuhan akan upaya manusia yang besar dan waktu yang diperlukan dalam pemrosesan data (Riadi et al., 2023). Algoritma yang sering digunakan untuk analisis sentimen meliputi Support Vector Machine dan Naïve Bayes.

Penulis menggunakan data dari Twitter berbasis bahasa Indonesia dengan topik “Pelecehan Nadin Amizah”, menggunakan social network scraper sebagai alat untuk mengumpulkan tweet pengguna. Tweet tersebut kemudian dianalisis menggunakan algoritma Support Vector Machine (SVM) dan Naïve Bayes untuk membangun model.

## **2. METODE**

Penulis menggunakan salah satu metode supervised learning yang digunakan untuk pengklasifikasian data yaitu Support Vector Machine dan Naïve Bayes. SVM adalah alat yang digunakan untuk prediksi klasifikasi dan regresi, memanfaatkan teori pembelajaran mesin untuk meningkatkan akurasi prediksi serta secara otomatis menghindari overfitting pada data. (Jakkula, 2006). Metode ini diperkenalkan oleh Vapnik pada tahun 1992 sebagai salah satu metode pembelajaran mesin yang beroperasi berdasarkan prinsip Structural Risk Minimization (SRM). Tujuannya adalah untuk menemukan hyperplane terbaik yang memisahkan dua kelas dalam ruang input. (Parapat & Furqon, 2018). Sedangkan Naïve Bayes merupakan salah satu algoritma paling populer yang digunakan untuk mengklasifikasi data. Tahap pengklasifikasian menggunakan algoritma Naïve Bayes melibatkan penghitungan jumlah kemunculan kata dalam dataset untuk setiap kelas. Karakteristik utama dari algoritma ini adalah asumsi bahwa setiap fitur bersifat independen satu sama lain. Data yang akan diklasifikasikan oleh algoritma adalah data hasil preprocessing yang telah diberi label berdasarkan sentimen opini. Pelabelan ini dilakukan secara manual untuk memastikan keakuratan sentimen yang lebih tinggi (Febriyani & Februariyanti, 2023).

Tahap paling awal dari penelitian ini adalah data collection atau pengambilan data dari platform Twitter, kemudian akan didapatkan data dari komentar masyarakat terkait dengan pelecehan terhadap Nadin Amizah, disini penulis menggunakan data sebanyak 1.622 data. Kemudian data yang diperoleh akan melalui tahap preprocessing data. Setelah dilakukan tahap pra-pemrosesan data, selanjutnya dilakukan pelabelan data secara manual. Setelah itu dilakukan klasifikasi data menggunakan algoritma Support Vector Machine (SVM) dan Naïve Bayes. Data yang diperoleh akan diklasifikasi menjadi dua kategori kelas yaitu positif atau Tidak Seksis, dan negatif atau Ya Seksis. Proses klasifikasi data dapat dilihat pada gambar 2.1.



Gambar 1. Proses Klasifikasi SVM

### a.1. Data Collection

Tahap pertama adalah pengumpulan data dengan memanfaatkan GoogleCollab sebagai platform untuk crawling data. Dataset ini berisi teks dalam bahasa Indonesia yang diperoleh dari media sosial Twitter atau yang sekarang berganti nama menjadi X, dengan menggunakan bahasa pemrograman Python. Kemudian penulis memasukkan beberapa keyword seperti: “Pelecehan Nadin”, “Insiden Nadin”, “Konser Nadin”, “Nadin Bandung”, dan juga mengambil data dari threads yang bersangkutan dengan pelecehan Nadin Amizah saat konser di Bandung pada tanggal 25 September 2023 dan menambahkan lang:id agar data yang didapatkan berbahasa Indonesia. Pengumpulan data dilakukan pada rentang tanggal 25 September sampai 11 Oktober 2023 dan diperoleh data sebanyak 1622. Semua data yang didapatkan akan disimpan di excel dengan format csv.

### a.2. Pre-Processing

Preprocessing data adalah langkah pengolahan data yang bertujuan untuk mempersiapkan data agar siap dianalisis. Teknik ini juga berguna untuk membersihkan dan mempersiapkan data mentah sebelum di proses atau analisis agar data lebih mudah di proses dan dianalisis secara akurat (Kusuma & Pamungkas, 2023). Dalam proses pra-pemrosesan ini, dilakukan beberapa hal sebagai berikut:

#### a.2.1. Cleaning

Data cleaning adalah proses menghilangkan gangguan dalam data, menghapus duplikasi, memvalidasi kestabilan data, dan menangani nilai yang hilang (Prihambodo et al., 2023). Data cleaning ini meliputi penghapusan username, penghapusan emoji, penghapusan

tagar, penghapusan url, penghapusan simbol, dan penghapusan data duplikat (Prakash & Aloysius, 2019). Disini penulis menggunakan sourcode dan membersihkan secara manual, data yang sebelumnya berjumlah 1.622 data setelah dibersihkan menjadi 1.474 data. Setelah melalui proses cleaning langkah selanjutnya adalah membersihkan data dengan manual, disini penulis menghapus data yang tidak relevan dengan topik dan menghapus data yang berbahasa Inggris untuk memastikan data yang digunakan yang digunakan pada penelitian memiliki arukasi tinggi.

#### a.2.2. Case Folding

Data case folding yaitu proses mengubah semua huruf kapital menjadi huruf kecil dengan menggunakan fungsi lowercase (Putri, 2022). Contoh dalam proses ini, teks “Haii” akan dirubah menjadi “haii”.

#### a.2.3. Tokenizing

Proses tokenisasi melibatkan pemecahan teks atau kata menjadi unit-unit yang bermakna seperti kata, frasa, atau elemen lainnya yang disebut token (Parhusip et al., 2021). Dalam penelitian ini, tokenisasi dilakukan untuk daftar kata dalam bahasa Indonesia. Hasil tokenisasi ini kemudian digunakan untuk tahap selanjutnya. Proses ini merupakan langkah penting dalam analisis sentimen karena membantu mengubah data tekstual yang belum diproses menjadi format yang dapat dengan mudah dianalisis oleh algoritma pembelajaran mesin. Dengan tokenisasi, setiap kata atau frasa dalam teks dipisahkan sehingga komputer dapat memahami dan menganalisis maknanya dengan lebih efisien (Sano et al., 2023). Data tokenisasi teks yang dihasilkan dari proses pra-pemrosesan akan dipisah per-kata di suatu kalimat dalam dokumen. Tujuannya untuk memangkas kalimat berdasarkan kata yang menyusun kalimat tersebut (Darwis et al., 2020).

#### a.2.4. Word Normalization

Word normalization adalah proses merubah kata-kata dalam suatu teks menjadi bentuk yang lebih umum atau standar through handling word variations, abbreviations, and acronyms. Tujuan utamanya adalah mengurangi variasi dan menciptakan representasi yang konsisten dengan mengurangi perbedaan kata-kata yang memiliki makna serupa (Sulaiman et al., 2024).

