

Perbandingan Model Naïve Bayes, Logistic Regression, SVM, XGBoost, dan SVM-XGBoost untuk Analisis Sentimen Tunaiku

Yabes Aryanto Melapa*, Setyoningsih Wibowo, Nur Latifah Dwi Mutiara Sari

Fakultas Teknik dan Informatika, Program Studi Informatika, Universitas PGRI Semarang, Semarang, Indonesia

Email: ^{1,*}yabesmelapa@gmail.com, ²setyoningsihwibowo@upgris.ac.id, ³nurlatifah@upgris.ac.id

Email Penulis Korespondensi: yabesmelapa@gmail.com

Submitted: 10/12/2025; Accepted: 26/12/2025; Published: 26/12/2025

Abstrak—Analisis sentimen dimanfaatkan untuk menggali persepsi pengguna terhadap layanan fintech seperti Tunaiku melalui evaluasi ulasan pelanggan. Penelitian ini secara khusus bertujuan untuk membandingkan performa beberapa algoritma klasifikasi sentimen guna menentukan model yang paling optimal dalam mengklasifikasikan ulasan pengguna aplikasi Tunaiku. Dataset yang digunakan dalam penelitian ini berupa kumpulan ulasan pengguna aplikasi Tunaiku yang diperoleh dari Google Play Store, dengan jumlah data sebanyak 18.458 ulasan. Studi ini membandingkan kinerja lima algoritma klasifikasi, yaitu Naïve Bayes, Logistic Regression, Support Vector Machine (SVM), XGBoost, serta model hybrid SVM-XGBoost. Tahapan penelitian meliputi prapemrosesan teks, ekstraksi fitur menggunakan TF-IDF, serta penerapan model klasifikasi yang divalidasi menggunakan metode cross-validation. Evaluasi kinerja model dilakukan berdasarkan metrik accuracy, precision, recall, dan F1-score. Hasil pengujian menunjukkan bahwa Naïve Bayes (91,96%), Logistic Regression (92,81%), SVM (92,56%), dan XGBoost (92,52%) memberikan performa yang baik, sementara model hybrid SVM-XGBoost menghasilkan performa terbaik dengan akurasi tertinggi sebesar 93,05%. Temuan ini menunjukkan bahwa pendekatan hybrid lebih efektif dalam analisis sentimen ulasan pengguna dan berpotensi menjadi dasar pengambilan keputusan dalam meningkatkan kualitas layanan Tunaiku sesuai dengan kebutuhan pengguna.

Kata Kunci: Analisis Sentimen; Klasifikasi; SVM–XGBoost; Machine Learning

Abstract—Sentiment analysis is used to explore user perceptions of fintech services such as Tunaiku through the evaluation of customer reviews. This study specifically aims to compare the performance of several sentiment classification algorithms to determine the most optimal model for classifying Tunaiku app user reviews. The dataset used in this study is a collection of Tunaiku app user reviews obtained from the Google Play Store, with a total of 18,458 reviews. This study compares the performance of five classification algorithms, namely Naïve Bayes, Logistic Regression, Support Vector Machine (SVM), XGBoost, and a hybrid SVM-XGBoost model. The research stages include text preprocessing, feature extraction using TF-IDF, and the application of a validated classification model using the cross-validation method. Model performance evaluation is carried out based on accuracy, precision, recall, and F1-score metrics. The test results showed that Naïve Bayes (91.96%), Logistic Regression (92.81%), SVM (92.56%), and XGBoost (92.52%) provided good performance, while the hybrid SVM-XGBoost model produced the best performance with the highest accuracy of 93.05%. These findings indicate that the hybrid approach is more effective in analyzing user review sentiment and has the potential to be a basis for decision-making in improving Tunaiku's service quality according to user needs.

Keywords: Sentiment Analysis; Classification; SVM–XGBoost; Machine Learning

1. PENDAHULUAN

Dalam beberapa tahun terakhir, perkembangan teknologi finansial (fintech) di Indonesia mengalami lonjakan pesat [1]. Berbagai inovasi di sektor ini menghadirkan kemudahan bagi masyarakat dalam mengakses layanan keuangan, salah satunya melalui pinjaman online. Layanan tersebut populer karena prosesnya cepat, persyaratannya fleksibel, dan pengajuannya sederhana dibandingkan lembaga keuangan tradisional [2]. Meski menawarkan kemudahan, persaingan antar penyedia pinjaman online semakin ketat, mendorong setiap perusahaan untuk terus berinovasi dan menjaga kualitas layanan [3]. Salah satu platform yang cukup dikenal adalah Tunaiku, aplikasi pinjaman online yang meraih angka unduhan yang menembus jutaan di google play store. Ribuan ulasan yang diberikan pengguna berisi pengalaman dan pendapat mereka, yang dapat menjadi sumber penting untuk menilai kinerja layanan, menemukan kendala, serta memahami kebutuhan pelanggan.

