

TESIS

**ANALISIS SENTIMEN CYBERBULLYING PADA KOMENTAR
INSTAGRAM MENGGUNAKAN NAIVE BAYES DAN SUPPORT
VECTOR MACHINE**



Disusun oleh:

Nama : Selamat Riadi
NIM : 21.52.2120
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2024

TESIS

**ANALISIS SENTIMEN CYBERBULLYING PADA KOMENTAR
INSTAGRAM MENGGUNAKAN NAIVE BAYES DAN SUPPORT
VECTOR MACHINE**

**SENTIMENT ANALYSIS OF CYBERBULLYING ON INSTAGRAM
COMMENTS USING NAIVE BAYES AND SUPPORT VECTOR
MACHINE**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Selamat Riadi
NIM : 21.52.2120
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA
YOGYAKARTA**

2024

HALAMAN PENGESAHAN

**ANALISIS SENTIMEN CYBERBULLYING PADA KOMENTAR INSTAGRAM
MENGUNAKAN NAIVE BAYES DAN SUPPORT VECTOR MACHINE**

**SENTIMENT ANALYSIS OF CYBERBULLYING ON INSTAGRAM COMMENTS
USING NAIVE BAYES AND SUPPORT VECTOR MACHINE**

Diperiapkan dan Disusun oleh

Selamet Riadi

21.52.2120

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Senin, 04 Maret 2024

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer

Yogyakarta, 04 Maret 2024

Rektor

Prof. Dr. M. Suyanto, M.M.
NIK. 190302001

HALAMAN PERSETUJUAN

ANALISIS SENTIMEN CYBERBULLYING PADA KOMENTAR INSTAGRAM MENGUNAKAN NAIVE BAYES DAN SUPPORT VECTOR

SENTIMENT ANALYSIS OF CYBERBULLYING ON INSTAGRAM COMMENTS USING NAIVE BAYES AND SUPPORT VECTOR MACHINE

Dipersiapkan dan Disusun oleh

Selamet Riadi

21.52.2120

Telah Ditujikan dan Dipertahankan dalam Sidang Ujian Tesis
Program Studi S2 Teknik Informatika
Program Pascasarjana Universitas AMIKOM Yogyakarta
pada hari Senin, 04 Maret 2024

Pembimbing Utama

Prof. Dr. Ema Utami, S.Si., M.Kom
NIK. 190302037

Pembimbing Pendamping

Ainul Yaqin, M.Kom
NIK. 190302255

Anggota Tim Penguji

Dr. Kumara Ari Yuana, S.T., M.T
NIK. 0

Dhani Ariatmanto, M.Kom., Ph.D
NIK. 190302197

Prof. Dr. Ema Utami, S.Si., M.Kom
NIK. 190302037

Tesis ini telah diterima sebagai salah satu persyaratan
untuk memperoleh gelar Magister Komputer.

Yogyakarta, 04 Maret 2024

Direktur Program Pascasarjana

Prof. Dr. Kusriani, M.Kom.
NIK. 190302106

HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Selamat Riadi
NIM : 21.52.2120
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:
Analisis Sentimen Cyberbullying Pada Komentar Instagram Menggunakan Naïve Bayes dan Support Vector Machine

Dosen Pembimbing Utama : Prof. Dr. Erna Utami, S.Si., M.Kom
Dosen Pembimbing Pendamping : Ainul Yaqin, M.Kom

1. Karya tulis ini adalah benar-benar *REAL* dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 04 Maret 2024

Yang Menyatakan,



METERAI TEMPEL
AAAFALX039762207

Selamat Riadi

HALAMAN PERSEMBAHAN

Dengan penuh rasa senang dan bangga saya persembahkan tesis ini kepada kedua orang tua saya, yang telah sepenuhnya mendukung, mendoakan, dan memberikan bantuan lainnya hingga saya dapat menyelesaikan penelitian tesis saya ini, yang menurut saya penuh pengorbanan dan desikasi yang sangat amat tinggi. Ini adalah buah dari perjuangan yang kadang membuat saya teseok, namun bangkit lagi, untuk terus memperjuangkan tesis ini. Alhamdulillah sekang saya bisa menyelesaikannya.

Kemudian teruntuk dosen pembimbing saya yang telah membimbing saya untuk menyelesaikan tesis ini, terimakasih atas sumbangsih ilmu yang telah dialirkan kepada saya dalam perjalanan saya menuntut ilmu sangat banyak dan bermanfaat untuk saya dan semoga untuk orang banyak aamiin, sekali lagi terimakasih banyak dan sebesar-besarnya. Dan juga kepada teman – teman seperjuangan saya yang telah selalu menjadi motivasi untuk segera dan secepatnya menyelesaikan tesis ini.

Selanjutnya teruntuk diri saya pribadi, saya ingin mengatakan “I am proud of you”, terimakasih telah berjuang, mempertaruhkan banyak hal, mempertaruhkan waktu yang begitu banyak, untuk digunakan menyelesaikan tesis ini, terimakasih telah cukup baik dalam memanager waktu mu.

HALAMAN MOTTO

“Segala pencapaian butuh perjuangan dan pasti ada yang harus
dipertaruhkan”

“Berani aja dulu”

“Tidak ada yang tidak bisa, asalkan tidak berhenti
diperjuangkan”



KATA PENGANTAR

Puji syukur kehadirat Allah SWT. Dengan izin Allah hingga saya bisa menyelesaikan tesis ini. Penulisan tesis ini dapat terselesaikan berkat bantuan dari banyak pihak. Oleh karena itu penulis mengucapkan terimakasih kepada pihak-pihak yang terlibat dalam penelitian ini :

1. Prof. Dr. M. Suyanto, MM. selaku Rektor Universitas AMIKOM Yogyakarta.
2. Ibu Prof. Dr. Kusriani, M.Kom. selaku Direktur Program Pascasarjana Universitas AMIKOM Yogyakarta.
3. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom. selaku Wakil Direktur Program Pascasarjana Universitas AMIKOM Yogyakarta sekaligus selaku Pembimbing Utama.
4. Bapak Ainul Yaqin, M.Kom selaku dosen pembimbing pendamping

Penulis mengakui bahwa dalam penyusunan tugas akhir ini masih ada kekurangan dan keterbatasan. Oleh karena itu, penulis berharap mendapatkan masukan yang membangun agar tulisan ini dapat memberikan manfaat untuk perkembangan ilmu pengetahuan di masa yang akan datang.

Yogyakarta, 04 Maret 2024


Penulis

DAFTAR ISI

HALAMAN JUDUL.....	II
HALAMAN PENGESAHAN.....	III
HALAMAN PERSETUJUAN.....	IV
HALAMAN PERNYATAAN KEASLIAN TESIS.....	V
HALAMAN PERSEMBAHAN.....	VI
HALAMAN MOTTO.....	VII
KATA PENGANTAR.....	VIII
DAFTAR ISI.....	IX
DAFTAR TABEL.....	XII
DAFTAR GAMBAR.....	XIII
DAFTAR ISTILAH.....	XIV
INTISARI.....	XV
<i>ABSTRACT</i>	XVI
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah.....	7
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	8
BAB II TINJAUAN PUSTAKA.....	9
2.1. Tinjauan Pustaka.....	9

2.2. Kerealan Penelitian	12
2.3. Landasan Teori.....	15
2.3.1 Natural Langue Processing (NLP).....	15
2.3.2 Analysis sentiment.....	15
2.3.3 Cyberbullying.....	16
2.3.4 Preprocessing.....	16
2.3.5 Feature Extraction.....	18
2.3.6 Bag of Words.....	19
2.3.7 Term Frequency – Inverse Document Frequency TF-IDF	20
2.3.8 N-gram.....	22
2.3.9 Feature Selection.....	23
2.3.10 Metode Support Vector Machine.....	25
2.3.11 Nive Bayes Classifier.....	27
BAB III METODE PENELITIAN	30
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	30
3.2. Metode Pengumpulan Data.....	31
3.3. Metode Analisis Data.....	31
3.4. Dataset.....	32
3.5. Alur Penelitian.....	39
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	45
4.1. Kondisi Dataset.....	45
4.2. Vektorisasi data.....	46
4.3. Model Naive Bayes.....	54

4.3.1 Skenario Pengujian Model Naive Bayes.....	55
4.4. Model Support Vector Machine.....	72
4.5. Analisis hasil klasifikasi	89
4.6. Perbandingan Dengan Penelitian Sebelumnya	94
BAB V PENUTUP.....	97
5.1. Kesimpulan.....	97
5.2. Saran.....	101
DAFTAR PUSTAKA.....	104



DAFTAR TABEL

Tabel 2.1 Matriks Literature Review	12
Tabel 3.1 Sample Dataset.....	34
Tabel 3.2 Proses preprocessing	37
Tabel 4.1 Skenario Model GNB	55
Tabel 4. 2 Hasil Skenario 1 Model GNB	57
Tabel 4. 3 Hasil Skenario 2 Model GNB.....	59
Tabel 4.4 Hasil Skenario 3 Model GNB.....	60
Tabel 4.5 Hasil Skenario 4 Model GNB.....	63
Tabel 4.6 Hasil Kinerja Skenario 6 Model GNB.....	67
Tabel 4.7 Hasil klasifikasi algoritma Gaussian Naive Bayes	69
Tabel 4.8 Rancangan Skenario Model SVM.....	73
Tabel 4.9 Hasil kinerja Skenario 1 Model SVM.....	74
Tabel 4. 10 Hasil kinerja Skenario 2 Model SVM.....	76
Tabel 4. 11 Hasil kinerja Skenario 3 Model SVM.....	78
Tabel 4.12 Hasil Kinerja Skenario 4 Model SVM.....	80
Tabel 4.13 Hasil Skenario 5 Model SVM.....	83
Tabel 4.14 Hasil Kinerja Skenario 6 Model SVM.....	85
Tabel 4.15 Performa evaluasi algoritma Support Vector Machine	86
Tabel 4.16 Perbandingan Dengan Penelitian Sebelumnya	95

DAFTAR GAMBAR

Gambar 1.1 Data Penggunaan Internet dan Media Social di Indonesia.....	2
Gambar 3. 1 Alur Preprocessing.....	39
Gambar 3. 2 Alur Penelitian.....	40
Gambar 4.1 Persentase Komentar non-bullying dan bullying.....	45
Gambar 4.2 Sintak Model Bag of Words.....	47
Gambar 4.3 Hasil Bag of Words.....	48
Gambar 4.4 Sintak Vectorisasi Kata Dengan TF-IDF.....	49
Gambar 4. 5 Hasil vectorisasi dengan TF-IDF.....	50
Gambar 4. 6 Sintak Pembobotan Kata dengan N-gram dan TF-IDF.....	52
Gambar 4.7 Hasil Pembobotan kata dengan N-gram dan TF-IDF.....	53
Gambar 4.8 Grafik kinerja Evaluasi GNB skenario 1.....	58
Gambar 4. 9 Grafik Kinerja Evaluasi GNB skenario 2.....	60
Gambar 4.10 Grafik kinerja Evaluasi GNB skenario 3.....	62
Gambar 4.11 Grafik Kinerja Evaluasi GNB Skenario 4.....	64
Gambar 4.12 Grafik Kinerja Evaluasi GNB Skenario 5.....	66
Gambar 4.13 Grafik Kinerja Evaluasi GNB Skenario 6.....	69
Gambar 4.14 Grafik Kinerja Evaluasi GNB.....	72
Gambar 4.15 Grafik Kinerja Evaluasi SVM Skenario 1.....	75
Gambar 4. 16 Grafik Kinerja Evaluasi SVM Skenario 2.....	77
Gambar 4.17 Grafik Kinerja Evaluasi SVM Skenario 3.....	80
Gambar 4.18 Gambar Kinerja Evaluasi SVM Skenario 4.....	82
Gambar 4.19 Grafik Kinerja Evaluasi SVM Skenario 5.....	84
Gambar 4.20 Grafik Kinerja Evaluasi SVM Skenario 6.....	86
Gambar 4.21 Grafik Kinerja Evaluasi SVM.....	89
Gambar 4.22 Grafik Pengujian Model.....	89

DAFTAR ISTILAH

Cyberbullying merupakan aksi perundungan, merendahkan, melecehkan orang dimedia social, salah satunya menggunakan teks yang bisa menyerang sikis, dan keperibadian seseorang, tanpa menggunakan fisik.

Akurasi merupakan ukuran angka persentase yang biasanya dimulai dari 1 sampai 100 persen.



INTISARI

Dalam beberapa dekade terakhir, internet telah menjadi bagian yang tidak dapat dipisahkan dari kehidupan manusia, menyediakan kemudahan akses dan kemudahan lainnya. Salah satu platform internet yang digunakan secara luas oleh masyarakat terutama di Indonesia adalah media sosial instagram. Meskipun memiliki dampak positif, tidak bisa dipungkiri bahwa ada konsekuensi negatif jika tidak digunakan dengan benar. Salah satu konsekuensi tersebut adalah peningkatan aktivitas perundangan daring di media sosial. Perundangan daring menjadi sorotan utama, hal tersebut mendorong peneliti untuk melakukan penelitian setidaknya menjadi solusi untuk dapat menganalisis cyberbullying, terutama di komentar platform media sosial instagram.

Penelitian ini menggunakan analisis sentimen untuk melakukan identifikasi atau klasifikasi komentar cyberbullying khususnya pada komentar instagram, menggunakan teknik pemrosesan bahasa alami dan analisis teks. Penelitian ini membandingkan kinerja algoritma Naive Bayes (Gaussian Naive Bayes) dan algoritma Support Vector Machine (SVM). Model vektorisasi, khususnya Bag of Words dan TF-IDF, bersama dengan pemilihan fitur (χ^2), digunakan untuk mengoptimalkan akurasi klasifikasi komentar. Hasil eksperimen disajikan dalam 6 skenario.

Akurasi tertinggi dicapai pada skenario keenam Gaussian Naive Bayes dan SVM sama – sama mencapai akurasi sebesar 93.84 %, namun hasil evaluasi kinerja berbeda GNB dengan presisi 100.00 %, recall 88.06 %, dan f1-score 91.33 %. Sementara SVM mendapatkan presisi 95.38 % lebih rendah dengan selisih 04.62 % , untuk recall 92.53 % dengan selisih 04.47 % dan f1-score 93.93 % dengan selisih 02.06 % Terlihat hasil evaluasi kinerja SVM lebih seimbang.

Kata kunci: Cyberbullying, BoW, TF-idf, Chi-square, GNB, SVM

ABSTRACT

In the past few decades, the internet has become an inseparable part of human life, providing ease of access and various conveniences. One widely used internet platform, especially in Indonesia, is the social media platform Instagram. Despite its positive impacts, it cannot be denied that there are negative consequences if not used correctly. One of these consequences is the increase in online bullying activities on social media. Online bullying has become a major concern, prompting researchers to conduct studies, at the very least, to find solutions for analyzing cyberbullying, especially in the comments section of the Instagram social media platform.

This research employs sentiment analysis to identify or classify cyberbullying comments, particularly on Instagram, using natural language processing techniques and text analysis. The study compares the performance of the Naive Bayes algorithm (Gaussian Naive Bayes) and the Support Vector Machine (SVM) algorithm. Vectorization models, specifically Bag of Words and TF-IDF, along with chi-square, are utilized to optimize the accuracy of comment classification. The experimental results are presented in six scenarios.

The highest accuracy was achieved in the sixth scenario, where Gaussian Naive Bayes and SVM both reached an accuracy of 93.84%. However, the performance evaluation results differ. GNB showed a precision of 100.00%, recall of 88.06%, and an F1-score of 91.33%. Meanwhile, SVM exhibited a precision of 95.38%, which is 4.62% lower, recall of 92.53%, which is 4.47% higher, and an F1-score of 93.93%, which is 2.60% higher. It is evident that the performance evaluation of SVM is more balanced.

Keyword: Cyberbullying, BoW, Tf-idf, Chi-square, GNB, SVM

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Teknologi telah menjadi bagian yang sulit dipisahkan dalam kehidupan masyarakat hari ini. Banyaknya dampak positif teknologi seperti keterbukaan akses dan kemudahan instan yang diperoleh dari perkembangan teknologi menjadikan masyarakat semakin nyaman dalam memanfaatkan kemajuan teknologi. Akan tetapi disisi lain terdapat dampak negative juga dari perkembangan teknologi. berbagai variasi masyarakat dalam mengelaborasi kemajuan teknologi informasi dapat dianalisis dari berbagai jenis informasi yang disebarkan dengan cepat melalui berbagai macam platform internet, salah satu yang paling umum digunakan adalah platform media social.

Informasi dari lembaga *We are Social* memaparkan bahwa di permulaan tahun 2022, pengguna internet dan social media di Indonesia mengalami peningkatan. Hal ini ditunjukkan pada gambar 1.1 Data Penggunaan Internet dan Media Social di Indonesia.



Gambar 1.1 Data Penggunaan Internet dan Media Social di Indonesia

Berdasarkan data yang dikeluarkan oleh lembaga *we are social* pada gambar 1.1 menunjukkan bahwa pengguna internet di Indonesia mencapai 204,7 juta orang mengalami kenaikan dari tahun sebelumnya sebesar 1%. Sementara untuk pengguna media social aktif sebanyak 191,4 juta jiwa. Angka ini mengalami peningkatan yang cukup signifikan dari tahun sebelumnya sebesar 12,6 %. Sehingga dapat dikongklusikan bahwa persentasi pengguna internet di Indonesia sebesar 73,7 % , peningkatan penggunaan internet dan media social ini berdampak positif terhadap kehidupan masyarakat seperti, masyarakat bisa lebih mudah dan cepat mendapatkan informasi yang dibutuhkan dari internet atau media social, menunjang aktivitas bisnis, berinteraksi jarak jauh yang semakin mudah, dan lain – lain. Akan tetapi, tidak dapat dipungkiri bahwa peningkatan penggunaan internet ini juga berkonsekuensi negative pada prilaku dimedia social, salah satu dampak negatifnya yaitu aksi *cyberbullying* atau jika diterjemahkan kedalam bahasa Indonesia yaitu perundungan siber.

Cyberbullying merupakan tindakan perundukan yang dilakukan oleh seseorang dengan menggunakan media internet, dengan berbasis pada situs atau *platform* jejaring social (Marsinun & Riswanto, 2020). Aksi bullying yang ditunjukkan dalam survey yang dilakukan oleh APJII, yang menemukan bahwa 49 persen pengguna internet melaporkan telah diintimidasi, diejek, atau dilecehkan di media sosial. survei ini juga menemukan bahwa 31,6% korban bullying membiarkan tindakan tersebut sekitar 7,9% yang merespon, sekitar 5,2% yang menghapus hinaan tersebut, sementara hanya 3,6% yang melaporkan tindakan tersebut ke pihak berwajib (APJII, 2020).

Pemaparan data hasil survey yang dilakukan oleh APJII tersebut tentunya menggambarkan banyak masyarakat yang mengalami *cyberbullying* di media sosial. ini tentunya bisa berdampak besar jika tidak ada upaya tindakan yang dilakukan, salah satunya dalam bidang penelitian misalnya, seperti upaya mengidentifikasi atau menganalisis teks pada komentar instagram yang mengandung unsur *cyberbullying* maupun non-*cyberbullying* menggunakan teknik Analisis sentimen dengan algoritma-algoritma tertentu yang efektif.

Analisis sentimen, juga disebut sebagai *opinion mining*, adalah bidang studi yang menganalisis pendapat, sentimen, penilaian, sikap, dan emosi orang terhadap entitas dan atribut yang dinyatakan dalam teks yang ditulis (Liu, 2015). Berdasarkan hal tersebut analisis sentimen dapat digunakan dalam penelitian ini untuk mengidentifikasi teks yang memiliki potensi *cyberbullying* dengan metode klasifikasi yang digunakan yaitu *Support Vector Machine* dan *Naïve Bayes* ,

sehingga diharapkan penelitian ini memberikan kontribusi dalam dunia penelitian terkhususnya terkait analisis sentiment *cyberbullying*.

Penelitian – penelitian terdahul telah menunjukkan bahwa analisis sentiment dan menggunakan algoritma – algoritma klasifikasi telah banyak digunakan. Beberapa penelitian terdahulu yang relevan dengan penelitian ini yaitu penelitian yang dilakukan oleh (M. F. Rizki et al., 2021) pada penelitian tersebut dilakukan proses analisis sentiment *cyberbullying* yang diunggah oleh pengguna pada media sosial twitter dengan mengembangkan system berbasis web untuk mengklasifikasi tweet yang mengandung unsur *cyberbullying* atau Non-*cyberbullying* menggunakan *Support Vector Machine*. Penelitian ini memperoleh hasil akurasi pengukuran evaluasi klasifikasi menggunakan metode confusion matrix dengan nilai recall 64%, precision 58% dan tingkat accuracy sebesar 70%.

Kemudian penelitian yang dilakukan oleh (Khadafi et al., 2022) dimana tujuan penelitiannya untuk menganalisis sentiment pada komentar Twitter untuk mengklasifikasikan tweet yang mengandung *cyberbullying* atau *non-cyberbullying* dengan metode penelitian dalam penelitian ini adalah diskriptif kualitatif dengan dengan algoritma *naive bayes* dan *lexicon Based* yang dimana hasil penelitian ini menghasilkan performansi dari *Naive Bayes Clasifier* dengan akurasi 80 %, dengan *Lexicon Based* sebesar 22 %. Dari hasil tersebut peneliti menyimpulkan bahwa *Naive Bayes Clasifier* lebih baik dan lebih akurat dari pada *Lexicon Based*.

Terdapat juga penelitian yang dilakukan oleh (Hafidz et al., 2020) dimana penelitian tersebut mencoba menggunakan dua algoritma untuk melakukan klasifikasi yaitu *Supprot Vector Machine* dan *Nive Bayes*, dimana hasil akurasi

yang diperoleh algoritma *Nive Bayes* sebesar 78,02% dan AUC 0,714, sedangkan *Support Vector Machine* menghasilkan akurasi sebesar 80,23% dan AUC 0,904. Penelitian ini juga melakukan optimasi dengan *Particle Swarm Optimization* (PSO), pada algoritma *Naïve bayes* sehingga dengan hasil akurasi 79,07% dan AUC 0,729, sedangkan pada algoritma *Support Vector Machine* setelah dilakukan optimasi dengan PSO menghasilkan akurasi sebesar 81,16% dan AUC 0,903. dari hasil tersebut disimpulkan bahwa algoritma *Support Vector Machine* selalu dapat menghasilkan akurasi yang lebih tinggi baik saat dilakukan optimasi ataupun tidak.

Peneleitian yang dilakukan oleh (Naf'an, Bimantara, et al., 2019) dimana penelitian ini bertujuan untuk membuat sebuah system yang bisa melakukan klasifikasi komentar yang mengandung unsur *cyberbullying* atau *non-cyberbullying*. Algoritma yang digunakan untuk klasifikasi dalam penelitian ini adalah algoritma *Nive Bayes Classifier* kemudian untuk pembobotan katanya menggunakan TFIDF dan untuk evaluasi dan pengujiannya menggunakan metode *K-Fold Cross Validation*. Hasil eksperimen terbaik berhasil mencapai akurasi sebesar 83,53% dengan menggunakan stemming dalam prosesnya.

Dalam penelitian yang dilakukan oleh (Maulana et al., 2020) penelitian tersebut menggunakan algoritma *Naïve Bayes*, yang dimana data dalam penelitian ini diambil dari akun yang sering mengunggah tweet yang berkaitan dengan politik dengan memanfaatkan twitter API. Dimana Pada data uji tweet yang tidak mengandung cyber bullying diberi label positif, sedangkan tweet yang mengandung cyber bullying diberi label negatif. Hasil pengujian dengan data uji real time pada tanggal 12 Mei 2020 pukul 01.00 WIB mendapatkan nilai akurasi sebesar 76%.

Kemudian sebuah penelitian yang dilakukan oleh (Atoum, 2020) dimana penelitiannya menggunakan model analysis sentiment untuk mengidentifikasi teks cyberbullying pada media social twitter, algoritma yang digunakan adalah *Support Vector Machine* (SVM) dan *Naïve Bayes*, Hasil dari pada model yang digunakan menyimpulkan bahwa klasifikator SVM memiliki ukuran kinerja yang lebih baik daripada klasifikator NB, namun penelitian tersebut tidak menggunakan feature

selection yang berpotensi memiliki pengaruh terhadap akurasi klasifikasi yang dilakukan.

Dari pemaparan diatas peneliti akan melakukan penelitian tentang analisis sentiment cyberbullying menggunakan metode klasifikasi *machine learning* seperti Support Vector Machine dan Naïve Bayes, kemudian menggunakan model feature extraction yaitu Bag of Words dan TF-IDF dan juga mencoba mengimplementasikan fitur seleksi untuk upaya meningkatkan akurasi klasifikasi dari algoritma yang digunakan. Maka dari itu peneliti melakukan penelitian dengan judul "Analisis Sentimen Cyberbullying Pada Komentar Pengguna Instagram Menggunakan Naïve Bayes Dan Support Vector Machine" dengan dilakukannya penelitian ini diharapkan dapat diketahui tingkat akurasi dari algoritma yang digunakan dan seberapa tingkat kemampuan dari algoritma yang digunakan dalam mengklasifikasi teks yang terdapat unsur bullying atau non-bullying.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang sudah dipaparkan sebelumnya, maka rumusan permasalahan dari penelitian ini adalah sebagai berikut :

- a. Bagaimana metode klasifikasi komentar bullying dan non-bullying instagram yang dibangun menggunakan algoritma *Naive Bayes* dan *Support Vector Machine* ?
- b. Berapakah nilai kinerja (akurasi, presisi, *recall*, dan *f1 score*) yang diperoleh oleh model ketika menggunakan setiap feature extraction (Bag of Words dan TF-IDF) ?
- c. Apakah teknik feature selection *Chi-square* dapat meningkatkan akurasi klasifikasi algoritma Naïve Bayes dan Support Vector Machine ?

