

Analisis Sentimen Masyarakat terhadap Film Horor Indonesia Menggunakan Metode SVM dan TF-IDF

Sentiment Analysis of Public towards Indonesian Horror Films Using SVM and TF-IDF Methods

Jesica Emarapenta Br Sinulingga^{1*}, Hizkya Cesar Kayika Sitorus²

Program Studi Teknik Informatika, Institut Teknologi Telkom Purwokerto, Purwokerto, Indonesia

*E-mail: jesikasinulingga204@gmail.com

Abstrak

Dalam era digital, opini masyarakat terkait dengan film horor Indonesia sering menjadi perhatian utama di media sosial. Tujuan dari studi ini adalah untuk mengevaluasi pandangan dan perasaan yang diungkapkan oleh masyarakat terkait film horor Indonesia. Metode Support Vector Machine (SVM) dan Term Frequency-Inverse Document Frequency (TF-IDF) digunakan sebagai alat analisis utama dalam penelitian ini. Isu-isu dan pandangan masyarakat terhadap film horor diekstraksi dari platform media sosial untuk diidentifikasi sebagai opini pro dan kontra. Penggunaan metode SVM bersama dengan representasi teks menggunakan TF-IDF diharapkan dapat memberikan pemahaman mendalam terhadap respons emosional masyarakat terhadap genre film tertentu. Data yang dianalisis terdiri dari 2281 data. Kemudian, penerapan algoritma Support Vector Machine (SVM) digunakan sebagai metode klasifikasi teks, yang disertai dengan pembobotan kata menggunakan TF-IDF. Hasil yang diperoleh dari analisis ini adalah sebesar 82.51% untuk akurasi, 5.28% untuk presisi, 7.26% untuk recall, dan 6.12% untuk F1 Score. Penelitian ini membuktikan kemampuan metode SVM dan TF-IDF dalam mengklasifikasikan sentimen opini masyarakat terhadap film horor Indonesia dan berpotensi memberikan wawasan tentang dampak sosial dan penerimaan karya film dalam industri hiburan.

Kata kunci: Algoritma SVM, TF-IDF, Film Horor, Analisis Sentimen

Abstract

In the digital era, public opinions regarding Indonesian horror films often receive significant attention on social media platforms. The objective of this study is to assess the perspectives and sentiments expressed by the public concerning Indonesian horror films. The Support Vector Machine (SVM) method along with Term Frequency-Inverse Document Frequency (TF-IDF) is utilized as the primary analytical tool in this research. Issues and public viewpoints regarding horror films are extracted from social media platforms to identify both pros and cons. Employing the SVM method in conjunction with text representation using TF-IDF is expected to provide comprehensive insights into the emotional responses of the public toward specific film genres. The analyzed dataset comprises 2281 entries. Subsequently, the application of the Support Vector Machine (SVM) algorithm is employed for text classification, coupled with word weighting using TF-IDF. The outcomes of this analysis exhibit an accuracy of 82.51%, a precision of 5.28%, a recall of 7.26%, and an F1 Score of 6.12%. This study demonstrates the efficacy of the SVM and TF-IDF methods in classifying public sentiment toward Indonesian horror films and has the potential to provide insights into the social impact and reception of film works within the entertainment industry.

Keywords: SVM Algorithm, TF-IDF, Horror Films, Sentiment Analysis

Naskah diterima 07 Jan. 2024; direvisi 29 Jan. 2024; dipublikasikan 01 Apr. 2024.

JAMIKA is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License.



I. PENDAHULUAN

Ulasan mengenai sebuah film adalah suatu kebutuhan yang penting bagi banyak individu, karena memberikan wawasan dan informasi mendalam mengenai substansi suatu film. Ulasan ini menjadi alat yang membantu dalam memperoleh gambaran menyeluruh mengenai alur cerita, peran para aktor, serta aspek konflik yang dihadirkan dalam narasi film. Lebih dari itu, ulasan juga memberikan gambaran tentang kelebihan dan kekurangan yang dapat ditemui dalam sebuah film. Penelitian ini dilakukan untuk mengenali, mengelompokkan, dan menelaah pola opini yang diungkapkan oleh masyarakat terkait elemen-elemen spesifik dalam film horor. [1]. Terutama, film horor Indonesia sering menjadi objek ketertarikan yang menarik banyak perhatian. Oleh karena itu, analisis terhadap sentimen masyarakat terhadap film-film horor menjadi krusial dalam memahami preferensi dan respons audiens terhadap karya film tersebut. Minat dan respons masyarakat

terhadap film-film horor sering tercermin dalam opini serta pandangan yang mereka bagikan melalui media sosial, seperti Twitter. Twitter merupakan media yang menjadi tempat bagi ribuan hingga jutaan opini yang disampaikan dalam bentuk tweet dan dapat dimanfaatkan untuk mengumpulkan opini masyarakat terhadap suatu film. Melihat banyaknya opini yang terdapat di Twitter, diperlukan pengelompokan berdasarkan sentimen yang diungkapkan untuk memperoleh pemahaman terhadap kecenderungan opini tersebut terhadap film, apakah bersifat positif atau negatif [2]. *Platform twitter* menjadi wadah di mana penonton bisa berbagi perspektif dan merekomendasikan film horor kepada orang lain [3].