#### a.2.5. Stopword Removal

Proses ini yaitu penghapusan kata umum atau memfilter kata-kata yang tidak memberikan informasi atau makna yang penting dalam analisis teks. Tujuannya untuk

meningkatkan kualitas analisis teks (Saif et al., 2014). Alasan di balik penghapusan kata-kata ini adalah untuk mengurangi dimensi data teks dan menghilangkan noise yang mungkin tidak berkontribusi banyak pada proses klasifikasi. Menghilangkan kata-kata ini dapat mengalihkan focus ke kata-kata yang lebih penting dan bermakna yang menyampaikan informasi emosional atau kontekstual (Sano et al., 2023).

#### a.2.6. Stemming

Proses ini proses yang bertujuan untuk menghilangkan kata imbuhan atau menyederhanakan kata ke bentuk dasar. Proses ini dilakukan dengan cara melibatkan penghapusan imbuhan atau akhiran kata, sehingga kata-kata yang memiliki makna sama bisa dianggap setara, walaupun mereka memiliki bentuk yang berbeda (Prakash & Aloysius, 2019). Contohnya kata “berlari” disederhanakan menjadi “lari”. Tujuan dari prosedur ini adalah untuk mengubah berbagai bentuk kata, seperti bentuk jamak atau konjugasi kata kerja, menjadi bentuk dasar yang umum. Ini membantu mengurangi jumlah dimensi dalam ruang fitur, yang pada gilirannya dapat meningkatkan akurasi dan efisiensi (Sano et al., 2023).

### a.3. Labelling Data

Setelah data telah diproses melalui tahap preprocessing, langkah berikutnya adalah melabeli data. Ini diperlukan agar data siap untuk digunakan dalam pembelajaran oleh SVM dan Naïve Bayes (Muhammadi et al., 2022). Pada proses labelling ini data akan dibagi menjadi 2 kategori yaitu positif atau Tidak Seksis, dan negatif atau Ya Seksis. Data dengan label positif berarti tidak mengandung ujaran seksisme atau ujaran kebencian, bisa juga diartikan sebagai pujian atau ujaran kebaikan. Sedangkan data dengan label negatif diartikan dengan makna kebencian atau mengandung ujaran seksisme. Sebelum masuk ke tahap klasifikasi, penulis melakukan pelabelan data secara manual. Disini penulis menggunakan 3 pengamat untuk melabeli data. Tugas pengamat 1 dan pengamat 2 adalah melabeli data secara manual dan untuk tugas pengamat 3 adalah menentukan label apabila pengamat 1 dan pengamat 2 berbeda pendapat. Hasil dari pelabelan ini adalah:

- a. Pengamat 1: 1227 positif atau tidak seksis dan 247 negatif atau seksis.
- b. Pengamat 2: 959 positif atau tidak seksis dan 515 negatif atau seksis.
- c. Pengamat 3: 1217 positif atau tidak seksis dan 257 negatif atau seksis.

Untuk mengukur tingkat kesepakatan antara pengamat 1 dan pengamat 2 ketika melabeli data ke dalam kategori yang sama maka penulis menggunakan statistik Cohen's kappa. Cohen's kappa merupakan statistik yang digunakan untuk menilai tingkat kesepakatan antara dua pengamat atau penilai dalam mengkategorikan item ke dalam kategori yang sama. Statistik ini memberikan ukuran yang mempertimbangkan kemungkinan bahwa kesepakatan dapat terjadi secara kebetulan (Adnan et al., 2023).

#### **a.4. Data Splitting**

Menurut (Putra et al., 2024) Pembagian data adalah proses membagi dataset menjadi dua atau lebih subset yang berbeda, sering digunakan untuk pelatihan dan pengujian model machine learning. Tujuannya utama adalah mengevaluasi kinerja model pada data yang tidak pernah dilihat selama pelatihan.

Beberapa jenis pembagian data yang umum meliputi:

##### **2.4.1 Data Train**

Data pelatihan digunakan untuk mengembangkan model dan melatih algoritma. Subset ini mengandung contoh-contoh yang telah diberi label atau output yang diinginkan, yang digunakan oleh model untuk belajar dan membuat prediksi pada data baru yang belum pernah dilihat sebelumnya.

##### **2.4.2 Data Test**

Ketika menghadapi data baru yang tidak dikenal, pengujian dilakukan untuk mengevaluasi performa algoritma yang telah dilatih sebelumnya. Subset ini digunakan untuk menguji kinerja model machine learning setelah melalui pelatihan dengan data pelatihan. Data pengujian berperan dalam mengukur kemampuan model untuk melakukan generalisasi pada data baru atau data yang belum pernah dilihat sebelumnya.

#### **a.5. Pembobotan Data**

Proses ini merupakan tahap dimana memberikan bobot di setiap kata dengan menggunakan perhitungan Term Frequency-Invert Document Frequency (TF-IDF). TF-IDF adalah permodelan yang dimanfaatkan untuk menemukan hubungan antara kata terhadap data dengan cara memberikan bobot pada setiap kata. TF(Term Frequency) untuk mengukur seberapa sering sebuah kata muncul pada dokumen, menunjukkan tingkat kepentingan kata dalam dokumen tersebut. IDF(Invert Document Frequency) untuk mengukur seberapa umum atau jarang suatu kata muncul di seluruh kumpulan dokumen, kata yang jarang muncul di seluruh kumpulan dokumen mendapatkan bobot



yang lebih tinggi, menandakan bahwa kata tersebut memiliki nilai informasi lebih besar (Hendrastuty et al., 2021). Metode pemrosesan teks ini digunakan untuk merepresentasikan dan menganalisis pentingnya kata-kata dalam sebuah dokumen atau teks. Hal ini membantu mengidentifikasi kata-kata yang paling penting yang mempengaruhi perasaan yang diekspresikan dalam teks (Sano et al., 2023).

## **a.6. Klasifikasi**

Klasifikasi merupakan proses yang bertujuan untuk menempatkan suatu objek ke dalam suatu kategori yang sudah ditetapkan sebelumnya. Klasifikasi data dapat dilakukan dari mulai membangun aturan klasifikasi tertentu dengan menggunakan data training dan data testing (Parapat & Furqon, 2018). Dalam penelitian ini penulis menggunakan dua metode, yaitu SVM(Support Vector Machine) dan Naïve Bayes. SVM dipilih karena kemampuannya dalam menangani dataset non-linier. Sedangkan Naïve Bayes dipilih karena kemudahan dan efisiensinya. Algoritma ini bertujuan untuk mendapatkan nilai positif dan negatif dari setiap data komentar.

### **2.6.1 Support Vector Machine(SVM)**

Support Vector Machine (SVM) merupakan algoritma machine learning terkenal untuk klasifikasi. SVM bertujuan menemukan hyper optimal yang memisahkan dua kelas dalam ruang input. Dengan menggunakan data pelatihan, SVM membangun model klasifikasi untuk memprediksi kelas data baru (Suryati et al., 2023). Algoritma ini berbasis teori pembelajaran statistik dan mampu menangani data tidak dapat dipisahkan linier dengan trik kernel. Trik kernel ini memetakan data ke ruang dimensi yang lebih tinggi, memungkinkan pemisahan linier dan meningkatkan fleksibilitas model. Dengan meletakkan hyperplane yang memaksimalkan margin antara batas atas dan bawah di ruang dimensi yang lebih tinggi, SVM secara efektif memisahkan kelompok pengamatan (Pimentel et al., 2024).

