

OPTIMASI KLASIFIKASI SENTIMEN KOMENTAR PENGGUNA GAME BERGERAK MENGGUNAKAN SVM, GRID SEARCH DAN KOMBINASI N-GRAM

Syahroni Wahyu Iriananda^{*1}, Renaldi Widi Budiawan², Aviv Yuniar Rahman³, Istiadi⁴

^{1, 2, 3, 4} Universitas Widya Gama Malang, Malang

Email: ¹syahroni@widyagama.ac.id, ²klonoawb12@gmail.com, ³aviv@widyagama.ac.id,

⁴istiadi@widyagama.ac.id

*Penulis Korespondensi

(Naskah masuk: 14 Desember 2023, diterima untuk diterbitkan: 8 Agustus 2024)

Abstrak

Game online telah menjadi fenomena budaya signifikan dalam industri yang berkembang pesat. Pengguna dan pengembang game menggunakan analisis sentimen untuk memahami opini dan ulasan pemain, yang membantu dalam pengembangan dan peningkatan game. Penelitian ini melakukan klasifikasi sentimen menggunakan algoritma Support Vector Machine (SVM) dengan penerapan teknik N-Gram untuk seleksi fitur. Grid Search (GS) digunakan untuk optimasi hyperparameter guna mencapai akurasi optimal. Eksperimen dilakukan dengan berbagai skenario, termasuk variasi jumlah data, pengaturan hyperparameter, rasio dataset pelatihan dan pengujian, serta konfigurasi N-Gram. Kinerja model dinilai menggunakan metrik seperti Akurasi, Presisi, Recall, dan Area di Bawah Kurva ROC (AUC). Hasil menunjukkan bahwa dengan dataset gabungan (Allgame) dan integrasi fitur seleksi N-Gram Unigram, Bigram, dan Trigram (UniBiTri), model ini mencapai akurasi 87,3%, presisi 88,5%, recall 85,5%, dan AUC 0,9081, menggunakan kernel Fungsi Basis Radial (RBF) dengan validasi silang k-fold (k=10).

Kata kunci: Optimasi, Sentimen, Game Bergerak, SVM, N-Gram, Grid Search

OPTIMIZING SENTIMENT CLASSIFICATION OF MOBILE GAME USER REVIEWS USING SVM, GRID SEARCH AND N-GRAM COMBINATIONS

Abstract

Online gaming has become a significant cultural phenomenon within a rapidly expanding industry. Game users and developers leverage sentiment analysis to understand player opinions and reviews, which subsequently guide game development and enhancements. In this study, sentiment classification was performed using the Support Vector Machine (SVM) algorithm, employing N-Gram techniques for feature selection. Grid Search (GS) was utilized for hyperparameter optimization to achieve the highest possible accuracy. To evaluate the impact of these methods, experiments were conducted across various scenarios, including different data quantities, hyperparameter settings, training and testing dataset ratios, and N-Gram configurations. The performance of the classification model was assessed using metrics such as Accuracy, Precision, Recall, and the Area Under the ROC Curve (AUC). The results of the study indicate that by using 3600 rows from a combined dataset (Allgame) and integrating Unigram, Bigram, and Trigram (UniBiTri) N-Gram selection features, along with k-fold cross-validation (k=10) and the Radial Basis Function (RBF) kernel, the model effectively classifies user reviews. Specifically, the model achieved an accuracy of 87.3%, precision of 88.5%, recall of 85.5%, and an AUC of 0.9081.

Keywords: Optimization, Sentiment, Mobile Game, SVM, N-Gram, Grid Search

1. PENDAHULUAN

Selama pandemi COVID-19, game online telah menjadi salah satu bentuk hiburan utama bagi banyak orang. Statistik menunjukkan peningkatan dramatis dalam waktu bermain dan penjualan game sejak kebijakan *lockdown* dimulai (King et al., 2020). Sebelum mengunduh game, pengguna cenderung memeriksa ulasan dan peringkat untuk memastikan

kualitas dan popularitasnya. (Hendriyanto et al., 2022).

Analisis sentimen memiliki peran yang penting, baik bagi pengguna maupun pengembang aplikasi game. Melalui evaluasi opini dan ulasan (*reviews*) yang disampaikan oleh pengguna, pengembang mampu memperoleh wawasan yang berharga mengenai kebutuhan dan preferensi pengguna.

Informasi ini menjadi panduan untuk menentukan arah pengembangan dan perbaikan game.

Dengan demikian, analisis sentimen membantu para pengembang mengidentifikasi aspek-aspek yang perlu ditingkatkan dalam game dan juga fitur-fitur yang paling dihargai oleh pengguna. Dengan memanfaatkan pendekatan ini, pengembang game dapat membuat keputusan berdasarkan data yang valid dan akurat, dengan tujuan meningkatkan kualitas game dan memenuhi ekspektasi pengguna dengan lebih baik. Selain itu, mereka dapat menentukan arah pengembangan dan perbaikan pada game tersebut. (Kusnadi et al., 2021).

Analisis sentimen ini dapat digunakan untuk menilai aspek spesifik dalam game seperti gameplay, cerita, grafik, dan lainnya. Selain itu, pengembang dapat mempertimbangkan ulasan kritikus, konsumen, dan *influencer* untuk memberikan pandangan secara menyeluruh tentang opini industri.

Support Vector Machine (SVM) sering digunakan dalam klasifikasi data teks karena kemampuannya menangani data berdimensi tinggi dan kompleks (Hendriyanto et al., 2022). Algoritma SVM tidak hanya menunjukkan efektivitas dan stabilitas yang unggul dalam ruang dimensi tinggi, tetapi juga mencapai tingkat akurasi yang sangat tinggi.

Selain itu, SVM lebih mudah dilatih dibandingkan dengan banyak algoritma pembelajaran mesin lainnya. Algoritma ini juga unggul dalam efisiensi penggunaan memori melalui teknik pemetaan kernel ke dalam ruang fitur berdimensi tinggi, yang semakin memperkuat posisinya dalam menangani klasifikasi data yang kompleks (Birjali et al., 2021).

Tantangan terbesar dalam penggunaan SVM adalah memilih fungsi kernel dan menentukan nilai parameter SVM yang tepat. Pengaturan parameter yang tidak tepat menyebabkan hasil klasifikasi yang buruk. Maka dari itu penyetelan *hyperparameter* adalah merupakan cara terbaik untuk mencapai nilai parameter pembelajaran mesin yang optimal (Prabu et al., 2022). Namun, optimalisasi *hyperparameter* dapat membutuhkan waktu yang sangat lama jika dilakukan secara manual terutama ketika algoritma pembelajaran memiliki banyak parameter (Khalid and Javaid, 2020). Salah satu metode populer yang sering digunakan untuk memilih *hyperparameter* yang populer diantaranya adalah *Grid Search (GS)* (Nurcahyo and Sasongko, 2023) dengan mekanisme *Cross Validation (CV)* dalam proses pengujian setiap parameter model tanpa harus melakukan validasi manual satu persatu (Nugraha and Sasongko, 2022).

Fungsi kernel digunakan untuk mentransformasi data ke ruang dimensi yang lebih tinggi, yang disebut ruang kernel yang berguna untuk memisahkan data secara linear. Pada ruang dimensi tinggi ini, dilakukan tahapan transformasi fitur (*feature selection*) untuk meningkatkan akurasi hasil klasifikasi, dan salah satu Teknik yang digunakan

adalah N-Gram, yang diterapkan dengan memodifikasi teks berdasarkan kata, yang memungkinkan analisis lebih detail dan akurat terhadap pola-pola teks. (Arifin et al., 2021).