Sejumlah penelitian telah mengeksplorasi analisis sentimen terhadap ulasan pengguna layanan pinjaman online. Penulis bernama Melda menerapkan algoritma Naive Bayes pada data ulasan di Twitter untuk aplikasi pinjol EasyCash. Hasil menunjukkan tingkat akurasi sebesar 87 %, dengan performa yang solid pada metrik ditinjau dari nilai precision, recall, dan f1-score yang dihitung untuk tiap label positif maupun negatif [4]. Kemudian penelitian yang ditulis Aminah Dinayati Ghani, penulis menganalisis ulasan pengguna aplikasi pinjol Kredivo dan AkuLaku. Menggunakan metode SVM, mereka mendapatkan akurasi 81 % untuk Kredivo dan 75 % untuk AkuLaku. Visualisasi kata penting juga ditampilkan melalui word cloud untuk memperkaya wawasan analisis [5]. Penelitian lain oleh Iqbal menerapkan SVM untuk mengevaluasi sentimen lima layanan pinjaman digital seperti kredivo, easycash, rupiah cepat, kredit Pintar dan adapundi). Dari Play Store, mayoritas sentimen negatif. SVM berhasil mencapai nilai rata-ratanya berada pada angka 72 %, dengan presisi 76 % serta recall 85 %, dengan Kredit Pintar memperoleh performa terbaik (akurasi 83 %) [6].

Naive Bayes bekerja menggunakan prinsip Teorema Bayes dan beroperasi berlandaskan anggapan bahwa seluruh setiap atribut pada data tidak saling bergantung satu sama lain [7]. Logistic Regression adalah teknik klasifikasi linear yang meskipun sederhana, mampu memberikan hasil yang efektif. Metode ini memanfaatkan fungsi logistik (sigmoid) untuk mengonversi input menjadi probabilitas suatu kelas tertentu, sehingga cocok digunakan

sebagai model dasar (baseline) dalam analisis sentiment [8]. SVM mencari hyperplane yang memberikan pemisahan optimal antar kelas. Ketika diterapkan pada data teks, penggunaan kernel memungkinkan pemetaan data ke ruang dengan dimensi lebih besar, hingga pola yang sebelumnya tidak terbagi secara linear di ruang asal dapat dipisahkan dengan baik dengan lebih baik [9]. Algoritma XGBoost bekerja menggunakan pendekatan ensemble pada decision tree, dengan cara menambahkan pohon-pohon baru secara bertahap yang ditujukan untuk memperbaiki kesalahan prediksi dari model sebelumnya [10]. Selain itu, terdapat pula pendekatan hybrid SVM-XGBoost yang menggabungkan keunggulan SVM dengan XGBoost. SVM sendiri terkenal berperan secara optimal dalam melakukan pemisahan pada data yang memiliki banyak dimensi, terutama pada kata. SVM dapat digunakan untuk menghasilkan representasi fitur atau decision function yang kemudian diproses lebih lanjut oleh XGBoost. Hasilnya, model hybrid ini mampu meningkatkan akurasi dengan menggabungkan kekuatan pemisahan optimal SVM dan kemampuan generalisasi XGBoost [11].

Pada analisis sentimen modern, pemilihan model klasifikasi tidak hanya harus mempertimbangkan algoritma yang populer, tetapi juga kemampuan metode tersebut untuk beradaptasi dengan karakteristik dataset yang berbeda. Meskipun banyak studi sebelumnya telah membandingkan beberapa algoritma dasar seperti *Naive Bayes*, *SVM*, dan *Logistic Regression*, masih terdapat keterbatasan dalam pemahaman performa model hybrid yang menggabungkan kekuatan berbagai pendekatan untuk meningkatkan akurasi dan stabilitas. Sebagai contoh, Studi yang dilakukan oleh Ngarifatul et al. membandingkan *Naive Bayes* dan *SVM* dalam klasifikasi opini publik di platform X dengan dataset tweet yang cukup besar. Hasilnya menunjukkan bahwa *SVM* memberikan tingkat akurasi lebih tinggi dibanding *Naive Bayes*, sekaligus menonjol dalam menangani data teks sosial media yang kompleks [12]. Selain itu, penelitian oleh Dermawan & Ayunda menunjukkan bahwa penggabungan model klasik dengan deep learning seperti LSTM bisa meningkatkan kinerja pada dataset teks media sosial [13]. Di sisi lain, Agresia & Suryono menemukan bahwa *SVM* sering memberikan akurasi yang lebih tinggi daripada *Naive Bayes* dan *Logistic Regression* dalam beberapa kasus ulasan Twitter [14]. Studi lain yang relevan oleh Rizaldi et al. menerapkan algoritma *SVM* dan *XGBoost* untuk menganalisis opini publik terhadap aplikasi Uber, menyoroti keunggulan model boosting dalam konteks tertentu [15]. Namun, belum banyak penelitian yang secara langsung membuat perbandingan menyeluruh antara model individual dan model hybrid seperti *SVM-XGBoost* pada data ulasan layanan fintech di Indonesia, sehingga gap ini menjadi motivasi utama dalam penelitian ini untuk menentukan algoritma mana yang paling optimal dalam klasifikasi sentimen pengguna Tunaiku.