### **2.6.2 Naïve Bayes**

Naïve Bayes merupakan algoritma klasifikasi yang terkenal dalam machine learning. Menurut (Paramitha et al., 2023) metode Naïve Bayes adalah salah satu metode sederhana dan efektif untuk memprediksi kelas dari suatu data.. Algoritma ini menghitung probabilitas munculnya item dalam setiap kategori target untuk item yang akan diklasifikasikan. Proses ini melibatkan pemilihan probabilitas yang paling

signifikan untuk menentukan kategori yang sesuai sebagai hasil klasifikasi (Guo et al., 2023).

### a.7. Evaluasi

Analisis dan evaluasi dilakukan untuk mengetahui performance model yang digunakan. Proses ini juga bertujuan untuk memberikan gambaran dan mengukur sejauh mana model dapat memprediksi data (Arsi & Waluyo, 2021). Perhitungan akurasi dalam klasifikasi adalah tahap terakhir yang krusial, karena menentukan kesesuaian penggunaan algoritma untuk permasalahan yang dihadapi. Pada tahap ini, evaluasi dilakukan dengan mengukur sejauh mana algoritma SVM cocok untuk kasus klasifikasi (Mawarni & Dahlan Yogyakarta, 2023). Untuk mengevaluasi hasil, penulis menggunakan Confusion Matrix yang merupakan alat untuk mengukur kinerja model klasifikasi Support Vector Machine dan Naïve Bayes. Matriks ini berisi angka yang menunjukkan sejauh mana model berhasil dalam mengklasifikasikan data dengan tepat. Parameter pengujian yang dilakukan pada evaluasi penelitian ini adalah akurasi, yang dihitung menggunakan tabel matriks klasifikasi atau tabel kontingensi (Rininda et al., 2023). Tabel berikut menunjukkan sebuah confusion matrix untuk pengklasifikasian ke dalam dua kelas.

Tabel 1. Tabel Confusion Matrix

		Kelas Prediksi	
		Positif	Negatif
Aktual	Positif	TP	FP
	Negatif	FN	FP

TP (True Positive) : Data positif yang diprediksi benar.

FN (False Negative) : Data negatif yang diprediksi benar.

FP (False Positive) : Data negatif namun diprediksi sebagai data positif.

FN (False Negative) : Data positif namun diprediksi data negative.

Keakuratan hasil diukur menggunakan nilai Akurasi, Presisi, Recall, dan F1-Score.

1. Akurasi merupakan tingkat kesesuaian hasil pengukuran kuantitas dengan nilai sebenarnya. Berikut adalah rumus akurasi dalam analisis sentimen (Anshor & Safuwan, 2023).

$$\text{Accuracy} = \frac{\text{TP}+\text{TN}}{\text{TP}+\text{TN}+\text{FP}+\text{FN}} \quad (1)$$

2. Presisi merupakan tingkat kecocokan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem(Anshor & Safuwani, 2023).

$$\text{Precision} = \frac{\text{TP}}{\text{TP}+\text{FP}} \quad (2)$$

3. Recall merupakan pengukuran tingkat kesuksesan sistem dalam mengingat Kembali atau menemukan kembali sebuah informasi(Anshor & Safuwani, 2023).

$$\text{Recall} = \frac{\text{TP}}{\text{TP}+\text{FN}} \quad (3)$$

4. F1-Score adalah alat evaluasi dalam model klasifikasi yang cara kerjanya adalah menggabungkan Precision dan Recall. Ini memberikan gambaran keseluruhan tentang seberapa baik model dalam memprediksi kelas positif secara tepat dan menemukan sebagian besar kasus yang sebenarnya positif. F1-Score membantu kita menilai keseimbangan antara ketepatan dan kemampuan model dalam menemukan kasus positif, terutama dalam situasi dengan ketidakseimbangan kelas. Ini merupakan alat penting bagi praktisi data science untuk mengukur kinerja model klasifikasi(Rininda et al., 2023).

$$\text{F1 - Score} = \frac{2 (\text{Precision} \times \text{Recall})}{\text{Precision} + \text{Recall}} \quad (4)$$

## **b. HASIL DAN PEMBAHASAN**

### **3.1 Data Collection**

Data yang dikumpulkan dalam penelitian ini diperoleh dari media social Twitter atau sekarang berubah naman menjadi X dengan cara scrapping tweet berbahasa Indonesia menggunakan Google Collab dengan kata kunci seperti: “Pelecehan Nadin”, “Insiden Nadin”, “Konser Nadin”, “Nadin Bandung”, dan juga mengambil data dari threads yang bersangkutan dengan pelecehan Nadin Amizah saat konser di Bandung pada tanggal 25 September 2023 dan menambahkan lang:id agar data yang didapatkan berbahasa Indonesia. Pengumpulan data dilakukan pada rentang tanggal 25 September sampai 11 Oktober 2023 dan diperoleh data sebanyak 1622.

## 3.2 Pre-Processing

### 3.2.1 Cleaning

Pada tahap cleaning dilakukan penghapusan username, tanda baca, simbol, tautan tagar, dan emoji. Proses ini menggunakan loop dengan modul re. Hasil data tweet setelah melalui proses cleaning ditunjukkan pada tabel 3.1.

Tabel 2. Hasil Cleaning Data

<b>Tweet</b>	<b>Cleaning</b>
@nerosalt Kalo menurutku nadin.. gatau aja, berat dengernya dia jadi korban pelecehan seksual dan sampe trauma gitu. Aku sedih banget liat atau denger kasus2 korban pelecehan □üò≠□üò≠	Kalo menurutku nadin gatau aja berat dengernya dia jadi korban pelecehan seksual dan sampe trauma gitu Aku sedih banget liat atau denger kasus korban pelecehan

### 3.2.2 Case Folding

Pada tahap ini dilakukan guna menyamaratakan atau mengubah huruf besar menjadi huruf kecil. Bertujuan untuk memudahkan tahap selanjutnya. Hasil case folding ditunjukkan pada tabel 3.2.

Tabel 3. Hasil Case Folding

<b>Cleaning</b>	<b>Case Folding</b>
Kalo menurutku nadin gatau aja berat dengernya dia jadi korban pelecehan seksual dan sampe trauma gitu Aku sedih banget liat atau denger kasus korban pelecehan	kalo menurutku nadin gatau aja berat dengernya dia jadi korban pelecehan seksual dan sampe trauma gitu aku sedih banget liat atau denger kasus korban pelecehan

### 3.2.3 Tokenizing

Setelah melakukan case folding, langkah selanjutnya adalah tokenizing, Mengubah data menjadi daftar kata atau list dilakukan dengan menggunakan library NLTK, khususnya dengan mengimpor fungsi `word_tokenize` dari modul `nltk.tokenize`. Fungsi `word_tokenize_wrapper` digunakan dalam kode tersebut sebagai perantara (wrapper), memungkinkan penerapan fungsi `word_tokenize` dari NLTK pada setiap baris teks. Hasil Tokenizing ditunjukkan pada tabel 3.3.