Penggunaan N-Gram berpengaruh besar terhadap akurasi model (Iriananda et al., 2022) Dimana pada penelitian tersebut berfokus pada kinerja N-Gram untuk klasifikasi. Dalam studi (Pujadayanti et al., 2018) dengan menggunakan metode klasifikasi Naïve Bayes yang memanfaatkan N-gram menerapkan *full preprocessing* dan kombinasi N-Gram menghasilkan akurasi yang lebih baik sebesar 97% tahap pengujian. Beberapa beberapa penelitian terdahulu yang terkait dengan penelitian ini disajikan pada Tabel 1.

Kajian terkait game dilakukan oleh (Abimanyu et al., 2022) terhadap *games online* Apex Legends dari sosial media Twitter menggunakan *VADER* untuk analisis sentimen, menghasilkan sentimen positif sebesar 18%, negatif sebanyak 4,8%, dan neutral sebesar 77,2%, dengan nilai akurasi sebesar 65,2% dari 500 data uji. Sementara itu (Febrianta et al., 2021) melakukan klasifikasi game indie pada Steam dengan Naïve Bayes dan pemodelan topik berbasis *Latent Dirichlet Allocation (LDA)* memiliki akurasi 75,45%.

Penelitian terkait algoritma Naïve Bayes (NB) dilakukan oleh (Sidiq et al., 2020) pada dataset Group Facebook komunitas game Arena of Valor (AoV) menghasilkan akurasi sebesar 75%, precision sebesar 63%, recall sebesar 67%, dan F-measure sebesar 64%.

Tabel 1. Komparasi Model Klasifikasi Sentimen

Author	Obyek	Metode
(Arifin et al., 2021)	Artikel Ilmiah, Syntax Jurnal Informatika	SVM, Linear, RBF, Polynomial, Sigmoid, TFIDF, N-Gram
(Abimanyu et al., 2022)	Twitter, Apex Legends	VADER
(Febrianta et al., 2021)	Game Indie, Steam	Naïve Bayes dan Model LDA
(Sidiq et al., 2020)	Facebook Group AoV	Naïve Bayes
(Pratmanto et al., 2020)	Google Playstore Review	Naïve Bayes
(Fide et al., 2021)	Tiktok, Google Playstore	SVM
(Sujadi, 2022)	Google Play Store Review, Online Shop	SVM
(Pamungkas and Kharisudin, 2021)	Twitter, COVID-19	SVM, NB, KNN
(Liang, 2021)	Twitter, Ujaran Kebencian,	SVM, XGBoost, dan Neural Network
(Rahman et al., 2021)	Google Play Store Review, Shopee, Ruangguru, Tokopedia, Gojek	NB dan GA, Cross Validation
(Iriananda et al., 2021)	Google Play Store Review, Bahasa	SVM, Kernel Linear, RBF, Polynomial,

Author	Obyek	Metode
(Thenata, 2021)	Indonesia, Marketplace, Twitter, Instagram, Facebook, Bahasa Indonesia	Decision Tree (DT), RF, LR, KNN, SVM, NB
(Iriananda et al., 2022)	Google Play Store Review, Bahasa Indonesia, Game Mobile	N-Gram, SVM, RBF, Polynomial, Linear Kernel

Penelitian yang menggunakan ulasan aplikasi Google Apps (Pratmanto et al., 2020) menggunakan 200 data review *E-marketplace* populer di Google Playstore, menghasilkan nilai akurasi NB 96,667%. Kajian (Fide et al., 2021) menganalisa review aplikasi Tiktok pada Google Playstore dengan SVM menghasilkan nilai akurasi 90,62%. Kajian terhadap dataset Tweeter terkait wabah COVID-19 (Sujadi, 2022) menghasilkan nilai akurasi metode Naïve Bayes 78,63% dan SVM 81,6%.

Kajian (Pamungkas and Kharisudin, 2021) terhadap opini terkait COVID-19 di Twitter menghasilkan nilai akurasi SVM Linear 90,01%, NB 72,20% dengan nilai Laplace = 1. Analisis sentimen terhadap ujian kebencian di Twitter oleh (Liang, 2021) menghasilkan nilai akurasi SVM 83,2%, XGBoots 79,6%, dan Neural Network (NN) 82,9%. Penelitian menggunakan dataset Google Playstore yang dilakukan oleh (Rahman et al., 2021) menganalisis sentimen ulasan Shopee, Ruangguru, Tokopedia dan Gojek dengan Naïve Bayes dan Algoritma Genetika menghasilkan nilai akurasi pada masing-masing aplikasi yaitu Shopee dengan nilai akurasi 96,53%, Ruangguru dengan nilai akurasi 95,54%, Tokopedia dengan nilai akurasi 96,87% dan Gojek dengan nilai akurasi 96,54%.

Kajian (Iriananda et al., 2021) yang menganalisis sentimen aplikasi marketplace yaitu Shopee, Tokopedia dan Lazada, menghasilkan Nilai akurasi optimum pada Decision Tree (DT) dan Random Forest (RF) dalam proses pelatihan adalah 96,55%. Namun dalam kajian ini masih terdapat kekurangan yaitu pada proses pengujian dimana SVM-RBF, dan RF menghasilkan tingkat akurasi 60,08% dalam proses pengujian. Penelitian pada Twitter, Instagram dan Facebook dengan dataset Bahasa Indonesia (Thenata, 2021) menghasilkan Nilai akurasi untuk KNN adalah 50%, dan SVM 98,13%. Sedangkan NB 88%.

Berdasarkan beberapa penelitian tersebut menunjukkan bahwa algoritma SVM memiliki akurasi yang optimal, sehingga penulis tertarik untuk menggunakan algoritma SVM untuk menganalisa sentiment terhadap tiga *mobile game* terpopuler di *Google Playstore*. Kebutuhan untuk mendapat hasil yang optimal menjadi sangat penting, maka dalam penelitian ini penulis menggunakan teknik *Grid Search* (GS) untuk mendapatkan *hyperparameter* yang tepat untuk Algoritma SVM.

Grid Search digunakan untuk tuning hyperparameter penting pada SVM seperti C, kernel, dan gamma. Analisis ini membandingkan kinerja Naive Bayes dan SVM sebelum dan sesudah tuning hyperparameter. Setelah tuning hyperparameter menggunakan Grid Search, SVM memberikan akurasi yang lebih baik (85,65%) dibandingkan dengan Naive Bayes (68,70%), membuktikan bahwa tuning dapat meningkatkan kinerja model secara signifikan (Chong and Shah, 2022).

Sementara itu studi yang melakukan analisis komparatif berbagai teknik tuning hyperparameter seperti Grid Search, Random Search, Bayesian Optimization, Particle Swarm Optimization (PSO), dan Genetic Algorithm (GA) untuk beberapa algoritma ML termasuk SVM dilakukan oleh (Elgeldawi et al., 2021).

Dalam proses *model selection* dengan seleksi fitur menggunakan kombinasi N-Gram diharapkan dapat menghasilkan nilai akurasi yang optimal. Beberapa skenario dilakukan dalam rangka menginvestigasi metode yang digunakan dalam penelitian ini terhadap akurasi SVM. Kemudian dilakukan evaluasi terhadap model klasifikasi secara menyeluruh menggunakan Akurasi (Acc), *Precision* (Prec), *Recall* (Rec), dan Area dibawah kurva ROC (AUC).