Kontribusi utama penelitian ini terletak pada penyajian evaluasi komprehensif antara model klasifikasi individual dan model hybrid dalam konteks ulasan layanan fintech di Indonesia, khususnya Tunaiku, yang masih relatif jarang dikaji dalam penelitian sebelumnya. Hasil penelitian diharapkan dapat menjadi acuan dalam pemilihan model klasifikasi sentimen yang paling sesuai berdasarkan karakteristik data ulasan pengguna. Pada analisis sentimen, performa model tidak hanya bergantung pada algoritmanya, melainkan juga pada teknik representasi teks yang digunakan sebelum proses klasifikasi. Salah satu pendekatan representasi yang banyak digunakan yaitu metode term frequency–inverse document frequency (TF-IDF) [16]. sehingga metode naive bayes, logistic regression, SVM, dan xgboost dapat mengenali pola sentimen secara lebih akurat dan pada akhirnya meningkatkan kualitas klasifikasi terhadap ulasan pengguna. Pada riset yang dilakukan ini, penulis melakukan perbandingan kinerja 5 algoritma populer, yaitu naive bayes, logistic regression, SVM, xgboost dan SVM-xgboost yang diintegrasikan dengan representasi teks berbasis TF-IDF [17]. Data yang dipakai dalam penelitian ini berupa ulasan pengguna aplikasi Tunaiku, salah satu layanan pinjaman daring di Indonesia. Perbandingan yang dilakukan bertujuan untuk menentukan algoritma paling optimal dalam mengenali dan mengategorikan sentimen pengguna terhadap layanan Tunaiku. Penelitian ini bertujuan untuk membandingkan performa lima algoritma klasifikasi, yaitu *Naive Bayes*, *Logistic Regression*, *SVM*, *XGBoost*, serta model hybrid *SVM-XGBoost*, yang diintegrasikan dengan representasi teks berbasis TF-IDF pada ulasan pengguna aplikasi Tunaiku.


2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

2.1.1 Metode

Studi ini memanfaatkan lima jenis algoritma pembelajaran mesin, yaitu *Naive Bayes*, *Logistic Regression*, *Support Vector Machine (SVM)*, *XGBoost*, serta model hibrida *SVM-XGBoost*, yang digunakan untuk melakukan pengelompokan sentimen terhadap ulasan yang diberikan oleh para pengguna aplikasi Tunaiku. Pelaksanaan penelitian dimulai dengan tahap pengumpulan data ulasan dari pengguna, yang kemudian dilanjutkan dengan proses prapengolahan teks. Tahap praproses ini mencakup pembersihan data dari karakter yang tidak relevan, penghapusan kata-kata umum atau stopword, proses tokenisasi, pemberian label sentimen, serta penerapan stemming menggunakan library Sastrawi untuk menormalkan kata ke bentuk dasarnya. Setelah seluruh data melalui tahap praproses, dataset selanjutnya dibagi menjadi dua bagian, yaitu data pelatihan dan data pengujian dengan rasio pembagian sebesar 70% untuk pelatihan dan 30% untuk pengujian. Representasi fitur teks dilakukan menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF) guna mengubah data teks menjadi bentuk numerik yang dapat diproses oleh algoritma klasifikasi. Selanjutnya, kinerja masing-masing model dievaluasi menggunakan beberapa metrik

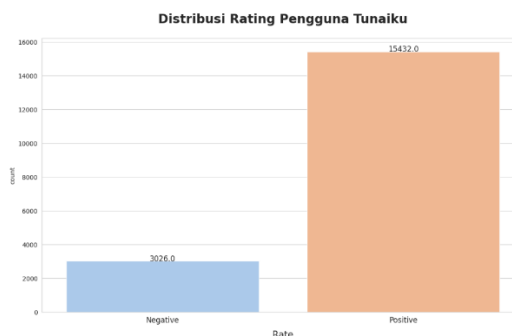
pengukuran, antara lain accuracy, precision, recall, dan f1-score [18], sehingga diperoleh gambaran menyeluruh mengenai performa setiap algoritma yang digunakan. Alur tahapan penelitian secara keseluruhan ditampilkan pada Gambar 1.