Tabel 4. Hasil Tokenizing

<b>Case Folding</b>	<b>Tokenizing</b>
kalo menurutku nadin gatau aja berat dengernya dia jadi korban pelecehan seksual dan sampe trauma gitu aku	kalo, menurutku, nadin, gatau, aja, berat, dengernya, dia, jadi, korban, pelecehan, seksual, dan, sampe,

sedih banget liat atau denger kasus korban pelecehan	trauma, gitu, aku, sedih, banget, liat, atau, denger, kasus, korban, pelecehan
--	--

### 3.2.4 Word Normalization

Proses mengubah kalimat slang menjadi formal dilakukan dengan menggunakan dan membaca kamus 'colloquial-indonesian-lexicon.csv'. Kamus ini berisi daftar kata slang dan padanan formalnya dalam bahasa Indonesia. Selanjutnya, dilakukan looping di mana setiap kata dalam teks diperiksa apakah ada dalam kamus dict\_slang. Jika kata tersebut ditemukan dalam kamus, kata slang akan diganti dengan bentuk formalnya sesuai kamus. Jika tidak ditemukan, kata tersebut tetap dipertahankan. Hasil Word Normalization ditunjukkan pada tabel 3.4.

Tabel 5. Hasil Word Normalization

Tokenizing	Word Normalization
kalo, menurutku, nadin, gatau, aja, berat, dengernya, dia, jadi, korban, pelecehan, seksual, dan, sampe, trauma, gitu, aku, sedih, banget, liat, atau, denger, kasus, korban, pelecehan	kalo, menurutku, nadin, enggak tau, saja, berat, dengernya, dia, jadi, korban, pelecehan, seksual, dan, sampai, trauma, begitu, aku, sedih, banget, lihat, atau, dengar, kasus, korban, pelecehan

### 3.2.5 Stopword Removal

Proses ini menghilangkan kata-kata yang tidak memiliki makna penting dilakukan menggunakan library NLTK dengan modul stopwords untuk bahasa Indonesia. Kode from nltk.corpus import stopwords mengimpor daftar stopwords (kata-kata pengisi) dalam bahasa Indonesia dari NLTK. Daftar ini digunakan untuk mengidentifikasi kata-kata yang harus dihapus dari teks. Selain itu, kode list\_stopwords\_id.extend menambahkan kata-kata tambahan ke daftar stopwords untuk menghilangkan kata-kata yang tidak memiliki arti selain yang disediakan dalam corpus stopword. Hasil Stopword Removal ditunjukkan pada tabel 3.5.

Tabel 6. Hasil Stopword Removal

Word Normalization	Stopword Removal
kalo, menurutku, nadin, enggak tau, saja, berat, dengernya, dia, jadi, korban, pelecehan, seksual, dan, sampai, trauma, begitu, aku, sedih, banget, lihat, atau, dengar, kasus, korban, pelecehan	menurutku, nadin, enggak tau, berat, dengernya, korban, pelecehan, seksual, trauma, sedih, banget, lihat, dengar, korban, pelecehan

### 3.2.6 Stemming

Proses ini dilakukan untuk menghapus imbuhan. Disini menggunakan Library sastrawi dahalam bahasa indonesia untuk menghapus imbuhan. Modul stemmer digunakan untuk membuat objek stemmer. Sementara StopWordRemoverFactory membuat objek remover stopwords yang akan digunakan dalam tahap penghapusan, disini kasusnya seperti mengurangi noise, seperti "dan", "atau", "di", "dari", dll. Modul swifter disini berfungsi untuk mempercepat proses stemming. Hasil Stemming ditunjukkan pada tabel 3.6.

Tabel 7. Hasil Stemming

Stopword Removal	Stemming
menurutku, nadin, enggak tau, berat, dengernya, korban, pelecehan, seksual, trauma, sedih, banget, lihat, dengar, korban, pelecehan	turut, nadin, enggak tau, berat, dengernya, korban, leceh, seksual, trauma, sedih, banget, lihat, dengar, korban, leceh

### 3.3 Labelling Data

Hasil Scrapping yang sudah diproses pada tahap pre-processing selanjutnya akan dilakukan pelabelan secara manual. Proses ini dibagi menjadi tiga kategori yaitu positif dan negatif. Hasil labelling ditunjukkan pada tabel 3.7.

Tabel 8. Hasil Labelling

Tweet	Label
kesempatan dalam kesempatan	Negatif (Ya Seksis)
stop normalisasi pelecehan seksual dan menyalahkan korban	Positif (Tidak Seksis)

Disini penulis menggunakan 3 pengamat untuk melabeli data. Tugas pengamat 1 dan pengamat 2 adalah melabeli data secara manual dan untuk tugas pengamat 3 adalah menentukan label apabila pengamat 1 dan pengamat 2 berbeda pendapat.

Hasil dari pelabelan ini adalah:

- Pengamat 1: 1227 positif atau tidak seksis dan 247 negatif atau seksis.
- Pengamat 2: 959 positif atau tidak seksis dan 515 negatif atau seksis.
- Pengamat 3: 1217 positif atau tidak seksis dan 257 negatif atau seksis.

Untuk mengukur tingkat kesepakatan antara dua pengamat atau penilai ketika melabeli data ke dalam kategori yang sama maka digunakan statistik Cohen's kappa. Statistik ini merupakan statistik yang digunakan untuk menilai tingkat kesepakatan

antara dua pengamat atau penilai dalam mengkategorikan item ke dalam kategori yang sama. Statistik ini memberikan ukuran yang mempertimbangkan kemungkinan bahwa kesepakatan dapat terjadi secara kebetulan (Afizah binti Adnan et al., 2023). Kappa dapat bervariasi dari -1 hingga 1. Ketika nilainya 1, itu menunjukkan kesepakatan sempurna; 0 menandakan kesakatan yang sama kebetulan, sementara nilai negatif menunjukkan kesepakatan yang buruk. Semakin tinggi kappa, semakin bisa dipercaya model klasifikasi untuk memprediksi data baru dengan akurasi yang baik (Rasiban & Praja Raymond Maruli, 2023). Berikut tabel untuk penilaian dan penghitungan Cohen's kappa statistik:

Tabel 9. Tabel Perhitungan Kappa

Nilai Kappa ( $\kappa$ )	Tingkat Kesepakatan
<0	Kesepakatan yang kurang baik
0.00 - 0.20	Kesepakatan yang sangat rendah
0.21 – 0.40	Kesepakatan rendah
0.41 – 0.60	Kesepakatan sedang
0.61 – 0.80	Kesepakatan tinggi
0.81 – 1.00	Kesepakatan sangat tinggi

- Buat Matriks Kesepakatan: Menentukan jumlah data yang diklasifikasikan oleh kedua pengamat dalam setiap kategori.
- Hitung Proporsi Kesepakatan yang diamati( $P_o$ ): Jumlah kesepakatan dibagi dengan total data
- Hitung Proporsi Kesepakatan yang Diharapkan secara kebetulan( $P_e$ ): Berdasarkan distribusi klasifikasi masing-masing pengamat.
- Hitung Cohen's Kappa( $\kappa$ ): Dengan menggunakan rumus  $\kappa = \frac{P_o - P_e}{1 - P_e}$