Penelitian ini berkontribusi dalam memperkuat pemahaman dengan penggunaan Grid Search dan kombinasi N-Gram untuk optimasi SVM dalam konteks ulasan pengguna mobile game yang telah dilakukan oleh (Iriananda et al., 2022). Studi ini tidak hanya memperlihatkan hasil akurasi yang lebih tinggi dibandingkan penelitian sebelumnya, tetapi juga menawarkan wawasan baru tentang bagaimana variasi jumlah baris data dan konfigurasi N-Gram dapat memengaruhi performa model.

Kontribusi kebaruan dalam penelitian ini dibandingkan dengan penelitian terkait sebelumnya adalah model *classifier* yang terdiri dari kombinasi algoritma Support Vector Machine (SVM), dengan hyperparameter tuning Grid Search dan Kombinasi N-Gram yaitu Unigram + Bigram + Trigram (UniBiTri) (Iriananda et al., 2022).

2. METODE PENELITIAN

Penelitian ini dilakukan pada situs Google Play Store dengan mengumpulkan komentar pengguna *mobile game* terbaik. Data ulasan tersebut mencakup informasi pengguna, tanggal ulasan, penilaian (*rating*) dalam bentuk bintang yang diberikan oleh pengguna, dan isi (*content*) dari ulasan tersebut.

Pada tahap input, dijelaskan mengenai data yang digunakan. Pada bagian proses sistem, dijelaskan langkah-langkah yang dilakukan mulai dari preprocessing, fitur yang digunakan, hingga proses klasifikasi. Tahap output mencakup hasil dari proses yang dapat menghasilkan nilai akhir, termasuk nilai akurasi yang terhitung.

2.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah Dataset Mobile Game, berbahasa Inggris yang sebelumnya telah digunakan dalam studi oleh (Iriananda et al., 2022) untuk mengeksplorasi kinerja N-Gram dalam tugas analisis sentimen. Penelitian ini melanjutkan dan memperluas analisis tersebut dengan fokus pada optimasi algoritma SVM dengan metode *hyperparameter tuning* Grid Search.

Terdapat tiga game mobile terpilih adalah Mobile Legends: Bang Bang (MLBB), Garena Free Fire Max (GFFM), dan Higgs Domino Island (HDI) (Iriananda et al., 2022). Dataset terdiri dari ulasan pengguna berbahasa Indonesia dengan total 7200 baris data. Setiap dataset game terdiri dari 2400 baris data ulasan. Dalam setiap dataset, terdapat 1200 baris data dengan label "positif" dan 1200 baris ulasan dengan label "negatif".

Data yang diambil untuk penelitian ini terfokus pada dua kolom, yaitu *Content* (isi ulasan) dan *Score* (skor). *Content* merupakan elemen kunci dalam penelitian ini, merepresentasikan komentar atau ulasan dari pengguna. Skor 1 dan 2 direpresentasikan sebagai label "Positif", sementara skor 4 dan 5 direpresentasikan sebagai label "Negatif". Proses labeling kemudian divalidasi dengan menggunakan Teknik auto labelling (Iriananda et al., 2023a).

2.2 Preprocessing Teks

Proses *preprocessing* teks sangat dibutuhkan pada setiap tugas analisis sentimen. Pada teks *review* di Google Playstore sangat sering ditemukan kata, frase atau istilah yang tidak konsisten, tidak baku, penggunaan bahasa gaul/alay (*slang*), redudansi kata, sehingga perlu melakukan data *preprocessing* sebelum melakukan klasifikasi sentiment (Fide et al., 2021). Tahap ini membutuhkan waktu dan sumber daya yang signifikan. Proses ini melibatkan generalisasi, penyaringan, normalisasi, konstruksi, dan transformasi data. Selain itu, penting untuk mengatasi ketidakseimbangan kelas (*imbalanced classes*), karena ketidakseimbangan ini dapat menghasilkan nilai akurasi yang bias dan tidak representatif dalam proses klasifikasi. (Kusnadi et al., 2021). Dalam penelitian ini dilakukan proses Tokenisasi, Case Folding, Filter Teks, Stopword Removal, dan Stemming.

2.3 Ekstraksi Fitur (TF-IDF)

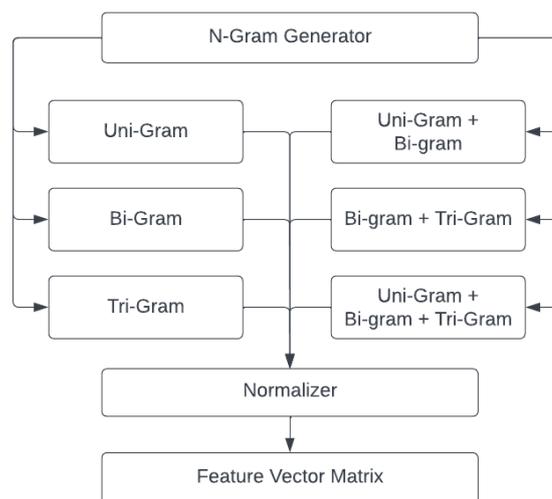
Ekstraksi fitur dalam penelitian ini menggunakan Teknik TF-IDF. Metode pembobotan ini dapat menghasilkan analisis sentimen yang efektif (Iriananda et al., 2023b). Data komentar yang telah selesai melalui proses *preprocessing* akan dilakukan proses TF-IDF. setiap kata atau term yang sudah melalui tahap *preprocessing* akan diberi boboturut berdasarkan id. Jika terdapat term yang sama maka jumlah *term frequency* (TF) akan bertambah 1 dan seterusnya. Setelah itu jika tidak proses akan

menghitung jumlah komentar lalu dilanjutkan dengan menghitung N-Term. Setelah dilakukan penghitungan TF-IDF dan menghasilkan hasil pembobotan TF-IDF. Proses ini akan berulang pada tiap term tiap komentar.

2.4 Seleksi Fitur N-Gram

Metode seleksi fitur N-Gram adalah sebuah metode yang digunakan untuk mengatur urutan token dalam sebuah dokumen. Dalam konteks ini, token-token ini dapat berupa kata-kata atau frasa-frasa, yang diurutkan dan dikelompokkan untuk membantu analisis teks. Metode ini memungkinkan pemahaman yang lebih baik terhadap struktur dan konteks teks yang sedang dianalisis. Secara garis besar konsep N-Gram disajikan pada Gambar 1.

Pada konteks komputasi linguistik, token ini biasanya berupa kata-kata, meskipun bisa berupa karakter atau himpunan bagian dari karakter. N hanya mengacu pada jumlah token. N-Gram biasanya digunakan untuk menangkap informasi statistik dari beberapa kumpulan data.



Gambar 1. Seleksi Fitur dengan Kombinasi N-Gram

Dalam Gambar 1 tersebut menunjukkan gambaran proses untuk mendapatkan nilai TF-IDF dengan fitur N-Gram. Dimulai dari input data latih atau data uji yang kemudian diproses oleh library Sklearn *Tfidfvectorizer* yang merupakan fungsi generator TF-IDF dan N-gram dalam sklearn. Dalam library ini kemudian ditentukan jangkauan N-gram pada variabel (*ngram_range*). Nilai jangkauan dapat berupa angka (1,1) untuk mendapatkan Unigram (Uni), *range* (2,2) untuk mendapatkan Bigram (Bi) dan *range* (3,3) untuk mendapatkan Trigram (Tri).