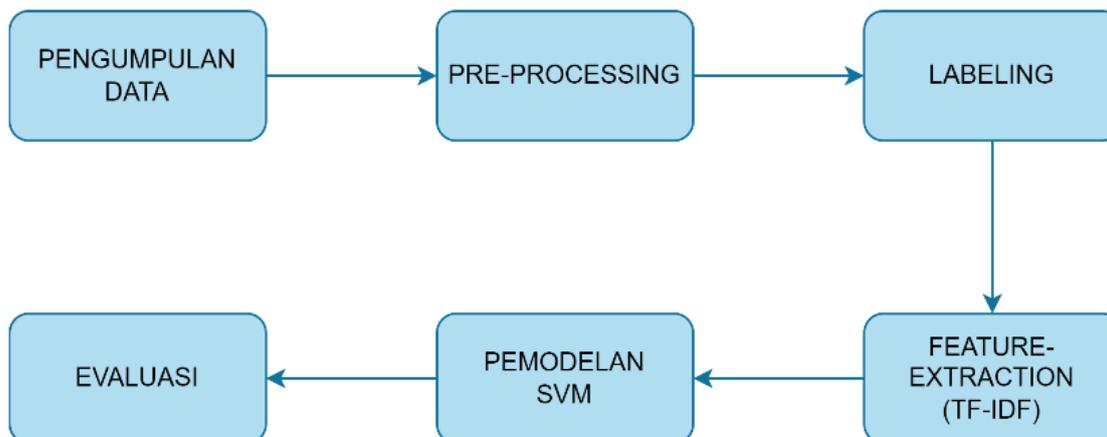
Ada beberapa algoritma dalam machine learning yang sering diajukan oleh para peneliti untuk melakukan analisis sentimen seperti *Random Forest* yang merupakan algoritma ensemble yang menggabungkan hasil dari berbagai pohon keputusan secara acak untuk menghasilkan prediksi akhir [4], *Multinomial Naive Bayes* yang menggunakan teorema Bayes dengan asumsi independensi fitur untuk menghitung probabilitas kelas sentimen [5]. Sementara itu, *Support Vector Machine* mencari hyperplane terbaik untuk memisahkan kelas dalam ruang fitur. Berdasarkan beberapa penelitian, *Support Vector Machine (SVM)* seringkali dipilih karena kemampuannya yang unggul dalam mencapai kinerja optimal dalam mengklasifikasikan dan secara konsisten menunjukkan keunggulan dalam akurasi dibandingkan metode klasifikasi lainnya. Dikarenakan kemampuan dalam menghasilkan akurasi yang tinggi dan memerlukan biaya komputasi yang rendah, SVM menjadi salah satu metode yang efektif dalam klasifikasi data [6].

Meskipun SVM membutuhkan format input dalam bentuk vektor, yang memerlukan konversi format dokumen ke format yang sesuai untuk pembelajaran mesin, penting untuk melakukan ekstraksi fitur dari dokumen teks. Ini berperan penting dalam pemilihan fitur yang akan digunakan dan mempengaruhi model pembelajaran mesin. Seringkali, ekstraksi fitur teks menggunakan pendekatan *N-Gram*, tetapi terdapat kekurangan pada pendekatan ini yaitu menghasilkan jumlah fitur yang besar dan tidak semuanya signifikan untuk proses klasifikasi. Alternatif lain yang dikenal adalah penggunaan metode *Term Frequency - Inverse Document Frequency (TF-IDF)* yang dianggap sebagai salah satu metode ekstraksi fitur terbaik untuk analisis teks [7]. Sebuah penelitian sebelumnya yang diprakarsai oleh Nur Fitriyah meneliti mengenai Analisis Sentimen Gojek di platform media sosial Twitter dengan menerapkan metode Klasifikasi SVM. Analisis terhadap 1.500 *tweet* pengguna Gojek pada 17-18 Januari 2019 menunjukkan mayoritas sentimen positif (1.142 *tweet* positif, 358 *tweet* negatif). Meskipun pelabelan dengan *sentiment scoring* tidak akurat (172 *tweet* kesalahan), hasil klasifikasi sentimen menggunakan SVM pada data manual dan *sentiment scoring* mencapai tingkat akurasi keseluruhan 79,19%. Pemodelan dengan kernel RBF dan parameter tertentu memberikan akurasi κ terbaik, yakni 16,52% pada data manual dan 21% pada *sentiment scoring* [6]. Kemudian pada penelitian yang dilakukan oleh Okta Ihza Gifari dengan judul Analisis Sentimen Review Film Menggunakan TF-IDF dan SVM dengan memperoleh hasil bahwa alasan pemilihan metode ini terletak pada kemampuannya dalam memberikan bobot pada kata-kata serta mengelompokkan data yang berdimensi tinggi. Berdasarkan uji skenario yang dilakukan, terbukti bahwa algoritma TF-IDF dan SVM mampu dioptimalkan pada situasi ulasan film dengan tingkat keakuratan (*Accuracy*) sebesar 85%, presisi (*Precision*) mencapai 100%, nilai keberhasilan dalam mengenali keseluruhan (*Recall*) sebesar 70%, dan nilai *F1-Score* sebesar 82% [8]. Dan penelitian lainnya oleh Vincentius Westley Dimitrius Thomas yaitu pada analisis sentimen ulasan hotel dalam Bahasa Indonesia, metode SVM dan TF-IDF. Berdasarkan penelitian tersebut, mendapatkan hasil bahwa penggunaan pembobotan TF-IDF dengan parameter teroptimal ($min_df=3$, $max_df=0.25$, $max_features=5000$), *slang handling* dengan penambahan kosa kata *slang* dan implementasi *stopword* berpengaruh signifikan terhadap prediksi SVM, menghasilkan tingkat akurasi 85%. Melalui eksperimen, penelitian ini mencapai *F1-Score* terbaik sebesar 83%, sementara tanpa *slang handling*, *F1-Score* sebesar 80%, dan tanpa *stopword* *F1-Score* sebesar 82%. Evaluasi kinerja model dengan *K-fold* menunjukkan nilai akurasi tertinggi pada Fold-7 mencapai 87%. [7].