Data Rinci

- Total data: 1474
- Kategori: positif, negatif
- Selisih perbedaan pendapat antara pengamat 1 dan pengamat 2: 332

1) Matriks Kesepakatan

Asumsikan bahwa kesepakatan dan ketidaksepakatan antara dua pengamat dirinci dalam tabel kontingensi (confusion matrix) sebagai berikut:

Tabel 10. Matruks kesepakatan

	Ya	Tidak	Total
Ya	215	32	247
Tidak	300	927	1227
Total	515	1243	1474

2) Menghitung Proporsi Kesepakatan yang Diamati ( $P_o$ )

$P_o$  adalah proporsi dari semua klasifikasi di mana kedua pengamat setuju. Ini dihitung dengan menjumlahkan nilai diagonal utama (kesepakatan) dari tabel kontingensi dan membaginya dengan total jumlah data.

$$P_o = \frac{\text{jumlah kesepakatan}}{\text{total data}} = \frac{215+927}{1474} = 0,7747 \quad (5)$$

3) Menghitung Proporsi Kesepakatan yang Diharapkan secara Kebetulan ( $P_e$ ) Untuk menghitung  $P_e$  kita perlu menghitung proporsi masing-masing kategori dari kedua pengamat.

$$P_1 = \frac{(a+c) \times (a+b)}{(a+b+c+d)^2} = \frac{515 \times 247}{1474^2} = \frac{127.205}{2.172.676} = 0,0585 \quad (6)$$

$$P_2 = \frac{(d+c) \times (d+b)}{(a+b+c+d)^2} = \frac{1227 \times 959}{1474^2} = \frac{1.176.693}{2.172.676} = 0,5415$$

$$P_e = P_1 + P_2 = 0,0585 + 0,5415 = 0,6$$

Keterangan:

(a)=jumlah positif benar, yaitu jumlah ‘Ya’ pengamat 1 dan pengamat 2

(b)= jumlah positif palsu, yaitu jumlah ‘Tidak’ di pengamat 2 dan ‘Ya’ di pengamat 1

(c)= jumlah negatif palsu, yaitu jumlah ‘Ya di pengamat 2 dan ‘Tidak’ di pengamat 1

(d)=jumlah negatif benar, yaitu jumlah ‘Tidak’ pengamat 1 dan pengamat 2

4) Hitung Cohens Kappa:

$$k = \frac{P_o - P_e}{1 - P_e} = \frac{0,7747 - 0,6}{1 - 0,6} = \frac{0,1747}{0,4} = 0,4367 \quad (7)$$

Jadi hasil dari Cohens Kappa adalah 0.4367 yang berarti menurut tabel kesepakatan Cohens Kappa menunjukkan hasil Kesepakatan Sedang

### 3.4 Data Splitting

Pada proses ini dilakukan pembagian pada dataset yaitu: data training dan data testing. Data training bertujuan untuk melatih model machine learning menggunakan metode Support Vector Machine dan Naïve Bayes, sementara data testing bertujuan untuk



menguji kinerja model. Pembagian dilakukan menggunakan train test split dari library Scikit-learn, dengan perbandingann 70% untuk data training dan 30% untuk data testing.

### 3.5 Pembobotan Data

Tahap ini bertujuan untuk menentukan bobot nilai dari setiap kata menggunakan pemodelan TF-IDF. Data teks yang digunakan berasal dari kolom stemming\_data, yang merupakan hasil akhir dari preprocessing data. Teks dalam kolom stemming\_data terlebih dahulu diubah menjadi bentuk daftar dengan word\_tokenize, yang bertujuan untuk memisahkan setiap kata guna memberikan nilai bobotnya. Kemudian dilakukan proses tokenized kembali untuk dataset, dengan word\_tokenized pada library nltk. Ini merupakan proses penting ketika melakukan pembobotan pada kata di kolom stemming\_data. Langkah selanjutnya adalah melakukan perhitungan bobot TF(Term Frequency) dari setiap kata dalam dataset di kolom stemming\_data. Hasilnya tersimpan dalam kolom 'TF\_dict'. Kemudian mengambil hasil perhitungan pada kolom TF\_dict atau hasil TF(Term Frequency) tadi dan menyajikannya kedalam bentuk dataframe/tabel agar mudah dibaca. Hasil TF(Term Frequency) ditunjukkan pada tabel 3.8.

Tabel 11. Hasil TF(Term Frequency)

<b>TF</b>
<pre>{   "turut": 0.07142857142857142,   "nadin": 0.07142857142857142,   "tidak": 0.07142857142857142,   "tahu": 0.07142857142857142,   "dengernya": 0.07142857142857142,   "korban": 0.14285714285714285,   "leceh": 0.14285714285714285,   "seksual": 0.07142857142857142,   "trauma": 0.07142857142857142,   "sedih": 0.07142857142857142,   "lihat": 0.07142857142857142,   "denger": 0.07142857142857142 }</pre>

Kemudian menghitung DF(Document Frequency) dan menyajikannya kedalam dataframe/tabel agar mudah dibaca. DF(Document Frequency) ditunjukkan pada tabel 3.9.

Tabel 12. Hasil DF(Document Frequency)

<b>Term</b>	<b>DF</b>
turut	3
nadin	943
tidak	37

Terakhir, dilakukan perhitungan bobot TF-IDF(Term Frequency-Inverse Document Frequency) untuk setiap kata dalam dataset dikolom Tweet. Dan hasilnya akan ditampilkan dalam dataframe bersama dengan kolom hasil TF tadi.

Tabel 13. Hasil TF-IDF(Term Frequency-Inverse Document Frequency)

TF	TF-IDF
{ "turut": 0.07142857142857142, "nadin": 0.07142857142857142, "tidak": 0.07142857142857142, "tahu": 0.07142857142857142, "dengernya": 0.07142857142857142, "korban": 0.14285714285714285, "leceh": 0.14285714285714285, "seksual": 0.07142857142857142, "trauma": 0.07142857142857142, "sedih": 0.07142857142857142, "lihat": 0.07142857142857142, "denger": 0.07142857142857142}	{ "turut": 0.4221029079735279, "nadin": 0.0318292076145558, "tidak": 0.26129635093020687, "tahu": 0.33261983879528734, "dengernya": 0.4716134208706669, "korban": 0.48338743818873364, "leceh": 0.25577193383098845, "seksual": 0.20379170116135467, "trauma": 0.35665356998251685, "sedih": 0.34363060164009157, "lihat": 0.23889223958341818, "denger": 0.35665356998251685}

### 3.6 Klasifikasi

#### 3.6.1 Support Vector Machine

Pada tahap ini, dengan menggunakan metode kernel linear, proses klasifikasi SVM ini tujuannya untuk melihat nilai akurasi yang didapat. Dataset yang digunakan dibagi menjadi 70% untuk training dan 30% untuk testing. Hasil klasifikasi SVM ditunjukkan pada gambar berikut:

Classification Report untuk Data Train:				
	precision	recall	f1-score	support
Tidak	1.00	0.95	0.97	837
Ya	0.81	0.98	0.89	194
accuracy			0.95	1031
macro avg	0.90	0.97	0.93	1031
weighted avg	0.96	0.95	0.96	1031

Gambar 2. Hasil Data Train SVM

Classification Report untuk Data Test:				
	precision	recall	f1-score	support
Tidak	0.92	0.85	0.88	380
Ya	0.37	0.52	0.43	63
accuracy			0.80	443
macro avg	0.64	0.69	0.66	443
weighted avg	0.84	0.80	0.82	443

Gambar 3. Hasil Data Test SVM

### 3.6.2 Naïve Bayes

Pada langkah ini, penerapan klasifikasi Naïve Bayes menggunakan metode MultinomialNB dilakukan. Alat ini cocok untuk klasifikasi Naïve Bayes yang dapat mengelola data dalam format teks. Kumpulan data yang digunakan dipisahkan menjadi 70% untuk pelatihan dan 30% untuk pengujian. Hasil klasifikasi SVM ditunjukkan pada gambar berikut:

Classification Report untuk Data Train:				
	precision	recall	f1-score	support
Tidak	1.00	0.86	0.93	837
Ya	0.63	0.99	0.77	194
accuracy			0.89	1031
macro avg	0.81	0.93	0.85	1031
weighted avg	0.93	0.89	0.90	1031

Gambar 4. Hasil Data Train Naïve Bayes

Classification Report untuk Data Test:				
	precision	recall	f1-score	support
Tidak	0.92	0.69	0.79	380
Ya	0.26	0.63	0.37	63
accuracy			0.69	443
macro avg	0.59	0.66	0.58	443
weighted avg	0.83	0.69	0.73	443

Gambar 5. Hasil Data Test Naïve Bayes

### 3.7 Evaluasi

Untuk mengevaluasi performa metode klasifikasi yang diterapkan, kita dapat memanfaatkan Confusion Matrix yang memperlihatkan jumlah prediksi yang tepat dan tidak tepat dari model. Dengan memanfaatkan pustaka scikit-learn dalam bahasa pemrograman Python, kita dapat menghasilkan Confusion Matrix menggunakan fungsi `confusion_matrix` serta menghitung Accuracy, Precision, Recall, dan F1-Score dari model tersebut.

	Text	Prediksi	Aktual	Hasil	Confusion Matrix
236	gacuma deh rujak besarbesaran udahudah nadin g...	Tidak	Tidak	Benar	True Positive (TP)
530	naonsihhh	Tidak	Tidak	Benar	True Positive (TP)
1333	salah pamer penasaran	Ya	Ya	Benar	False Positif (FP) untuk aktual Negatif tapi p...
5	resah nadin amizah selebriti alami leceh seksual	Tidak	Tidak	Benar	True Positive (TP)
94	ohh nadin kena leceh min	Tidak	Tidak	Benar	True Positive (TP)

Gambar 6. Dataframe Confusion Matrix SVM

	Text	Prediksi	Aktual	Hasil	Confusion Matrix
236	gacuma deh rujak besarbesaran udahudah nadin g...	Ya	Tidak	Salah	False Negatif (FN) untuk aktual Positif tapi p...
530	naonsihhh	Ya	Tidak	Salah	False Negatif (FN) untuk aktual Positif tapi p...
1333	salah pamer penasaran	Ya	Ya	Benar	False Positif (FP) untuk aktual Negatif tapi p...
5	resah nadin amizah selebriti alami leceh seksual	Ya	Tidak	Salah	False Negatif (FN) untuk aktual Positif tapi p...
94	ohh nadin kena leceh min	Tidak	Tidak	Benar	True Positive (TP)

Gambar 7. Dataframe Confusion Matrix Naïve Bayes

Prediksi yang benar: 356 data  
 Prediksi yang salah: 87 data

Akurasi: 80.36%

Presisi: 83.70%

Recall: 80.36%

F1 Score: 81.73%

Gambar 8. Hasil Confusion Matrix SVM

Prediksi yang benar: 304 data  
 Prediksi yang salah: 139 data

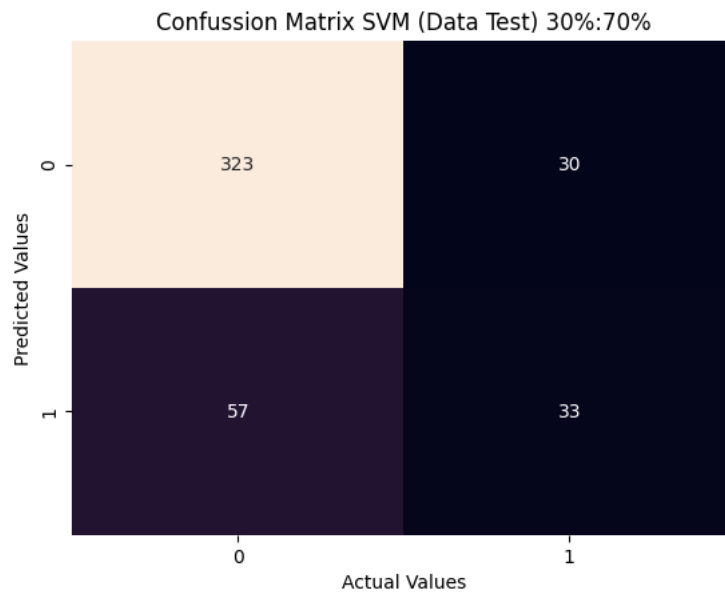
Akurasi: 68.62%

Presisi: 82.55%

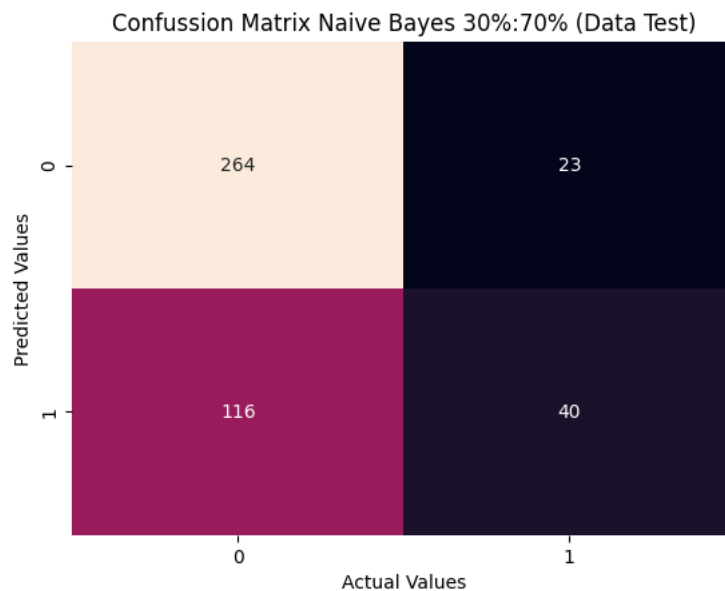
Recall: 68.62%

F1 Score: 73.10%

Gambar 9. Hasil Confusion Matrix Naïve Bayes



Gambar 10. Visualisai Confussion Matrix SVM



Gambar 11. Visualisai Confussion Matrix Naïve Bayes

Pada gambar diatas telah dilakukan klasifikasi menggunakan Confussion Matrix Menggunakan algoritma SVM dan Naïve Bayes. Pada algoritma SVM menghasilkan prediksi data yang benar adalah: 365 data, dan prediksi data yang salah adalah: 87 data dengan rincian: Akurasi: 80,36%, Presisi 83,70%, Recall 80,36%, dan F1-Score: 81,73%. Dan pada algoritma Naïve Bayes menghasilkan prediksi data yang benar adalah: 304 data, dan prediksi data yang salah adalah: 139 data dengan rincian: Akurasi: 68,62%, Presisi 82,55%, Recall 68,62%, dan F1-Score: 73,10%.