Gambar 1. Metode Penelitian

2.1.2 Pengumpulan Data

Studi ini menggunakan dataset yang bersumber dari kumpulan ulasan pengguna aplikasi Tunaiku yang diperoleh melalui Google Play Store. Dataset tersebut terdiri dari 18.458 ulasan, yang diklasifikasikan ke dalam dua kelas sentimen, yaitu 15.432 ulasan positif dan 3026 ulasan negatif. Ulasan ini memuat beragam opini dan pengalaman pengguna terhadap layanan yang diberikan, sehingga merepresentasikan persepsi konsumen secara langsung. Distribusi kelas pada dataset menunjukkan bahwa [seimbang/tidak seimbang], sehingga perlu diperhatikan dalam proses pelatihan dan evaluasi model. Data ini menjadi dasar utama dalam analisis sentimen untuk mengukur tingkat kepuasan pengguna serta memahami pandangan mereka terhadap kualitas layanan Tunaiku, sebagaimana ditunjukkan pada Gambar 2 [19].



Gambar 2. Distribusi Dataset

2.1.3 Pra-pemrosesan

Tahap prapemrosesan data diawali dengan pembersihan teks, yaitu menghilangkan karakter yang tidak relevan seperti angka, simbol, dan karakter khusus. Selanjutnya dilakukan proses stopwords removal untuk menghapus kata-kata umum yang tidak memiliki kontribusi signifikan terhadap makna sentimen, serta tokenisasi untuk memecah teks menjadi unit kata. Pelabelan sentimen dilakukan secara otomatis berdasarkan indikator rating yang diberikan oleh pengguna pada Google Play Store, di mana ulasan dengan rating bintang 1 dan 2 dikategorikan sebagai sentimen negatif, sedangkan ulasan dengan rating bintang 3, 4, dan 5 diklasifikasikan sebagai sentimen positif. Pendekatan ini dipilih karena rating numerik dianggap merepresentasikan persepsi sentimen pengguna secara langsung dan konsisten. Setelah proses pelabelan, dilakukan stemming menggunakan algoritma Sastrawi untuk mengubah kata ke bentuk dasarnya. Seluruh tahapan ini bertujuan menghasilkan data yang bersih, terstruktur, dan siap diproses secara optimal oleh algoritma machine learning [20].

2.1.4 Representasi Teks dengan TF-IDF

Teknik TF-IDF mentransformasikan teks ke representasi berupa vektor angka melalui pemberian bobot pada kata-kata, yang dihitung dari frekuensi kemunculan suatu kata pada dokumen tertentu serta tingkat kejarangannya pada keseluruhan dokumen dalam sekumpulan dokumen [21].

2.1.5 Tahap Memecah Dataset Menjadi Bagian Pelatihan dan Pengujian

Dataset dibagi dengan komposisi 70 persen sebagai data pelatihan dan 30 persen sebagai data pengujian. Porsi data latih digunakan dalam pembangunan digunakan untuk membentuk model klasifikasi, sementara data pengujian bertugas menilai kemampuan model dalam menangani data baru yang sebelumnya tidak dikenali [22].

2.1.6 Klasifikasi Model

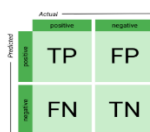
Penelitian ini membandingkan performa lima algoritma klasifikasi yang umum digunakan dalam analisis sentimen, yaitu Naïve Bayes, Logistic Regression, Support Vector Machine (SVM), dan XGBoost, serta satu pendekatan kombinasi SVM-XGBoost. Pada skema hybrid ini, SVM digunakan sebagai *base classifier* untuk menghasilkan probabilitas prediksi kelas pada data latih dan data uji (1). Nilai probabilitas keluaran dari SVM kemudian