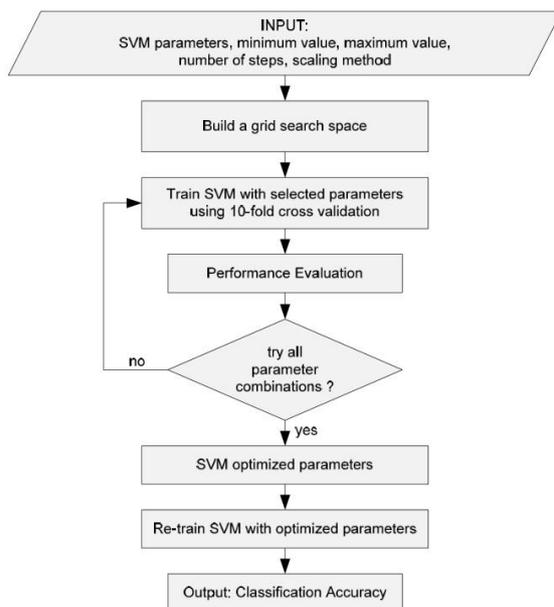
Penelitian ini mengadopsi fitur selection kombinasi N-gram, khususnya Unigram + Bigram + TriGram (UniBiTri), dengan jumlah fitur maksimal yang ditetapkan sebanyak 3000. Kinerja model seleksi fitur N-Gram dapat meningkatkan nilai akurasi algoritma klasifikasi (Iriananda et al., 2022). Dalam penelitian ini beberapa kombinasi N-Gram

didapatkan dengan menggunakan konfigurasi jangkauan N-Gram.

Konfigurasi tersebut yaitu (1,2) untuk mendapatkan Unigram + Bigram (UniBi), *range* (2,3) untuk mendapatkan Bigram + Trigram (BiTri), dan *range* (1,3) untuk Unigram + Bigram + Trigram (UniBiTri). Berdasarkan *range* N-Gram yang sudah ditentukan, kemudian dihitung nilai TF-IDF pada setiap *range* N-Gram dan dilakukan normalisasi sehingga membentuk *Feature Vector Matrix* yang kemudian digunakan pada proses selanjutnya.

2.5 Grid Search

Grid Search adalah teknik pencarian hyperparameter yang sistematis di mana parameter yang dicari dieksplorasi melalui grid dari nilai-nilai yang ditentukan menggunakan nilai minimal atau batas bawah (*lower bound*), nilai maksimal atau batas atas (*upper bound*), dan jumlah langkah (Khalid and Javaid, 2020). Teknik ini memungkinkan evaluasi berbagai kombinasi parameter untuk menemukan yang paling optimal berdasarkan kriteria kinerja yang telah ditentukan. Optimasi parameter SVM menggunakan Grid Search dijelaskan pada Gambar 2.



Gambar 2. Diagram Alir Grid Search

GS menggunakan mekanisme *Cross Validation* dengan kemudahan dalam proses pengujian setiap parameter model tanpa harus melakukan validasi manual satu persatu (Nugraha and Sasongko, 2022). Metode ini digunakan untuk optimasi dalam mencari *hyperparameter* terbaik SVM di sebuah Grid untuk menentukan *hyperparameter* dan konfigurasi yang optimal dengan menggunakan pendekatan estimator terbaik. GS merupakan cara terbaik untuk menentukan parameter dalam pengaturan sebuah algoritma (Radzi et al., 2021), teknik validasi silang (*cross-validation*) dapat mencegah masalah *over-fitting* (Khalid and Javaid, 2020).

Untuk memilih C dan Gamma menggunakan *k-fold Cross-Validation (CV)*, Langkah pertama adalah membagi data yang tersedia menjadi bagian himpunan k (di sebagian besar eksperimen, kami menetapkan k=10). Satu subset digunakan sebagai data pengujian dan kemudian dievaluasi menggunakan subset pelatihan k-1 yang tersisa. Kemudian kami menghitung kesalahan CV menggunakan kesalahan split ini untuk pengklasifikasi SVM menggunakan nilai C, Gamma, dan parameter lainnya yang berbeda. Akhirnya, berbagai kombinasi nilai *hyperparameter* dimasukkan. Dengan akurasi validasi silang terbaik (atau kesalahan CV terendah) dipilih dan digunakan untuk melatih SVM di seluruh kumpulan data.

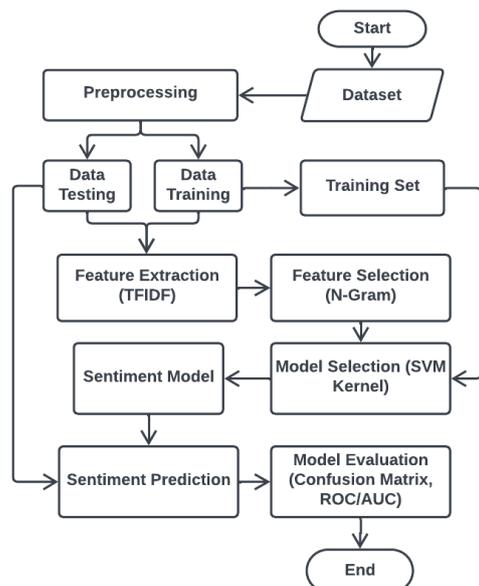
Dalam proses Grid Search yang disajikan pada Gambar 2 tersebut, rentang minimum dan maksimum *hyperparameter*, jumlah *cross-validation (CV)*, dan metode klasifikasi menjadi inisialisasi *input*. Kemudian diproses dalam ruang Grid Search. Klasifikasi dilakukan dengan melatih dan menguji data sebanyak 10 kali. Dari proses tersebut dievaluasi sampai memiliki nilai akurasi optimum. Dalam pengujian ini, kami menggunakan rentang parameter C dan Gamma mulai dari 0,001 hingga 100 (0.001, 0.01, 0.1, 1, 10, 100, 100). Dengan *estimator* kernel dalam pengujian GS adalah Linear, Polynomial, RBF dan Sigmoid.

2.6 Model Klasifikasi

Gambar 3 memberikan representasi global dari model klasifikasi yang digunakan. Proses dimulai dengan masukan berupa dataset ulasan dari pengguna game online populer di Google Play Store. Selanjutnya, dilakukan preprocessing teks yang membagi hasilnya menjadi dua bagian: data pelatihan (*training data*) dan data pengujian (*testing data*).

Langkah berikutnya adalah ekstraksi fitur dengan menerapkan metode pembobotan kata menggunakan metode pembobotan kata menggunakan Term Frequency Inverse Document Frequency (TF-IDF). Setelah dilakukan serangkaian perhitungan bobot setiap kata, kemudian dipilih fitur terbaik dengan N-Gram, yaitu Unigram (Uni), Bigram (Bi), atau Trigram (Tri) dan kombinasi Unigram + Bigram (UniBi), Bigram + Trigram (BiTri), dan Unigram + Bigram + Trigram (UniBiTri).

Berdasarkan Gambar 3, hasil dari Transformasi Term Frequency-Inverse Document Frequency (TF-IDF) dan teknik N-Gram digunakan dalam proses pemilihan model (*model selection*) dengan memanfaatkan data pelatihan (*training data*) yang telah ditetapkan sebelumnya. Dalam penelitian ini, pemilihan model dilakukan menggunakan metode Grid Search (GS) untuk menemukan kombinasi *hyperparameter* yang optimal bagi model klasifikasi. Dalam proses ini, juga memungkinkan untuk menentukan jangkauan N-Gram (*n-gram range*) dan batasan maksimal fitur (*max feature*) yang paling efektif pada setiap tahapan analisis.