1.3. Batasan Masalah

Batasan masalah pada penelitian ini adalah sebagai berikut:

- a. Berfokus pada algoritma Naïve Bayes dan Support Vector Machine sebagai model pengklasifikasian komentar bullying dan non-bullying.
- b. Memanfaatkan dataset yang sudah dikumpulkan sebelumnya yang terdiri dari teks komentar Instagram yang sudah dikategorikan sebagai bullying dan non-bullying.
- c. Menerapkan feature extraction seperti Bag of Words dan TF-IDF termasuk ngram, bertujuan untuk mengubah teks komentar menjadi representasi fitur numerik yang dapat dimanfaatkan oleh Naïve Bayes dan Support Vector Machine.
- d. Menerapkan feature selection chi-square untuk memilih subset fitur yang memiliki informasi paling penting dan relevan.
- e. Melakukan evaluasi kinerja metode klasifikasi memanfaatkan matrik evaluasi seperti akurasi, presisi, *recall* dan *f1 score*. Perbandingan kinerja antara Naïve Bayes dan Support Vector Machine akan dievaluasi ketika diterapkan feature extraction, kemudian sebelum dan setelah penerapan feature selection.

1.4. Tujuan Penelitian

Penelitian ini dilakukan bertujuan untuk mencapai beberapa tujuan berikut ini:

- a. Menguji dan mengevaluasi akurasi algoritma Naïve Bayes dan Support Vector Machine dalam mengklasifikasi komentar bullying atau non-bullying.

- b. Mengetahui hasil perbandingan akurasi model vectorisasi yang digunakan yaitu Bag of Words dan TF-IDF ketika diterapkan pada algoritma klasifikasi Naïve Bayes dan Support Vector Machine untuk klasifikasi komentar bullying atau non-bullying.
- c. Mengidentifikasi pengaruh penerapan fitur seleksi terhadap hasil akurasi algoritma Naïve Bayes dan Support Vector Machine.

1.5. Manfaat Penelitian

Penelitian ini dilakukan diharapkan dapat memberikan manfaat sebagai berikut:

- a. Diharapkan penelitian ini dapat memberikan edukasi tentang komentar cyberbullying atau non-cyberbullying dimedia social Instagram.
- b. Diharapkan Rancangan model klasifikasi dengan algoritma yang diterapkan mempermudah dalam pengklasifikasian teks dengan tingkat akurasi yang baik.
- c. Diharapkan penerapan model algoritma yang diterapkan dalam penelitian ini dapat dijadikan referensi untuk penelitian selanjutnya sebagai tambahan ilmu pengetahuan baru

BAB II

TINJAUAN PUSTAKA

2.1. Tinjauan Pustaka

Peninjauan pustaka dilakukan oleh peneliti sebelum melakukan penelitian tentang sentiment analysis *cyberbullying* dengan melakukan tinjauan pustaka terkait penelitian-penelitian terdahulu yang relevan untuk dijadikan panduan atau referensi dalam pengembangan penelitian yang akan dilakukan. dari tinjauan pustakan yang dilakukan oleh peneliti ditemukan beberapa penelitian sebelumnya yang berkaitan dan relevan dengan penelitian yang akan dilakukan.

Seperti penelitian yang dilakukan oleh (Atoum, 2020), menyajikan penelitian yang menunjukkan implementasi metode analisis sentimen dalam mendeteksi *cyberbullying* di media sosial. Peneliti mengevaluasi tonalitas atau emosi dari konten dan mengklasifikasikan konten sebagai *bully* atau tidak. Hasil dari penelitian menunjukkan bahwa analisis sentimen dapat digunakan sebagai metode efektif dalam mendeteksi *cyberbullying* di media social dan algoritma SVM menunjukkan hasil akurasi klasifikasi yang lebih tinggi yaitu sebesar 92,02% sementara NB menghasilkan rata-rata akurasi sebesar 81,1%. Hasil dengan akurasi tinggi yang berhasil didapatkan dalam penelitian salah satunya disebabkan oleh penerapan feature selection. Feature selection yang digunakan dalam penelitian tersebut yaitu chi-square and information gain.

Penelitian lain juga yang dilakukan oleh (Dalvi et al., 2020), membahas penelitian yang menunjukkan implementasi perangkat lunak yang dapat mendeteksi tweet yang berisi *bully* atau *cyberbullying* di platform Twitter menggunakan

metode Machine Learning (SVM dan RF). Hasil dari penelitian menunjukkan bahwa metode SVM lebih efektif dalam mengidentifikasi tweet yang berisi bully dibandingkan metode NB. Dimana akurasi yang didapatkan oleh algoritma Naive Bayes yaitu 52.70 %, sedangkan algoritma Support Vector Machine berhasil mendapatkan akurasi sebesar 71.25 %. Sementara untuk classification report yang didapatkan dari masing – masing algoritma yang digunakan yaitu untuk Naive Bayes dengan Precision sebesar 52 %, dengan Recall 52% dan F-Score 53%. Kemudiann untuk algoritma Support Vector Machine dengan Precision sebesar 71 %, dengan Recall 71% dan F-Score 70%.

(Alduailaj & Belghith, 2023) juga melakukan penelitian yang bertujuan untuk meningkatkan akurasi deteksi cyberbullying dalam bahasa Arab dan meningkatkan kinerja dan kemampuan Pemrosesan Bahasa Alami bahasa Arab. Penelitian tersebut mengkombinasikan N-gram dan Tf-idf untuk pembobotannya. Penelitian ini menggunakan algoritma SVM dan NB yang berhasil mendapatkan persentasi akurasi sebesar 95.742 %, sedangkan NB hanya menghasilkan akurasi sebesar 70.942%. Sayangnya penjelasan proses klasifikasi menggunakan algoritma NB tidak ditampilkan secara jelas dan lengkap.

Dalam penelitain lain, (W. A. Prabowo & Azizah, 2021) melakukan penelitian untuk menganalisis sentimen pada komentar yang terdapat di media sosial untuk mengetahui nilai sentimen dari komentar di platform media social, penelitian ini menggunakan TTF-IDF dan SVM sebagai model pembobotan kata dan pengklasifikasian. Penelitian ini berhasil mendapatkan akurasi dari model yang

digunakan yaitu sebesar 93%, nilai presisi sebesar 95%, dan nilai recall sebesar 97%.

(Farid & El-Tazi, 2020) dalam penelitiannya memiliki tujuan utama untuk menentukan apakah ada perlakuan buruk atau tidak dalam komentar yang ditulis di internet semacam bullying dan lain-lain. Peneliti tersebut mengusulkan algoritma yang dibangun sendiri oleh peneliti, dan mengusulkan dataset arabic moderen, egyptian arabic dialects dan emoticon yang dikombinasikan. Sebagai faktor tambahan dalam mendeteksi cyberbullying dalam penelitian tersebut yaitu emoji dan riwayat pengguna. Penelitian tersebut menyimpulkan bahwa model yang digunakan dapat menentukan dengan lebih akurat apakah komentar tersebut merupakan bully atau tidak meskipun penelitian tersebut masih mempertahankan akurasi minimal sebesar 73% untuk komentar bully.

Penelitian berikutnya yang dilakukan oleh (Afina et al., 2020) penelitian tersebut menggunakan algoritma klasifikasi SVM dan memanfaatkan informasi semantic yang diperoleh melalui embedding kata yang telah dilatih untuk mengumpulkan kata-kata yang mirip yang muncul dalam data latih untuk mengganti kata-kata yang tidak dikenal dalam data pengujian. Hasilnya yang ditunjukkan terbukti dapat meningkatkan akurasi klasifikasi sebesar 7% dari 67% menjadi 74%.

Perbedaan penelitian jika di bandingkan dengan penelitian terdahulu adalah penggunaan feature selection dimana penggunaan feature selection ini bertujuan

untuk mengetahui dan mencoba meningkatkan akurasi dari klasifikasi algoritma yang digunakan.

2.2. Kerealan Penelitian

Tabel 2.1 Matriks Literature Review
Analisis Sentimen Cyberbullying Pada Komentar Instagram Menggunakan Naive Bayes Dan Support Vector Machine

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Sentiment Analysis of Cyberbullying on Instagram User Comments	Journal Of Data Science And Its Applications	Membuat system yang bisa mengklasifikasi komentar apakah mengandung unsur <i>cyberbullying</i> atau tidak.	System yang dibangun atau digunakan berhasil mengklasifikasi komentar apakah mengandung unsur <i>cyberbullying</i> atau tidak, dengan pencapaian akurasi 83,53 %.	Dataset yang digunakan tidak seimbang dimana jumlah coment yang tidak mengandung <i>cyberbullying</i> yaitu 284, sementara yang mengandung <i>cyberbullying</i> yaitu 171 coment yang tentunya mempengaruhi kinerja atau hasil klasifikasi.	Feature extraction yang digunakan hanya tf-idf. Dalam penelitian ini akan menggunakan n-gram dan dikombinasikan dengan tf-idf kemudian dibandingkan dengan Bag of Words
2	Sentiment Analysis for Detecting Cyberbullying Using TF-IDF and SVM	RESTI Journal (System Engineering And Information Technology)	menganalisis sentimen pada komentar yang terkandung di media sosial untuk mengetahui nilai sentimen dari komentar instagram.	Penelitian tersebut menghasilkan akurasi dari model yang dibangun atau gunakan yaitu 93 %, dengan precision 95 %, dan recall 97%.	Temuan akan lebih kaya jika feature extraction yang digunakan yaitu tf-idf dikombinasikan dengan teknik yang berfokus pada pemahaman konteks text seperti N-gram.	Akan mencoba mengkombinasikan N-gram dan TF-IDF lalu membandingkannya dengan Bag of Words.

Tabel 2.2 Lanjutan Matriks Literature Review

No	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan	Tujuan Penelitian
3	Identifikasi Cyberbullying pada Kolom Komentar Instagram dengan Metode Support Vector Machine dan Semantic Similarity	J-COSINE	Bertujuan untuk meningkatkan akurasi pendeteksian cyberbullying pada komentar instagram menggunakan <i>Support Vector Machine</i> dengan memanfaatkan <i>Semantic Similarity</i> dengan harapan bisa meningkatkan hasil akurasi.	Penelitian tersebut berhasil meningkatkan akurasi deteksi cyberbullying menggunakan <i>Support Vector machine</i> dan memanfaatkan <i>Semantic Similarity</i> dengan persentasi kenaikan sebesar 7 %, dari 67 % ke 74 %.	Penggantian kata yang tidak tepat, menjadi salahsatu kelemahan dari pnerapan <i>semantic similarity</i> . Salah satu solusinya dengan memahami konteks lebih luas dengan memanfaatkan teknik N-gram.	Melakukan pendekatan yang berbeda dengan menerapkan N-gram dengan TF-IDF yang dibandingkan dengan Bag of Words dan mencrapkan feature selection.
4	Comparison Support Vector Machine and Naive Bayes Methods for Classifying Cyberbullying in Twitter	Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)	Bertujuan untuk mengklasifikasi bentuk cyberbullying di twjitter menggunakan naive bayes dan Support Vector Machine (SVM) danjuga memanfaatkan K-Fold Cross-Validation untuk mengeliminasi bias pada data.	Hasil dari penelitian tersebut menghasilkan akurasi klasifikasi dengan algoritma Naive bayes sebesar 97.99 % dan SVM sebesar 99.60 %, dapat disimpulkan klasifikasi SVM lebih baik dari NB.	Tabapan preprocessing tidak dijelaskan secara detail. Tidak dilakukan teknik pembobotan kata.	Penggunaan N-gram dengan TF-IDF akan diterapkan untuk memberikan representasi yang lebih kuat dan informatif dan akan dibandingkan dengan Bag of Words.

Tabel 2.3 Lanjutan Matriks Literature Review

No	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan	Tujuan Penelitian
5	Cyberbullying Sentiment Analysis with Word2Vec and One-Against-All Support Vector Machine	IJNMT (International Journal of New Media Technology)	Mengklasifikasi komentar toxic. Dengan memanfaatkan <i>word embedding</i> untuk melakukan analisis sentiment dengan menerapkan word2vec, kemudian metode One-Against-All (OAA) dengan model Support Vector Machine (SVM) akan digunakan untuk membuat prediksi dalam bentuk multi labelling.	Akurasi yang didapat dari model yang diterapkan dalam penelitian tersebut adalah 83,40% dan hamming loss (kekeliruan) sebesar 15,13 %.	Penelitian selanjutnya dapat membandingkan algoritma lain sebagai referensi performa algoritma mana yang lebih baik.	Sama-sama menggunakan SVM namun penelitian tersebut memanfaatkan metode OAA untuk membuat prediksi dalam bentuk multilabel . Sedangkan penelitian ini menggunakan SVM dengan Naive bayes sebagai klasifikasi dan juga fitur selection.
6.	Analisis Sentiment Cyberbullying Pada Sosial Media Twitter Menggunakan Metode Support Vector Machine	JATI (Jurnal Mahasiswa Teknik Informatika)	Mengembangkan system berbasis web untuk mengklasifikasi sentiment <i>cyberbullying</i> yang disampaikan oleh pengguna pada media social twitter menggunakan metode <i>support vector machine</i> .	Penelitian ini berhasil mendapat hasil pengukuran evaluasi klasifikasi dengan menggunakan metode confusion matrix dengan nilai recall 64%, precision 58% dan tingkat accuracy sebesar 70%.	Teknik ekstraksi fitur yang digunakan yaitu TF-IDF akan berpotensi lebih maksimal jika dikombinasikan dengan N-gram.	Akan mengkombinasikan N-gram dengan TF-IDF dan membandingkannya dengan Bag of Words. Dan akan menggunakan feature selection untuk memaksimalkan hasil akurasi.

2.3. Landasan Teori

2.3.1 Natural Language Processing (NLP)

Natural Language Processing adalah teknik komputasi yang digunakan untuk menganalisis dan merepresentasikan teks yang muncul secara alami dalam berbagai tingkatan analisis linguistik, dengan tujuan untuk mencapai pengolahan bahasa seperti manusia dalam berbagai tugas atau aplikasi. Tujuan NLP adalah untuk melakukan pemrosesan bahasa seperti manusia. Pemilihan kata 'pemrosesan' sangat sengaja dan tidak boleh diganti dengan 'pemahaman' karena meskipun tujuan akhir dari NLP adalah untuk mencapai pemahaman bahasa yang seperti manusia, teknologi saat ini belum mampu mencapai tingkat tersebut sepenuhnya (Liddy, 2001).

2.3.2 Analysis sentiment

Analisis Sentimen, yang juga disebut *opinion mining* adalah bidang studi yang mempelajari opini, perasaan, evaluasi, dan persepsi seseorang terhadap berbagai entitas seperti produk, jasa, organisasi, individu, masalah, peristiwa, dan topik, serta atribut-atributnya (Liu, 2012). Aspek penting dari analisis sentimen adalah untuk menganalisis sebuah teks untuk memahami pendapat yang diungkapkan oleh teks tersebut dan faktor lain seperti suasana hati dan cara yang digunakan dalam penyampaiannya. Secara Umum, Analisis sentimen dapat dilakukan pada berbagai tingkatan, seperti pada tingkat kalimat per kalimat, paragraf, atau dokumen secara keseluruhan. Biasanya sentimen ditentukan pada dokumen secara keseluruhan atau dengan menambahkan beberapa kalimat. Analisis

polaritas umumnya melibatkan pemberian skor untuk perasaan positif dan negatif yang dinyatakan dalam dokumen dan kemudian memberikan label pada dokumen berdasarkan skor yang didapat (Sarkar, 2016).

2.3.3 Cyberbullying

Cyberbullying adalah bentuk intimidasi yang dilakukan melalui teknologi informasi dan komunikasi, terutama internet dan telepon seluler (Dewi et al., 2020). Cyberbullying adalah tindakan negatif yang dilakukan oleh seseorang atau kelompok tertentu dengan cara mengirimkan pesan teks, foto, gambar meme, dan video ke akun media sosial seseorang dengan tujuan untuk menyindir, menghina, melecehkan, mendiskriminasi bahkan mempersekusi individu (Marsinun & Riswanto, 2020). Jenis cyberbullying yang paling umum dilakukan adalah flaming, membuat komentar kasar, menyebarkan rumor, membuat komentar yang mengancam akan melukai saat online dan memposting foto memalukan yang dilakukan secara online (Dewi et al., 2020).

2.3.4 Preprocessing

Preprocessing data adalah proses dimana menyeleksi data yang tidak sesuai dan mengubah data tersebut menjadi bentuk yang lebih mudah diproses oleh system (Muhammad et al., 2022). Preprocessing data dilakukan untuk menghilangkan data yang bising (Fransiska & Irham Gufroni, 2020). Terdapat beberapa faktor yang dapat mempengaruhi keberhasilan Machine Learning pada proyek tertentu. Salah satu faktor yang paling penting adalah data yang digunakan (kualitas data). Preprocessing

data sangat penting karena secara langsung mempengaruhi kualitas proses analisis intelektual. Jika data tidak diproses dengan benar, maka analisis yang dilakukan tidak akan menghasilkan hasil yang diharapkan, yang pada gilirannya dapat mengarah pada kesimpulan yang salah (Madrakhimov et al., 2021). Maka dengan demikian, *preprocessing* merupakan bagian yang penting dalam proses *machine learning*. Preprocessing memainkan peran yang sangat penting dan menjadi langkah pertama dalam proses text mining (Vijayarani et al., n.d.). Aktivitas pada tahap preprocessing beragam, tergantung pada data yang akan diproses dan tujuan dari pengolahan data.

1. Cleansing

Pembersingahan atau biasa dikenal dengan cleansing dalam proses preprocessing Natural Language Processing merupakan tahapan dalam proses preprocessing yang bertujuan menghilangkan non-abjad di dalam sebuah postingan dihilangkan untuk mengurangi karakter yang tidak diperlukan atau kurang relevan. Karakter-karakter ini dapat berupa angka, tanda pagar (#), simbol at (@), emoji, atau tautan dari situs web dalam postingan.

2. Tokenizing

Tokenizing merupakan proses pemisahan kata berdasarkan tiap kata yang menyusunnya menjadi potongan tunggal (Santoso & Nugroho, 2019). Tokenisasi sederhananya bertujuan untuk membagi teks menjadi bagian-bagian lebih kecil yang lebih mudah diproses oleh sistem pemrosesan bahasa alami. Token ini nantinya bisa

berupa kata-kata, frasa, simbol, tanda baca, atau elemen lain yang memiliki makna yang jelas.

3. Case Folding

Case Folding merupakan proses dimana seluruh huruf yang terdapat dalam dokumen diubah menjadi huruf kecil kemudian menghilangkan karakter selain huruf (Lahitani, 2022). Tujuannya untuk membuat data lebih mudah diolah dan memastikan bahwa hanya informasi yang relevan yang digunakan dalam analisis.

4. Stemming.

Stemming adalah salah satu langkah dalam proses ekstraksi informasi dari teks. Dalam stemming, kata-kata dalam teks dikonversi menjadi bentuk dasarnya. Ini membantu memperoleh informasi yang lebih relevan dan akurat dari teks yang sedang diproses (A. S. Rizki et al., 2019). Dengan bahasa sederhana stemming bertujuan untuk menghilangkan imbuhan – imbuhan yang biasanya terdapat diawal atau akhir kata. Contohnya, misalnya dari kata “persahabatan” dasar katanya adalah “sahabat”.

2.3.5 Feature Extraction

Dalam melakukan analisis sentimen, terdapat langkah yang dapat dilakukan adalah ekstraksi fitur. Tahap ekstraksi fitur dilakukan untuk memproses kata-kata yang menggambarkan sentimen yang terdapat dalam dataset, dan kemudian mengubahnya menjadi fitur atau aspek yang dapat digunakan dalam analisis lebih lanjut (Permataning Tyas et al., 2022).

Tahap ekstraksi fitur dengan melakukan weighting atau pembobotan fitur bertujuan untuk memberikan bobot atau nilai pada kata-kata yang terdapat dalam teks. Dalam hal ini, weighting atau pembobotan dapat membantu mengidentifikasi kata-kata yang paling penting dalam mengekspresikan sentimen yang terkandung dalam sebuah teks pendek, seperti pesan singkat atau status media sosial (Ramadhy & Sibaroni, 2022). Dapat dikatakan bahwa dengan menggunakan fitur-fitur ekstraksi yang relevan, kita dapat mengidentifikasi pola-pola dalam data yang membantu dalam memahami sentimen di balik teks tersebut.

2.3.6 Bag of Words

Bag of Words merupakan Teknik vektorisasi kata yang dimanfaatkan untuk menkonversi teks ke dalam format vector, agar dapat proses pada algoritma klasifikasi. Bag-of-words akan menggambarkan kalimat atau dokumen sebagai himpunan multiset kata-kata yang terdapat di dalamnya (Putri et al., n.d.). Bag of Words merupakan bentuk representasi kalimat yang mencerminkan keberadaan kata-kata dalam suatu kalimat. Dalam Bag of Words, terdapat dua pendekatan. Pendekatan pertama, Count Vectorizer, melibatkan penghitungan kemunculan kata dalam kalimat. Sementara pendekatan kedua, TF-IDF, melibatkan perhitungan frekuensi kata dalam kalimat, dikalikan dengan frekuensi dokumen yang mengandung kata tersebut (Eshan & Hasan, 2017).

Dalam penelitian ini akan menggunakan CountVectorizer. CountVectorizer melakukan perhitungan seberapa sering kata muncul

dalam dokumen dengan menggunakan pendekatan "bag of words". Dengan kata lain, CountVectorizer hanya memperhatikan frekuensi kemunculan kata dalam setiap dokumen tanpa memperhatikan urutan kata (Juniandikaa & Mahendraa, 2023).

2.3.7 Term Frequency – Inverse Document Frequency TF-IDF

TF-IDF adalah metode untuk menghitung atau menimbang kata dalam sebuah dokumen dilakukan dengan teknik tokenisasi, penghapusan kata-kata umum (stopwords), pemangkasan kata (stemming), dan menghitung frekuensi kemunculan kata dalam dokumen yang diberikan. Dalam metode ini, pentingnya kata dalam dokumen dapat ditentukan berdasarkan frekuensi kemunculan kata tersebut. Pembobotan kata dalam dokumen dilakukan dengan mengalikan nilai TF (term frequency) dan IDF (inverse document frequency) berdasarkan hasil query (Rofiqi et al., 2019).

Untuk mengetahui tingkat prevalensi suatu kata dalam sebuah dokumen, salah satu caranya adalah dengan menghitung frekuensi munculnya kata tersebut dan menghasilkan bobot nilai frekuensi term. Persamaan perhitungan TF-IDF berikut ini menunjukkan formula perhitungan bobot menggunakan TF untuk suatu kata t dalam dokumen j .

$tf(t, d)$ = jumlah frekuensi kemunculan kata t dalam dokumen d .

Keterangan :

$tf(t, d)$ = jumlah frekuensi kemunculan kata t dalam dokumen d

t = kata yang akan dihitung bobotnya

d = document yang memiliki kata t didalamnya

Bobot nilai inverse document frequency (IDF) didapat dengan melakukan pembagian antara jumlah dokumen dalam seluruh koleksi dengan jumlah dokumen yang memiliki kata " t ". Pembobotan IDF memberikan bobot yang kecil pada kata yang sering muncul dan memberikan bobot yang besar pada kata yang jarang muncul dalam koleksi dokumen. Bobot nilai inverse document frequency bisa dilakukan penghitungan dengan persamaan berikut :

$$idf_t = \log \left(\frac{N}{n_t} \right)$$

Keterangan :

idf_t = bobot nilai idf untuk kata t

N = jumlah total dokumen dalam koleksi (korpus)

n_k = jumlah dokumen yang terdapat kata t

Bobot nilai TF-IDF didapatkan dengan mengalikan bobot nilai TF dan IDF seperti pada persamaan berikut :

$$tfidf(t, d) = tf(t, d) \times idf_t$$

Keterangan :

$tfidf(t, d)$ = bobot nilai tfidf untuk kata t

$tf(t, d)$ = jumlah kemunculan kata t dalam dokumen d

idf_t = jumlah dokumen yang terdapat kata t .

2.3.8 N-gram

Secara fundamental, model N-gram merupakan probabilistik model yang diperkenalkan oleh matematikawan rusia, pertama kali pada abad ke 20, lalu kemudian dikembangkan untuk memprediksi item berikutnya dalam rangkaian item. Jenis item ini bisa mencakup huruf atau karakter, bahkan kata atau lainnya tergantung pada penggunaannya. Salah satu contohnya yaitu model berbasis kata menggunakan N-gram, yang digunakan untuk memprediksi kata selanjutnya dalam suatu urutan kata spesifik. N-gram pada intinya merupakan himpunan kata-kata, di mana setiap himpunan terdiri dari n kata. Sebagai contoh, koleksi n-gram dengan panjang 1 disebut sebagai unigram; yang berukuran 2 dikenal sebagai "bigram"; sedangkan yang berukuran 3 disebut sebagai "trigram," dan seterusnya.