Penelitian ini dilakukan dengan tujuan menganalisis persepsi masyarakat terkait film horor menggunakan metode *Support Vector Machine (SVM)* dan *Term Frequency-Inverse Document Frequency (TF-IDF)*. Evaluasi yang akan dilakukan terhadap hasil eksperimen yang dilakukan pada penelitian ini menggunakan *confusion matrix*.

II. METODE PENELITIAN

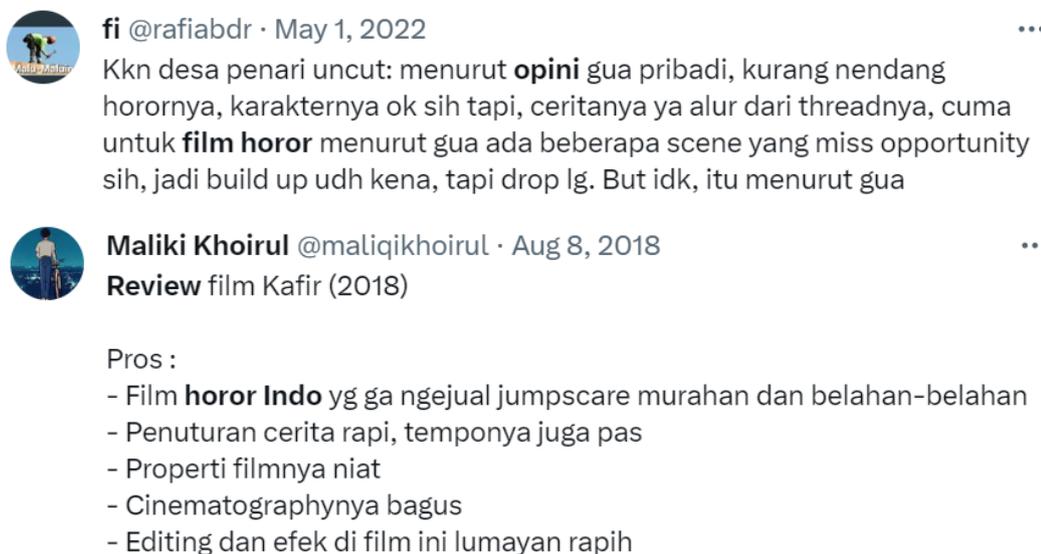
Dalam penelitian ini, terdapat beberapa langkah yang digambarkan pada gambar 1. Tahapan awal dimulai dari pengumpulan data, kemudian dilanjutkan dengan proses *pre-processing*, *labeling*, pembobotan kata menggunakan TF-IDF, penerapan *Support Vector Machine (SVM)*, dan terakhir proses evaluasi.



Gambar 1. Tahapan Penelitian

Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah opini masyarakat terhadap film horor Indonesia secara umum tanpa menentukan sebuah judul film horror tertentu pada media social twitter dengan beberapa kata kunci yaitu “ulasanfilmhorrorindonesia”, “#HororIndonesia”, “Review Film Horror” dan “#filmhorrorindonesia”. Dimana file dataset tersebut disimpan ke dalam format .CSV (*Comma-Separated Values*). Data yang dikumpulkan merupakan data yang dimulai sejak 24 Desember 2019 sampai dengan 14 Desember 2023. Data diproses menggunakan bahasa pemrograman Python dengan menggunakan Google Colab sebagai editor teks. Python dikenal sebagai salah satu bahasa pemrograman yang sangat populer dan sering digunakan dalam berbagai aplikasi. Google Colab adalah sebuah platform editor teks berbasis web yang menyediakan lingkungan pengembangan yang memungkinkan pengguna untuk menulis dan mengeksekusi kode Python secara interaktif dalam browser web [10]. Gambar 2 merupakan contoh ulasan nasyarakat terhadap film horror di media social Twitter.

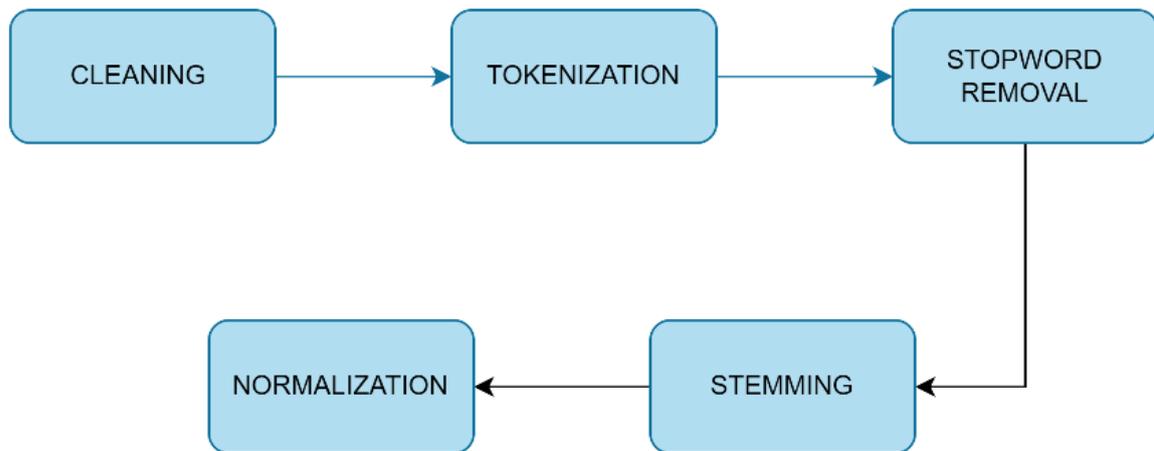


Gambar 2. Contoh ulasan masyarakat terhadap film horror pada Twitter

Pre-Processing

Tahap *pre-processing* sangat krusial dalam text mining dan data mining karena berperan dalam seleksi data pada setiap dokumen yang akan diproses. Hasil dari proses *pre-processing* memiliki dampak besar terhadap data yang diolah dan bisa memengaruhi akurasi klasifikasi dokumen [11]. Dalam tahapan ini, digunakan pustaka sastrawi yang memuat serangkaian aturan dan algoritma untuk melakukan pemrosesan teks dalam bahasa Indonesia. Sastrawi adalah perpustakaan yang berfungsi untuk melakukan *stemming*, yaitu