Gambar 3. Model Klasifikasi Sentimen

Tahap prediksi sentimen memanfaatkan data pengujian (testing data) yang telah ditentukan dan dipisahkan pada langkah sebelumnya. Prediksi ini dilakukan dengan model SVM yang telah dioptimalkan sebelumnya, untuk memperoleh nilai akurasi, presisi, recall, dan ROC/AUC yang optimal selama proses evaluasi.

3. HASIL DAN PEMBAHASAN

Dalam penelitian ini, dilakukan eksperimen dengan tiga skenario, yaitu Grid Search, N-Gram, dan variasi jumlah baris data. Pada skenario Grid Search, eksperimen dilakukan dengan menggunakan gabungan seluruh dataset dari Mobile Legends: Bang Bang (MLBB), Garena Free Fire Max (GFFM), dan Higgs Domino Island (HDI). Jumlah sampel dalam dataset sebanyak 3600 baris data, dengan rasio perbandingan data latih dan data uji adalah 75:25, artinya 75% data digunakan sebagai data latih dan 25% sebagai data uji. Selain itu, Feature Selection (FS) dilakukan dengan menggunakan Unigram + Bigram + Trigram (UniBiTri).

Peramalan klasifikasi menggunakan Estimator SVC pada kernel SVM melibatkan empat kernel, yaitu Linear, Polynomial, RBF, dan Sigmoid, dengan penggunaan cross-validation sebanyak 10 kali ($cv = 10$). Pengujian dilakukan untuk mencari parameter C (complexity) dan Gamma (γ) dengan jangkauan nilai (0.001, 0.01, 0.1, 1, 10, 100). Model kernel yang paling optimum diidentifikasi dengan menerapkan Teknik Grid Search (GS), dengan jumlah kombinasi optimum GS (Fit) sebanyak $6 \times 6 \times 4 \times 10 = 1440$ kombinasi.

Meskipun terdapat 1440 kombinasi yang mungkin, dalam kajian ini, penulis hanya memperlihatkan lima kombinasi terbaik yang memberikan nilai evaluasi optimal. Kelima kombinasi ini mencerminkan gambaran nilai optimum dari keseluruhan 1440 kombinasi yang

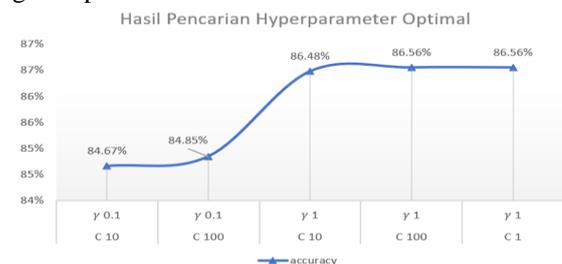
dihasilkan dalam proses Grid Search. Presentasi hasil dilakukan pada Tabel 2, yang memuat informasi tentang lima hasil paling optimum dari proses GS (Fit).

Tabel 2. Evaluasi Skenario Grid Search

C	Gamma	Kernel	Acc. (%)	Prec. (%)	Rec. (%)
1	γ 1	RBF	86.56	86.62	86.56
100	γ 1	RBF	86.56	86.59	86.56
10	γ 1	RBF	86.48	86.53	86.48
100	γ 0.1	RBF	84.85	84.90	84.85
10	γ 0.1	RBF	84.67	84.72	84.67

Berdasarkan hasil tersebut, dapat dilihat bahwa nilai akurasi optimum diperoleh dengan parameter Gamma = 1, C = 1, dan C = 100 menggunakan kernel RBF mencapai 86,56%. Selain itu, terdapat nilai precision sebesar 86,62% dan nilai recall sebesar 86,56%. Menariknya, dalam hasil tersebut, nilai C = 1 dan C = 100 memberikan akurasi yang sama. Namun, dalam pertimbangan penulis, nilai precision juga menjadi faktor yang diperhitungkan. Hal ini menunjukkan bahwa pemilihan hyperparameter yang tepat sangat penting untuk mencapai akurasi yang optimal.

Hasil Grid Search merekomendasikan kombinasi parameter Gamma = 1, C = 1, dengan kernel RBF sebagai nilai yang paling optimum, mengingat nilai precision yang optimal. Sebagai ilustrasi, penulis menyajikan visualisasi dalam bentuk grafik pada Gambar 4



Gambar 4. Grafik Nilai Akurasi Skenario Grid Search

Dalam skenario pengujian dengan pendekatan N-Gram, penelitian ini memanfaatkan 3.600 entri dari dataset gabungan yang dikenal sebagai Allgame. Kemudian membagi dataset ini menjadi data latih dan data uji dengan proporsi 75% untuk pelatihan dan 25% untuk pengujian. Dalam pengujian ini, diterapkan metode Feature Selection (FS) dengan berbagai kombinasi N-Gram termasuk Unigram (Uni), kombinasi Unigram dan Bigram (UniBi), gabungan Unigram, Bigram, dan Trigram (UniBiTri), hanya Bigram (Bi), kombinasi Bigram dan Trigram (BiTri), serta hanya Trigram (Tri).

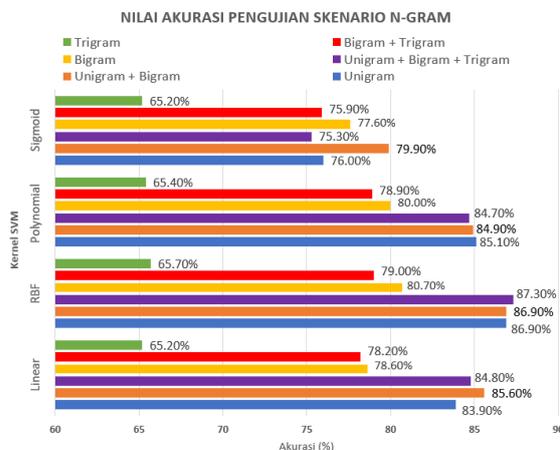
Pada seluruh pengujian yang dilakukan, nilai Gamma (γ) dipertahankan tetap pada 1, dan nilai C (kompleksitas) ditetapkan pada 1. Proses cross-validation dilakukan dengan $cv = 10$. Hasil akurasi dari berbagai skenario N-Gram ini dirangkum dalam Tabel 3.

Tabel 3. Nilai Akurasi Pada Skenario N-Gram (dalam %)

N-Gram	Linear	RBF	Polynomial	Sigmoid
Uni	83.90	86.90	85.10	76.00
UniBi	85.60	86.90	84.90	79.90
UniBiTri	84.80	87.33	84.70	75.30
Bi	78.60	80.70	80.00	77.60
BiTri	78.20	79.00	78.90	75.90
Tri	65.20	65.70	65.40	65.20

Berdasarkan hasil pengujian pada tabel 3 tersebut dapat dilihat bahwa nilai akurasi maksimum didapatkan dengan fitur seleksi Unigram + Bigram + Trigram (UniBiTri) dengan menggunakan kernel RBF yaitu 87,33%. Hasil pengujian menunjukkan bahwa kernel Radial Basis Function (RBF) secara konsisten memberikan nilai akurasi tertinggi dibandingkan dengan kernel lainnya. Sebaliknya, nilai akurasi terendah tercatat pada penggunaan fitur Trigram (Tri), yaitu sebesar 65,22% dengan kernel Linear dan Sigmoid. Secara visual hasil tabel 3 direpresentasikan pada Gambar 5.