Dalam konteks pembuatan karakter, n-gram merujuk pada rangkaian karakter sepanjang n karakter yang diambil dari sebuah string. Dalam definisi lain, m-gram adalah fragmen karakter dengan panjang n yang diambil dari suatu string. Pendekatan n-gram digunakan untuk mengekstrak serangkaian n karakter dari sebuah kata atau teks yang dibaca secara berkelanjutan dari awal hingga akhir dokumen. Contohnya seperti kata "DATA" dimana data tersebut dapat dibagi menjadi n-gram, sebagai berikut :

Unigram : D, A, T, A

Bigram : DA, AT, TA

Tri-gram : DAT, ATA

Quad-gram : DATA, ATA_

Sementara itu, dalam pembentukan kata, metode n-gram digunakan untuk mengekstrak segmen kata berpanjang n dari rangkaian kata (seperti kalimat, paragraf, atau teks yang terus-menerus dibaca) dari sumber teks hingga akhir dokumen. Contohnya kalimat "Saya senang berjalan-jalan di taman pada hari yang cerah." Dapat dibagi menjadi N-gram berikut ini :

uni-gram : saya, senang, berjalan-jalan, di, taman, pada, hari, yang, cerah

bi-gram : saya senang, senang berjalan-jalan, berjalan-jalan di, di taman, taman pada, pada hari, hari yang, yang cerah

tri-gram : saya senang berjalan-jalan, senang berjalan-jalan di, berjalan-jalan di taman, di taman pada, taman pada hari, pada hari yang, hari yang cerah

2.3.9 Feature Selection

Seleksi fitur merupakan tahapan preprocessing dengan menghilangkan kata-kata yang tidak relevan (Feldman & Sanger, 2007). Seleksi fitur merupakan bagian yang sangat penting dalam pengolahan dokumen. Tujuan utama dari seleksi fitur adalah memilih fitur yang penting dan menghapus fitur yang tidak penting dan kurang penting terhadap kelas label guna meningkatkan kinerja classifier yaitu meningkatkan akurasi dan

mengurangi waktu komputasi (Jupriyadi, 2018). Feature selection terbagi dalam dua kelompok, yaitu (Yualinda et al., 2020) :

1. Ranging Selection

Di dalam kelompok ini, setiap fitur dalam data diberi peringkat dan fitur yang tidak memenuhi syarat atau standar diabaikan. Ranging selection bertujuan untuk menilai tingkat peringkat secara independen antara satu fitur dan fitur lainnya.

2. Subset Selection

Untuk kelompok subset selection dilakukan untuk mencari set fitur dalam data yang dianggap sebagai fitur paling optimal. Terdapat tiga jenis metode dalam subset selection, diantaranya :

a. Wrapper

Wrapper metode feature selection yang dimana metode ini melibatkan pemilihan fitur secara bersamaan dengan penerapan pemodelan.

b. Filter

Dalam metode feature selection yang ini , dimana yang dilakukan adalah menggunakan salah satu fitur dari beberapa fitur yang ada dalam data.

c. Embedded

Dalam jenis ini, penggunaan machine learning digunakan dalam proses pemilihan fitur. Fitur yang dianggap tidak memberikan pengaruh dalam pengolahan data akan secara otomatis dihapus.

Dalam penelitian ini metode feature selection yang akan diterapkan yaitu metode filter, dimana metode yang akan digunakan yaitu metode chi-square dan. Chi-square disebut sebagai metode filter karena dalam hal ini, chi-square digunakan untuk menghapus term-term yang tidak mencapai ambang batas tertentu, yang pada akhirnya memengaruhi biaya dan akurasi dari metode tersebut (Listiwarni & Puspa Dewi, 2020). Statistik chi-square, yang juga dapat disimbolkan sebagai χ^2), merupakan sebuah metode nonparametrik yang digunakan untuk menganalisis data yang bersifat nominal (kategori) dengan melakukan pengujian terhadap frekuensi.

$$\chi^2 = \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i}$$

Dimana :

χ^2 = statistik uji yang mendekati distribusi chi-kuadrat secara asimtotik

O_i = frekuensi yang diamati

E_i = frekuensi yang diharapkan

n = jumlah hasil yang mungkin disetiap peristiwa

2.3.10 Metode Support Vector Machine

Sistem pembelajaran mesin yang menggunakan fungsi linear dalam ruang fitur berdimensi besar sebagai hipotesis untuk mempelajari pola atau karakteristik dari data pelatihan. Sistem ini dilatih dengan algoritma

pembelajaran yang didasarkan pada teori optimasi, dengan memanfaatkan deviasi pembelajaran yang dihasilkan dari teori pembelajaran statistic (Sulastomo et al., 2022). Support Vector Machine sebagai alat pengklasifikasian yang menggunakan garis untuk membagi data menjadi kategori yang berbeda dalam ruang dimensi tinggi. Batas pemisah antar kategori dinyatakan sebagai kombinasi dari fungsi yang diparametrikkan oleh titik-titik pelatihan yang dipilih sebagai "support vector".

Tujuan dari menggunakan algoritma SVM adalah untuk membuat garis atau batas keputusan yang optimal yang dapat membagi ruang data dalam beberapa kelas. Dengan demikian, kita dapat dengan mudah mengklasifikasikan data baru ke dalam kelas yang sesuai di masa yang akan datang. Persamaan support vector machine sendiri sebagai berikut :

$$f(x) = w \cdot x + b \text{ atau } f(x) = \sum_{i=1}^m a_i y_i K(x, x_i) + b$$

Keterangan :

w : Parameter *hyperplane* yang dicari (garis yang tegak lurus antara garis *hyperplane* dan titik *support vector*)

x : titik data masukan support vector machine

a_i : nilai bobot setiap titik data

(x, x_i) : fungsi kernel

b : parameter *hyperplane* yang dicari (nilai bias)

2.3.11 Naive Bayes Classifier

Naive Bayes adalah metode klasifikasi dalam penambangan teks yang digunakan dalam analisis sentimen. Metode ini berpotensi baik dalam klasifikasi dalam hal presisi dan komputasi data. Naive Bayes Classifier menghitung probabilitas dengan ketentuan bahwa class keputusan adalah benar karena vektor informasi objek, mengasumsikan bahwa atribut objek ini independent (Khadafi et al., 2022). Berikut persamaan *Naive Bayes Classifier* :

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

Keterangan :

X : vektor input, menggambarkan fitur/data dari item yang akan diklasifikasikan.

c : sebuah class spesifik, menggambarkan kelas yang akan dicari probabilitasnya.

$P(C|X)$: probabilitas class berdasar vektor input yang diketahui (posteriori probability), menggambarkan kemungkinan kelas c sebenarnya setelah melihat data X . Ini adalah apa yang ingin kita hitung. $P(x|c)$: probabilitas likelihood dari fitur X dalam kelas C .

$P(c)$: probabilitas class yang dicari (prior probability) dari keseluruhan data, menggambarkan seberapa sering kelas c muncul dalam data kita secara umum.

$P(x|c)$: probabilitas tiap input berdasarkan kondisi pada class, menggambarkan seberapa mungkin fitur X terjadi jika item sebenarnya berada dalam kelas c.

$P(x)$: probabilitas suatu input dari keseluruhan data, menggambarkan seberapa mungkin fitur X terjadi secara umum, tidak peduli kelas apa yang item tersebut miliki.

Terdapat berbagai variasi naïve bayes yang sering digunakan. Dalam penelitian ini varian naïve bayes yang akan digunakan adalah gaussian naïve bayes. Gaussian Naïve Bayes merupakan varian dari Naive Bayes yang mengimplementasikan distribusi normal Gaussian dan mendukung data kontinu untuk klasifikasi (Ismail et al., 2020). Gaussian Naive Bayes bersifat probabilistik dan mengasumsikan distribusi gaussian (normal) dari fitur-fitur dalam setiap kelas. Metode ini memanfaatkan properti distribusi Gaussian untuk menghitung probabilitas posteriori, mengasumsikan bahwa setiap fitur dalam kelas tertentu berdistribusi normal. Berikut persamaan gaussian naïve bayes :

$$P(C|X) = \frac{1}{\sqrt{(2\pi)^n |\Sigma|}} \exp\left(-\frac{1}{2} (X - \mu)^T \Sigma^{-1} (X - \mu)\right) P(C)$$

Dengan :

X : Vector input , menggambarkan fitur / data dari item yang diklasifikasikan

C : klas spesifik yang akan dicari probabilitasnya

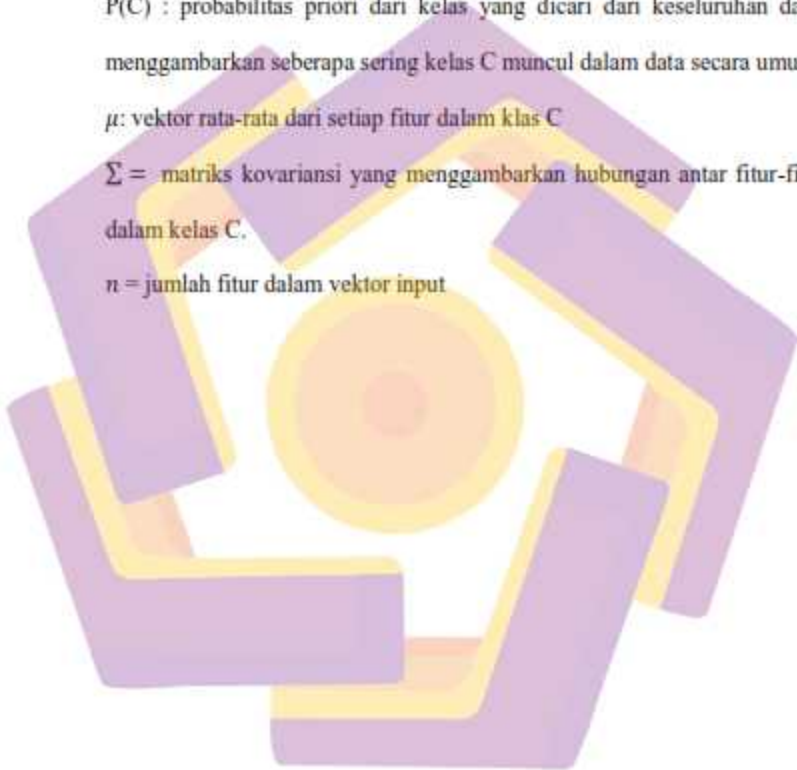
$P(C|X)$: probabilitas class bedasar vektor input yang diketahui (posteriori probability), menggambarkan kemungkinan kelas C sebenarnya melihat data X

$P(C)$: probabilitas priori dari kelas yang dicari dari keseluruhan data, menggambarkan seberapa sering kelas C muncul dalam data secara umum

μ : vektor rata-rata dari setiap fitur dalam klas C

Σ = matriks kovariansi yang menggambarkan hubungan antar fitur-fitur dalam kelas C .

n = jumlah fitur dalam vektor input



BAB III

METODE PENELITIAN

3.1. Jenis, Sifat, dan Pendekatan Penelitian

Adapun jenis, sifat dan pendekatan penelitian yang akan dilakukan pada penelitian ini sebagai berikut :

1. Jenis penelitian eksperiment

Penelitian ini dilakukan untuk mengetahui bagaimana penerapan atau perbandingan dua algoritma klasifikasi yaitu *Support Vector Machine* dan *Naïve Bayes* pada saat menggunakan dan tidak menggunakan *feature selection* untuk deteksi unsur *cyberbullying* dan berapa tingkat akurasi.

2. Sifat Penelitian Deskriptif

Penelitian ini bersifat deskriptif, karena menguraikan hasil dari pengujian-pengujian yang dilakukan pada kumpulan data yang tersedia untuk menentukan metode yang memiliki akurasi, presisi, recall, F1 score terbaik.

3. Pendekatan kuantitatif

Penelitian ini menggunakan pendekatan kuantitatif. Dimana Karena melibatkan angka, dimulai dari pengumpulan data, interpretasi data tersebut, dan penyajian hasilnya, sesuai yang dijelaskan oleh (Arikunto, 2013).

Dalam penelitian ini akan menghasilkan data berupa angka yang bisa diproses dan dianalisis secara statistik. Output dari penelitian ini

akan melibatkan nilai-nilai numerik yang mencerminkan kinerja algoritma *Support Vector Machine* dan *Naïve Bayes* untuk deteksi unsur *cyberbullying* berupa angka dan diagram yang menunjukkan tingkat akurasi dari penerapan algoritma klasifikasi tersebut, seperti akurasi, presisi, recall, f1-score.

3.2. Metode Pengumpulan Data

Data yang digunakan pada penelitian ini memanfaatkan data sekunder yang dapat diakses oleh orang lain. Data sekunder merupakan sumber data yang diperoleh tidak langsung oleh peneliti, tetapi merupakan data yang sudah ada dan dikumpulkan oleh pihak lain sebelumnya (Sugiyono, 2018). Penyedia data sekunder yang digunakan adalah website www.kaggle.com. Kaggle menjadi tempat bagi para peneliti atau siapapun yang ingin berkontribusi dalam menyediakan data demi kemajuan penelitian di dunia, selain itu website ini juga dapat digunakan para peneliti untuk membagikan hasil percobaan seperti uji coba dengan metode menggunakan bahasa pemrograman python. Penelitian ini menggunakan data yang didapatkan dari website kaggle dengan nama *Cyberbullying Bahasa Indonesia* yang berjumlah 650 baris. Data yang digunakan adalah data jenis teks yang berisi komentar pada postingan beberapa pengguna isntagram dengan format csv dan sudah ada label didalamnya yaitu dengan label *cyberbullying* dan *non-cyberbullying*.

3.3. Metode Analisis Data

Sebelum memulai proses analisis data, langkah awal yang diambil adalah preprocessing. Tahapan preprocessing ini melibatkan beberapa tahapan seperti

memisahkan kata, merubah huruf besar menjadi huruf kecil, merubah kata tidak baku menjadi kata baku, menghilangkan kata yang tidak penting, dan mengkonversi kata ke bentuk dasarnya.

Setelah proses preprocessing dilakukan, data akan melewati serangkaian langkah tambahan. Langkah pertama menambah konteks kata menggunakan n-gram dan pembobotan kata menggunakan tfidf. Langkah selanjutnya adalah melakukan pemilihan fitur menggunakan pendekatan chi-square.

Setelah fitur-fitur penting telah terpilih, langkah berikutnya adalah menjalankan proses klasifikasi dengan memanfaatkan algoritma *Support Vector Machine* dan *Naïve Bayes*. Kedua algoritma ini akan diterapkan untuk melakukan prediksi terhadap kelas atau label dari data yang telah ada.

Setelah penyelesaian proses klasifikasi, langkah terakhir melibatkan penilaian performa untuk mendapatkan nilai akurasi, presisi, recall, dan F1 score. Penilaian ini akan memberikan panduan dan referensi dalam menentukan hasil dari penelitian ini. Dengan menganalisis hasil evaluasi performa tersebut, peneliti dapat memahami sejauh mana model klasifikasi yang telah dibangun mampu menghasilkan prediksi yang tepat dan dapat dipercaya.

Oleh karena itu, keseluruhan proses ini membentuk suatu struktur kerja yang komprehensif untuk melakukan analisis data dan menilai kinerja model klasifikasi yang telah dibangun dalam penelitian ini.

3.4. Dataset

Data yang digunakan dalam penelitian ini memanfaatkan data sekunder yang diperoleh dari website kaggle dengan judul "Cyberbullying Bahasa

Indonesia" sebanyak 650 data yang sudah dilabeli dan terdapat 1827 kata. Dataset ini juga pernah digunakan oleh (Muhariya et al., 2022b), dimana penelitian tersebut menggunakan algoritma K-means clustering untuk mengklasifikasikan komentar apakah termasuk kedalam cyberbullying atau non-cyberbullying. Data dalam penelitian ini bersifat open public berisi 650 record baris data.

Data ini mencakup lima atribut utama yang digunakan dalam penelitian ini. Lima atribut-atribut tersebut yaitu Nama Instagram, Komentar, Kategori, Tanggal Posting, dan Nama Akun Korban. Semua atribut ini memiliki kontribusi dalam klasifikasi komentar yang mengandung cyberbullying dan non-cyberbullying. Kemudian, dataset ini memiliki satu atribut kelas atau label yaitu atribut 'Kategori,' yang digunakan sebagai landasan utama dalam mengklasifikasi komentar menggunakan algoritma Naive Bayes dan Support Vector Machine.

Tabel 3.1 Sample Dataset

No	Nama Instagram	Komentar	Kategori	Tanggal Post	Nama akun IG Artis/Celebrity	
0	1	@delliananda	"Kaka tidur yaa, udah pagi, gaboleh capek2"	Non-bullying	14 Oktober 2019	@isyanasarasvati
1	2	@fenninbl	"makan nasi padang aja begini badannya"	Non-bullying	14 Oktober 2019	@isyanasarasvati
2	3	@abdurahmanshq	"yang aku suka dari dia adalah selalu cukur jambut sebelum manggung"	Bullying	14 Oktober 2019	@isyanasarasvati
3	4	@najla.yoo	"Hai kak Isyana aku ngefans banget sama kak Isyana.aku paling suka lagu kak Isyana itu lagu tetap didalam jiwa"	Non-bullying	14 Oktober 2019	@isyanasarasvati
4	5	@dessy_____	"Manusia apa bidadari sih herann deh cantik terus ????"	Non-bullying	14 Oktober 2019	@isyanasarasvati
...
645	646	@_sigesrek	"aku memutuskan untuk menjadi fans isyana. gila keren banget ya, otak mereka berdua bisa berfungsi dg menjalankan perintah ke tangan dan kaki, di waktu bersamaan"	Non-bullying	13 Februari 2021	@isyanasarasvati
646	647	safronlux.id	"AMZING ISYANAA!! Jujur aku amazed banget dengan skill dan minat Isyana dalam bermusik. Ga Cuma bernyanyi tapi main alat musik pun jago banget"	Non-bullying	13 Februari 2021	@isyanasarasvati
647	648	@rikzikhuktyana	"paling ngiri liat orang keren maen alat musik dan dalem banget nikmatin permainan sendiri"	Non-bullying	13 Februari 2021	@isyanasarasvati
648	649	@antoniusbennys	"Sampe ga bisa berkata2 lagi buat isyana, sangat2 sempurna org ini"	Non-bullying	13 Februari 2021	@isyanasarasvati
649	650	@dikha.wirasathya	"Inimah bukan main alat musik lagi. Olahraga jari dan kaki ini mah"	Non-bullying	13 Februari 2021	@isyanasarasvati

Tahap selanjutnya dilakukan proses preprocessing dimana proses ini terdapat 5 tahapan yaitu : Tokenization, Case Folding, Normalization, Stopword Removal, dan Stemming. Supaya lebih jelasnya alur dari proses preprocessing dapat dilihat pada gambar 3.

- a. Tokenization merupakan langkah untuk membagi teks menjadi unit-unit yang lebih kecil yang disebut 'token', dan dibagi atau dipisah bisa menggunakan “,” , spasi dan lainnya. Jenis token ini dapat berupa kata, frasa, atau karakter, tergantung pada aturan yang diterapkan dalam proses tokenisasi. Dalam lingkup penelitian ini, kami menerapkan metode tokenisasi untuk memisahkan teks menjadi kata-kata tunggal. Dengan menguraikan teks menjadi token-token, kami dapat melakukan analisis dan pemrosesan terhadap setiap kata secara terindividu. Hal ini memungkinkan kami untuk melakukan berbagai jenis perhitungan statistik, analisis sentimen, atau pemodelan lain yang mengharuskan pemrosesan kata-kata secara individual.
- b. Case Folding adalah proses merubah teks menjadi huruf kecil semua. Dalam penelitian ini, kami menggunakan case folding sebagai salah satu tahapan preprocessing untuk menjaga konsistensi dan keseragaman dalam teks. Dengan demikian, kami dapat mengurangi tingkat kompleksitas dan membuat proses analisis dan pemrosesan berikutnya menjadi lebih mudah dan efektif. Penggunaan case folding ini membantu kami dalam mempersiapkan data dengan baik untuk analisis dan memastikan hasil yang lebih konsisten serta terstruktur.

- c. Normalization adalah proses untuk mengubah teks menjadi bentuk standar atau normal sehingga memudahkan analisis dan pemrosesan lebih lanjut. Tujuan normalisasi adalah mengatasi variasi dalam teks yang tidak relevan atau mengganggu, sehingga mesin atau model NLP dapat lebih efektif dalam memahami dan mengolah teks tersebut. Normalisasi berperan dalam menghasilkan data teks yang seragam dan bersih, membantu memastikan kualitas analisis yang lebih tinggi.
- d. Stopword Removal adalah proses eliminasi atau penghapusan *common word* yang tidak memberikan manfaat signifikan pada pemahaman konten teks. Kata – kata penghubung atau kata – kata yang sering muncul dalam bahasa tertentu yang tidak memberikan penafsiran makna yang spesifik, seperti "adalah, ialah," serta kata penghubung seperti "dan, atau," beserta kata ganti orang seperti "aku, kamu, dan dia."
- e. Stemming Porter merupakan teknik yang paling umum digunakan dalam pemrosesan teks untuk mengkonversi kata-kata menjadi bentuk dasar atau kata dasar. Ini mengacu pada aturan linguistik dan berbagai langkah pemrosesan untuk menghasilkan bentuk kata dasar, contohnya misalnya kata "berjalan" akan diubah menjadi "jalan" menggunakan metode Stemming Porter. Metode stemming porter ini mengacu pada algoritma Porter Stemming.