pengembalian kata ke bentuk dasarnya, menghilangkan *stopword* atau kata-kata umum yang tidak memiliki makna khusus, serta tokenisasi yang merupakan pemisahan teks menjadi kata-kata. Dalam bidang text mining maupun data mining tahapan preprocessing sangat berperan penting [10]. Berikut pada gambar 3 menunjukkan tahapan awal hingga akhir *pre-processing* data.



Gambar 3. Tahapan Pre-Processing

Berikut proses *pre-processing* yang dilakukan:

a. *Cleaning Data*

Dalam proses Pembersihan Teks, terdapat beberapa tahapan yang salah satunya adalah tahap *Case Folding* yang melibatkan proses mengubah dataset menjadi huruf kecil [10]. Contoh implementasi dari *Case Folding* adalah saat kata "Pocong" diubah menjadi "pocong", "HOROR" menjadi "horor", atau "ANGKER" menjadi "angker". Tahapan ini umumnya diikuti dengan penghapusan tanda baca seperti koma, titik, tanda tanya, tanda seru, serta penghapusan karakter non-huruf seperti angka, hashtag, URL situs web, dan spasi kosong.

b. *Tokenization*

Tokenisasi adalah langkah krusial dalam analisis leksikal yang bertujuan untuk memecah teks atau kalimat menjadi unit-unit kecil yang disebut dengan "token.". Token dapat berupa kata, frasa, atau karakter tergantung pada tingkat granularitas yang diinginkan [3]. Contoh tokenisasi pada kalimat "Saya sedang belajar pemrograman" menjadi "Saya", "sedang", "belajar" dan "pemrograman".

c. *Stopword Removal*

Tahap *stopword removal* bertujuan untuk menghapus kata yang sering muncul namun tidak terlalu penting. Menghilangkan kata-kata umum yang tidak memberikan kontribusi signifikan terhadap analisis. Misalnya, "bisa", "pake", "di". Proses ini dilakukan dengan menggunakan library sastrawi yaitu *StopwordRemoverFactory()* [7]

d. *Stemmed*

Tahap ini, tujuannya adalah untuk mengonversi kata-kata menjadi bentuk dasarnya dengan menghapus imbuhan, awalan, dan akhiran. Proses ini dilakukan dengan bantuan library sastrawi [7]. Sebagai contoh, kalimat "Proses pengolahan teks sangat penting dalam analisis data." diubah menjadi "Proses olah teks penting analisis data."

e. *Normalization*

Hasil dari kalimat yang telah dimodifikasi akan diteruskan ke tahap normalisasi kata, di mana kata-kata yang tidak baku akan diubah menjadi bentuk baku [7].

Dalam penelitian ini dilakukan proses *pre-processing data*, yaitu *cleaning text*, *tokenization*, *stopword* dan *stemming* serta *normalization* [12]. Tabel 1 menunjukkan hasil *pre-processing* data yang telah dilakukan. Beberapa contoh opini masyarakat yang mendukung dan menentang film horor Indonesia dipilih sebagai sampel. Dapat diamati bahwa langkah-langkah pra-pemrosesan telah berfungsi sebagaimana mestinya untuk setiap tahapannya.

Labeling

Pelabelan data adalah tahap di mana dataset dikelompokkan ke dalam kategori-kategori tertentu. Ini merupakan langkah awal dalam pekerjaan terkait machine learning. Dalam analisis sentimen, fokus utamanya adalah mengelompokkan teks dalam kalimat atau dokumen ke dalam kategori positif atau negatif, serta menilai opini yang terkandung dalam teks tersebut. [13]. Setiap tweet dalam file CSV dianalisis sentimennya menggunakan *TextBlob*. *TextBlob* sebuah perpustakaan Python yang berurusan dengan informasi teks yang memberikan antarmuka pemrograman aplikasi (API) sederhana untuk mengakses aktivitas Pemrosesan Bahasa Alami seperti ekstraksi Frasa Nomina, penandaan *Part-of-Speech (PoS)*, analisis sentimen, dan lain-lain [14]. Iterasi dilakukan pada setiap tweet, dan berdasarkan nilai polaritasnya, tweet diberi label positif atau negatif. Total tweet yang dianalisis sebanyak 2283 data. Hasil akhirnya adalah jumlah tweet yang terklasifikasi sebagai positif atau negatif yang ditunjukkan pada tabel 2.

TABEL 2
 HASIL LABELLING DATA

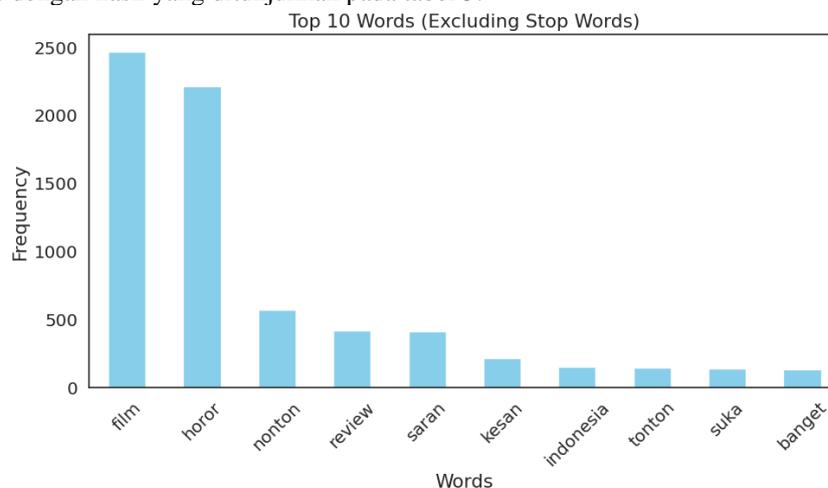
Sentimen	Jumlah
Positif	1884
Negatif	399