Berdasarkan grafik yang ditampilkan pada Gambar 5, dapat dilihat bahwa fitur seleksi Bigram (Bi), Bigram + Trigram (BiTri), dan Trigram (3,3) secara umum menunjukkan tingkat akurasi yang lebih rendah dibandingkan dengan seleksi fitur yang mencakup Unigram. Meskipun demikian, penting untuk diperhatikan bahwa dalam konteks kernel Sigmoid, akurasi fitur seleksi Bigram (Bi) ternyata lebih tinggi dibandingkan dengan Unigram (Uni).



Gambar 5. Nilai Akurasi Fitur Seleksi N-Gram

Penyelidikan lebih lanjut dilakukan dengan menguji berbagai skenario terkait jumlah baris data. Eksperimen ini menggunakan dataset gabungan (Allgame) dengan ukuran data sebanyak 1200, 2400, dan 3600 baris. Rasio antara data latih dan data uji dipertahankan pada 75:25, yang menunjukkan bahwa 75% dari data digunakan untuk pelatihan sementara 25% sisanya digunakan untuk pengujian. Seleksi fitur dalam penelitian ini menerapkan metode N-Gram UniBiTri sebagai teknik Feature Selection (FS).

Nilai Gamma (γ) adalah 1 untuk seluruh dataset. Nilai C (complexity) adalah 1 pada jumlah baris dataset 1200 dan 2400. Sedangkan, untuk baris data 3600, nilai C (complexity) adalah 10, berdasarkan rekomendasi hasil pencarian grid (GS) yang telah

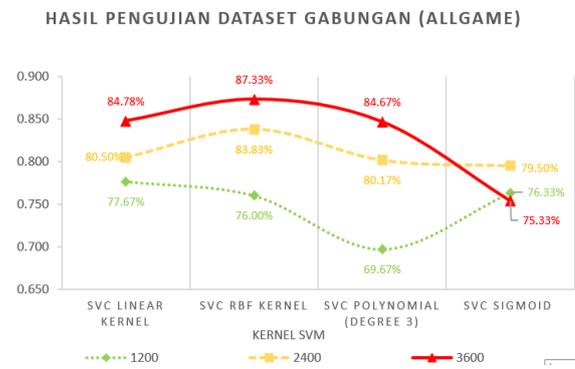
dilakukan. Sampel dipilih secara acak dan seimbang dengan nilai random_state adalah 42, dan dilakukan secara bertingkat (*stratified*). Kernel yang digunakan melibatkan Linear, Polynomial, Radial Basis Function (RBF), dan Sigmoid. Hasil pengujian skenario berdasarkan jumlah baris dataset dapat dilihat pada Tabel 4 berikut.

Tabel 4. Nilai Akurasi Skenario Jumlah Baris Data (dalam %)

Jumlah Baris	Linear	RBF	Polynomial	Sigmoid
1200	77.70	76.00	69.70	76.30
2400	80.50	83.80	80.20	79.50
3600	84.80	87.33	84.70	75.30

Berdasarkan hasil pengujian pada Tabel 4 di atas, terlihat bahwa nilai akurasi maksimum adalah 87,33%, dihasilkan dari dataset Allgame (3600) dengan ukuran baris data sebanyak 3600. Penggunaan kernel RBF pada data dataset Allgame (3600) memberikan hasil akurasi tertinggi. Sebaliknya, nilai akurasi paling rendah adalah 69,7%, dihasilkan dari dataset Allgame (1200) dengan ukuran baris data sebanyak 1200, menggunakan kernel Polynomial.

Hasil pengujian dengan skenario jumlah dataset pada tabel tersebut kemudian digunakan untuk membuat grafik visualisasi, yang secara visual merepresentasikan hasil pengujian menggunakan dataset gabungan dengan skenario jumlah baris data 1200, 2400, dan 3600. Grafik ini dapat dilihat pada Gambar 6.



Gambar 6. Grafik Nilai Akurasi Skenario

Gambar ini memberikan gambaran visual atas hasil pengujian dengan menggunakan dataset gabungan pada tiga skenario jumlah baris data tersebut. Visualisasi yang disajikan pada Gambar 6 merepresentasikan nilai akurasi dari setiap pengujian dengan skenario jumlah baris data pada dataset gabungan. Grafik tersebut menunjukkan bahwa semakin banyak jumlah baris data, nilai akurasi cenderung meningkat. Fenomena ini terlihat pada kernel Linear, Polynomial, dan RBF. Namun, terjadi kebalikan pada kernel Sigmoid.

Nilai akurasi optimum diperoleh dari pengujian dengan jumlah baris data sebanyak 3600 pada kernel RBF (3600), menghasilkan nilai akurasi sebesar 87,3%. Pada kasus kernel RBF (2400), nilai akurasi mencapai 83,8%, sementara kernel Linear (1200) memiliki nilai akurasi tertinggi, yaitu 76%. Dari

grafik tersebut juga dapat diperhatikan bahwa dengan penambahan jumlah baris data menjadi 3600, rata-rata nilai akurasi meningkat untuk seluruh kernel jika dibandingkan dengan jumlah baris data 1200 dan 2400. Nilai akurasi pada kernel RBF (3600) memiliki selisih 0,5% dibandingkan dengan kernel RBF (2400).

Hasil yang menarik perhatian terjadi pada kernel RBF (1200) dengan nilai akurasi sebesar 76,0%. Hasil ini menunjukkan penurunan sebesar 1,7% dibandingkan dengan kernel Linear (1200) yang mencapai 77,7%, dan 0,3% lebih rendah daripada kernel Sigmoid (1200) yang mencapai 76,3%. Selain itu, secara umum, skenario dengan jumlah baris data 1200 memiliki nilai akurasi yang cenderung lebih rendah dibandingkan dengan skenario 2400 dan 3600.

Terdapat satu pengecualian pada skenario dengan kernel Sigmoid (2400), yang memiliki nilai akurasi sebesar 79,5%, lebih unggul sebesar 4,2% dibandingkan dengan Sigmoid (3600) yang mencapai 79,3%. Selain itu, nilai akurasi pada kernel Sigmoid (1200) juga lebih baik 0,3% daripada RBF (1200).

Berdasarkan hasil eksperimen yang telah dilakukan, tampaknya jumlah baris data pada pengujian berpengaruh pada hasil akurasi Algoritma SVM. Pada tahap selanjutnya, evaluasi dilakukan secara menyeluruh terhadap model klasifikasi SVM dengan menggunakan hyperparameter $C = 1$ dan $\Gamma = 1$ pada 3600 data dari dataset Allgame.

Proses pemilihan hyperparameter yang dilakukan menggunakan Grid Search dan Cross-Validation dengan $cv = 10$ mengidentifikasi bahwa parameter optimal untuk algoritma SVM adalah nilai C (kompleksitas) sebesar 1 dan Γ (gamma) sebesar 1. Hasil evaluasi model klasifikasi sentiment disajikan pada Tabel 5 berikut.