Tabel 3.2 Proses preprocessing

	Text	cleaning	Case Folding	Tokenization	Stemming
18	"Ibu kamu pelakor plus hamil di luar nikah ya? Pantesan anaknya kyk gini modelannya"	Ibu kamu pelakor plus hamil di luar nikah ya Pantesan anaknya kyk gini modelannya	ibu kamu pelakor plus hamil di luar nikah ya pantesan anaknya kyk gini modelannya	[ibu, kamu, pelakor, plus, hamil, di, luar, nikah, ya, pantesan, anaknya, kyk, gini, modelannya]	[ibu, kamu, pelakor, plu, hamil, di, luar, nikah, ya, pantesan, anaknya, kyk, gini, modelannya]
19	"Anaknya udh pinter, maknya yang kelempengan.. berasa masih baby, tingginya azka aj melebihi mamanya.."	Anaknya udh pinter maknya yang kelempengan berasa masih baby tingginya azka aj melebihi mamanya	anaknya udh pinter maknya yang kelempengan berasa masih baby tingginya azka aj melebihi mamanya	[anaknya, udh, pinter, maknya, yang, kelempengan, berasa, masih, baby, tingginya, azka, aj, melebihi, mamanya]	[anaknya, udh, pinter, maknya, yang, kelempengan, berasa, masih, babi, tingginya, azka, aj, melebihi, mamanya]
20	"Anak yg cerdas terbentuk dr pola asuh sekaligus pola didik ortu yg cerdas pula sih pada saranya. Sesimple itu"	Anak yg cerdas terbentuk dr pola asuh sekaligus pola didik ortu yg cerdas pula sih pada saranya Sesimple itu	anak yg cerdas terbentuk dr pola asuh sekaligus pola didik ortu yg cerdas pula sih pada saranya sesimple itu	[anak, yg, cerdas, terbentuk, dr, pola, asuh, sekaligus, pola, didik, ortu, yg, cerdas, pula, sih, pada, saranya, sesimple, itu]	[anak, yg, cerda, terbentuk, dr, pola, asuh, sekaligus, pola, didik, ortu, yg, cerda, pula, sih, pada, saranya, sesimpl, itu]
21	"Setengah iri setengah jadi motivasi ini"	Setengah iri setengah jadi motivasi ini	setengah iri setengah jadi motivasi ini	[setengah, iri, setengah, jadi, motivasi, ini]	[setengah, iri, setengah, jadi, motivasi, ini]
22	"Ancur hidup lu kalau sama dia Sumpah.."	Ancur hidup lu kalau sama dia Sumpah	ancur hidup lu kalau sama dia sumpah	[ancur, hidup, lu, kalau, sama, dia, sumpah]	[ancur, hidup, lu, kalau, sama, dia, sumpah]
23	"serem banget muka lo mel kayak ayam potong merah banget"	serem banget muka lo mel kayak ayam potong merah banget	serem banget muka lo mel kayak ayam potong merah banget	[serem, banget, muka, lo, mel, kayak, ayam, potong, merah, banget]	[serem, banget, muka, lo, mel, kayak, ayam, potong, merah, banget]
24	"Yaudah jd pengusaha kuliner aja gausah artis, makanannya emang bikin ngiler sih wkwkw"	Yaudah jd pengusaha kuliner aja gausah artis makanannya emang bikin ngiler sih wkwkw	yaudah jd pengusaha kuliner aja gausah artis makanannya emang bikin ngiler sih wkwkw	[yaudah, jd, pengusaha, kuliner, aja, gausah, artis, makanannya, emang, bikin, ngiler, sih, wkwkw]	[yaudah, jd, pengusaha, kulin, aja, gausah, arti, makanannya, emang, bikin, ngiler, sih, wkwkw]
25	"Kamu emang cocoknya jadi pengusaha kuliner udah fixs. Semoha lancat terusssss"	Kamu emang cocoknya jadi pengusaha kuliner udah fixs Semoha lancat terusssss	kamu emang cocoknya jadi pengusaha kuliner udah fixs semoha lancat terusssss	[kamu, emang, cocoknya, jadi, pengusaha, kuliner, udah, fixs, semoha, lancat, terusssss]	[kamu, emang, cocoknya, jadi, pengusaha, kulin, udah, fix, semoha, lancat, terusssss]
26	"Tak sejelek IMAGE Owner ya..? Artis ups bukan Artis? Hallo secara tidak langsung semua orang itu tau IMAGE lu jelek gentong!"	Tak sejelek IMAGE Owner ya Artis ups bukan Artis? Hallo secara tidak langsung semua orang itu tau IMAGE lu jelek gentong	tak sejelek image owner ya artis ups bukan artis hallo secara tidak langsung semua orang itu tau image lu jelek gentong	[tak, sejelek, image, owner, ya, artis, ups, bukan, artis, hallo, secara, tidak, langsung, semua, orang, itu, tau, image, lu, jelek, gentong]	[tak, sejelek, imag, owner, ya, arti, up, bukan, arti, hallo, secara, tidak, langsung, semua, orang, itu, tau, imag, lu, jelek, gentong]
27	"Apaan sih gak jelas hidupnya"	Apaan sih gak jelas hidupnya	apaan sih gak jelas hidupnya	[apaan, sih, gak, jelas, hidupnya]	[apaan, sih, gak, jela, hidupnya]

Tabel 3.3 Lanjutan Proses preprocessing


	Text	cleaning	Case Folding	Tokenization	Stemming
28	"Sebelum aku Unfol, aku mau bilang NAJISSSS"	Sebelum aku Unfol, aku mau bilang NAJISSSS	sebelum aku unfol, aku mau bilang najissss	[sebelum, aku, unfol, aku, mau, bilang, najissss]	[sebelum, aku, unfol, aku, mau, bilang, najissss]
29	"muka lu sensual tapi norak kenapa dah"	muka lu sensual tapi norak kenapa dah	muka lu sensual tapi norak kenapa dah	[muka, lu, sensual, tapi, norak, kenapa, dah]	[muka, lu, sensual, tapi, norak, kenapa, dah]
30	"Udah gk jaman ngebully orang hey netizen mending ngaca dari kekurangan sendiri"	Udah gk jaman ngebully orang hey netizen mending ngaca dari kekurangan sendiri	udah gk jaman ngebully orang hey netizen mending ngaca dari kekurangan sendiri	[udah, gk, jaman, ngebully, orang, hey, netizen, mending, ngaca, dari, kekurangan, sendiri]	[udah, gk, jaman, ngebully, orang, hey, netizen, mend, ngaca, dari, kekurangan, sendiri]
31	"Kalau pas penempatannya, sebenarnya kamu imut banget loh mel."	Kalau pas penempatannya sebenarnya kamu imut banget loh me	kalau pas penempatannya sebenarnya kamu imut banget loh mel	[kalau, pas, penempatannya, sebenarnya, kamu, imut, banget, loh, mel]	[kalau, pa, penempatannya, sebenarnya, kamu, imut, banget, loh, mel]
32	"Capek kaga jelek iya HAHAH"	Capek kaga jelek iya HAHAH	capek kaga jelek iya hahah	[capek, kaga, jelek, iya, hahah]	[capek, kaga, jelek, iya, hahah]
33	"jari jari kaki kayak jarinya tukang panggul"	jari jari kaki kayak jarinya tukang panggul	jari jari kaki kayak jarinya tukang panggul	[jari, jari, kaki, kayak, jarinya, tukang, panggul]	[jari, jari, kaki, kayak, jarinya, tukang, panggul]
34	"Kakinya kek lagi hamil tua ya bun, semacam kaki gajah @ayuugsia"	Kakinya kek lagi hamil tua ya bun semacam kaki gajah ayuugsia	kakinya kek lagi hamil tua ya bun semacam kaki gajah ayuugsia	[kakinya, kek, lagi, hamil, tua, ya, bun, semacam, kaki, gajah, ayuugsia]	[kakinya, kek, lagi, hamil, tua, ya, bun, semacam, kaki, gajah, ayuugsia]
35	"Suka heran sama yg ngehina fisik, ternyata bener ya kita semua pendosa dengan cara kita sendiri."	Suka heran sama yg ngehina fisik ternyata bener ya kita semua pendosa dengan cara kita sendiri	suka heran sama yg ngehina fisik ternyata bener ya kita semua pendosa dengan cara kita sendiri	[suka, heran, sama, yg, ngehina, fisik, ternyata, bener, ya, kita, semua, pendosa, dengan, cara, kita, sendiri]	[suka, heran, sama, yg, ngehina, fisik, ternyata, bener, ya, kita, semua, pendosa, dengan, cara, kita, sendiri]



Gambar 3. 1 Alur Preprocessing

3.5. Alur Penelitian

Dalam penelitian ini, beberapa langkah penelitian termasuk didalamnya. Langkah awal yaitu preprocessing data, dimana dalam tahapan ini data yang diperoleh akan melalui tahapan preprocessing yang diantaranya Cleaning, Case Folding, Tokenization, dan stemming porter dengan tujuan untuk menghasilkan teks yang lebih rapi atau terstruktur. Langkah berikutnya adalah melakukan ekstraksi fitur menggunakan metode Bag of Words dan TF-IDF yang dikombinasikan dengan n-gram, dengan tujuan mengidentifikasi kata-kata penting dalam teks. Selanjutnya, feature selection dilakukan menggunakan algoritma Chi-Square untuk memilih fitur-fitur yang memiliki relevansi tertinggi dan memberikan dampak yang signifikan dalam proses klasifikasi. Langkah selanjutnya melibatkan proses klasifikasi, di mana kita akan memanfaatkan algoritma Gaussian Naive Bayes dan Support Vector Machine untuk mengategorikan teks ke dalam kategori yang sesuai berdasarkan fitur-fitur yang telah diekstraksi sebelumnya. Evaluasi diterapkan untuk mengukur performa model klasifikasi, yang melibatkan metrik seperti akurasi, presisi, recall, dan F1-score. Dan pada tahapan berikutnya, kesimpulan akan ditarik berdasarkan hasil evaluasi ini, dan akan menunjukkan apakah model yang telah dikembangkan dalam penelitian ini berhasil atau memiliki kekurangan tertentu.



Gambar 3. 2 Alur Penelitian

Penelitian ini diawali dengan melakukan pengumpulan data, dengan menggunakan dataset cyberbullying pada komentar instagram bahasa Indonesia yang diambil dari website <https://www.kaggle.com/> dengan judul "Cyberbullying Bahasa Indonesia". Dataset ini sebelumnya telah dimanfaatkan dalam penelitian oleh (Muhariya et al., 2022b), yang menggunakan metode K-means clustering untuk mengklasifikasikan komentar sebagai cyberbullying atau non-cyberbullying. Data yang digunakan dalam penelitian ini adalah data sekunder yang terdiri dari 650 baris data.

Tahapan selanjutnya dilakukan preprocessing teks dengan tahapan cleaning, case folding, tokenization, dan stemming. Hal ini bertujuan untuk mempersiapkan data teks secara optimal sebelum dilakukan analisis atau pemrosesan lebih lanjut, sehingga memungkinkan peningkatan kualitas dan efisiensi dalam pemahaman dan ekstraksi informasi suatu teks.

Tahapan berikutnya dilakukan penerapan feature extraction. Feature extraction merupakan langkah penting dalam klasifikasi sentimen karena melibatkan pengambilan informasi berharga dari data teks, dan hal ini langsung mempengaruhi kinerja model. Penerapan ekstraksi feature bertujuan untuk mengekstrak informasi berharga yang mencerminkan fitur-fitur paling esensial dari teks (Wankhade et al., 2022). Dalam penelitian ini kami menggunakan Bag of Words (BoW) dan tf-idf, dimana tf-idf di kombinasi dengan n-gram dengan jenis N-gram yang digunakan adalah Tri-gram.

Tahapan berikutnya melibatkan penerapan feature extraction menggunakan BoW dan TF-IDF. Dalam konteks ini, TF-IDF dibandingkan dengan Bag of Words, dengan tambahan penggunaan N-gram pada metode tf-idf, khususnya menggunakan Tri-gram. Tujuannya adalah untuk membandingkan kemampuan representasi fitur antara pendekatan BoW dan TF-IDF, yang diperkuat oleh penggunaan N-gram. Pemilihan Tri-gram diharapkan dapat mengakomodasi konteks lebih lanjut dalam representasi fitur, membantu dalam analisis data yang lebih akurat dan kontekstual.

Setelah data diekstraksi, langkah berikutnya adalah penerapan feature selection. Feature selection bertujuan untuk memperoleh feature yang paling

informatif dengan dampak peningkatan akurasi dan efisiensi (Himawan & Nugraha, 2023). Dalam tahapan ini dilakukan feature selection yang bertujuan untuk memilih sekelompok fitur yang paling relevan dan memberikan kontribusi signifikan dalam proses klasifikasi atau analisis data. Inti dari tahapan ini adalah untuk mengurangi dimensi data dan menjaga fitur yang memiliki informasi paling penting. Melalui penerapan metode feature selection dalam penelitian ini dapat memperbaiki efisiensi pengolahan data, mencegah overfitting, serta mengoptimalkan performa model yang digunakan. Metode feature selection yang akan digunakan yaitu Chi-square.

Sebelum melakukan proses klasifikasi, langkah yang penting dilakukan yaitu membagi dataset menjadi dua bagian, yaitu data training dan data testing. Pembagian ini mengikuti rasio 80% untuk data training dan 20% untuk data testing. Penggunaan pembagian proporsi ini dapat mencerminkan data, memungkinkan evaluasi model yang efisien, menciptakan distribusi yang seragam antara data pelatihan dan pengujian, serta menghasilkan akurasi yang optimal (Pratama & Tjahyanto, 2021).

Kemudian dilakukan proses klasifikasi dengan algoritma klasifikasi yang sudah ditentukan. Algoritma klasifikasi dalam penelitian ini merupakan algoritma yang digunakan untuk melakukan klasifikasi data kedalam label atau kelas tertentu sesuai karakteristik atau atribut yang dimiliki oleh data tersebut. Terdapat berbagai algoritma klasifikasi yang digunakan dalam banyak pengaplikasian misalnya klasifikasi dokumen, face recognition, sentiment analysis kemudian masih banyak lagi. Terdapat beragam teknik yang dapat digunakan untuk melakukan klasifikasi,

beberapa diantaranya yaitu seperti K-Nearest Neighbors (K-NN), Jaringan Saraf (Neural Networks), Algoritma Genetika, Decision Trees (J48), Naive Bayes, dan Support Vector Machines (SVM). Dalam penelitian ini menggunakan salah satu varian dari algoritma Naive Bayes yaitu Gaussian Naïve Bayes dan Support Vector Machine untuk mengklasifikasi teks apakah termasuk cyberbullying atau non-cyberbullying.

Kemudian evaluasi kinerja algoritma klasifikasi diterapkan untuk mengukur sejauh mana kemampuan model klasifikasi dalam memprediksi data yang belum pernah dikenal sebelumnya, yaitu data uji. Dalam penelitian ini digunakan beberapa metrik evaluasi kinerja yang biasanya digunakan dalam konteks klasifikasi, diantaranya sebagai berikut :

1. Akurasi (Accuracy): Tingkat akurasi mengukur sejauh mana model mampu membuat prediksi yang tepat. Akurasi dihitung dengan cara membagi jumlah prediksi yang benar dengan jumlah total data. Rumus akurasi adalah sebagai berikut: $(TP+TN)/(TP+TN+FP+FN)$
2. Presisi (Precision): Tingkat presisi mengukur sejauh mana model berhasil dalam mengidentifikasi prediksi positif yang tepat (klasifikasi sebagai kelas positif). Rumus presisi adalah: $TP/(TP+FP)$
3. Recall (Sensitivity): Tingkat recall mengukur seberapa baik model dalam mengidentifikasi kelas positif dengan benar. Rumus recall adalah: $TP/(TP+FN)$

4. F1-Score: F1-Score merupakan rata-rata harmonis antara presisi dan recall. F1-Score mengukur keseimbangan antara presisi dan recall. Rumus F1-Score adalah: $2 * (\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})$.

Pada kondisi membandingkan berbagai model dengan menggunakan evaluasi kinerja, diperlukan untuk memberikan fokus pada beberapa metrik evaluasi kinerja. Hal ini dikarenakan sebuah model bisa menunjukkan kinerja yang baik dalam satu metrik, tetapi kurang baik dalam metrik lainnya.

Langkah akhir dalam studi ini adalah memperoleh perbandingan hasil antara dua metode algoritma, yaitu Naive Bayes dan Support Vector Machine, dalam mengklasifikasi cyberbullying atau non-cyberbullying.

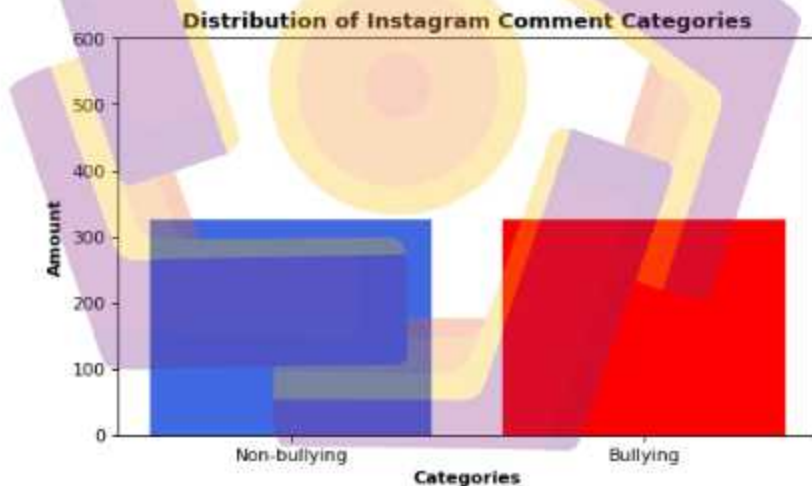


BAB IV

HASIL PENELITIAN DAN PEMBAHASAN

4.1. Kondisi Dataset

Sesuai dengan dataset yang telah dikumpulkan dari situs web Kaggle.com dengan judul dataset "Cyberbullying Bahasa Indonesia", dimana jumlah dataset ini diketahui sebanyak 650 data yang sudah dilabeli dan terdapat 1827 kata. Kumpulan data ini terbagi menjadi 2 jenis kategori, yakni cyberbullying dan non-cyberbullying. Untuk memberikan ilustrasi yang lebih terperinci, dataset dapat disajikan secara visual melalui diagram yang tergambar pada Gambar 4.1.



Gambar 4.1 Persentase Komentar non-bullying dan bullying

Dalam gambar 4.1 komentar non-cyberbullying direpresentasikan dengan warna biru yang berjumlah 325, dimana merupakan 50% dari jumlah komentar atau ulasan. Kemudian warna merah merepresentasikan komentar cyberbullying yang memiliki jumlah sama dengan komentar non-cyberbullying yaitu berjumlah 352 komentar, atau 50% dari jumlah total komentar. Ini dilakukan dengan tujuan untuk secara jelas membedakan antara komentar non-cyberbullying dan cyberbullying dalam representasi visual tersebut.

4.2. Vektorisasi data

Dalam tahapan penelitian ini proses Vektorisasi yang digunakan dilakukan dengan menggunakan word embedding yang dimana dalam penelitian ini menggunakan Teknik Bag of Words yang dibandingkan dengan Teknik vektorisasi TF-IDF yang dikombinasikan dengan model n-gram yaitu tri-gram.

4.2.1 Bag of Word

Bag of Words adalah metode vektorisasi kata yang digunakan untuk mengubah teks ke dalam format vektor, sehingga dapat diolah oleh algoritma klasifikasi. Berikut dibawah ini gambar sintak dari model Bag of Words yang digunakan dalam penelitian ini :

```

from sklearn.feature_extraction.text import CountVectorizer
# Misalnya, jika df['stemming'] adalah kolom yang berisi teks hasil stemming
data = df['str_stemm'].tolist()
# Inisialisasi CountVectorizer tanpa stop_words dan min_df
vectorizer = CountVectorizer()
# Panggil fit_transform pada data teks
dtm = vectorizer.fit_transform(data)

dtm

dtm.toarray()

df_BoW = pd.DataFrame(dtm.toarray())

df_BoW.index = X

vectorizer.get_feature_names_out()

df_BoW.columns = vectorizer.get_feature_names_out()

```

Gambar 4.2 Sintak Model Bag of Words

Melalui gambar sintak diatas, dapat dilihat bahwa kami menerapkan teknik Bag-of-Words (BoW) dengan menggunakan modul CountVectorizer dari library scikit-learn dalam lingkungan pemrograman google colab . Proses dimulai dengan pengambilan data teks dari kolom 'str_stemm' dalam DataFrame (df), diubah menjadi sebuah daftar. Langkah ini menjadi langkah awal penting untuk mempersiapkan data yang akan diolah menggunakan BoW. Selanjutnya, objek CountVectorizer diinisialisasi tanpa konfigurasi tambahan. CountVectorizer memainkan peran krusial dalam mengonversi kumpulan dokumen teks menjadi representasi numerik, dengan setiap kata berperan sebagai fitur yang memuat informasi penting. Setelahnya, metode fit_transform dipanggil pada objek vectorizer untuk menghasilkan Document-Term Matrix (DTM). DTM memberikan representasi frekuensi kemunculan kata dalam setiap dokumen, yang kemudian dikonversi menjadi DataFrame (df_BoW). DataFrame ini mempermudah visualisasi dan pemahaman representasi numerik dari teks, disajikan dalam bentuk tabel. Langkah selanjutnya melibatkan penetapan indeks DataFrame (df_BoW)

menggunakan variabel X . Ini memberikan informasi mengenai indeks atau label dokumen yang menjadi berguna dalam tahapan analisis lebih lanjut. Nama kolom DataFrame ditetapkan menggunakan `get_feature_names_out()` dari objek `CountVectorizer`, menyajikan daftar kata-kata atau fitur yang ditemukan dalam seluruh kumpulan data teks.

Berikut hasil dari penerapan teknik Bag of Words yang sudah diterapkan pada data yang telah dilakukan preprocessing:



Gambar 4.3 Hasil Bag of Words

Setelah menyelesaikan proses vektorisasi kata dengan metode Bag of Words (BoW), sesuai dengan yang terlihat pada Gambar 4.3, terciptalah matriks yang memiliki 2170 kolom, dan siap diproses ketahapan berikutnya.

4.2.2 Vectorisasi dataset dengan TF-IDF tanpa N-Gram

Dalam pemrosesan teks salah satu yang umum digunakan yaitu TF-IDF. TF-IDF mengukur bobot kata dengan mempertimbangkan frekuensi kemunculan kata di dalam suatu dokumen dan frekuensi kemunculan kata di seluruh koleksi dokumen. Pentingnya suatu kata dalam teks dapat direpresentasikan dengan menggunakan bobot TF-IDF. Di bawah ini, terdapat sintak implementasi TF-IDF.

```
from sklearn.feature_extraction.text import TfidfVectorizer
import pandas as pd

# Inisialisasi objek TfidfVectorizer
vectorizer = TfidfVectorizer()

# Menghitung nilai TF-IDF
tf_idf = vectorizer.fit_transform(x)

# Mendapatkan daftar kata kunci yang digunakan sebagai fitur
feature_names = vectorizer.get_feature_names_out()

# Membuat DataFrame dari matriks TF-IDF
df = pd.DataFrame(tf_idf.toarray(), columns=feature_names)

# Menampilkan DataFrame
df
```

Gambar 4.4 Sintak Vectorisasi Kata Dengan TF-IDF

Dalam gambar 4. 4, proses vectorisasi kata dapat diamati dengan langkah awal yaitu mengimpor modul "TfidfVectorizer" dari pustaka "sklearn.feature_extraction.text". Modul ini digunakan untuk menghitung nilai TF-IDF. Selanjutnya, objek "TfidfVectorizer" diinisialisasi dengan pernyataan "vectorizer = TfidfVectorizer()". Objek ini akan dipergunakan untuk menghitung nilai TF-IDF. Langkah berikutnya adalah menghitung nilai TF-IDF dengan menggunakan "tfidf = vectorizer.fit_transform(x)", di mana "x" merujuk pada data

teks yang akan dinilai TF-IDF-nya. Operasi "fit_transform" akan menghasilkan matriks TF-IDF berdasarkan informasi teks yang diberikan. Selanjutnya, kita memperoleh daftar kata kunci yang berfungsi sebagai fitur dalam matriks TF-IDF melalui pernyataan "feature_names = vectorizer.get_feature_names_out()". Fungsi "get_feature_names_out()" menghasilkan daftar kata kunci yang digunakan dalam langkah transformasi TF-IDF. Setelahnya, sebuah DataFrame kami buat dari matriks TF-IDF menggunakan pernyataan "df = pd.DataFrame(tfidf.toarray(), columns=feature_names)". Fungsi "toarray()" mengubah matriks TF-IDF menjadi "array numpy", dan selanjutnya, DataFrame dibuat dari array tersebut dengan kolom yang sesuai dengan daftar kata kunci. DataFrame merupakan bentuk tabel atau data tabular yang menggunakan array dua dimensi, terdiri dari baris dan kolom. Struktur data ini menjadi cara yang umum digunakan untuk menyimpan informasi. Terakhir, kita menampilkan DataFrame yang berisi nilai-nilai TF-IDF dengan pernyataan "print(df)". Tindakan ini akan mencetak DataFrame ke output. Berikut

	_di	aa	aaa	aamiin	abaikan	...	youtub	yuhuuu	yutub	ziu	zoo
0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
1	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
2	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
3	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
4	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
...
645	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
646	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
647	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
648	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0
649	0.0	0.0	0.0	0.0	0.0	...	0.0	0.0	0.0	0.0	0.0

Gambar 4. 5 Hasil vectorisasi dengan TF-IDF

Setelah melalui proses vektorisasi kata menggunakan metode TF-IDF, seperti yang terlihat pada Gambar 4. 5, didapatkan matriks dengan 2170 kolom. Matriks ini memuat informasi krusial mengenai karakteristik yang sedang dianalisis.

4.2.3 Vectorisasi Dataset Dengan TF-IDF & Model N-Gram

TF-IDF dan n -gram merupakan dua strategi yang lazim diterapkan dalam konteks klasifikasi teks. Representasi TF-IDF adalah singkatan dari Term Frequency-Inverse Document Frequency, yakni ukuran numerik yang mencerminkan tingkat relevansi sebuah kata terhadap dokumen dalam kumpulan atau korpus. N -gram, di sisi lain, adalah deretan n elemen yang berurutan dari sepotong teks atau ucapan yang diberikan. Penggunaannya adalah untuk menggambarkan teks sebagai vektor fitur dalam rangka tugas klasifikasi teks. Dalam analisis bahasa alami serta pembangunan model bahasa, trigram umumnya diadopsi sebagai entitas dasar yang digunakan untuk mengilustrasikan struktur dan relasi antara kata-kata. Penggunaan Teknik n -gram yang digunakan adalah tri-gram. Penggunaan trigram memberikan wawasan mendalam terhadap pola yang mendasari urutan kata dalam teks. Hal ini berguna dalam berbagai konteks, termasuk pemrosesan bahasa alami, pembuatan model topik, pemahaman kalimat, dan banyak tugas lainnya. Hasil analisis trigram ini juga dapat digunakan dalam berbagai aplikasi, seperti pemodelan bahasa alami, terjemahan mesin, atau pengembangan sistem berbasis teks yang lebih cerdas. Dengan demikian, trigram menjadi alat penting dalam menyelidiki bahasa alami dan mengembangkan

pemahaman yang lebih mendalam tentang struktur dan makna teks. Berikut ini terdapat gambar sintak dari N-gram yang dikombinasikan dengan tf-idf

```

from sklearn.feature_extraction.text import TfidfVectorizer

tf_idf = TfidfVectorizer(ngram_range=(1,3))
tf_idf.fit(X)

# Melihat Jumlah Fitur
print(len(tf_idf.get_feature_names_out()))

# Melihat fitur-fitur apa saja yang ada di dalam corpus
print(tf_idf.get_feature_names_out())

# transformasi teks ke representasi TF-IDF
X_tf_idf = tf_idf.transform(X).toarray()
X_tf_idf

# Membuat DataFrame dari representasi TF-IDF
data_tf_idf = pd.DataFrame(X_tf_idf, columns=tf_idf.get_feature_names_out())
data_tf_idf

```

Gambar 4. 6 Sintak Pembobotan Kata dengan N-gram dan TF-IDF

Dalam Gambar 4.6, dapat disaksikan langkah-langkah pembobotan kata dimulai dengan mengimpor modul "TfidfVectorizer" dari pustaka "sklearn.feature_extraction.text," yang kemudian digunakan untuk perhitungan nilai TF-IDF. Selanjutnya dilakukan inisialisasi objek "TfidfVectorizer" menggunakan "tf_idf = TfidfVectorizer(ngram_range=(1, 3))" Dalam kondisi ini, kita menetapkan nilai parameter "n-gram_range" menjadi "(1, 3)," yang mengindikasikan penggunaan trigram sebagai fitur dalam penghitungan nilai TF-IDF. Trigram merupakan rangkaian dua kata yang berurutan dalam suatu teks. Langkah berikutnya adalah melakukan pelatihan menggunakan data teks yang telah disimpan dalam variabel X dengan "tf_idf.fit(X)". Proses pelatihan model TF-IDF

melibatkan perhitungan frekuensi kata dalam dokumen-dokumen yang terdapat dalam variabel X, lalu menghitung bobot TF-IDF yang relevan. Selanjutnya, kami menerapkan metode `"tf_idf.get_feature_names_out()"` untuk mengakses daftar kata-kata atau fitur yang telah diidentifikasi oleh model TF-IDF, yang akan menjadi bagian integral dari representasi TF-IDF kami. Setelah itu, kami menggunakan fungsi `"len"` untuk menghitung panjang atau jumlah elemen dalam daftar ini. Untuk menampilkan daftar fitur yang digunakan dalam perhitungan TF-IDF, kami menggunakan perintah `"print(tf_idf.get_feature_names_out())"`. Ini memungkinkan kita untuk melihat secara lengkap daftar kata-kata atau istilah-istilah yang dianggap penting dalam analisis berdasarkan nilai TF-IDF. Berikut hasil dari pembobotan kata dengan N-gram dan TF-IDF.