Feature Extraction (TF-IDF)

Tahap ini dikenal sebagai ekstraksi fitur atau vektorisasi, yang merupakan langkah penting dalam analisis teks. Proses ini mengonversi kata-kata menjadi representasi numerik, baik dalam bentuk integer atau float, tergantung pada algoritma yang digunakan dalam pembelajaran mesin. Dalam penelitian ini, dua teknik yang umum dan populer untuk vektorisasi teks adalah *Count Vectorizer* dan *TF-IDF Vectorizer* [3].

TF-IDF merupakan salah satu teknik untuk menghitung bobot dari setiap kata setelah proses *Feature Extraction* [15]. TF-IDF memiliki dua tahap utama. Tahap pertama adalah menghitung frekuensi kemunculan sebuah kata pada setiap dokumen. Tahap kedua adalah menghitung bobot term tersebut di seluruh dokumen. Proses perhitungan TF-IDF memungkinkan penilaian seberapa penting suatu kata dalam sebuah dokumen dibandingkan dengan keberadaannya di seluruh koleksi dokumen [16]. Berikut merupakan identifikasi 10 kata teratas yang paling sering muncul. Visualisasi dilakukan dengan menggunakan diagram batang, yang menampilkan kata-kata teratas pada sumbu x (kata) dan frekuensi kemunculan pada sumbu y (frekuensi) yang ditunjukkan pada gambar 4.

Proses TF-IDF menggunakan *TfidfVectorizer* dari *scikit-learn* untuk mengonversi teks dari kolom 'NORMALIZED' menjadi representasi numerik berdasarkan bobot kata-kata yang dihitung menggunakan formula TF-IDF. Bobot kata tersebut kemudian digunakan sebagai fitur dalam algoritma *Synthetic Minority Over-sampling Technique (SMOTE)* untuk menangani ketidakseimbangan kelas dalam kasus klasifikasi. SMOTE digunakan untuk membuat sampel sintesis dari kelas minoritas (*oversampling*) agar seimbang dengan kelas mayoritas dengan hasil yang ditunjukkan pada tabel 3.



Gambar 4. Kata Yang Paling Sering Muncul

TABEL 3
 HASIL IMPLEMENTASI SMOTE

	Sebelum melakukan SMOTE	Sesudah melakukan SMOTE
Positif	1882	1882
Negatif	399	1882

Pemodelan Support Vector Machine (SVM)

Algoritma *Support Vector Machine (SVM)* didesain untuk menemukan *hyperplane* dengan margin terbesar yang bisa memisahkan dua kelas data secara optimal. SVM adalah metode pembelajaran mesin yang menggunakan fungsi-fungsi linier dalam ruang fitur yang memiliki dimensi tinggi. Metode Support Vector Machine (SVM) dikenal karena berbagai keunggulan yang dimilikinya dalam melakukan klasifikasi. Salah satu keunggulannya adalah kemampuannya dalam memisahkan kelas data, terutama dalam ruang berdimensi tinggi. SVM efektif dalam menangani kasus di mana terdapat banyak variabel, sementara tetap mampu mengatasi masalah overfitting. SVM juga dikenal mampu menangani kasus klasifikasi dengan jumlah sampel kecil hingga menengah, serta dapat bekerja baik dalam menangani masalah margin yang besar. Proses pembelajaran SVM didasarkan pada teori optimasi dan menerapkan prinsip pembelajaran statistik [17]. Tujuannya adalah menemukan *hyperplane* terbaik yang memiliki margin terbesar di antara kelas data, digunakan untuk memisahkan data dengan tingkat akurasi paling optimal. SVM menggunakan *support vector* untuk membangun *hyperplane* ini, yang memungkinkan pemisahan data dengan ketepatan tinggi antara kelas yang berbeda. SVM dengan kernel linear diinisialisasi dan dilatih menggunakan data latih yang telah diubah ke dalam representasi TF-IDF. Tahapannya yaitu melakukan pembuatan model klasifikasi sentimen dengan SVM. Data teks dan sentimen diubah menjadi representasi vektor TF-IDF dan dilatih menggunakan SVM dengan kernel linear. Model yang sudah dilatih disimpan dalam file 'SVM_classifier_24.pickle' untuk digunakan di proses selanjutnya [7]. Jumlah data dengan sentiment positif atau negatif baik untuk *data training* dan *data testing* ditunjukkan pada tabel 4.