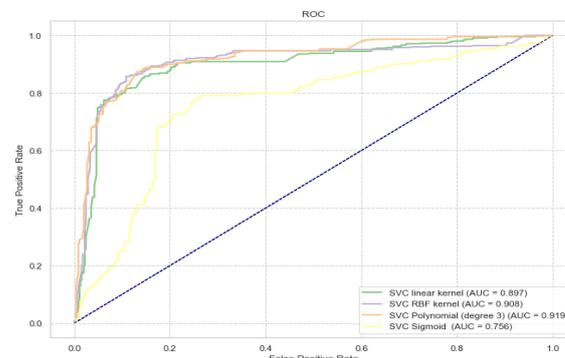
Tabel 5. Evaluasi Model Klasifikasi Sentimen

Kernel	Acc.	Prec.	Recall	AUC
Linear	84.78%	81.78%	87.00%	0.8968
RBF	87.33%	85.78%	88.53%	0.9081
Polynomial	84.67%	77.11%	90.84%	0.9193
Sigmoid	75.33%	70.89%	77.80%	0.7565

Eksperimen ini melibatkan fitur seleksi UniBiTri, dengan batasan maksimum fitur sebanyak 3000 fitur. Kernel yang digunakan mencakup Linear, RBF, Polynomial, dan Sigmoid. Hasil pengujian pada Tabel 5 menunjukkan bahwa Kernel RBF memberikan hasil yang optimal, dengan nilai akurasi tertinggi sebesar 87,33%, Precision 85,78%, Recall 88,53%, dan nilai AUC 0.9081.

Selanjutnya, Kernel Linear mencapai akurasi sebesar 84,78%, Precision 81,78%, Recall 87,00%, dan nilai AUC 0.8968. Pada Kernel Polynomial, nilai akurasi dan Precision lebih rendah dibandingkan dengan Kernel Linear dan RBF. Meskipun demikian, nilai Recall dan AUC pada Kernel Polynomial lebih tinggi dari semua kernel lainnya, yaitu Recall sebesar 90,84%, dan AUC mencapai 0.9193. Hasil evaluasi

divisualisasikan dalam bentuk area dibawah kurva pada Gambar 7 berikut.



Gambar 7 Nilai AUC Klasifikasi Sentimen

Berdasarkan eksperimen, dapat dilihat dari Gambar 7 bahwa Kernel RBF menunjukkan hasil akurasi yang paling optimal, mencapai 87,33%, dibandingkan dengan Kernel Linear (84,48%), Polynomial (84,67%), dan nilai terendah pada Sigmoid (75,3%). Meskipun demikian, ketika dilihat dari nilai AUC, Kernel Polynomial menunjukkan kinerja yang lebih baik dengan nilai AUC sebesar 0,919, melebihi Kernel RBF yang memiliki nilai AUC sebesar 0,908 dengan selisih 0,0112 poin. Hal ini mengindikasikan bahwa kinerja Algoritma klasifikasi dengan menggunakan Kernel Polynomial lebih unggul daripada RBF.

Namun, perlu dicatat bahwa penelitian ini belum dapat memberikan kepastian mengenai penyebab perbedaan tersebut, sehingga memerlukan investigasi lebih lanjut pada penelitian selanjutnya.

4. KESIMPULAN

Melalui hasil analisis dan pengujian yang telah diuraikan pada bab sebelumnya, dapat diambil beberapa kesimpulan dalam kajian ini. Metode Support Vector Machine (SVM) terbukti efektif dalam menganalisis sentimen dari teks ulasan pengguna pada permainan mobile populer yang tersedia di Google Play Store. Pada skenario pengujian dengan dataset gabungan (allgame) yang menggunakan 3600 baris data, metode SVM mencapai akurasi optimum sebesar 87,33%.

Penelitian ini menunjukkan peningkatan akurasi hingga 87,33%, yang lebih tinggi 17,33% dibandingkan penelitian sebelumnya (Arifin et al., 2021), dengan akurasi 70%. Sementara penelitian ini mencapai akurasi sebesar 87,33% dengan mengadopsi rasio data latihan dan data uji sebesar 75:25 menggunakan kombinasi N-Gram dan optimasi Grid Search. Penggunaan model selection melalui algoritma Grid Search dan Cross-Validation dengan $cv = 10$ terbukti dapat meningkatkan performa dari algoritma Support Vector Machine (SVM).

Optimalisasi parameter SVM dengan Grid Search dan Cross-Validation menghasilkan nilai C dan Γ sebesar 1. Ini menegaskan bahwa penentuan parameter yang tepat sangatlah penting

untuk mencapai akurasi yang optimal dalam model. Dengan kata lain, keputusan yang cermat dalam memilih parameter dapat secara signifikan meningkatkan kinerja keseluruhan dari model analisis yang diterapkan.

Pada penelitian ini, akurasi tertinggi yang dicapai adalah 86,56%, didukung oleh nilai recall sebesar 86,56%, precision sebesar 86,62%, dan f-measure sebesar 86,55%. Hasil ini dicapai berkat pemilihan kernel yang tepat, yaitu menggunakan kernel Radial Basis Function (RBF). Penting juga untuk mencatat bahwa pemilihan jenis feature selection, seperti N-Gram, memiliki peran yang signifikan dalam meningkatkan nilai akurasi algoritma klasifikasi.

Dalam penelitian ini, penggunaan teknik seleksi fitur N-Gram terbukti efektif dalam meningkatkan performa algoritma, menghasilkan akurasi sebesar 87,33%. Hal ini mengkonfirmasi penelitian sebelumnya (Iriananda et al., 2022) dan menunjukkan bahwa pemilihan fitur yang tepat dapat secara signifikan memperbaiki hasil analisis model. Penelitian ini berhasil meningkatkan akurasi SVM hingga 87,33% melalui penerapan Grid Search dan Cross-Validation, menekankan pentingnya optimisasi parameter.

Berdasarkan hasil yang telah dijelaskan di atas, dapat dilihat bahwa semakin banyak jumlah dataset, semakin tinggi pula tingkat cross-validation, dan semakin banyak parameter yang digunakan dalam proses penyetelan melalui Grid Search (GS), maka semakin besar pula penggunaan sumber daya memory dan waktu yang diperlukan dalam proses tersebut. Meskipun peningkatan parameter dan dataset meningkatkan akurasi, hal ini juga menyebabkan kebutuhan akan sumber daya memory dan waktu yang lebih besar, yang perlu diperhitungkan dalam penerapan praktis.

Hasil ini menunjukkan bahwa dengan pemilihan parameter yang tepat, metode SVM dapat secara signifikan meningkatkan akurasi dalam analisis sentimen teks, yang bermanfaat untuk aplikasi seperti analisis ulasan pengguna di Google Play Store.

Ke depan, penelitian ini dapat diperluas dengan mengeksplorasi berbagai jenis dataset atau mengkombinasikan SVM dengan metode machine learning lainnya seperti Naïve Bayes, Random Forest, XGBoost atau bahkan metode Deep Learning untuk lebih meningkatkan akurasi dalam analisis sentimen. Naïve Bayes dan Random Forest dapat menawarkan kecepatan atau interpretabilitas yang lebih baik dalam situasi tertentu, sementara Deep Learning dapat menangani kompleksitas data yang lebih tinggi.

DAFTAR PUSTAKA

ABIMANYU, D., BUDIANITA, E., CYNTHIA, E.P., YANTO, F., YUSRA, Y., 2022. Analisis Sentimen Akun Twitter Apex Legends Menggunakan VADER. *Jurnal Nasional*

Komputasi dan Teknologi Informasi (JNKTI) 5, 423–431.

<https://doi.org/10.32672/jnkti.v5i3.4382>

ARIFIN, N., ENRI, U., SULISTIYOWATI, N., 2021. Penerapan Algoritma Support Vector Machine (SVM) dengan TF-IDF N-Gram untuk Text Classification. *STRING* 6, 129.