	_di	_di	budget	_di	budget	cantik	...	zoo	zoo	kunjungannya	zoo	kunjungannya	keluarga
0	0.0	0.0			0.0			0.0		0.0		0.0	0.0
1	0.0	0.0			0.0			0.0		0.0		0.0	0.0
2	0.0	0.0			0.0			0.0		0.0		0.0	0.0
3	0.0	0.0			0.0			0.0		0.0		0.0	0.0
4	0.0	0.0			0.0			0.0		0.0		0.0	0.0
...													
645	0.0	0.0			0.0			0.0		0.0		0.0	0.0
646	0.0	0.0			0.0			0.0		0.0		0.0	0.0
647	0.0	0.0			0.0			0.0		0.0		0.0	0.0
648	0.0	0.0			0.0			0.0		0.0		0.0	0.0
649	0.0	0.0			0.0			0.0		0.0		0.0	0.0

Gambar 4.7 Hasil Pembobotan kata dengan N-gram dan TF-IDF

Dalam Tabel 4.7, terdapat perbedaan dalam hasil pembobotan kata antara TF-IDF dan TF-IDF dengan n-gram, di mana jumlah kolom pada TF-IDF dengan n-gram mencapai 13009 kolom. Penggunaan n-gram, yang tidak hanya mempertimbangkan kata-kata secara individual, tetapi juga mengambil kombinasi kata-kata yang berdekatan. Dengan menyertakan kombinasi kata-kata ini sebagai fitur tambahan, kerangka fitur menjadi lebih luas dan lebih kompleks, yang pada gilirannya meningkatkan jumlah kolom dalam proses pembobotan. Di sisi lain, ketika kita hanya menggunakan metode TF-IDF, pertimbangan terbatas pada frekuensi kata dalam dokumen dan seluruh korpus, sehingga menciptakan ruang fitur yang lebih terbatas dan jumlah kolom yang lebih minim.

4.3. Model Naive Bayes

Model Gaussian Naive Bayes difokuskan pada perhitungan probabilitas untuk menentukan kelas mana yang paling mungkin cocok dengan suatu data berdasarkan informasi yang ada. Tujuan dari algoritma Gaussian Naive Bayes (GNB) adalah untuk mengklasifikasikan data dengan akurasi yang baik dengan menciptakan batasan keputusan yang optimal. GNB sangat efektif ketika atribut dalam data memiliki distribusi Gaussian (normal). Meskipun asumsi dasar Gaussian Naive Bayes adalah independensi antar atribut dan distribusi normal dari setiap atribut, algoritma ini sering memberikan hasil yang baik dalam praktiknya. GNB memanfaatkan perhitungan probabilitas dan asumsi distribusi normal ini untuk mengklasifikasikan data dengan tepat

Setelah proses pelatihan, model Gaussian Naive Bayes dapat digunakan untuk melakukan prediksi terhadap kelas dari data baru dengan mempertimbangkan

probabilitasnya terhadap setiap kelas yang telah diestimasi selama tahap pelatihan. Model Gaussian Naive Bayes juga mampu menghasilkan skor kepercayaan atau probabilitas yang mencerminkan tingkat keyakinan model terhadap setiap prediksi yang dihasilkan.

4.3.1 Skenario Pengujian Model Naive Bayes

Dalam tahapan ini, kami merencanakan 4 skenario pengujian yang berbeda untuk mengevaluasi kinerja model Gaussian Naive Bayes (GNB) yang telah kami buat. Berikut adalah rencana skenario yang akan digunakan untuk melakukan klasifikasi terhadap komentar bullying atau non-bullying.

Tabel 4.1 Skenario Model GNB

Skenario	GNB	Bag of Word	TF-IDF	N-gram	Feature Selection	Akurasi	Precision	Recall	F1-Score
					Chi-square				
1	✓	✓			
2	✓		✓		
3	✓	✓			✓
4	✓		✓	✓	
5	✓		✓		✓
6	✓		✓	✓	✓

Tabel di atas menunjukkan kombinasi beberapa metode atau teknik yang akan diterapkan dalam evaluasi kinerja model klasifikasi dengan menggunakan algoritma Gaussian Naive Bayes. Berikut adalah penjelasannya :

1. Pada kolom **Skenario** : Menunjukkan nomor atau urutan skenario dari kombinasi metode atau teknik yang akan diuji.
2. Pada kolom **GNB (Gaussian Naive Bayes)**: Menunjukkan apakah metode Gaussian Naive Bayes akan digunakan dalam pengolahan teks untuk skenario tertentu.

3. Pada kolom **Bag of Word**: Menunjukkan apakah metode Bag of Word akan digunakan dalam proses pengolahan teks untuk skenario tertentu.
4. Pada kolom **TF-IDF**: Menunjukkan apakah metode TF-IDF akan digunakan dalam pengolahan teks atau tidak pada skenario tertentu.
5. Pada kolom **N-gram**: Menunjukkan apakah teknik N-gram (tri-gram) akan digunakan dalam pengolahan teks atau tidak dalam skenario tertentu.
6. Pada kolom Feature Selection (**Chi-square**): Menunjukkan apakah metode seleksi fitur Chi-Squared akan digunakan atau tidak diskenario tertentu.
7. Pada kolom **Akurasi, Precision, Recall, F1-Score**: Kolom-kolom ini akan diisi dengan nilai-nilai metrik evaluasi kinerja model untuk setiap skenario, namun belum diisi dalam contoh tabel yang diatas. Dan,
8. Tanda centang (✓) : menunjukkan penggunaan, sedangkan tidak ada tanda (✓) menunjukkan tidak digunakan.

Pada skenario pertama, kami menggunakan teknik vektorisasi dengan metode Bag of Word, Kemudian Algoritma Gaussian Naive Bayes (GNB) untuk melakukan proses klasifikasi komentar cyberbullying atau non-cyberbullying. Kami memanfaatkan semua fitur yang tersedia tanpa menjalani proses feature selection. Dengan penerapan model Bag of Word, berhasil mendapatkan feature dari corpus sebanyak 2.170 features tanpa menggunakan feature selection. Dengan menerapkan algoritma Gaussian Naive Bayes dan vektorisasi Bag of Word, kami dapat mengkategorikan komentar – komentar yang ada dalam data sebagai cyberbullying atau non-cyberbullying berdasarkan informasi yang terkandung

dalam feature tersebut. Skenario ini memberikan pemahaman awal mengenai kinerja Gaussian Naive Bayes dalam mengklasifikasikan komentar cyberbullying atau non-cyberbullying sebelum melanjutkan dengan metode feature selection untuk penyempurnaan.

Tabel 4. 2 Hasil Skenario 1 Model GNB

	Precision	Recall	F1-Score	Accuracy
Bullying	0.7812	0.7462	0.7633	0.7615
Non-bullying	0.7424	0.7777	0.7596	

Tabel tersebut memberikan hasil evaluasi kinerja model Bag of Word dengan penerapan algoritma Gaussian Naive Bayes. Dari hasil evaluasi, terlihat bahwa akurasi model mencapai 0.7615. Hasil ini menunjukkan kesesuaian yang cukup baik antara Bag of Word dan Gaussian Naive Bayes. Selain akurasi, parameter evaluasi lainnya juga perlu dipertimbangkan. Seperti, Precision untuk kelas Bullying adalah 0.7812, menunjukkan seberapa tepat model mengidentifikasi komentar sebagai bullying. Recall untuk kelas Bullying adalah 0.7462, menggambarkan seberapa baik model dapat mengenali sejumlah besar komentar yang sebenarnya terkait dengan bullying. F1-Score untuk kelas Bullying adalah 0.7633. Sementara itu, untuk kelas Non-bullying, precision sebesar 0.7424 menunjukkan seberapa tepat model dalam mengidentifikasi komentar sebagai non-bullying. Recall sebesar 0.7777 menunjukkan seberapa baik model dapat mengenali sejumlah besar komentar yang sebenarnya tidak terkait dengan bullying. F1-Score untuk kelas Non-bullying adalah 0.7596. Hasil evaluasi ini memberikan wawasan yang lebih mendalam tentang kinerja model dalam membedakan antara komentar-komentar yang terkait dengan bullying dan yang tidak. Potensi kombinasi Bag of Word dan Gaussian Naive Bayes dalam pemrosesan teks terlihat melalui tingkat

akurasi yang baik, namun tetap diperlukan pemahaman lebih lanjut terhadap precision, recall, dan F1-Score untuk memahami lebih detail performa model dalam tugas klasifikasi ini.

Demi mempermudah peresapan informasi, data tersebut akan ditampilkan dalam bentuk grafik. Penerapan grafik bertujuan memberikan gambaran yang lebih terang dan mudah dipahami terkait dengan hasil evaluasi kinerja algoritma Gaussian Naïve Bayes.



Gambar 4.8 Grafik kinerja Evaluasi GNB skenario 1


Dalam skenario kedua, kami menerapkan pendekatan berbeda dengan menggunakan teknik vektorisasi model TF-IDF. Dengan menerapkan model TF-IDF pada skenario ini, TF-IDF berhasil mendapatkan feature sebanyak 2.170, memiliki jumlah feature yang sama dengan feature yang diperoleh oleh model vektorisasi Bag of Word pada skenario pertama. Evaluasi lanjutan akan mengeksplorasi potensi dan kinerja model ini dalam memproses data teks secara lebih rinci, terutama dalam hal representasi TF-IDF dengan algoritma Gaussian Naïve Bayes.

Tabel 4. 3 Hasil Skenario 2 Model GNB

	Precision	Recall	F1-Score	Accuracy
Bullying	0.7758	0.6716	0.7200	0.7307
Non-bullying	0.6944	0.7936	0.7407	

Pada skenario kedua, metrik evaluasi kinerja model mencakup Precision, Recall, F1-Score, dan Accuracy untuk dua kelas: "Bullying" dan "Non-bullying". Untuk kelas "Bullying", Model mencapai Precision sebesar 0.7758, Recall 0.6716, dan F1-Score 0.7200. Sementara itu, untuk kelas "Non-bullying", model mencapai Precision 0.78, Recall 0.81, dan F1-Score 0.80. dengan tingkat akurasi keseluruhan sebesar 0.7307. Ini menunjukkan bahwa model pendekatan TF-IDF, dan menggunakan Gaussian Naïve Bayes, memberikan tingkat akurasi sebesar 0.7307. Hasil ini menunjukkan performa yang lebih rendah dibandingkan dengan pendekatan menggunakan Bag of Word pada skenario 1 yaitu sebesar 0.7615 memiliki selisih performa sebesar 0.0308. Penemuan pada skenario pertama ini menunjukkan feature extraction Bag of Word lebih unggul dari TF-IDF, ini disebabkan oleh model Bag of Word yang memiliki potensi perhitungan dengan mempertahankan urutan kata dalam setiap document, sesuai dengan temuan dalam penelitian yang dilakukan oleh (Putra et al., 2023).

Sama seperti data hasil skenario 1, data pada skenario 2 juga akan diimplementasikan kedalam bentuk grafik untuk memudahkan dalam visualisasi informasi.



Gambar 4. 9 Grafik Kinerja Evaluasi GNB skenario 2

Dalam skenario ketiga, kami menggabungkan metode Bag of Word dengan seleksi fitur menggunakan chi-square untuk meningkatkan performa klasifikasi. Setelah melakukan ekstraksi fitur dengan Bag of Word, kami menerapkan metode chi-square untuk menilai signifikansi setiap fitur dalam membedakan kelas. Fitur-fitur dengan skor chi-square tertinggi dipilih sebagai fitur penting dalam model klasifikasi dengan parameter $K=1000$. Selanjutnya, kami menggunakan Gaussian Naive Bayes untuk mengklasifikasikan data berdasarkan fitur-fitur yang terpilih melalui metode chi-square. Dengan skenario ini, harapan kami adalah meningkatkan kemampuan model dalam mengenali pola yang relevan dengan memilih fitur-fitur yang paling informatif melalui pendekatan Bag of Word dan seleksi fitur chi-square.

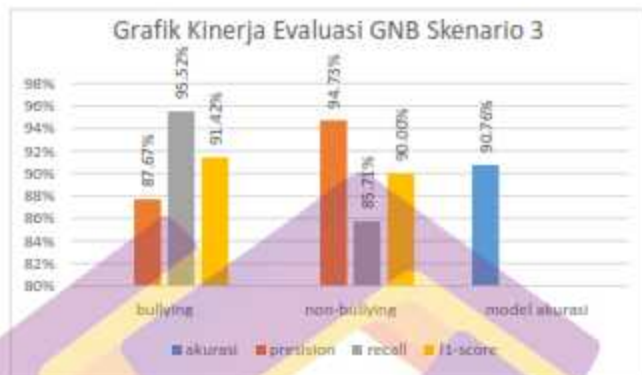
Tabel 4.4 Hasil Skenario 3 Model GNB

	Precision	Recall	F1-Score	Accuracy
Bullying	0.8767	0.9552	0.9142	0.9076
Non-bullying	0.9473	0.8571	0.9000	

Dalam skenario ketiga, dimana kami mengintegrasikan metode Bag of Word dengan seleksi fitur menggunakan chi-square untuk meningkatkan performa

klasifikasi. Setelah melakukan ekstraksi fitur dengan Bag of Word, kami menggunakan metode chi-square untuk menilai signifikansi setiap fitur dalam membedakan kelas, dengan fitur-fitur terpilih untuk model klasifikasi. Hasil evaluasi model menggunakan Gaussian Naive Bayes menunjukkan precision sebesar 0.8767, recall sebesar 0.9552, dan untuk F1-Score sebesar 0.9142 untuk kategori Bullying, menciptakan keseimbangan yang baik antara kepresisian dan ketepatan dalam mengidentifikasi teks Bullying. Sementara itu, kategori Non-bullying memiliki precision sekitar 0.9473, recall sekitar 0.8571 dan F1-score sebesar 0.9000. Kemudian untuk akurasi model yang didapatkan pada scenario ke tiga ini sebesar 0.9076, jika dibandingkan dengan akurasi yang didapatkan oleh model vektorisasi Bag of Word tanpa feature selection pada scenario 1 yaitu sebesar 0.7615, terdapat peningkatan akurasi sebesar 0.1461. Temuan ini disebabkan oleh penerapan chi-square sebagai feature selection, yang dimana chi-square dapat menganalisa secara statistic pada setiap fitur seberapa terkaitnya dengan kelas atau label (Ikhsani Larasati et al., 2019). Hasil ini menunjukkan bahwa penggunaan, Chi-square sebagai metode seleksi fitur berhasil meningkatkan kemampuan model, sesuai dengan temuan penelitian yang dilakukan oleh (Kisworini, 2020).

Pada data hasil kinerja evaluasi GNB dalam skenario 3 juga akan divisualisasi dalam bentuk grafik untuk kemudahan penyerapan informasi.



Gambar 4.10 Grafik kinerja Evaluasi GNB skenario 3


Pada skenario keempat, kami melakukan pendekatan yang berbeda lagi, dalam skenario 4 ini, kami menggabungkan model tf-idf dengan n-gram (tri-gram) tanpa menggunakan seleksi fitur, untuk mengetahui dampak dari penerapan n-gram pada tf-idf dalam skenario 4. Pendekatan N-gram yang digunakan yaitu n-gram jenis tri-gram. Pendekatan ini teradaptasi dari penelitian yang telah dilakukan oleh (Wynne & Wint, 2019). Dalam penelitian yang mereka lakukan berhasil meningkatkan akurasi TF-IDF dengan menerapkan metode n-gram yaitu teknik tri-gram dengan kenaikan akurasi sebesar 0.03. kemudian setelah fitur diekstraksi menggunakan tf-idf & tri-gram, kami menggunakan Gaussian Naive Bayes untuk mengklasifikasikan data berdasarkan fitur-fitur yang dihasilkan oleh model vektorisasi tf-idf & tri-gram. Dengan skenario ini, kami berusaha meningkatkan kinerja model dalam melakukan klasifikasi.

Tabel 4.5 Hasil Skenario 4 Model GNB

	Precision	Recall	F1-Score	Accuracy
Bullying	0.8103	0.7014	0.7520	0.7615
Non-bullying	0.7222	0.8254	0.7703	

Dalam tabel hasil skenario 4, dapat dilihat bahwa untuk kategori "Bullying," model menunjukkan precision sekitar 0.8103, yang mengindikasikan sekitar 81.03% dari teks yang diklasifikasikan sebagai Bullying secara akurat termasuk dalam kategori tersebut. Recall sekitar 0.7014 menunjukkan bahwa model mampu mengidentifikasi sekitar 70.14% dari semua teks yang diklasifikasi sebagai Bullying. F1-Score, yang mencerminkan keseimbangan antara precision dan recall, sekitar 0.94, menunjukkan performa yang baik dalam mengklasifikasikan teks Bullying. Kemudian untuk kategori "Non-bullying" memiliki precision sekitar 0.7222, yang berarti sekitar 72.22% dari teks yang diklasifikasikan sebagai Non-bullying. Recall sekitar 0.8254 menunjukkan bahwa model dapat mengidentifikasi sekitar 82.54%. F1-Score sekitar 0.7703 menciptakan keseimbangan antara precision dan recall dalam mengklasifikasikan teks Non-bullying. Secara keseluruhan, akurasi model mencapai 0.7615, memiliki keunggulan sekitar 0.0308 dari skenario kedua yang dimana tf-idf tidak menggunakan model n-gram. Temuan ini menunjukkan bahwa, kombinasi tf-idf dengan n-gram berhasil meningkatkan akurasi kemampuan model dalam mengklasifikasi, ini sesuai dengan temuan penelitian yang dilakukan oleh (Wynne & Wint, 2019) yang berhasil meningkatkan akurasi model dengan penerapan tri-gram.

Data kinerja evaluasi GNB pada skenario ke 4 yang didapatkan akan ditampilkan dalam bentuk grafik, untuk memudahkan dalam memahami.



Gambar 4.11 Grafik Kinerja Evaluasi GNB Skenario 4

Pada scenario kelima peneliti menerapkan metode TF-IDF, Chi-square, algoritma Gaussian Naive Bayes untuk melakukan klasifikasi teks komentar cyberbullying. Frekuensi-Term dan Inverse Document Frequency (TF-IDF) digunakan untuk menilai signifikansi kata-kata dalam teks. Dengan memperhitungkan frekuensi kemunculan kata-kata dalam teks, pendekatan ini membantu mengenali kata-kata yang memiliki peran krusial dalam mengklasifikasi antara teks komentar bullying dan non-bullying. Selain itu, peneliti menggunakan metode Chi-square sebagai pendekatan untuk menyeleksi fitur. Chi-square digunakan untuk mengevaluasi tingkat keterkaitan antara kehadiran suatu fitur (kata) dengan kelas klasifikasi (bullying dan non-bullying). Dengan menerapkan pendekatan ini, peneliti dapat mengidentifikasi fitur-fitur yang memiliki korelasi yang cukup berarti dengan klasifikasi teks komentar bullying atau non-bullying. Kemudian peneliti menggunakan algoritma Gaussian Naive Bayes untuk membangun model klasifikasi. Gaussian Naive Bayes adalah suatu teknik klasifikasi yang memiliki penggunaan yang penting dalam analisis teks. Algoritma

ini merupakan varian dari Naive Bayes yang secara khusus dikembangkan untuk menangani data teks yang memiliki fitur-fitur berdistribusi kontinu, seperti nilai numerik atau atribut yang bersifat berkelanjutan. Gaussian Naive Bayes beroperasi dengan mengasumsikan bahwa distribusi fitur-fitur dalam setiap kelas mengikuti pola distribusi Gaussian atau distribusi normal (Taslim et al., 2023). Sederhananya

Gaussian Naive Bayes bekerja dengan menganggap bahwa fitur-fitur dalam setiap kelas mengikuti pola distribusi normal atau Gaussian. Ini memungkinkan algoritma untuk membuat prediksi kelas dengan memanfaatkan probabilitas distribusi fitur pada setiap kategori, sehingga membantu dalam mengklasifikasi teks komentar bullying atau non-bullying.


Gambar 4.6 Hasil Skenario 5 Model GNB

	Precision	Recall	F1-Score	Accuracy
Bullying	0.9666	0.8656	0.9133	0.91538
Non-bullying	0.8714	0.9682	0.9172	

Pada scenario lima peneliti melakukan eksplorasi pendekatan dengan melibatkan, chi-square dan Gaussian Naive Bayes dengan tujuan meningkatkan akurasi dari model yang digunakan yaitu Gaussian Naive Bayes. Pendekatan ini terinspirasi dari penelitian yang dilakukan oleh (Rosidin et al., 2021) dimana dalam penelitian mereka menerapkan chi-square pada algoritma Naive Bayes dan berhasil meningkatkan akurasinya sebesar 1.9 %. Dalam penelitian ini peneliti menerapkan chi-square pada algoritma Gaussian Naive Bayes yaitu pada scenario kelima dan berhasil mendapatkan akurasi sebesar 0.91538, menunjukkan bahwa terjadi peningkatan akurasi 0.1846 dari scenario kedua yang dimana pendekatannya tidak

melibatkan chi-square. Penemuan ini menunjukkan bahwa penerapan feature selection chi-square berhasil meningkatkan akurasi model. Temuan berkontribusi dalam pengembangan model klasifikasi yang lebih baik.

Untuk memudahkan dalam interpretasi informasi data pada table hasil kinerja scenario 5 model GNB akan ditampilkan dalam bentuk grafik.



Gambar 4.12 Grafik Kinerja Evaluasi GNB Skenario 5

Dalam scenario keenam peneliti menerapkan pendekatan yang lebih kompleks. Dalam scenario keenam ini peneliti menggunakan TF-IDF, n-gram (trigram), dan algoritma Gaussian Naïve Bayes. Pertama, peneliti menggunakan metode TF-IDF untuk mengekstraksi fitur dari dataset teks. Dengan menerapkan TF-IDF, model dapat menilai tingkat signifikansi suatu kata berdasarkan frekuensi kemunculan kata tersebut pada keseluruhan dataset. Ini membantu dalam mengenali kata-kata yang penting yang memiliki potensi untuk melakukan klasifikasi komentar teks bullying atau non-bullying. Kemudian, Peneliti memanfaatkan model n-gram untuk memperhitungkan konteks dan urutan kata dalam teks komentar. Dengan menggabungkan beberapa kata menjadi satu unit,

model n-gram dapat menangkap pola-pola yang lebih kompleks dalam teks, yang berkontribusi dalam peningkatan klasifikasi teks komentar. Berikutnya, peneliti menggunakan metode chi-square untuk memilih fitur. Chi-square digunakan untuk mengevaluasi keterkaitan antara setiap fitur (kata) dan label klasifikasi (komentar bullying atau non-bullying). Kemudian terakhir klasifikasi menggunakan Gaussian Naïve Bayes, Gaussian Naïve Bayes akan digunakan untuk membangun model klasifikasi teks komentar bullying atau non-bullying dalam scenario enam ini. Menerapkan pendekatan ini memungkinkan peneliti untuk menemukan fitur-fitur yang memiliki keterkaitan yang signifikan dengan label klasifikasi, serta mengesampingkan fitur-fitur yang kurang relevan dan model melakukan klasifikasi dengan efektif.