TABEL 4
 DATA TRAINING TESTING SUMMARY

	Setelah di Training	Setelah di Testing
Positif	1882	2102
Negatif	399	179

Evaluasi

Beberapa metrik tersedia untuk menilai kualitas hasil penelitian suatu model klasifikasi. Dalam studi ini, evaluasi dilakukan menggunakan parameter seperti Akurasi, Presisi (*Precision*), *Recall*, dan *F1-Score* [18]. Hal ini bertujuan untuk mengevaluasi sejauh mana hasil yang dihasilkan oleh model klasifikasi dan seberapa baik kualitas penelitian yang telah dikembangkan [19].

$$accuracy = (TP + TN) / (TP + TN + FP + FN) * 100$$

$$precision = (TP) / (TP + FP) * 100$$

$$recall = (TP) / (TP + FN) * 100$$

$$F1_score = 2 * (recall * precision) / (recall + precision)$$

Penilaian performa dilakukan terhadap sistem analisis sentimen dan hasil analisis sentimen dari partisipan. *Precision*, *Recall*, dan *F1-Score* memberikan skor dari 0 hingga 1. Nilai yang lebih tinggi mendekati 1 menandakan hasil yang lebih baik dalam evaluasi [20]. Langkah terakhir dalam penelitian ini, yaitu evaluasi, apakah algoritma *Support Vector Machine (SVM)* merupakan pengklasifikasi teks yang baik sehingga dapat memperoleh nilai akurasi yang tinggi pada analisis sentimen masyarakat terhadap film horror Indonesia. Proses evaluasi dilakukan menggunakan confusion matrix dengan melihat nilai kurasi eksperimen yang dilakukan.

III. HASIL DAN PEMBAHASAN

Pada penelitian ini, dilakukan analisis sentimen terhadap opini masyarakat mengenai film horor Indonesia. Pengolahan data dilakukan menggunakan Bahasa pemrograman *Python* dan teks editor *Google*

	precision	recall	f1-score	support
negatif	0.75	0.23	0.35	80
positif	0.86	0.98	0.92	377
accuracy			0.85	457
macro avg	0.80	0.60	0.63	457
weighted avg	0.84	0.85	0.82	457

Average accuracy across folds: 85.23%

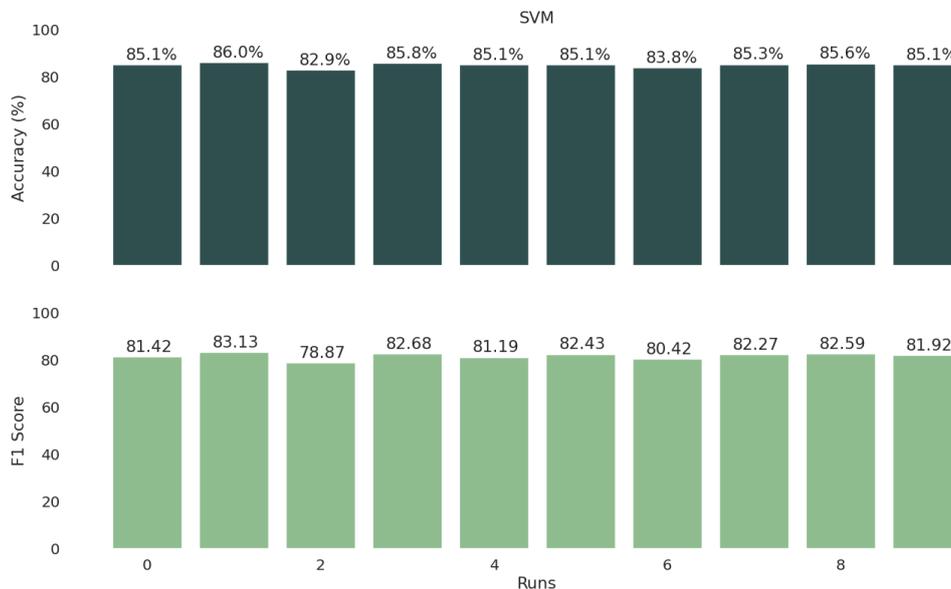
Average F1 Score across folds: 82.03%

Average confusion Matrix across folds:

```
[[ 19.7  60.1]
 [  7.4 369.8]]
```

Gambar 6. Model Performance Metrics

Selanjutnya mempersiapkan data teks untuk proses klasifikasi. Tahap ini mencakup transformasi teks ke dalam representasi numerik menggunakan metode TF-IDF dari *TfidfVectorizer*. Selanjutnya, model klasifikasi *Support Vector Machine (SVM)* diinisialisasi dengan beberapa parameter yang telah ditentukan. Proses pelatihan model SVM dilakukan dengan menggunakan data yang sudah diubah menjadi representasi TF-IDF sebelumnya. Setelah model dilatih, hasilnya disimpan dalam format file *pickle* untuk penggunaan selanjutnya tanpa perlu melatih ulang model. Performa dari model klasifikasi SVM pada gambar 7 menunjukkan sumbu x (*horizontal*) merupakan jumlah iterasi *cross-validation* atau "*Runs*" yang telah dilakukan, sedangkan sumbu y (*vertikal*) merupakan nilai akurasi atau F1 Score yang dihasilkan oleh model pada setiap iterasi tersebut dimana *cross validation* digunakan untuk menguji efektivitas suatu model dengan melatihnya menggunakan sebagian data input dan mengujinya pada sebagian data input yang berbeda dan belum pernah digunakan sebelumnya.