- a. SVM memiliki akurasi yang lebih tinggi (80.36%) dibandingkan dengan Naïve Bayes (68.62%). Akurasi yang lebih tinggi menunjukkan bahwa SVM lebih sering membuat prediksi yang benar secara keseluruhan.
- b. Presisi SVM adalah 83.70%, sedikit lebih tinggi daripada Naïve Bayes yang memiliki presisi 82.55%. Presisi yang tinggi menunjukkan bahwa model tidak sering membuat kesalahan prediksi positif palsu.
- c. Recall SVM adalah 80.36%, yang lebih tinggi daripada Naïve Bayes yang memiliki recall 68.62%. Recall yang tinggi menunjukkan bahwa model tidak sering melewatkan kasus positif sebenarnya.
- d. F1 Score SVM adalah 81.73%, lebih tinggi daripada Naïve Bayes yang memiliki 73.10%. F1 Score adalah rata-rata harmonis dari presisi dan recall, dan memberikan gambaran keseluruhan tentang kinerja model dengan mempertimbangkan kedua metrik ini. F1 Score yang lebih tinggi menunjukkan bahwa model seimbang dalam hal presisi dan recall.

Secara keseluruhan algoritma SVM memiliki akurasi, recall, dan F1 Score yang lebih tinggi dibandingkan Naïve Bayes. Ini menunjukkan bahwa algoritma SVM lebih efektif dalam membuat prediksi yang benar secara keseluruhan dan lebih baik dalam mengenali serta memprediksi kasus positif sebenarnya dibandingkan Naïve Bayes.

## **4. PENUTUP**

### **4.1 Kesimpulan**

Penulis telah melakukan penelitian dan mengambil kesimpulan bahwa pendeteksian ujaran sexism di platform Twitter yang menggunakan dua algoritma, yaitu Support Vector Machine dan Naïve Bayes, telah berhasil dilakukan. Data yang digunakan untuk analisis sentimen dikumpulkan dari Twitter, dengan total 1622 tweet yang diambil antara tanggal 25 September sampai 11 Oktober 2023. Setelah tahap Preprocessing, jumlah data yang digunakan untuk analisis sentimen adalah 1474 tweet. Hasil analisis menunjukkan bahwa 82.56% (1217 tweet) memiliki label positif atau tidak seksis dan 17.44% (257 tweet) memiliki label negatif. Dari analisis tersebut, algoritma Support Vector Machine(SVM) mendapatkan akurasi sebesar 80.36%, sedangkan algoritma Naïve Bayes mendapatkan akurasi sebesar 68.62%. Secara keseluruhan algoritma SVM lebih tinggi dibandingkan Naïve Bayes. Ini menunjukkan bahwa algoritma SVM lebih

efektif dalam membuat prediksi yang benar secara keseluruhan dan lebih baik dalam mengenali serta memprediksi kasus positif sebenarnya dibandingkan Naïve Bayes.

#### **4.2 Saran**

Penulis menyadari bahwa penelitian ini masih memiliki potensi untuk peningkatan di masa mendatang. Untuk meningkatkan kualitas hasil, penulis berharap penelitian berikutnya dapat menggunakan dataset yang lebih luas sehingga analisis sentimen yang dihasilkan lebih informatif. Selain itu, penelitian ini juga bisa diperkaya dengan menerapkan algoritma yang berbeda untuk perbandingan, serta menambahkan algoritma lainnya untuk dibandingkan dengan Naive Bayes dan Support Vector Machine, dengan harapan dapat meningkatkan akurasi hasil.

#### **DAFTAR PUSTAKA**

- Adnan, N., Hasan, A & Teknologi Maklumat dan Komunikasi, J. (2023). Menentukan Kebolehpercayaan Set Kompetensi Kerja 4IR Menggunakan Analisis Kappa. *Engineering And Technology International Journal* Maret 2023 |, 5(1), 2714–2755. <https://doi.org/10.556442>
- Kusuma, F., & Pamungkas, E. (2023). Pendeteksian Hate Speech Pada Sosial Media Indonesia Dengan Algoritma Support Vector Machine (Svm) Dan Decision Tree. *Eprints.Ums.Ac.In*, 5.
- Parhusip, H., Susanto, B., Putri, C., & Kristen Satya Wacana Salatiga, U. (2021). Word Cloud of UKSW Lecturer Research Competence Based on Google Scholar Source. *Journals Ums*, 7(1), 53. <https://spamassassin>.
- Arsi, P., & Waluyo, R. (2021). Analisis Sentimen Wacana Pemindahan Ibu Kota Indonesia Menggunakan Algoritma Support Vector Machine (Svm). *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8(1), 147–156. <https://doi.org/10.25126/jtiik.202183944>
- Darwis, D., Pratiwi, E., Ferico, A., & Pasaribu, O. (2020). Penerapan Algoritma Svm Untuk Analisis Sentimen Pada Data Twitter Komisi Pemberantasan Korupsi Republik Indonesia. *Jurnal Ilmiah Edutic*, 7(1), 6–7.
- Febriyani, E., & Februariyanti, H. (2023). Analisis Sentimen Terhadap Program Kampus Merdeka Menggunakan Algoritma Naive Bayes Classifier Di Twitter. *Jurnal Tekno Kompak*, 17(1).
- Guo, W., Wang, G., Wang, C., & Wang, Y. (2023). Distribution network topology identification based on gradient boosting decision tree and attribute weighted naive Bayes. *Energy Reports*, 9, 727–736. <https://doi.org/10.1016/j.egyr.2023.04.256>