Tabel 4.6 Hasil Kinerja Skenario 6 Model GNB

	Precision	Recall	F1-Score	Accuracy
Bullying	1.0000	0.8806	0.9133	0.9384
Non-bullying	0.8873	1.0000	0.9403	

Dalam tabel hasil kinerja skenario 6, dapat dilihat peneliti melakukan experiment, dimana mengkombinasikan TF-IDF dengan n-gram dan chi-square dengan tujuan melakukan klasifikasi komentar bullying atau non-bullying. Dengan pendekatan yang diimplementasikan dalam skenario 6 ini, dapat disaksikan peningkatan signifikan yang dihasilkan pada akurasi model Gaussian Naive bayes yang awalnya pada skenario 4 dapat disaksikan dengan hanya menggunakan tf-idf, n-gram, dan Gaussian Naive Bayes hanya berhasil mendapatkan akurasi sebesar 0.7615, setelah ditambahkan feature selection chi-square model berhasil meningkat dengan akurasi sebesar 0.9384, peningkatan akurasi yang didapat kan ini sejalan

dengan penelitian yang dilakukan oleh (Dimas Pratama et al., 2018) dimana salam penelitian mereka berhasil meningkatkan akurasi model setelah menerapkan feature selection chi-square. Penerapan pan metode tf-idf, n-gram, chi-square dan gaussian naive bayes berhasil meningkatkan akurasi model secara keseluruhan. Hasil penelitian ini memperlihatkan bahwa penggabungan metode n-gram dan chi-square pada algoritma Gaussian Naive Bayes secara signifikan meningkatkan akurasi yaitu berhasil meningkat sebesar 0.1769. Temuan tersebut menunjukkan kemampuan model yang dirancang dalam penelitian memiliki perkembangan dalam mengklasifikasi teks komentar bullying atau non-bullying menggunakan Gaussian Naive Bayes. Temuan dalam pendekatan yang dirancang ini memiliki andil yang perlu dalam meningkatkan klasifikasi teks komentar bullying dengan mempertimbangkan konteks kata kemudian juga korelasi fitur secara lebih efektif. Oleh karena itu, pendekatan pada skenario ini dapat dinyatakan sebagai langkah yang baik dan efektif dalam meningkatkan performa model dalam mengklasifikasi teks komentar bullying atau non-bullying.

Untuk memudahkan dalam memahami data yang disajikan dalam tabel 4.7, data tersebut akan ditampilkan dalam bentuk grafik, grafik memudahkan fisualisasi karna mudah dipahami.



Gambar 4.13 Grafik Kinerja Evaluasi GNB Skenario 6

Setelah mencari hasil optimal dari setiap kondisi atau situasi pada model Gaussian Naïve Bayes, langkah berikutnya yaitu membandingkan hasil tersebut di antara situasi-situasi tersebut untuk menilai situasi atau scenario mana yang memberikan kinerja terbaik pada model Gaussian Naïve Bayes. Berikut merupakan hasil klasifikasi model Gaussian Naïve Bayes :

Tabel 4.7 Hasil klasifikasi algoritma Gaussian Naïve Bayes

Skenario	GNB	Bag of Word	TF-IDF	N-gram	Feature selection	Akurasi	Precision		Recall		F1-Score	
					Chi-Square		Bullying	Non-bullying	Bullying	Non-bullying	Bullying	Non-bullying
1	✓	✓				0,7615	0,7812	0,7424	0,7462	0,7777	0,7633	0,7596
2	✓		✓			0,7307	0,7758	0,6944	0,6716	0,7936	0,7200	0,7407
3	✓	✓			✓	0,9076	0,8767	0,9473	0,9552	0,8571	0,9142	0,9000
4	✓		✓	✓		0,7615	0,8103	0,7222	0,7014	0,8254	0,7520	0,7703
5	✓		✓		✓	0,9153	0,9666	0,8714	0,8656	0,9682	0,9133	0,9172
6	✓		✓	✓	✓	0,9384	1,0000	0,8806	0,8806	1,0000	0,9133	0,9403


Berdasarkan data yang terdapat dalam tabel, dapat ditarik kesimpulan bahwa gabungan fitur dan metode seleksi fitur pada algoritma Gaussian Naïve Bayes

Bayes memiliki pengaruh terhadap performa model klasifikasi komentar bullying atau non bullying. Hasil evaluasi memaparkan bahwa skenario ke-enam memiliki hasil terbaik dari skenario yang lain dengan menggunakan metode TF-IDF, N-gram, dan Chi-Square, berhasil mendapatkan akurasi tertinggi yaitu sebesar 0.9384. kemudian model ini juga memiliki nilai precision, recall, dan f1-score, untuk bullying, precision mendapatkan sebesar 1.0000, recall sebesar 0.8806, f1-score sebesar 0.9133. Untuk non-bullying, precision mendapatkan sebesar 0.8806, recall sebesar 1.0000, dan f1score sebesar 0.9403.

Sementara untuk skenario lain, terdapat berbagai variasi kinerja model. Skenario pertama, dimana menggunakan metode vectorisasi Bag of Word (BoW) mendapat akurasi sebesar 0.7615. Untuk skenario 3 dimana dengan penerapan feature selection chi-square berhasil meningkatkan akurasi ketika hanya menggunakan BoW saja, yaitu berhasil mendapatkan akurasi sebesar 0.9076. lalu pada skenario 2 dimana vectorisasi hanya menggunakan TF-IDF mendapatkan akurasi sebesar 0.7307 ini mengindikasikan model yang dirancang cukup baik. Sementara pada skenario 5, yang dimana model yang dirancang yaitu TF-IDF dengan menggunakan feature selection chi-square untuk memilih fitur yang relevan dan informatif, dan berhasil mendapat akurasi sebesar 0.9153. itu artinya peningkatan akurasi terjadi dan itu disebabkan oleh penerapan feature selection pada skenario 5 dimana bertujuan untuk memilih fitur yang informatif guna untuk meningkatkan hasil akurasi dalam sebuah model. Lalu terdapat skenario 4 dengan metode vectorisasi TF-IDF kombinasi N-gram berhasil mendapat akurasi sebesar 0.7615, yang artinya berhasil melakukan peningkatan akurasi dengan penerapan

model n-gram (tri-gram), dimana pada skenario 2 yang hanya mendapat akurasi sebesar 0.7307 dikarenakan tidak menerapkan model n-gram (tri-gram) yang bisa membantu memperluas makna teks dalam data. Dari berbagai skenario yang telah dilakukan diatas dapat dilihat bahwa untuk metode vectorisasi dengan akurasi terbaik antara BoW dan TF-IDF (tanpa n-gram) diraih oleh metode vectorisasi BoW, akan tetapi ketika metode vectorisasi TF-IDF dikombinasikan dengan model N-gram (trigram), metode vectorisasi terbaik dicapai oleh TF-IDF-(trigram) karena tri-gram mampu mengikat konteks dari teks dalam sebuah dataset, yang dimana dapat mempermudah model untuk menginterpretasi dan memudahkan melakukan klasifikasi berdasarkan kelas. Sementara ketika penerapan feature selection pada kedua metode, akurasi terbaik dicapai oleh metode TF-IDF-(N-gram) dikarenakan jumlah fitur yang dihasilkan oleh metode TF-IDF-(N-gram) lebih banyak dari pada BoW yang dimana memudahkan untuk feature selection chi-square dalam menyeleksi atau memilih fitur – fitur terbaik dari banyaknya fitur yang dihasilkan oleh metode TF-IDF-(N-gram). Sementara untuk metode feature selection berdasarkan dari skenario model Gaussian Naive Bayes yang telah dilakukan, feature selection chi-square berhasil secara signifikan meningkatkan akurasi klasifikasi komentar bullying atau non-bullying menggunakan model Gaussian Naive Bayes.

Untuk dapat lebih mudah dipahami, data tersebut akan disajikan dalam bentuk grafik. Tujuan penggunaan grafik adalah untuk memberikan gambaran yang lebih jelas dan mudah dipahami terkait hasil evaluasi kinerja. Oleh karena itu, disajikanlah hasil kinerja evaluasi GNB dalam bentuk grafik.



Gambar 4.14 Grafik Kinerja Evaluasi GNB

4.4. Model Support Vector Machine

Dalam proses klasifikasi, model Support Vector Machine (SVM) berusaha menemukan hiperplane yang memisahkan dua kelas data sejauh mungkin dari titik-titik data terdekat dari kedua kelas tersebut. Tujuannya adalah menciptakan batas keputusan optimal agar dapat mengklasifikasikan data baru dengan tingkat akurasi yang tinggi. Model SVM dapat menangani baik data yang bersifat linier maupun non-linier. Jika data bersifat non-linier, SVM menggunakan fungsi kernel untuk mentransformasi ruang fitur ke dalam dimensi yang lebih tinggi, memungkinkan hiperplane untuk secara efektif memisahkan kelas-kelas data tersebut.

4.4.1. Scenario pengujian model SVM

Pada tahap ini kami merancang enam scenario pengujian yang berbeda untuk menguji model SVM yang telah kami bangun. Berikut ini adalah rancangan scenario yang akan digunakan.

Tabel 4.8 Rancangan Skenario Model SVM

Skenario	SVM	Bag of Word	TF-IDF	N-gram	Feature Selection	Akurasi	Precision	Recall	F1-Score
					Chi-square				
1	✓	✓			
2	✓		✓		
3	✓	✓			✓
4	✓		✓	✓	
5	✓		✓		✓
6	✓		✓	✓	✓

Tabel di atas menunjukkan kombinasi beberapa metode atau teknik yang akan diterapkan dalam evaluasi kinerja model klasifikasi dengan menggunakan algoritma Support Vector Machine Berikut adalah penjelasannya :

9. Pada kolom **Skenario** : Menunjukkan nomor atau urutan skenario dari kombinasi metode atau teknik yang akan diuji.
10. Pada kolom **SVM (Support Vector Machine)**: Menunjukkan apakah metode Support Vector Machine akan digunakan dalam pengolahan teks untuk skenario tertentu.
11. Pada kolom **Bag of Word**: Menunjukkan apakah metode Bag of Word akan digunakan dalam proses pengolahan teks untuk skenario tertentu.
12. Pada kolom **TF-IDF**: Menunjukkan apakah metode TF-IDF akan digunakan dalam pengolahan teks atau tidak pada skenario tertentu.

13. Pada kolom **N-gram**: Menunjukkan apakah teknik N-gram (tri-gram) akan digunakan dalam pengolahan teks atau tidak dalam skenario tertentu.
14. Pada kolom Feature Selection (**Chi-square**): Menunjukkan apakah metode seleksi fitur Chi-Squared akan digunakan atau tidak diskenario tertentu.

Pada skenario pertama, kami menggunakan teknik vektorisasi dengan metode Bag of Word. Kemudian Algoritma Support Vector Machine (GNB) untuk melakukan proses klasifikasi komentar bullying atau non-bullying. Kami memanfaatkan seluruh fitur yang ada yang dihasilkan oleh Bag of Word tanpa melakukan proses feature selection. Dengan menerapkan algoritma Support Vector Machine, kami dapat mengkategorikan komentar – komentar yang ada dalam data sebagai bullying atau non-bullying berdasarkan informasi yang terkandung dalam data tersebut. Skenario ini memberikan pemahaman awal mengenai kinerja Support Vector Machine dalam mengklasifikasikan komentar bullying atau non-bullying sebelum melanjutkan dengan metode feature selection untuk mengefisiensikan.


Tabel 4.9 Hasil kinerja Skenario 1 Model SVM

	Precision	Recall	F1-Score	Accuracy
Bullying	0.8285	0.8656	0.8467	0.8384
Non-bullying	0.8500	0.8095	0.8292	

Tabel tersebut mencerminkan hasil evaluasi kinerja model menggunakan metode Bag of Word dan algoritma Support Vector Machine. Dalam evaluasi tersebut, akurasi model yang mencapai 0.8384% menunjukkan tingkat keberhasilan dalam mengklasifikasikan data. Hasil akurasi ini menunjukkan bahwa penggunaan Bag of Word bersama dengan Support Vector Machine menghasilkan tingkat

akurasi yang memadai, menunjukkan adanya sinergi antara kedua metode tersebut. Selain itu, evaluasi juga menggambarkan potensi kombinasi ini dalam pemrosesan teks dan memberikan dasar penilaian terhadap performa model dalam tugas klasifikasi. Dengan precision sekitar 0.78 untuk kategori "Bullying" dan 0.71 untuk kategori "Non-bullying," recall masing-masing sebesar 0.70 dan 0.79, serta F1-Score sekitar 0.74 dan 0.75, hasil tersebut menunjukkan keseimbangan yang baik antara ketepatan dan keakuratan model dalam mengklasifikasi. Pencapaian ini memberikan imajinasi awal tentang kemampuan model Support Vector Machine dalam melakukan klasifikasi komentar bullying atau non-bullying sebelum melakukan penerapan – penerapan untuk penyempurnaan atau pengefektifitasan dengan melibatkan kombinasi – kombinasi lebih lanjut.

Data hasil scenario 1 SVM akan ditampilkan dalam bentuk grafik untuk memudahkan pemahaman informasi dari data kinerja model SVM yang didapatkan.



Gambar 4.15 Grafik Kinerja Evaluasi SVM Skenario 1

Dalam scenario kedua, kami menerapkan pendekatan yang berbeda dimana metode feature extraction yang digunakan yaitu TF-IDF dan membangun model

klasifikasinya menggunakan algoritma Support Vector Machine. Peneliti menggunakan seluruh fitur yang ada tanpa melakukan feature selection untuk memilih fitur yang relevan. Dengan algoritma klasifikasi Support Vector Machine yang digunakan untuk melakukan klasifikasi komentar bullying atau non-bullying dari dataset yang digunakan. Scenario ini sebagai tahap awal untuk mengetahui berbagai pencapaian dan perbedaan hasil akurasi dibandingkan dengan metode Bag of Word dalam pengimplementasiannya pada algoritma Support Vector Machine, dan ketika tanpa menerapkan kombinasi – kombinasi metode lain salah satunya feature selection untuk mengefektifkan hasil akurasi klasifikasi komentar bullying atau non-bullying.


Tabel 4. 10 Hasil kinerja Skenario 2 Model SVM

	Precision	Recall	F1-Score	Accuracy
Bullying	0.8923	0.8656	0.8787	0.8769
Non-bullying	0.8615	0.8888	0.8750	

Pada table hasil scenario kedua model SVM dapat dilihat bahwa hasil kinerja evaluasi, untuk bagian kategori "Bullying," hasil evaluasi menunjukkan precision sebesar 0.8923, mencerminkan bahwa sekitar 89.23% dari teks yang diklasifikasikan sebagai Bullying secara akurat termasuk dalam kategori tersebut. Recall sebesar 0.8656 menunjukkan bahwa model mampu mengidentifikasi sekitar 86.56% dari semua kategori Bullying. F1-Score sebesar 0.8787 menciptakan keseimbangan antara precision dan recall, menunjukkan performa yang baik dalam mengklasifikasikan teks Bullying. Untuk kategori "Non-bullying," precision sebesar 0.8615 menunjukkan bahwa sekitar 86.15% dari teks yang diklasifikasikan sebagai Non-bullying. Recall sebesar 0.8888. F1-Score sebesar 0.85 menciptakan

keseimbangan antara precision dan recall, menunjukkan performa yang baik dalam mengklasifikasikan teks atau komentar Non-bullying. Dalam skenario kedua Akurasi yang didapatkan oleh algoritma Support Vector Machine dengan metode vectorisasi TF-IDF berhasil mencapai akurasi sebesar 0.8769, menunjukkan tingkat keunggulan hasil yang didapatkan ketika TF-IDF dikombinasikan dengan algoritma klasifikasi Support Vector Machine, ini sejalan dengan kesimpulan temuan penelitian yang dilakukan oleh (Apriani et al., 2023) bahwa kombinasi TF-IDF dan algoritma Support Vector Machine menghasilkan kinerja yang unggul. Temuan ini dapat berkontribusi sebagai referensi untuk membangun model yang unggul dengan menggunakan model Support Vector Machine.

Data hasil skenario 2 model SVM yang telah didapatkan juga akan ditampilkan dalam bentuk grafik, tujuannya untuk lebih mempermudah pemahaman dari data hasil skenario 2 model SVM.



Gambar 4. 16 Grafik Kinerja Evaluasi SVM Skenario 2

Pada scenario ketida, peneliti menggunakan Bag of Word untuk metode vectorisasi dan menggunakan feature selection untuk melakukan seleksi fitur yang dihasilkan oleh Bag of Word, sebelum dilanjutkan dengan melakukan klasifikasi memanfaatkan algoritma klasifikasi Support Vector Machine. Peneliti melakukan perhitungan dan penyeleksian fitur menggunakan metode chi-square, dimana fitur – fitur dengan skor tertinggi dianggap sebagai fitur terpenting yang kemudian dipilih sebagai fitur yang kemudian fitur – fitur yang terpilih dimasukkan kedalam mesin klasifikasi yang dibangun dengan algoritma klasifikasi Support Vector Machine. Dengan perancangan model seperti ini dalam scenario tiga ini meningkatkan kemampuan SVM dalam melakukan klasifikasi komentar bullying dan non-bullying dengan fitur – fitur yang dipilih dengan metode feature selection chi-square yang memiliki hubungan yang relevan dengan komentar bullying dan non-bullying.

Tabel 4. 11 Hasil kinerja Skenario 3 Model SVM

	Precision	Recall	F1-Score	Accuracy
Bullying	0.8507	0.8507	0.8507	0.8461
Non-bullying	0.8412	0.8412	0.8412	

Dalam tabel hasil kinerja skenario ketiga menggunakan model SVM, dapat dianalisis kinerja evaluasi yang diperoleh, bahwa pada kategori "Bullying," didapatkan precision sebesar 0.8507 menunjukkan bahwa sekitar 85.07% dari teks yang diklasifikasikan sebagai Bullying secara akurat termasuk dalam kategori tersebut. Recall sebesar 0.8507 menunjukkan bahwa model mampu mengidentifikasi sekitar 85.07% dari seluruh kategori Bullying. F1-Score sebesar 0.8507 menciptakan keseimbangan antara precision dan recall, menunjukkan

performa yang baik dalam mengklasifikasikan teks Bullying. Sementara itu, untuk kategori "Non-bullying," didapatkan precision sebesar 0.8412 menunjukkan bahwa sekitar 84,12% dari teks yang diklasifikasikan sebagai Non-bullying. Recall sebesar 0.8412 menunjukkan bahwa model dapat mengidentifikasi sekitar 84,12% dari seluruh kategori Non-bullying. F1-Score sebesar 0.8412 menciptakan keseimbangan antara precision dan recall dalam mengklasifikasikan teks Non-bullying. Untuk akurasi model yang dirancang dalam skenario ini berhasil mendapatkan akurasi sebesar 0.8461. Dapat dilihat bahwa mengalami kenaikan dari skenario pertama dari 0.8384 menjadi 0.8461 mengalami kenaikan sekitar 0.0077. ini disebabkan karena dalam skenario pertama tidak diterapkannya feature selection chi-square, karena feature selection chi-square dapat membantu meningkatkan akurasi SVM, karna dalam sebuah penelitian yang dilakukan oleh (Somantri & Apriliani, 2018) yang dimana penelitian yang mereka lakukan berhasil meningkatkan akurasi SVM dan chi-square. Temuan dalam penelitian ini merepresentasikan dukungan dari penelitian (Somantri & Apriliani, 2018), bahwa kami menyampaikan kombinasi chi-square dan SVM menjadi pendekatan yang baik dalam meningkatkan kinerja model klasifikasi.

Dari data hasil skenario 3 model SVM juga akan direpresentasikan dalam bentuk grafil, guna untuk menyederhanakan atau memudahkan pemahaman data hasil skenario 3 pada model SVM.



Gambar 4.17 Grafik Kinerja Evaluasi SVM Skenario 3


Dalam skenario keempat, kami menggabungkan model tf-idf dengan n-gram (tri-gram) untuk memperluas fitur-fitur yang akan digunakan dalam klasifikasi pada skenario 4. Pendekatan ini melibatkan ekstraksi pola kata berurutan dalam bentuk tri-gram, sehingga memungkinkan model untuk memahami konteks dan hubungan antar kata secara lebih komprehensif. Kemudian kami juga menggunakan algoritma SVM untuk membangun model klasifikasi teks komentar bullying atau non-bullying dengan input berupa fitur – fitur yang telah diekstraksi dari hasil kombinasi model tf-idf dengan tri-gram. Dengan pendekatan ini, peneliti berharap bisa meningkatkan kemampuan dari algoritma SVM dalam mengklasifikasi komentar bullying atau non-bullying dengan memanfaatkan konteks yang lebih utuh dengan metode n-gram (tri-gram).

Tabel 4.12 Hasil Kinerja Skenario 4 Model SVM

	Precision	Recall	F1-Score	Accuracy
Bullying	0.9333	0.8358	0.8818	0.8846
Non-bullying	0.8428	0.9365	0.8872	

Hasil dari tabel skenario 4 menggunakan model TF-IDF, N-gram, dan SVM dapat dianalisis kinerja evaluasi yang diperoleh bahwa untuk kategori "Bullying," didapatkan precision sebesar 0.9333 mengindikasikan bahwa sekitar 93.33% dari teks yang diklasifikasikan sebagai Bullying secara akurat. Recall sebesar 0.8358. F1-Score sebesar 0.8818 menciptakan keseimbangan yang baik antara precision dan recall. Untuk kategori "Non-bullying," didapatkan precision sebesar 0.8428 menunjukkan bahwa sekitar 84.28% dari teks yang diklasifikasikan sebagai Non-bullying secara akurat. Recall sebesar 0.8358 menunjukkan bahwa model dapat mengidentifikasi sekitar 83.58% dari seluruh kategori Non-bullying. F1-Score sebesar 0.8872 menciptakan keseimbangan antara precision dan recall dalam mengklasifikasikan teks Non-bullying. Untuk akurasi klasifikasi model Support Vector Machine dalam skenario 4 ini berhasil mencapai 0.8846. ini menunjukkan terdapat peningkatan akurasi klasifikasi algoritma Support Vector Machine ketika menerapkan metode vektorisasi TF-IDF dengan kombinasi N-gram (tri-gram) , yang dimana ketika pada skenario 2 TF-IDF dan SVM hanya mendapatkan 0.8769, memiliki selisih peningkatan akurasi sebesar 0.0077 ketika menggunakan kombinasi TF-IDF, N-gram, dan Support Vector Machine. Temuan ini selaras dengan yang pernah dilakukan oleh (Pacol & Palaoag, 2021) diaman dalam penelitian tersebut mereka memanfaatkan model n-gram dan SVM guna meningkatkan akurasi model, diaman dalam penelitian yang mereka lakukan berhasil meningkatkan akurasi klasifikasi algoritma support vector machine. Temuan dari studi tersebut menunjukkan bahwa penerapan model n-gram mampu meningkatkan akurasi SVM.

Untuk memudahkan pemahaman terkait dengan data hasil scenario 4 model SVM yang telah didapatkan, data tersebut akan disajikan dalam bentuk grafik.



Gambar 4.18 Gambar Kinerja Evaluasi SVM Skenario 4

Pada scenario kelima kami melakukan pendekatan yang berbeda dimana kami memanfaatkan feature selection chi-square untuk melakukan seleksi fitur sebelum melakukan klasifikasi komentar bullying atau non bullying menggunakan algoritma klasifikasi Support Vector Machine. Feature selection Chi-square melakukan pemberian score untuk setiap fitur, mencerminkan tingkat keterkaitan antara keberadaan fitur tersebut dengan label atau klas komentar bullying atau non bullying. Fitur-fitur yang mendapatkan skor chi-square tinggi dianggap memiliki keterkaitan yang signifikan dengan kelas bullying atau non-bullying dan digunakan sebagai fitur yang penting pada model klasifikasi. Berikutnya, kami menggunakan algoritma SVM untuk melakukan klasifikasi berdasarkan fitur-fitur yang terpilih melalui seleksi chi-square. Dengan langkah ini, kami bertujuan meningkatkan kemampuan SVM dalam melakukan klasifikasi komentar bullying

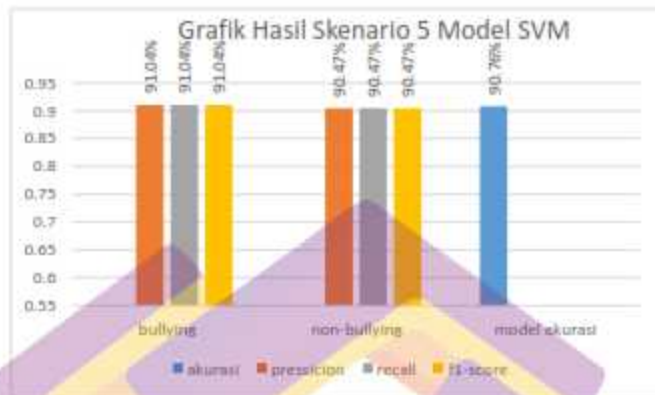
dan non-bullying. Dengan memanfaatkan hasil pemilihan fitur – fitur yang memiliki relevansi dengan komentar bullying atau non-bullying, yang dilakukan oleh feature selection chi-square.

Tabel 4.13 Hasil Skenario 5 Model SVM

	Precision	Recall	F1-Score	Accuracy
Bullying	0.9104	0.9104	0.9104	0.9076
Non-bullying	0.9047	0.9047	0.9047	

Pada skenario lima, dapat disaksikan akurasi yang didapatkan yaitu 0.9076, menunjukkan peningkatan yang signifikan dari akurasi kombinasi model yang digunakan pada skenario 2 yang dimana tanpa penerapan feature selection yaitu hanya mendapatkan akurasi sebesar 0.8769. Ini menunjukkan penerapan feature selection chi-square dapat meningkatkan akurasi klasifikasi algoritma klasifikasi Support Vector Machine. Temuan ini selaras dengan temuan penelitian yang pernah dilakukan oleh (Rama et al., 2023). Penelitian yang telah mereka lakukan membuktikan bahwa chi-square mampu meningkatkan akurasi algoritma klasifikasi Support Vector Machine. Dalam pendekatan ini diaman menggunakan TF-IDF, Chi-Square, dan SVM dapat menjadi pendekatan yang ampuh untuk meningkatkan model klasifikasi.