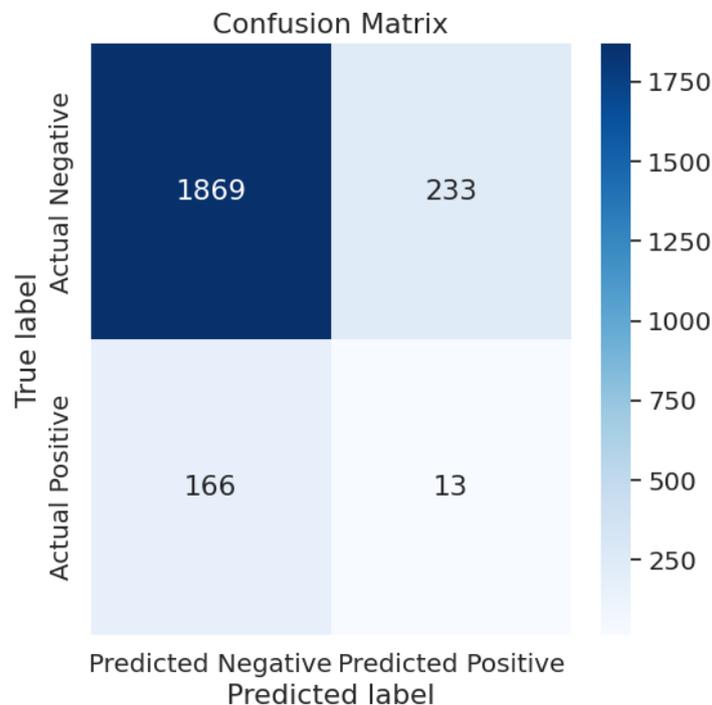


Gambar 7. Grafik Performa Model SVM

Model klasifikasi *Support Vector Machine (SVM)* dengan kernel linear dibuat dan dilatih menggunakan data latih yang telah melalui proses vektorisasi sebelumnya. Model ini kemudian digunakan untuk melakukan prediksi sentimen pada data uji, yang telah diubah menjadi vektor menggunakan vektorisasi yang sama dengan data latih. Selanjutnya membuat sebuah list yang berisi kamus dari setiap baris dalam kolom 'NORMALIZED'

dan nilai prediksi (*'prediction_linear'*). Proses dimulai dengan inialisasi list kosong yang disebut *'result_tweet'*. Selanjutnya, dilakukan iterasi melalui indeks dari nilai prediksi (*'prediction_linear'*). Pada setiap iterasi, dilakukan pengecekan nilai prediksi, jika nilainya adalah 1, maka sentimen hasilnya akan diidentifikasi sebagai *'positive'*, sedangkan jika nilai prediksinya adalah -1, sentimen hasilnya akan diidentifikasi sebagai *'negative'*. Kamus baru dengan kunci *'tweet'* yang mengambil nilai dari kolom *'NORMALIZED'* dan kunci *'class'* yang mengambil nilai dari prediksi, kemudian ditambahkan ke dalam list *'result_tweet'*. Proses ini akan menghasilkan list kamus yang berisi informasi sentimen hasil prediksi untuk setiap baris dalam kolom *'NORMALIZED'*.

Lalu mengevaluasi kinerja suatu model klasifikasi yang memprediksi sentimen dari teks. Evaluasi ini melibatkan perhitungan nilai-nilai seperti akurasi (*Accuracy*), *recall*, *F1 Score* dan presisi (*Precision*). empat variabel (TN, TP, FN, FP) mewakili nilai dari setiap kategori dalam *confusion matrix*, yaitu *True Negative (TN)*, *True Positive (TP)*, *False Negative (FN)* dan *False Positive (FP)*. Kemudian, dilakukan perhitungan persentase dari masing-masing kategori tersebut terhadap total jumlah data. Visualisasi yang dihasilkan merupakan *pie chart* dengan label masing-masing kategori dan persentase dari masing-masing kategori ditunjukkan pada gambar 8.



Gambar 8. Confusion Matrix

Untuk menghitung akurasi (*accuracy*) dari confusion matrix yang telah diberikan dari perhitungan yang dilakukan menggunakan nilai *True Negative (TN)* = 1869, *False Negative (FN)* = 166, *False Positive (FP)* = 233, dan *True Positive (TP)* = 13. Dalam kasus ini hasil yang didapat yaitu *Accuracy* 82.51%, *Precision* 5.28%, *Recall* 7.26%, *F1 Score* 6.12. Nilai presisi mengindikasikan seberapa tepat model dalam mengklasifikasikan data positif, sedangkan *recall* mengukur kemampuan model untuk menemukan kembali semua instance yang benar positif. Nilai *F1-score* mencerminkan keseimbangan antara presisi dan *recall*. Ini berarti model telah memprediksi dengan benar sekitar 82,51% dari total sampel yang diamati, hasil akurasi dihitung menggunakan rumus pada persamaan (1):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{1}$$

$$Accuracy = \frac{13+1869}{13+1869+233+166}$$

Accuracy = 0.8251

IV. KESIMPULAN

Dalam penelitian ini, berhasil diciptakan model klasifikasi Analisis Sentimen menggunakan metode *Support Vector Machine (SVM)* dengan representasi teks berdasarkan *Term Frequency-Inverse Document Frequency (TF-IDF)*. Model ini memperoleh akurasi sebesar 82.51%, *Precision* 5.28%, *Recall* 7.26% dan *F1 Score* 6.12 dalam memprediksi sentimen dari data teks yang diobservasi. Penelitian ini memberikan pandangan berharga bagi para pengambil keputusan terkait pengembangan industri film, menunjukkan variasi opini masyarakat terkait film horor Indonesia. Pengetahuan ini dapat menjadi pertimbangan bagi industri film dalam memahami preferensi dan respons masyarakat terhadap karya film horor yang dihasilkan. Untuk pengembangan lebih lanjut, disarankan untuk melakukan eksplorasi lebih terhadap pemilihan fitur yang lebih optimal, peningkatan pada proses pembersihan data, serta eksperimen dengan model atau parameter yang berbeda guna meningkatkan performa model analisis sentimen pada data teks.