- Anshor, A., & Safuwani, A. (2023). Analisis Sentimen Opini Warganet Twitter Terhadap Tes Screening Genose Pendeteksi Virus Covid-19 Menggunakan Metode Naïve Bayes Berbasis Particle Swarm Optimization. *Jinteks*, 5(1), 170–178.
- Hendrastuty, N., Isnain, A., & Rahmadhani, A. (2021). Analisis Sentimen Masyarakat Terhadap Program Kartu Prakerja Pada Twitter Dengan Metode Support Vector Machine. *Electronic Journal Politeknik Harapan Bersama Tegal*, 6(3), 154–155. <http://situs.com>
- Irvani A. (2023). Penggunaan Gaya Bahasa Sinisme Dan Sarkasme Oleh Netizen Indonesia Di Twitter. Skripsi Thesis, Universitas Hasanuddin. , 2–5.
- Jakkula, V. (2006). Tutorial on Support Vector Machine (SVM). School of EECS, 4–5.
- Jannah, P. M. (2021). Pelecehan Seksual, Seksisme dan Bystander. *Psikobuletin: Buletin Ilmiah Psikologi*, 2(1), 61. <https://doi.org/10.24014/pib.v2i1.12023>
- Sulaiman, J., Baehaqi, F., Cahyono, N. (2024). Analisis Sentimen Terhadap Cyberbullying Pada Komentar di Instagram Menggunakan Algoritma Naïve Bayes. *Indonesian Journal of Computer Science*, 13 No.1, 1054.
- Legowo, R. S. (2023). Ketika Penyebaran Berita Palsu Melahirkan Industri Baru: Studi Kasus Drone Emprit. *Journals Ums, Vol 15 No 1*, 76–78. <https://journals.ums.ac.id/index.php/komuniti/article/view/20053>
- Martínez-Bacaicoa, J., Real-Brioso, N., Mateos-Pérez, E., & Gámez-Guadix, M. (2024). The role of gender and sexism in the moral disengagement mechanisms of technology-facilitated sexual violence. *Computers in Human Behavior*, 152, 2–5. <https://doi.org/10.1016/j.chb.2023.108060>
- Parapat, I., & Furqon, M. (2018). Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(10), 3163–3169. <http://j-ptiik.ub.ac.id>
- Muhammadi, R. H., Laksana, T. G., & Arifa, A. B. (2022). Combination of Support Vector Machine and Lexicon-Based Algorithm in Twitter Sentiment Analysis. *Journals Ums, Vol 8 No 1*, 61. <https://github.com/evanmartua34/>
- Putri. (2022). Hate Speech Detection On Indonesia Language Twitter Using The Naïve Bayes Algorithm. *Ejurnal.Umri.Ac.Id*, 3–4.
- Pimentel, J. S., Ospina, R., & Ara, A. (2024). A novel fusion Support Vector Machine integrating weak and sphere models for classification challenges with massive data. *Decision Analytics Journal*, 11, 2–4. <https://doi.org/10.1016/j.dajour.2024.100457>
- Prakash, T. N., & Aloysius, A. (2019). Data Preprocessing In Sentiment Analysis Using Twitter Data. *International Educational Applied Research Journal (Iearj)*, 3(7), 91.
- Prihambodo, B., Wildan F Y, A., Prayoga, E., & Jaffar, A. (2023). Klasifikasi Kualitas Air Sungai Berbasis Teknik Data Mining Dengan Metode K-Nearest Neighbor (K-



NN). Emitter: Jurnal Teknik Elektro, 1(1), 31–36.  
<https://doi.org/10.23917/emitor.v1i1.20833>

Putra, F., Tahiyat, H. F., Ihsan, R. M., Rahmaddeni, R., & Efrizoni, L. (2024). Penerapan Algoritma K-Nearest Neighbor Menggunakan Wrapper Sebagai Preprocessing untuk Penentuan Keterangan Berat Badan Manusia. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(1), 273–281. <https://doi.org/10.57152/malcom.v4i1.1085>

Rasiban, J., & Maruli, S. (2023). Penerapan Data Mining Untuk Memprediksi Penerimaan Peserta Didik Baru. *INNOVATIVE: Journal Of Social Science Research*, 3, 10065–10079.

Riadi, I., Fadlil, A. (2023). Identifying Hate Speech in Tweets with Sentiment Analysis on Indonesian Twitter Utilizing Support Vector Machine Algorithm. *Journals Ums*, 9(2), 179–181.

Rininda, G., Santi, I. H., & Kirom, S. (2023). Penerapan Svm Dalam Analisis Sentimen Pada Edlink Menggunakan Pengujian Confusion Matrix. *Jurnal Mahasiswa Teknik Informatika*, 7(5).

Saif, H., Fernandez, M., He, Y., & Alani, H. (2014). On stopwords, filtering and data sparsity for sentiment analysis of Twitter Conference or Workshop Item On Stopwords, Filtering and Data Sparsity for Sentiment Analysis of Twitter. *European Language Resources Association (ELRA)*, 810–817. <http://rec2014.lrec-conf.org/en/>

Sano, A. V. D., Stefanus, A. A., Madyatmadja, E. D., Nindito, H., Purnomo, A., & Sianipar, C. P. M. (2023). Proposing a visualized comparative review analysis model on tourism domain using Naïve Bayes classifier. *Procedia Computer Science*, 227, 482–489. <https://doi.org/10.1016/j.procs.2023.10.549>

Santoso, H., Putri, R. A., & Sahbandi, S. (2023). Deteksi Komentar Cyberbullying pada Media Sosial Instagram Menggunakan Algoritma Random Forest. *Jurnal Manajemen Informatika (JAMIKA)*, 13(1), 62–72. <https://doi.org/10.34010/jamika.v13i1.9303>

Septiawan, Y. (2023). Perbandingan Akurasi Metode Deteksi Ujaran Kebencian dalam Postingan Twitter Menggunakan Metode SVM dan Decision Trees yang Dioptimalkan dengan Adaboost. *IJCCS*, x, No.x, 1–5.

Mawarni, U. (2023). Medical External Wound Image Classification Using Support Vector Machine Technique. *Journals Ums*, 9(2), 100–101. [www.kaggle.com](http://www.kaggle.com)

Sulatri, N. L. P. A. (2021). Ujaran Seksisme Yoshiro Mori: Persoalan Stereotip Gender Pada Olimpiade Tokyo. *KIRYOKU*, 5(2), 265–271. <https://doi.org/10.14710/kiryoku.v5i2.265-271>

Suryati, E., Ari Aldino, A., Suryati, E. (2023). Analisis Sentimen Transportasi Online Menggunakan Ekstraksi Fitur Model Word2vec Text Embedding Dan Algoritma

Support Vector Machine (SVM). *JURNAL Teknologi Dan Sistem Informasi (JTISI)*, 4(1), 96–106. <https://doi.org/10.33365/jtsi.v4i1.2445>

Wijaya, B., & Mawardi, V. C. (2023). Pendeteksi Ujaran Kebencian Pada Platform Media Sosial Twitter Menggunakan Support Vector Machine. *Teknik Dan Kedokteran*, 1(1), 11–17. <https://doi.org/10.24912/jsstk.v1i1.22746>

Yolanda Paramitha, N., Nuryaman, A., Faisol, A., Setiawan, E., Dina Eka Nurvazly, dan, Matematika, J., Mipa, F., Lampung Jl Soemantri Brojonegoro No, U., Lampung, B., Kunci, K., & Bayes, N. (2023). Klasifikasi Penyakit Stroke Menggunakan Metode Naïve Bayes. *Jurnal Siger Matematika*, 04(01), 12–13. <https://www.kaggle.com/datasets/zzettrkalpakbal/full-filled->