Data dalam tabel skenario lima model SVM akan disajikan dalam bentuk grafik untuk mempermudah dalam memvisualisasi data yang tersaji dan yang sudah diperoleh dari skenario lima yang sudah dijalankan.



Gambar 4.19 Grafik Kinerja Evaluasi SVM Skenario 5


Pada scenario enam kami menggunakan pendekatan model n-gram tri-gram dengan dengan feature selection chi-square untuk meningkatkan performa klasifikasi komentar bullying dan non-bullying. Setelah mengekstraksi fitur n-gram (tri-gram), kami menggunakan metode chi-square untuk menilai signifikansi setiap fitur model n-gram (tri-gram) dalam membedakan komentar bullying dan non-bullying. Fitur – fitur dengan skor tertinggi dipiling sebagai fitur penting oleh chi-square untuk digunakan dalam model klasifikasi yang dibangun. Selanjutnya kami menggunakan algoritma Support Vector Machine untuk membangun model klasifikasi komentar bullying atau non-bullying berdasarkan fitur - fitur n-gram yang telah diseleksi menggunakan metode chi-square. Dengan pendekatan ini , peneliti bertujuan dapat meningkatkan kemampuan Support Vector Machine untuk mengklasifikasi komentar bullying atau non-bullying dengan memilih fitur-fitur yang panging informatif melalui pemanfaatan n-gram dan feature selection chi-square.

Tabel 4.14 Hasil Kinerja Skenario 6 Model SVM

	Precision	Recall	F1-Score	Accuracy
Bullying	0.9538	0.9253	0.9393	0.9384
Non-bullying	0.9230	0.9523	0.9375	

Pada table hasil kinerja yang didapatkan pada scenario enam model SVM ini dapat dilihat bahwa pendekatan n-gram dengan feature selection chi-square berhasil mencapai akurasi sebesar 0.9384, dimana dapat dilihat dengan pendekatan ini model SVM mengalami peningkatan yang signifikan dibandingkan scenario sebelumnya dimana pada scenario 4 yang hanya menerapkan model n-gram (tri-gram) tanpa feature selection chi-square hanya mencapai akurasi sebesar 0.8846, dapat dilihat mengalami peningkatan dalam scenario enam ini yaitu sekitar 0.0538. Temuan ini menunjukkan bahwa penggunaan pendekatan n-gram dan chi-square pada algoritma klasifikasi Support Vector Machine dapat mencapai kinerja klasifikasi yang lebih baik dari pendekatan yang hanya menerapkan model n-gram tanpa feature selection. Efektifitas penerapan n-gram dan feature selection chi-square juga telah berhasil dibuktikan oleh penelitian yang dilakukan oleh (Fachrurrozi et al., 2021) dimana dalam penelitian mereka berhasil meningkatkan kemampuan algoritma SVM dengan penerapan n-gram dan feature selection chi-square. Temuan penelitian dalam scenario enam ini menekankan bahwa kinerja algoritma Support Vector Machine dipengaruhi oleh pengimplementasian n-gram dan chi-square, yang memiliki dampak pada jumlah dan kualitas feature yang digunakan. Dapat menjadi acuan bahwa menentukan model N-gram dan jumlah dan kualitas feature secara baik supaya bisa mencapai kinerja klasifikasi yang maksimal.

Informasi dari tabel pada skenario enam model SVM akan diubah menjadi grafik untuk memudahkan visualisasi data yang telah dikumpulkan dari pelaksanaan skenario enam.



Gambar 4.20 Grafik Kinerja Evaluasi SVM Skenario 6

Setelah meraih hasil terbaik dari masing-masing skenario dengan model Support Vector Machine (SVM), langkah berikutnya adalah membandingkan hasil tersebut antar skenario untuk menentukan skenario mana yang menghasilkan kinerja terbaik pada model SVM. Berikut ini adalah hasil klasifikasi dari model Support Vector Machine:

Tabel 4.15 Performa evaluasi algoritma Support Vector Machine


Skenario	SVM	Bag of Words	TF-IDF	N-gram	Feature selection	Akurasi	Precision		Recall		F1-Score	
					Chi-Square		Bullying	Non-bullying	Bullying	Non-bullying	Bullying	Non-bullying
1	✓	✓				0.8384	0.8285	0.8500	0.8656	0.8095	0.8467	0.8292
2	✓		✓			0.8769	0.8923	0.8615	0.8656	0.8888	0.8787	0.8750
3	✓	✓			✓	0.8461	0.8507	0.8412	0.8507	0.8412	0.8507	0.8412
4	✓		✓	✓		0.8846	0.9333	0.8428	0.8358	0.9365	0.8818	0.8872
5	✓		✓		✓	0.9076	0.9104	0.9047	0.9104	0.9047	0.9104	0.9047
6	✓		✓	✓	✓	0.9384	0.9538	0.9230	0.9253	0.9523	0.9393	0.9375

Berdasarkan hasil table, dapat ditarik kesimpulan bahwa kombinasi model TF-IDF, N-gram, feature selection chi-square dengan SVM memiliki pengaruh yang signifikan terhadap performa model dalam klasifikasi komentar bullying atau non-bullying. Hasil evaluasi menunjukkan bahwa scenario enam merupakan scenario terbaik dengan kombinasi model TF-IDF, N-gram, feature selection chi-square dengan SVM, menghasilkan akurasi tertinggi yaitu sebesar 0.9384, model ini juga memiliki nilai precision untuk kategori bullying sebesar 0.938 untuk non-bullying sebesar 0.9538, recall untuk bullying sebesar 0.9253 untuk non-bullying sebesar 0.9523, f1-score untuk bullying sebesar 0.9393 untuk non-bullying sebesar 0.9375.

Sementara untuk skenario lain, terdapat berbagai variasi kinerja model. Skenario pertama, dimana menggunakan metode vectorisasi Bag of Words (BoW) mendapat akurasi sebesar 0.8384. Untuk skenario 3 dimana dengan penerapan feature selection chi-square berhasil meningkatkan akurasi ketika hanya menggunakan BoW saja, yaitu berhasil mendapatkan akurasi sebesar 0.8461. lalu pada skenario 2 dimana vectorisasi hanya menggunakan TF-IDF mendapatkan akurasi sebesar 0.8769 ini mengindikasikan model tf-idf lebih baik ketika tanpa kombinasi model. Sementara pada skenario 5, yang dimana model yang dirancang yaitu TF-IDF dengan menggunakan feature selection chi-square untuk memilih fitur yang relevan dan informatif, dan berhasil mendapat akurasi sebesar 0.9076. itu artinya peningkatan akurasi terjadi dan itu disebabkan oleh penerapan feature selection pada skenario 5 dimana bertujuan untuk memilih fitur yang informatif guna untuk meningkatkan hasil akurasi dalam sebuah model. Lalu terdapat skenario 4

dengan metode vectorisasi TF-IDF kombinasi N-gram berhasil mendapat akurasi sebesar 0.8846, yang artinya berhasil melakukan peningkatan akurasi dengan penerapan model n-gram (tri-gram), dimana pada skenario 2 yang hanya mendapat akurasi sebesar 0.8769 dikarenakan tidak menerapkan model n-gram (tri-gram) yang bisa membantu memperluas makna teks dalam data. Dari berbagai skenario yang telah dilakukan diatas dapat dilihat bahwa untuk metode vectorisasi dengan akurasi terbaik antara BoW dan TF-IDF (tanpa n-gram) diraih oleh metode vectorisasi TF-IDF dari setiap kombinasi model. Sementara ketika penerapan feature selection pada kedua metode, akurasi terbaik dicapai oleh metode TF-IDF-(N-gram) dikarenakan jumlah fitur yang dihasilkan oleh metode TF-IDF-(N-gram) lebih banyak dari pada BoW yang dimana memudahkan untuk feature selection chi-square dalam menyeleksi atau memilih fitur – fitur terbaik dari banyaknya fitur yang dihasilkan oleh metode TF-IDF-(N-gram). Sementara untuk metode feature selection berdasarkan dari skenario model Support Vector Machine yang telah dilakukan, feature selection chi-square berhasil secara signifikan meningkatkan akurasi klasifikasi komentar bullying atau non-bullying menggunakan model klasifikasi Support Vector Machine.

Agar dapat lebih dipahami dengan mudah, data tersebut akan diilustrasikan melalui grafik. Penggunaan grafik bertujuan memberikan gambaran yang lebih terang dan mudah dimengerti terkait hasil evaluasi kinerja. Oleh karena itu, hasil evaluasi kinerja SVM disajikan dalam bentuk grafik.



Gambar 4.21 Grafik Kinerja Evaluasi SVM

4.5. Analisis hasil klasifikasi

Semua rincian uji coba model algoritma Gaussian Naïve Bayes dan Support Vector Machine akan dijabarkan secara lengkap dalam grafik pada Gambar 4.6.



Gambar 4.22 Grafik Pengujian Model

Berdasarkan hasil pada grafik pengujian model, dapat dilihat bahwa performa kedua algoritma yaitu Gaussian Naïve Bayes (GNB) dan Support Vector Machine bervariasi. Pada scenario 1 dimana kedua algoritma klasifikasi sama-sama menerapkan metode vektorisasi Bag of Words (BoW) sebagai feature extractionnya dan akurasi tertinggi didapatkan oleh algoritma SVM dengan akurasi sebesar 83.84 %. Untuk scenario kedua dimana kedua algoritma klasifikasi sama – sama menerapkan tf-idf sebagai feature extraction tanpa ada pemilihan fitur dengan metode feature selection. Scenario ini sebagai pembandingan scenario pertama yang menggunakan feature extraction yang berbeda yaitu BoW, dalam scenario ini akurasi tertinggi didapatkan oleh algoritma Support Vector Machine dengan akurasi sebesar 87.69 %. Menunjukkan akurasi SVM yang didapatkan lebih tinggi dibandingkan dengan scenario pertama ketika metode vektorisasi yang digunakan yaitu BoW. Temuan yang didapatkan ini dipengaruhi oleh karakteristik TF-IDF yang menghasilkan hasil fitur yang beragam dari pada BoW karena TF-IDF mempertimbangkan frekuensi kata dalam dokumen dan seberapa umum kata tersebut diseluruh dataset, ini sesuai dengan karakteristik Algoritma klasifikasi SVM yang mampu menangani keberagaman data dengan baik karena SVM dapat menempatkan data ke ruang berdimensi tinggi dan mencari batas keputusan yang optimal, mengakibatkan kesesuaian dalam melakukan proses klasifikasi.

Kemudian untuk akurasi yang didapatkan GNB pada scenario pertama berhasil mencapai akurasi sebesar 76.15, kemudian pada scenario kedua berhasil mencapai akurasi sebesar 73.07 %. Menunjukkan keunggulan GNB pada scenario pertama dimana metode vektorisasi yang digunakan adalah BoW, Temuan ini

dikarenakan karakteristik dari algoritma Gaussian Naïve Bayes yang memiliki asumsi independensi fitur dan menganggap data atau fitur terdistribusi normal. asumsi independensi ini memiliki potensi kurang optimal ketika data menjadi lebih beragam dan terdapat ketergantungan yang signifikan antara fitur-fiturnya, sehingga memiliki kesesuaian ketika dikombinasikan dengan metode BoW yang dimana memiliki karakteristik fitur yang dihasilkan tidak terlalu beragam dikarenakan karakteristik BoW yang hanya menghitung prevalensi kemunculan kata tanpa mempertimbangkan seberapa umum kata tersebut diseluruh data.

Pada scenario ke 3 pendekatan yang diterapkan dikedua algoritma yang digunakan yaitu, metode vectorisasi Bag of Word kemudian diterapkan metode feature selection chi-square untuk melihat apakah dengan menerapkan feature selection dapat meningkatkan kinerja model. Dapat dilihat dimana pada scenario 3 ini, model SVM berhasil mendapatkan akurasi sebesar 84.61 %. Sementara pada scenario sebelumnya yaitu scenario 1 hanya mendapatkan akurasi sebesar 83.84 %. Dengan feature selection chi-square berhasil naik sekitar 0.77. ini menunjukkan bahwa penerapan chi-square pada algoritma svm efektif untuk meningkatkan akurasi klasifikasi. Sementara untuk GNB berhasil mendapatkan akurasi sebesar 90.67 %, mengalami peningkatan dari scenario 1 yang hanya mendapatkan akurasi sebesar 76.15 %, mengalami peningkatan signifikan sekitar 14.52 %. Jika diperhatikan akurasi yang didapatkan oleh GNB lebih tinggi dari pada SVM dalam scenario ketiga ini. Ini menunjukkan chi-square lebih efektif diterapkan pada algoritma Gaussian Naïve Bayes dengan dengan metode vectorisasi BoW karena kesesuaian antara masing-masing model. Secara keseluruhan dalam scenario 3 ini

terbukti bahwa feature selection chi-square berhasil meningkatkan akurasi kedua algoritma.

Dapat dilihat dalam scenario 4 bahwa kedua algoritma menggunakan pendekatan yang dilakukan menggunakan TF-IDF, N-gram, dimana scenario 4 memiliki tujuan salah satunya untuk mengetahui efek dari penerapan n-gram (trigram). Pencapaian gaussian Naïve bayes berhasil mendapatkan akurasi sebesar 76.15 % lebih tinggi dari pada pencapaian sebelumnya yaitu pada scenario 2 yang dimana dalam scenario tersebut peneliti tidak menerapkan n-gram dan hanya mencapai akurasi sebesar 73.07 %, mengalami kenaikan sebesar 3.08. ini menunjukkan bahwa penerapan n-gram memiliki pengaruh terhadap hasil akurasi Gaussian Naïve Bayes. Kemudian untuk algoritma SVM berhasil mendapatkan akurasi sebesar 88.46 % memiliki akurasi yang lebih tinggi dari scenario sebelumnya yang hanya mendapatkan akurasi sebesar 87.69. memiliki selisih kenaikan sebesar 0.77 %. Jika diperhatikan dalam scenario ini SVM berhasil mendapatkan akurasi lebih tinggi dari GNB yang hanya mendapatkan akurasi sebesar 76.15 %. Ini menunjukkan SVM lebih efektif dari GNB dalam menangani fitur hasil dari metode TF-IDF yang dikombinasikan dengan N-gram karena SVM memiliki kemampuan untuk menangani fitur yang beragam yang dihasilkan oleh metode TF-IDF dengan kombinasi n-gram.

Untuk scenario lima dimana pendekatan yang dilakukan yaitu menggunakan metode TF-IDF dengan feature selection chi-square, pendekatan ini dilakukan sebagai pembandingan dari scenario 2 dimana pada scenario tersebut hanya menggunakan metode vektorisasi TF-IDF, tanpa menggunakan N-gram dan juga

feature selection. Dalam skenario lima dapat dilihat bahwa akurasi untuk SVM berhasil mendapatkan akurasi sebesar 90.76 jauh lebih tinggi dari pada akurasi sebelumnya yaitu pada skenario 2. Kemudian pada algoritma GNB berhasil mendapatkan akurasi sebesar 91.53, menunjukkan peningkatan yang signifikan dari pada akurasi pada skenario sebelumnya. Jika diperhatikan dalam skenario 5 algoritma GNB memiliki akurasi yang lebih tinggi dari SVM, ini dikarenakan karakteristik fitur yang dihasilkan oleh chi-square cenderung terdistribusi normal sehingga lebih memaksimalkan peran GNB yang memiliki karakteristik mengasumsikan seluruh data inputan terdistribusi normal dalam kelas.

Pada skenario enam pendekatan yang dilakukan oleh peneliti pada kedua algoritma adalah penggunaan metode feature extraction yaitu TF-IDF, N-gram dan Feature Selection chi-square. dalam skenario ini memiliki tujuan salah satunya untuk sebagai perbandingan dari skenario sebelumnya yaitu skenario 4 dan lima 5 dimana, pada skenario 4 pendekatan yang dilakukan pada kedua algoritma adalah menggunakan metode TF-IDF, dan N-gram. Dan pada skenario 5 menggunakan metode TF-IDF dan feature selection chi-square. Sementara pendekatan dalam skenario enam ini menggunakan semua metode yang digunakan dalam kedua skenario tersebut (skenario 4 & 5). Di mana dalam skenario ini SVM berhasil mendapatkan akurasi sebesar 93.84 % sementara GNB berhasil mencapai akurasi sebesar 93.84 %, ini menunjukkan akurasi yang dihasilkan kedua algoritma pada skenario ini mengalami peningkatan yang signifikan dari skenario sebelumnya (skenario 4 & 5). Temuan ini mengindikasikan bahwa penerapan metode Tf-idf, n-gram, dan fitur seleksi chi-square sangat berpengaruh terhadap peningkatan akurasi

pada algoritma Gaussian Naïve Bayes dan Support Vector Machine. Jika diamati kedua algoritma memiliki akurasi yang seimbang, namun dapat dilihat dari nilai presisi, recall, dan F1-score, SVM yang sudah dipaparkan pada tabel 4.15 dan grafik 4.20 menunjukkan kinerja yang baik dengan nilai yang seimbang antara kelas Bullying dan Non-bullying. Untuk GNB nilai presisi, recall, dan F1-score yang didapat, dapat dilihat pada tabel 4.7 dan gambar 4.13 dimana GNB memiliki presisi yang sempurna (1.0000) untuk kelas Bullying, tetapi memiliki recall yang lebih rendah (0.8806), dan menghasilkan F1-score yang sedikit lebih rendah dibandingkan dengan SVM. Dengan melihat hasil ini, secara keseluruhan, SVM dapat dikatakan lebih unggul karena dapat memberikan keseimbangan yang baik antara presisi dan recall untuk kedua kelas, menunjukkan kemampuannya untuk mengklasifikasikan data dengan baik pada kedua kategori.

4.6. Perbandingan Dengan Penelitian Sebelumnya

Sebagai bagian dari evolusi penelitian dalam klasifikasi komentar bullying atau non-bullying pada komentar Instagram, sangat penting untuk merunut kajian-kajian sebelumnya sebagai titik pembandingan. Rincian lebih lanjut dapat ditemukan dalam tabel terlampir.

Tabel 4.16 Perbandingan Dengan Penelitian Sebelumnya

Peneliti	feature	Algoritma classifier	accuracy	Precision	recall	F-score
(Muhariya et al., 2022a)	TF - IDF	K-means Clusterings	67.38 %	76.70 %	67.48 %	-
(Riadi et al., 2023)	TF-IDF, N-gram, Chi-square	NB Without chi-square	83.85 %	85 %	84 %	84 %
		NB With chi-square	90,77 %	91 %	91 %	91 %
		SVM Without chi-square	82.31 %	84 %	77 %	81 %
		SVM With chi-square	90.00 %	96 %	82 %	89 %
(Dhuhita & Zone, 2023)	BoW	Multinomial Naive Bayes	0.769	-	-	-
	TF-IDF	Multinomial Naive Bayes	0.646	-	-	-
Proposed work	BoW	GNB	76.15 %	78.12 %	74.62 %	76.33 %
		SVM	83.84 %	82.85 %	86.56 %	84.67 %
	TF-IDF	GNB	73.07 %	77.58 %	67.16 %	72.00 %
		SVM	87.69 %	89,23 %	86,56 %	87,87 %
	BoW, chi-square	GNB	90.76 %	87.67 %	95.52 %	91.42 %
		SVM	84.61 %	85.07 %	85.07 %	85.07 %
	TF-IDF, N-gram	GNB	76.15 %	81.03 %	70.14 %	75.20 %
		SVM	88.46 %	93.33 %	83.58 %	88.18 %
	TF-IDF, chi-square	GNB	91.53 %	96.66 %	86.56 %	91.33 %
		SVM	90.76 %	91.04 %	91.04 %	91.04 %
TF-IDF, N-gram, chi-square	GNB	93.84	100,00 %	88,06 %	91,33 %	
	SVM	93.84 %	95.38 %	92.53 %	93.93 %	

Dalam tabel di atas, dapat diamati bahwa penelitian yang sedang berlangsung saat ini menunjukkan kinerja yang lebih unggul dibandingkan dengan studi yang dilakukan oleh (Riadi et al., 2023) dan (Dhuhita & Zone, 2023) . Dhuhita

menggunakan model BoW dan TF-IDF lalu menggunakan algoritma multinomial naïve bayes dan berhasil mendapatkan akurasi tertinggi dengan pendekatan model BoW dan Multinomial Naïve Bayes dengan akurasi sebesar 0.769 atau skitar 76.9 %. Meskipun demikian, penelitian yang kini tengah dilakukan telah mengimplementasikan metode yang lebih mutakhir dan inovatif.

Dalam penelitian ini, peneliti memanfaatkan metode TF-IDF sebagai fondasi ekstraksi fitur. Peneliti juga menggabungkan strategi n-gram (tri-gram) dan seleksi fitur untuk meningkatkan akurasi klasifikasi. Hasil paling optimal dicapai melalui pendekatan tri-gram dan chi-square, dengan tingkat akurasi mencapai 93.84 %. Temuan ini menunjukkan terjadi peningkatan yang signifikan dari akurasi yang diperoleh dari penelitian sebelumnya. Melalui integrasi TF-IDF dengan n-gram dan chi-square, peneliti dapat mengakses informasi yang lebih komprehensif dan kompleks dari teks komentar. Hal ini berkontribusi pada peningkatan kemampuan sistem dalam melakukan klasifikasi ulasan secara lebih akurat. Penelitian ini memberikan dampak positif dalam penelitian komentar instagram dengan kategori bullying atau non-bullying.

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan hasil yang telah dicapai dalam penelitian mengenai klasifikasi komentar cyberbullying atau non-cyberbullying menggunakan Gaussian Naïve Bayes dan Support Vector Machine. Dapat disimpulkan beberapa hal sebagai berikut :

1. Penelitian ini membangun model klasifikasi dengan membaginya kedalam 6 skenario yang dimana setiap scenarionya menggunakan metode – metode tertentu yang telah ditentukan. Scenarionya 1 dibangun menggunakan Teknik Bag of Words (BoW) dengan algoritma klasifikasi Gaussian Naïve Bayes (GNB) dan Support Vector Machine (SVM). Akurasi tertinggi dicapai oleh algoritma SVM dengan akurasi sebesar 83.84 % sementara GNB hanya sebesar 76.15 %. Kemudian pada scenarionya 2 dimana teknik vektorisasi yang digunakan yaitu TF-IDF akurasi tertinggi dicapai oleh SVM dengan capaian sebesar 87.69 % sementara GNB sebesar 73,07 %. Untuk scenarionya 3 dimana Teknik BoW dengan feature selection chi-square diterapkan dalam scenarionya ini, akurasi tertinggi didapatkan oleh GNB dengan akurasi sebesar 90.76 % sementara SVM sebesar 84.61 %. Untuk scenarionya 4 teknik vektorisasi TF-IDF dan N-gram diterapkan, akurasi tertinggi dicapai oleh algoritma SVM dengan akurasi 88.46 % sementara GNB hanya sebesar 76.15 %. Kemudian dalam scenarionya 5 pendekatan yang diterapkan yaitu Teknik vektorisasi

yang digunakan adalah TF-IDF lalu dilakukan seleksi fitur dengan chi-square, akurasi tertinggi didapatkan oleh GNB dengan akurasi sebesar 91.53 %, dan SVM mendapatkan akurasi sebesar 90.76 %. Untuk scenario 6 pendekatan yang digunakan yaitu penerapan Teknik TF-IDF dan N-gram, kemudian dilakukan seleksi fitur menggunakan chi-square, akurasi yang di capai oleh kedua algoritma berimbang yaitu sama – sama mendapatkan akurasi sebesar 93.84 %, namun jika dianalisis dari nilai evaluasi precision, recall, dan f1-score SVM menunjukkan kinerja yang baik dengan nilai yang seimbang antara kelas Bullying dan Non-bullying. GNB memiliki presisi yang sempurna (1.0000) untuk kelas Bullying, tetapi memiliki recall yang lebih rendah (0.8806), dan menghasilkan F1-score yang sedikit lebih rendah dibandingkan dengan SVM. Jika dilihat dari hasil ini, secara keseluruhan, SVM dapat dikatakan lebih unggul karena dapat memberikan keseimbangan yang baik antara presisi dan recall.