UCAPAN TERIMA KASIH

Puji dan syukur peneliti panjatkan kepada Tuhan Yang Maha Esa atas limpahan rahmat dan karunia-Nya yang telah memungkinkan penelitian dengan judul “Analisis Sentimen Opini Masyarakat terhadap Film Horor Indonesia Menggunakan Metode *Support Vector Machine (SVM)* dan *Term Frequency-Inverse Document Frequency (TF-IDF)* dapat diselesaikan. Peneliti juga ingin mengucapkan terima kasih kepada Institut Teknologi Telkom Purwokerto atas dukungan yang diberikan dalam menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- [1] Razaq. Thariq, “Analisis Sentimen Review Film Menggunakan Naive Bayes Classifier Dengan Fitur TF-IDF,” Bandung, Apr. 2023.
- [2] Y. Nurtikasari, Syariful Alam, and Teguh Iman Hermanto, “Analisis Sentimen Opini Masyarakat Terhadap Film Pada Platform Twitter Menggunakan Algoritma Naive Bayes,” *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 1, no. 4, pp. 411–423, Aug. 2022, doi: 10.55123/insologi.v1i4.770.
- [3] M. Alfi, R. Reynaldi, and Y. Sibaroni, “Analisis Sentimen Review Film pada Twitter menggunakan Metode Klasifikasi Hybrid SVM, Naive Bayes, dan Decision Tree.”
- [4] M. Asjad Adna Jihad and W. Astuti, “Analisis Sentimen Terhadap Ulasan Film Menggunakan Algoritma Random Forest.”
- [5] A. Z. Amrullah, A. Sofyan Anas, M. Adrian, and J. Hidayat, “Analisis Sentimen Movie Review Menggunakan Naive Bayes Classifier Dengan Seleksi Fitur Chi Square,” *Jurnal*, vol. 2, no. 1, 2020, doi: 10.30812/bite.v2i1.804.
- [6] N. Fitriyah, B. Warsito, D. Asih, and I. Maruddani, “ANALISIS SENTIMEN GOJEK PADA MEDIA SOSIAL TWITTER DENGAN KLASIFIKASI SUPPORT VECTOR MACHINE (SVM),” *JURNAL GAUSSIAN*, vol. 9, no. 3, pp. 376–390, 2020, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/>
- [7] V. W. D. Thomas and F. Rumaisa, “Analisis Sentimen Ulasan Hotel Bahasa Indonesia Menggunakan Support Vector Machine dan TF-IDF,” *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 6, no. 3, p. 1767, Jul. 2022, doi: 10.30865/mib.v6i3.4218.
- [8] O. I. Gifari, M. Adha, I. Rifky Hendrawan, F. Freddy, and S. Durrand, “Analisis Sentimen Review Film Menggunakan TF-IDF dan Support Vector Machine,” *JIFOTECH (JOURNAL OF INFORMATION TECHNOLOGY)*, vol. 2, no. 1, 2022.
- [9] D. R. Alghifari, M. Edi, and L. Firmansyah, “Implementasi Bidirectional LSTM untuk Analisis Sentimen Terhadap Layanan Grab Indonesia,” *Jurnal Manajemen Informatika (JAMIKA)*, vol. 12, no. 2, pp. 89–99, Sep. 2022, doi: 10.34010/jamika.v12i2.7764.
- [10] R. Wati, S. Ernawati, and H. Rachmi, “Pembobotan TF-IDF Menggunakan Naive Bayes pada Sentimen Masyarakat Mengenai Isu Kenaikan BIPIH,” *Jurnal Manajemen Informatika (JAMIKA)*, vol. 13, no. 1, pp. 84–93, Apr. 2023, doi: 10.34010/jamika.v13i1.9424.

- [11] A. Brijith, "Data Preprocessing for Machine Learning." [Online]. Available: <https://www.researchgate.net/publication/375003512>
- [12] K. Maharana, S. Mondal, and B. Nemade, "A review: Data pre-processing and data augmentation techniques," *Global Transitions Proceedings*, vol. 3, no. 1, pp. 91–99, Jun. 2022, doi: 10.1016/j.glt.2022.04.020.
- [13] F. Fridom Mailo *et al.*, "Analisis Sentimen Data Twitter Menggunakan Metode Text Mining Tentang Masalah Obesitas di Indonesia," 2019.
- [14] D. Hazarika, G. Konwar, S. Deb, and D. J. Bora, "Sentiment Analysis on Twitter by Using TextBlob for Natural Language Processing," in *Proceedings of the International Conference on Research in Management & Technovation 2020*, PTI, Jan. 2020, pp. 63–67. doi: 10.15439/2020km20.
- [15] S. A. Helmayanti, F. Hamami, and R. Y. Fa'rifah, "PENERAPAN ALGORITMA TF-IDF DAN NAÏVE BAYES UNTUK ANALISIS SENTIMEN BERBASIS ASPEK ULASAN APLIKASI FLIP PADA GOOGLE PLAY STORE," *Jurnal Indonesia : Manajemen Informatika dan Komunikasi*, vol. 4, no. 3, pp. 1822–1834, Sep. 2023, doi: 10.35870/jimik.v4i3.415.
- [16] S. Khairunnisa, A. Adiwijaya, and S. Al Faraby, "Pengaruh Text Preprocessing terhadap Analisis Sentimen Komentar Masyarakat pada Media Sosial Twitter (Studi Kasus Pandemi COVID-19)," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 5, no. 2, p. 406, Apr. 2021, doi: 10.30865/mib.v5i2.2835.
- [17] "Penggunaan Algoritma Support Vector Machine SVM Un".
- [18] E. Hokijuliandy, H. Napitupulu, and F. Firdaniza, "Analisis Sentimen Menggunakan Metode Klasifikasi Support Vector Machine (SVM) dan Seleksi Fitur Chi-Square".
- [19] M. Fadli and R. A. Saputra, "KLASIFIKASI DAN EVALUASI PERFORMA MODEL RANDOM FOREST UNTUK PREDIKSI STROKE Classification And Evaluation Of Performance Models Random Forest For Stroke Prediction," vol. 12, [Online]. Available: <http://jurnal.umt.ac.id/index.php/jt/index>
- [20] M. Azhari, Z. Situmorang, and R. Rosnelly, "Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 5, no. 2, p. 640, Apr. 2021, doi: 10.30865/mib.v5i2.2937.