<https://doi.org/10.30998/string.v6i2.10133>

BIRJALI, M., KASRI, M., BENI-HSSANE, A., 2021. A comprehensive survey on sentiment analysis: Approaches, challenges and trends. *Knowledge-Based Systems* 226, 107134. <https://doi.org/10.1016/j.knosys.2021.107134>

CHONG, K., SHAH, N., 2022. Comparison of Naive Bayes and SVM Classification in Grid-Search Hyperparameter Tuned and Non-Hyperparameter Tuned Healthcare Stock Market Sentiment Analysis. *IJACSA* 13. <https://doi.org/10.14569/IJACSA.2022.0131213>

ELGELDAWI, E., SAYED, A., GALAL, A.R., ZAKI, A.M., 2021. Hyperparameter Tuning for Machine Learning Algorithms Used for Arabic Sentiment Analysis. *Informatics* 8, 79. <https://doi.org/10.3390/informatics8040079>

FEBRIANTA, M.Y., WIDIYANESTI, S., RAMADHAN, S.R., 2021. Analisis Ulasan Indie Video Game Lokal pada Steam Menggunakan Analisis Sentimen dan Pemodelan Topik Berbasis Latent Dirichlet Allocation. *Journal of Animation and Games Studies* 7, 117–144. <https://doi.org/10.24821/jags.v7i2.5162>

FIDE, S., SUPARTI, S., SUDARNO, S., 2021. Analisis Sentimen Ulasan Aplikasi Tiktok Di Google Play Menggunakan Metode Support Vector Machine (SVM) dan Asosiasi. *Jurnal Gaussian* 10, 346–358. <https://doi.org/10.14710/j.gauss.v10i3.32786>

HENDRIYANTO, M.D., RIDHA, A.A., ENRI, U., 2022. Analisis Sentimen Ulasan Aplikasi Mola Pada Google Play Store Menggunakan Algoritma Support Vector Machine. *INTECOMS: Journal of Information Technology and Computer Science* 5, 1–7. <https://doi.org/10.31539/intecom.v5i1.3708>

IRIANANDA, S.W., BUDIAWAN, R.W., RAHMAN, A.Y., ISTIADI, I., 2022. Kinerja Seleksi Fitur N-Gram Pada Analisis Sentimen Ulasan Mobile Game di Google Playstore. *Conference on Innovation and Application of Science and Technology (CIASTECH)* 5, 639–648.

IRIANANDA, S.W., PUTRA, R.P., FARHAN, A., 2023a. KINERJA AUTO LABELLING PADA Analisis Sentimen Terhadap Pasangan Calon Presiden 2024 di Media Sosial X. *Conference on Innovation and Application of Science and Technology (CIASTECH)* 6, 618–633. <https://doi.org/10.31328/ciastech.v6i1.5354>

- IRIANANDA, S.W., PUTRA, R.P., NUGROHO, K.S., 2021. Analisis Sentimen dan Analisis Data Eksploratif Ulasan Aplikasi Marketplace Google Playstore. Presented at the Conference on Innovation and Application of Science and Technology (CIASTECH) 2021, Universitas Widyagama Malang, Malang, Indonesia, p. 10.
- IRIANANDA, S.W., PUTRA, R.P., RAIHAN, A.A., SAPUTRA, D.A., VERDIANSYAH, E., 2023b. Analisis Sentimen Ulasan Game Mobile First-Person Shooter Di Google Play Store Menggunakan Metode Pembobotan TF-IDF. *Prosidia Widya Saintek* 2, 281–288.
- KHALID, R., JAVAID, N., 2020. A survey on hyperparameters optimization algorithms of forecasting models in smart grid. *Sustainable Cities and Society* 61, 102275. <https://doi.org/10.1016/j.scs.2020.102275>
- KING, D.L., DELFABBRO, P.H., BILLIEUX, J., POTENZA, M.N., 2020. Problematic online gaming and the COVID-19 pandemic. *Journal of Behavioral Addictions* 9, 184–186. <https://doi.org/10.1556/2006.2020.00016>
- KUSNADI, R., YUSUF, Y., ANDRIANTONY, A., ARDIAN YAPUTRA, R., CAINTAN, M., 2021. Analisis Sentimen Terhadap Game Genshin Impact Menggunakan Bert. *rabit* 6, 122–129. <https://doi.org/10.36341/rabit.v6i2.1765>
- LIANG, S., 2021. Comparative Analysis of SVM, XGBoost and Neural Network on Hate Speech Classification. *RESTI* 5, 896–903. <https://doi.org/10.29207/resti.v5i5.3506>
- NUGRAHA, W., SASONGKO, A., 2022. Hyperparameter Tuning on Classification Algorithm with Grid Search. *SISTEMASI* 11, 391. <https://doi.org/10.32520/stmsi.v11i2.1750>
- NURCAHYO, J.A., SASONGKO, T.B., 2023. Hyperparameter Tuning Algoritma Supervised Learning untuk Klasifikasi Keluarga Penerima Bantuan Pangan Beras. *Indonesian Journal of Computer Science* 12. <https://doi.org/10.33022/ijcs.v12i3.3254>
- PAMUNGKAS, F.S., KHARISUDIN, I., 2021. Analisis Sentimen dengan SVM, Naive Bayes dan KNN untuk Studi Tanggapan Masyarakat Indonesia Terhadap Pandemi Covid-19 pada Media Sosial Twitter 4, 7.
- PRABU, S., THIYANESWARAN, B., SUJATHA, M., NALINI, C., RAJKUMAR, S., 2022. Grid Search for Predicting Coronary Heart Disease by Tuning Hyper-Parameters. *Computer Systems Science and Engineering* 43, 737–749. <https://doi.org/10.32604/csse.2022.022739>
- PRATMANTO, D., ROUSYATI, R., WATI, F.F., WIDODO, A.E., SULEMAN, S., WIJANTO, R., 2020. App Review Sentiment Analysis Shopee Application In Google Play Store Using Naive Bayes Algorithm. *J. Phys.: Conf. Ser.* 1641, 012043. <https://doi.org/10.1088/1742-6596/1641/1/012043>
- PUJADAYANTI, I., FAUZI, M.A., SARI, Y.A., 2018. Prediksi Rating Otomatis pada Ulasan Produk Kecantikan dengan Metode Naïve Bayes dan N-gram 7.
- RADZI, S.F.M., KARIM, M.K.A., SARIPAN, M.I., RAHMAN, M.A.A., ISA, I.N.C., IBAHIM, M.J., 2021. Hyperparameter Tuning and Pipeline Optimization via Grid Search Method and Tree-Based AutoML in Breast Cancer Prediction. *J Pers Med* 11, 978. <https://doi.org/10.3390/jpm11100978>
- RAHMAN, A., UTAMI, E., SUDARMAWAN, S., 2021. Sentimen Analisis Terhadap Aplikasi pada Google Playstore Menggunakan Algoritma Naïve Bayes dan Algoritma Genetika. *JKKI* 5, 60–71. <https://doi.org/10.31603/komtika.v5i1.5188>
- SIDIQ, R.P., DERMAWAN, B.A., UMAIDAH, Y., 2020. Sentimen Analisis Komentar Toxic pada Grup Facebook Game Online Menggunakan Klasifikasi Naïve Bayes. *JIUP* 5, 356. <https://doi.org/10.32493/informatika.v5i3.6571>
- SUJADI, H., 2022. Analisis Sentimen Pengguna Media Sosial Twitter Terhadap Wabah Covid-19 Dengan Metode Naive Bayes Classifier Dan Support Vector Machine. *INFOTECH journal* 8, 22–27. <https://doi.org/10.31949/infotech.v8i1.1883>
- THENATA, A.P., 2021. Text Mining Literature Review on Indonesian Social Media. *JEPIN* 7, 226. <https://doi.org/10.26418/jp.v7i2.47975>