2. Penerapan metode feature extraction TF-IDF dan Bag of Word (BoW) dilakukan dalam penelitian ini, untuk Teknik BoW diterapkan pada scenario 1 dan 3. Pada scenario 1 BoW mendapatkan akurasi tertinggi pada algoritma SVM dengan akurasi sebesar 83.84 % dengan presisi 82.85 %, recall 85.56 %, dan f1 -score 84.67 %. Sementara GNB hanya mendapatkan akurasi sebesar 76.15 %, dengan presisi 78.12 %, recall 74.62, dan f1-score 76.33 %. Kemudian pada scenario 3 dimana pendekatan yang digunakan adalah metode BoW dan seleksi fitur chi-

square dimana dalam scenario ini akurasi tertinggi dicapai oleh GNB sebesar 90.76 %, dengan presisi 87.67 %, recall 95.52 % dan f1-score 91.42 %. Sementara SVM hanya mendapatkan akurasi sebesar 84.61 % dengan presisi 85.07 %, recall 85.07 %, f1-score 85.07 %. Untuk Teknik TF-IDF diterapkan pada empat skenario yaitu scenario 2, 4, 5, dan 6. Untuk scenario 2 kami hanya menggunakan Teknik TF-IDF pada kedua algoritma klasifikasi, akurasi tertinggi didapatkan oleh algoritma SVM dengan akurasi sebesar 87.69 % dengan presisi 89.23 %, recall 86.56 % dan f1-score 87.87 %. Sementara GNB hanya mendapatkan akurasi sebesar 73.07 % dengan presisi 77.58 %, recall 67.16 %, f1-score 72.00 %. Kemudian pada scenario 4 dilakukan pendekatan dengan Teknik TF-IDF dengan metode n-gram (tri-gram) untuk memperluas makna atau konteks, akurasi tertinggi didapatkan oleh SVM dengan akurasi 88.46 % dengan presisi 93.33 %, recall 83.58 %, f1-score 88.18 %. Sedangkan GNB hanya mendapat akurasi sebesar 76.15 % dengan presisi 81.03 % recall 70.14 %, f1-score 75.20 %. Kemudian pada scenario 5 pendekatan yang dilakukan yaitu diterpkan Teknik TF-IDF (tanpa n-gram) dan chi-square akurasi tertinggi diperoleh GNB sebesar 91.53 % presisi 96.66 % recall 86.56 %, f1-score 91.33 %. Sedangkan SVM mendapatkan akurasi sebesar 90.76 % dengan presisi 91.04 %, recall 91.04 %, f1-score 91.04 %. Kemudian scenario 6 dimana pendekatan yang dilakukan cukup kompleks yaitu diterapkan Teknik TF-IDF, N-gram, Chi-square, akurasi yang didapatkan kedua algoritma

pada scenario ini berimbang yaitu sama-sama mendapatkan akurasi sebesar 93.84 % namun terdapat perbedaan pada hasil evaluasi menggunakan presisi, recall dan f1-score, untuk GNB didapatkan presisi sebesar 100.00 %, recall 88.06 % f1-score sebesar 91.33 %. Sementara SVM dengan presisi 95.38 %, recall 92.53 % f1-score 93.93. jika diamati teknik akurasi algoritma ketika menerapkan TF-IDF lebih unggul dan seimbang pada sebagian besar scenario yang dilakukan, menunjukkan seberapa penting penyesuaian metode saat membangun model klasifikasi komentar bullying atau non-bullying Instagram.

3. Berdasarkan hasil eksperimen, terlihat bahwa penerapan feature selection Chi-square secara signifikan meningkatkan akurasi klasifikasi komentar cyberbullying atau non-cyberbullying instagram pada model Bag of Words (BoW) dan TF-IDF, serta pada algoritma Gaussian Naïve Bayes (GNB) dan Support Vector Machine (SVM). Peningkatan ini dapat diamati pada gambar 4.6. Pada skenario 3, 5 dan 6, terlihat bahwa penggunaan feature selection dengan Chi-square pada model BoW dan pada algoritma Gaussian Naïve Bayes menghasilkan peningkatan akurasi dari yang sebelumnya terlihat pada scenario 1 mendapatkan akurasi sebesar 76.15 % lalu pada scenario ke 3 akurasi yang didapatkan berhasil meningkat menjadi 90.76 %, pada algoritma SVM juga mengalami peningkatan diaman pada scenario 1 hanya mendapatkan akurasi sebesar 83.84 % lalu pada scenario 3 setelah diterapkan chi-square berhasil meningkat menjadi 84.61 %. Begitu juga dengan model

TF-IDF berhasil mengalami peningkatan akurasi dari akurasi yang sebelumnya yang dapat dilihat pada scenario 2 yaitu 73.07 % untuk GNB berhasil mengalami peningkatan menjadi 91.53 % pada scenario 5, untuk algoritma SVM juga mengalami peningkatan dari akurasi sebesar 87.69 % menjadi 90.76 %. Lalu pada model TF-IDF yang dikombinasikan dengan N-gram (tri-gram) berhasil mengalami peningkatan setelah diterapkan feature selection chi-square dimana untuk GNB yang akurasinya dari 91.53 % meningkat menjadi 93.84 % begitu juga dengan SVM dimana akurasi yang didapatkan sebelum diterapkan chi-square sebesar 90.76 % berhasil meningkat menjadi 93.84 %. Penggunaan metode seleksi fitur Chi-Square secara signifikan meningkatkan akurasi klasifikasi komentar bullying dan non-bullying instagram pada Gaussian Naive Bayes dan Support Vector Machine. Hal ini menunjukkan bahwa seleksi fitur memiliki peran penting dalam meningkatkan kemampuan algoritma dalam komentar bullying dan non-bullying dengan lebih akurat.

5.2. Saran

Ada beberapa saran yang direkomendasikan untuk penelitian selanjutnya pada topik penelitian yang sama, sebagai berikut :

1. Penelitian selanjutnya dapat menggunakan dataset komentar Instagram yang lebih banyak untuk memaksimalkan algoritma yang digunakan salah satunya seperti SVM yang mampu menangani data yang cukup banyak dan kompleks.

2. Penelitian selanjutnya dapat mengkhususkan eksplorasi metode feature selection atau membandingkan dengan feature selection yang lain, terdapat beberapa feature selection yang populer selain Chi-square, seperti information gain, mutual information, Recursive Feature Elimination (RFE), LASSO (Least Absolute Shrinkage and Selection Operator), dan principal component analysis (PCA). Menjelajahi berbagai metode tersebut dapat membantu mengenali fitur-fitur yang lebih relevan dan meningkatkan tingkat akurasi klasifikasi komentar cyberbullying atau non-cyberbullying.
3. Penelitian selanjutnya juga dapat memperluas cakupan dengan mengeksplorasi model vectorisasi selain BoW dan TF-IDF. Beberapa opsi yang dapat dipertimbangkan meliputi wordembedding seperti word2vec, FastText, yang memperhitungkan subkata dalam representasi vektor kata, serta GloVe yang menggunakan analisis statistik kemunculan bersama untuk membentuk vektor kata. Dengan mempertimbangkan berbagai model vectorisasi ini, penelitian memiliki potensi untuk mendapatkan wawasan yang lebih mendalam, meningkatkan pemahaman representasi teks.
4. Penelitian selanjutnya dapat mengeksplorasi algoritma klasifikasi deep learning, tidak berhenti hanya pada machine learning seperti Gaussian Naïve Bayes atau Support Vector Machine (SVM). Model deep learning, seperti Convolutional Neural Networks (CNNs), Recurrent Neural Networks (RNNs), dan Long Short-Term Memory (LSTM), memiliki potensi untuk menangkap representasi yang lebih kompleks dan kontekstual dari teks. Pemahaman mendalam terhadap struktur dan hubungan dalam

kalimat dapat ditingkatkan dengan memanfaatkan arsitektur deep learning ini. Selain itu, metode seperti Transfer Learning dan Fine-tuning dapat diterapkan untuk meningkatkan kinerja algoritma deep learning dengan menggunakan pengetahuan yang telah dipelajari dari tugas-tugas sebelumnya. Dengan menjelajahi algoritma klasifikasi deep learning, penelitian dapat membuka pintu untuk pengembangan model yang lebih adaptif dan cerdas dalam mengenali dan mengklasifikasikan komentar bullying atau non-bullying diinstagram.



DAFTAR PUSTAKA

PUSTAKA BUKU

- Arikunto, S. (2013). *Prosedur Penelitian Suatu Pendekatan Praktik*. PT. Rineka Cipta.
- Feldman, R., & Sanger, J. (2007). *Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. Cambridge University Press.
- Liddy, E. D. (2001). *Natural Language Processing*.
- Liu, B. (2012). *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers.
- Liu, B. (2015). Sentiment analysis: Mining opinions, sentiments, and emotions. In *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. <https://doi.org/10.1017/CBO9781139084789>
- Sarkar, D. (2016). *Text Analytics with Python: A Practical Real-World Approach to Gaining Actionable Insights from your Data* (1st ed).
- Sugiyono. (2018). *Metode Penelitian Kuantitatif, Kualitatif dan R&D*. PT. Alfabet.

PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Afina, L., Raudhoti, H., Herdiani, A., Romadhony, & Ade. (2020). Identifikasi Cyberbullying pada Kolom Komentar Instagram dengan Metode Support Vector Machine dan Semantic Similarity (Cyberbullying Identification on Instagram Comment Using Support Vector Machine and Semantic Similarity). *J-Cosine*, 4(1), 1-8.

- Alduailaj, A. M., & Belghith, A. (2023). *Detecting Arabic Cyberbullying Tweets Using Machine Learning*. 29–42.
- APJII. (2020). Laporan Survei Internet APJII 2019 –2020. *Asosiasi Penyelenggara Jasa Internet Indonesia*, 1–146.
- Apriani, I., Sibaroni, Y., & Palupi, I. (2023). Perbandingan Pembobotan Fitur TF-IDF dan TF-ABS Dalam Klasifikasi Berita Online Menggunakan Support Vector Machine (SVM). *E-Proceeding of Engineering* :, 10(3), 3652–3663.
- Arikunto, S. (2013). *Prosedur Penelitian Suatu Pendekatan Praktik*. PT. Rineka Cipta.
- Atoum, J. O. (2020). Cyberbullying Detection through Sentiment Analysis. *Proceedings - 2020 International Conference on Computational Science and Computational Intelligence, CSCCI 2020*, 292–297. <https://doi.org/10.1109/CSCCI51800.2020.00056>
- Bayu Baskoro, B., Susanto, I., Khomsah, S., Informatika, P., Sains Data, P., Teknologi Telkom Purwokerto Jl Panjaitan, I. DI, & Tengah, J. (2021). Analisis Sentimen Pelanggan Hotel di Purwokerto Menggunakan Metode Random Forest dan TF-IDF (Studi Kasus: Ulasan Pelanggan Pada Situs TRIPADVISOR). *Inista*, 3(2), 021–029. <https://doi.org/10.20895/INISTA.V3>
- Dalvi, R. R., Baliram Chavan, S., & Halbe, A. (2020). Detecting A Twitter Cyberbullying Using Machine Learning. *Proceedings of the International Conference on Intelligent Computing and Control Systems, ICICCS 2020*, *Iciccs*, 297–301. <https://doi.org/10.1109/ICICCS48265.2020.9120893>

- Dewi, H. A., Suryani, & Sriati, A. (2020). Faktor-Faktor yang Memengaruhi Cyberbullying Pada Remaja: A Systematic Review. *Journal of Nursing Care*, 3(2), 128–141.
- Dhuhita, W. M. P., & Zone, F. (2023). Perbandingan Kinerja Algoritma Multinomial dan Bernoulli Naïve Bayes dalam Mengklasifikasikan Komentar Cyberbullying. *Komputika: Jurnal Sistem Komputer*, 12(2), 109–117. <https://doi.org/10.34010/komputika.v12i2.9767>
- Dimas Pratama, N., Sari, Y. A., & Adikara, P. P. (2018). Analisis Sentimen Pada Review Konsumen Menggunakan Metode Naive Bayes Dengan Seleksi Fitur Chi Square Untuk Rekomendasi Lokasi Makanan Tradisional. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(9), 2982–2988.
- Eshan, S. C., & Hasan, M. S. (2017). An application of machine learning to detect abusive bengali text. *2017 20th International Conference of Computer and Information Technology (ICIT)*, 1–6.
- Fachrurrozi, S., Muljono, Shidik, G. F., Fanani, A. Z., Purwanto, & Zami, F. A. (2021). Increasing Accuracy of Support Vector Machine (SVM) By Applying N-Gram and Chi-Square Feature Selection for Text Classification. *2021 International Seminar on Application for Technology of Information and Communication (ISemantic)*, 42–47. <https://doi.org/10.1109/iSemantic52711.2021.9573210>
- Farid, D., & El-Tazi, Dr. N. (2020). Detection of Cyberbullying in Tweets in Egyptian Dialects. *International Journal of Computer Science and Information Security (IJCSIS)*, 18(7), 34–41.

- Feldman, R., & Sanger, J. (2007). *Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. Cambridge University Press.
- Fransiska, S., & Irham Gufroni, A. (2020). Sentiment Analysis Provider by.U on Google Play Store Reviews with TF-IDF and Support Vector Machine (SVM) Method. *Scientific Journal of Informatics*, 7(2), 2407–7658.
- Hafidz, N., Anggraeni, S., Gata, W., & Ratino. (2020). Sentimen Analisis Informasi Covid-19 menggunakan Support Vector Machine dan Naïve Bayes. *Jurnal JUPITER*, 12(2), 1–11.
- Himawan, S. N., & Nugraha, N. B. (2023). *Feature Selection Menggunakan Algoritma Meta-Heuristik*. 2(2), 84–89.
- Ikhsani Larasati, U., Aziz Muslim, M., & Arifudin, R. (2019). Improve the Accuracy of Support Vector Machine Using Chi Square Statistic and Term Frequency Inverse Document Frequency on Movie Review Sentiment Analysis. *Scientific Journal of Informatics*, 6(1), 2407–7658. <http://journal.unnes.ac.id/nju/index.php/sji>
- Ismail, M., Hassan, N., & Saleh Bafjaish, S. (2020). Comparative Analysis of Naive Bayesian Techniques in Health-Related for Classification Task. *JOURNAL OF SOFT COMPUTING AND DATA MINING*, 1(2), 1–10. <https://doi.org/10.30880/jscdm.2020.01.02.001>
- Juniandikaa, I. M., & Mahendraa, I. B. M. (2023). *Analisis Sentimen Aplikasi Zenius Menggunakan Metode Logistic Regression*.

- Jupriyadi. (2018). Implementasi Seleksi Fitur Menggunakan Algoritma FVBRM Untuk Klasifikasi Serangan Pada Intrusion Detection System (Ids). *Seminar Nasional Teknologi Informasi (SEMNASTEK)*, 17, 1–6.
- Khadafi, M. Al, Kartika, K. P., Febrinita, F., Informasi, F. T., Balitar, U. I., Blitar, K., Based, L., Sentimen, A., Widodo, P. J., Program, P., & Kesehatan, J. (2022). Penerapan Metode Naïve Bayes Classifier Dan Lexicon Based Untuk Analisis Sentimen Cyberbullying Pada Bpjs. *Jurnal Mahasiswa Teknik Informatika*, 6(2), 725–733.
- Kisworini, R. Y. (2020). Peningkatan Performa Naive Bayes Dengan Seleksi Atribut Menggunakan Chi Square Untuk Klasifikasi Loyalitas Pelanggan GRAB. *INISTA (Journal of Informatics Information System Software Engineering and Applications)*, 2(2), 69–75.
- Lahitani, A. R. (2022). Automated Essay Scoring menggunakan Cosine Similarity pada Penilaian Esai Multi Soal. *Jurnal Kajian Ilmiah*, 22(2), 107–118. <https://doi.org/10.31599/jki.v22i2.1121>
- Liddy, E. D. (2001). *Natural Language Processing*.
- Listiowarni, I., & Puspa Dewi, N. (2020). Pemanfaatan Klasifikasi Soal Biologi Cognitive Domain Bloom's Taxonomy Menggunakan KNN Chi-Square Sebagai Penyusunan Naskah Soal. *Digital Zone: Jurnal Teknologi Informasi Dan Komunikasi*, 11(2), 186–197. <https://doi.org/10.31849/digitalzone.v11i2.4798>
- Liu, B. (2012). *Sentiment Analysis and Opinion Mining*. Morgan & Claypool Publishers.

- Liu, B. (2015). Sentiment analysis: Mining opinions, sentiments, and emotions. In *Sentiment Analysis: Mining Opinions, Sentiments, and Emotions*. <https://doi.org/10.1017/CBO9781139084789>
- Madrakhimov, S., Makharov, K., & Lolaev, M. (2021). Data preprocessing on input. *AIP Conference Proceedings*, 2365(July). <https://doi.org/10.1063/5.0058132>
- Marsinun, R., & Riswanto, D. (2020). Perilaku Cyberbullying Remaja di Media Sosial. *Analitika*, 12(2), 98–111. <https://doi.org/10.31289/analitika.v12i2.3704>
- Maulana, F. A., Ernawati, I., Labu, P., & Selatan, J. (2020). *Analisa sentimen cyberbullying di jejaring sosial twitter dengan algoritma naïve bayes*. 529–538.
- Muhammad, F., Maghfur, N. M., & Voutama, A. (2022). Sentiment Analysis Dataset on COVID-19 Variant News. *Systematics*, 4(1), 382–391.
- Muhariya, A., Riadi, A., & Prayudi, I. (2022a). *Cyberbullying Analysis on Instagram Using K-Means Clustering* (Vol. 10, Issue 2).
- Muhariya, A., Riadi, I., & Prayudi, Y. (2022b). Cyberbullying Analysis on Instagram Using K-Means Clustering. *JUITA : Jurnal Informatika*, 10(2), 261. <https://doi.org/10.30595/juita.v10i2.14490>
- Naf'an, M. Z., Bimantara, A. A., Larasati, A., Risondang, E. M., & Nugraha, N. A. S. (2019). Sentiment Analysis of Cyberbullying on Instagram User Comments. *Journal of Data Science and Its Applications*, 2(1), 88–98. <https://doi.org/10.21108/jdsa.2019.2.20>

- Naf'an, M. Z., Burhanuddin, A., & Riyani, A. (2019). Penerapan Cosine Similarity dan Pembobotan TF-IDF untuk Mendeteksi Kemiripan Dokumen. *Jurnal Linguistik Komputasional*, 2(1), 23–27.
- Pacol, C. A., & Palaoag, T. D. (2021). Enhancing Sentiment Analysis of Textual Feedback in the Student-Faculty Evaluation using Machine Learning Techniques. *European Journal of Engineering Science and Technology*, 4(1), 27–34. <https://doi.org/10.33422/ejest.v4i1.604>
- Permataning Tyas, S. M., Rintyarna, B. S., & Suharso, W. (2022). The Impact of Feature Extraction to Naïve Bayes Based Sentiment Analysis on Review Dataset of Indihome Services. *Digital Zone: Jurnal Teknologi Informasi Dan Komunikasi*, 13(1), 1–10. <https://doi.org/10.31849/digitalzone.v13i1.9158>
- Prabowo, W. A., & Azizah, F. (2021). Sentiment Analysis for Detecting Cyberbullying Using TF-IDF and SVM. *RESTI Journal*, 10, 11–12.
- Prabowo, Y. D., Marselino, T. L., & Suryawiguna, M. (2019). Pembentukan vector space model bahasa indonesia menggunakan metode word to vector. *Jurnal Buana Informatika*, 10(1), 29–40.
- Pratama, R. P., & Tjahyanto, A. (2021). The influence of fake accounts on sentiment analysis related to COVID-19 in Indonesia. *Procedia Computer Science*, 197(2021), 143–150. <https://doi.org/10.1016/j.procs.2021.12.128>
- Putra, K. T., Hariyadi, M. A., & Crysdiyan, C. (2023). Perbandingan Feature extraction TF-IDF dan BOW Untuk Analisis Sentimen Berbasis SVM. *Jurnal Cahaya Mandalika ISSN 2721-4796 (Online)*, 3(2), 1449–1463.

Putri, S. A., Daru Kusuma, P., & Setianingsih, C. (n.d.). *CLUSTERING TOPIK PADA DATA SENTIMEN BPJS KESEHATAN MENGGUNAKAN METODE LATENT DIRICHLET ALLOCATION TOPIC CLUSTERING ON SENTIMENT DATA OF BPJS KESEHATAN USING LATENT DIRICHLET ALLOCATION METHOD.*

Rama, P., Putra, B., & Perdana, R. S. (2023). *Klasifikasi Judul Berita Online menggunakan Metode Support Vector Machine (SVM) dengan Seleksi Fitur Chi-square.* *7(5)*, 2132–2141.

Ramadhy, I. F., & Sibaroni, Y. (2022). Analisis Trending Topik Twitter dengan Fitur Ekspansi FastText Menggunakan Metode Logistic Regression. *JURIKOM (Jurnal Riset Komputer)*, *9(1)*, 1. <https://doi.org/10.30865/jurikom.v9i1.3791>

Riadi, S., Utami, E., & Yaqin, A. (2023). Comparison of NB and SVM in Sentiment Analysis of Cyberbullying using Feature Selection. *Sinkron*, *8(4)*, 2414–2424. <https://doi.org/10.33395/sinkron.v8i4.12629>

Rizki, A. S., Tjahyanto, A., & Trialih, R. (2019). Comparison of stemming algorithms on Indonesian text processing. *Telkonnika (Telecommunication Computing Electronics and Control)*, *17(1)*, 95–102. <https://doi.org/10.12928/TELKOMNIKA.v17i1.10183>

Rizki, M. F., Auliasari, K., & Primaswara Prasetya, R. (2021). Analisis Sentiment Cyberbullying Pada Sosial Media Twitter Menggunakan Metode Support Vector Machine. *JATI (Jurnal Mahasiswa Teknik Informatika)*, *5(2)*, 548–556. <https://doi.org/10.36040/jati.v5i2.3808>

- Rofiqi, M. A., Fauzan, Abd. C., Agustin, A. P., & Saputra, A. A. (2019). Implementasi Term-Frequency Inverse Document Frequency (TF-IDF) Untuk Mencari Relevansi Dokumen Berdasarkan Query. *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, 1(2), 58–64. <https://doi.org/10.28926/ilkomnika.v1i2.18>
- Rosidin, S., Shidik, G. F., Fanani, A. Z., & Al Zami, F. (2021). Improvement with Chi Square Selection Feature using Supervised Machine Learning Approach on Covid-19 Data. *2021 International Seminar on Application for Technology of Information and Communication (ISemantic)*, 32–36.
- Santoso, E. B., & Nugroho, A. (2019). Analisis Sentimen Calon Presiden Indonesia 2019 Berdasarkan Komentar Publik Di Facebook. *Eksplora Informatika*, 9(1), 60–69. <https://doi.org/10.30864/eksplora.v9i1.254>
- Sarkar, D. (2016). *Text Analytics with Python: A Practical Real-World Approach to Gaining Actionable Insights from your Data* (1st ed).
- Septian, J. A., Fachrudin, T. M., & Nugroho, A. (2019). Analisis Sentimen Pengguna Twitter Terhadap Polemik Persepakbolaan Indonesia Menggunakan Pembobotan TF-IDF dan K-Nearest Neighbor. *Journal of Intelligent System and Computation*, 1(1), 43–49. <https://doi.org/10.52985/insyst.v1i1.36>
- Smetanin, S., & Komarov, M. (2019). Sentiment analysis of product reviews in Russian using convolutional neural networks. *Proceedings - 21st IEEE Conference on Business Informatics, CBI 2019, 1*, 482–486. <https://doi.org/10.1109/CBI.2019.00062>

- Somantri, O., & Apriliani, D. (2018). Support Vector Machine Berbasis Feature Selection Untuk Sentiment Analysis Kepuasan Pelanggan Terhadap Pelayanan Warung dan Restoran Kuliner Kota Tegal. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 5(5), 537. <https://doi.org/10.25126/jtiik.201855867>
- Sugiyono. (2018). *Metode Penelitian Kuantitatif, Kualitatif dan R&D*. PT. Alfabet.
- Sulastomo, H., Gibran, K., Maryansyah, E., & Tegar, A. (2022). Analisis Sentimen Pada Twitter @Ovo_Id dengan Metode Support Vectore Machine (SVM). *Jurnal Sains Komputer & Informatika*, 6(2), 1050–1056.
- Taslim, T., Handayani, S., & Fajrizal, F. (2023). Kinerja Komparatif Optimasi Algoritma Naive Bayes dalam Klasifikasi Teks untuk Uji Klinis Kanker. *Jurnal Eksplora Informatika*, 13(1), 113–123. <https://doi.org/10.30864/eksplora.v13i1.994>
- Vijayarani, S., Ilamathi, M. J., Nithya, M., Professor, A., & Research Scholar, M. P. (n.d.). *Preprocessing Techniques for Text Mining -An Overview*. 5(1), 7–16.
- Wankhade, M., Rao, A. C. S., & Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, 55(7), 5731–5780. <https://doi.org/10.1007/s10462-022-10144-1>
- Wynne, H. E., & Wint, Z. Z. (2019). Content based fake news detection using n-gram models. *Proceedings of the 21st International Conference on Information Integration and Web-Based Applications & Services*, 669–673.

Yualinda, S., Wijaya, D. R., & Hernawat, E. (2020). *APLIKASI BERBASIS DATASET E-COMMERCE UNTUK PREDIKSI KEMISKINAN MENGGUNAKAN ALGORITMA NAÏVE BAYES, XGBOOST DAN SIMILARITY BASED FEATURE SELECTION*. 6(2), 1495–1508.

Yunanto, I., & Yulianto, S. (2022). Twitter Sentiment Analysis Pedulilindungi Application Using Naïve Bayes and Support Vector Machine. *Jurnal Teknik Informatika (Jutif)*, 3(4), 807–814.
<https://doi.org/10.20884/1.jutif.2022.3.4.292>