dimanfaatkan sebagai fitur tambahan (*stacking-based approach*) yang menjadi input bagi model XGBoost. Dengan demikian, XGBoost tidak hanya mempelajari representasi fitur dari TF-IDF, tetapi juga memanfaatkan informasi prediksi dari SVM untuk memperbaiki kesalahan klasifikasi melalui mekanisme boosting. Pendekatan ini diharapkan mampu menggabungkan keunggulan SVM dalam menentukan batas pemisah optimal antar kelas dengan kemampuan XGBoost dalam meningkatkan performa model secara bertahap [23]. Mengingat performa algoritma seperti SVM dan XGBoost sangat dipengaruhi oleh pemilihan hyperparameter, penelitian ini melakukan proses penyesuaian parameter menggunakan pendekatan grid search yang dikombinasikan dengan cross-validation. Pada SVM, parameter utama yang dioptimalkan meliputi nilai C dan jenis kernel, sedangkan pada XGBoost dilakukan penyesuaian terhadap parameter seperti learning rate, maximum depth, dan number of estimators. Proses ini bertujuan untuk memperoleh konfigurasi model yang memberikan performa terbaik sekaligus menghindari terjadinya overfitting, sehingga hasil evaluasi yang diperoleh lebih stabil dan dapat digeneralisasikan pada data baru [24].

$$f(x) = \sum_i \alpha_i K(x_i, x) + b \quad (1)$$

2.1.7 Evaluasi Model

Confusi matrix adalah tabel penilaian yang memperlihatkan kinerja suatu model klasifikasi berdasarkan jumlah prediksi yang tepat dan tidak tepat pada setiap kelas. Matriks ini mencakup empat kategori: TP menunjukkan data positif yang diprediksi dengan benar, TN menandai data negatif yang dikenali tepat, FP adalah data negatif yang keliru diberi label positif, sedangkan FN merupakan data positif yang salah diprediksi sebagai negatif. Gambar 3 menyajikan visualisasi dari keempat komponen tersebut.



Predicted	Actual	
	Positif	Negatif
Positif	TP	FP
Negatif	FN	TN

Gambar 3. Confusion Matrix

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

Kajian ini dilakukan dengan tujuan untuk mengevaluasi secara komprehensif kinerja lima algoritma klasifikasi yang banyak digunakan dalam analisis sentimen, yakni Naïve Bayes, Logistic Regression, Support Vector Machine (SVM), XGBoost, serta varian hybrid SVM-XGBoost. Pemilihan kelima metode tersebut bukan tanpa alasan; masing-masing algoritma telah banyak dibahas dalam literatur dan terbukti efektif dalam berbagai penelitian terdahulu, baik pada konteks analisis teks maupun bidang pembelajaran mesin lainnya. Dengan demikian, penggunaan algoritma-algoritma tersebut diharapkan mampu memberikan gambaran yang lebih lengkap mengenai pendekatan mana yang paling tepat untuk mengolah dan menginterpretasikan data ulasan pengguna secara akurat. Proses klasifikasi dalam penelitian ini mengikuti alur umum yang lazim digunakan pada studi analisis sentimen, mencakup tahapan mulai dari prapemrosesan teks, pembentukan representasi fitur, hingga pembangunan model klasifikasi. Pendekatan ini dipilih agar hasil penelitian dapat disejajarkan dan dibandingkan dengan berbagai riset serupa yang telah dipublikasikan sebelumnya, sehingga posisi hasil penelitian dalam konteks akademik dapat lebih mudah dipahami. Selain itu, standar prosedur ini memastikan bahwa perbandingan kinerja antaralgoritma dilakukan dalam kondisi yang setara. Untuk memastikan bahwa model tidak hanya bekerja dengan baik pada data pelatihan tetapi juga memiliki kemampuan generalisasi yang kuat terhadap data baru, penelitian ini menggunakan metode validasi *cross-validation*. Teknik ini membantu mengurangi potensi *overfitting* dan memberikan gambaran performa model yang lebih objektif karena setiap model diuji pada beberapa pembagian data. Melalui proses evaluasi yang berulang tersebut, diperoleh hasil klasifikasi yang lebih stabil dari masing-masing algoritma. Seluruh hasil evaluasi kemudian dirangkum pada Tabel 1, yang menampilkan hasil performa setiap metode berdasarkan metrik yang telah ditetapkan. Tabel ini menjadi dasar bagi peneliti untuk melakukan analisis perbandingan secara lebih mendalam, sehingga dapat ditentukan algoritma mana yang menunjukkan akurasi dan performa paling unggul ketika diterapkan pada dataset ulasan pengguna yang digunakan dalam kajian ini. Dengan demikian, temuan penelitian tidak hanya memberikan informasi mengenai performa algoritma secara individual, tetapi juga menghasilkan rekomendasi praktis terkait model yang paling sesuai untuk digunakan dalam tugas analisis sentimen pada domain serupa.

Tabel 1. Hasil Klasifikasi

Metode	Hasil
Naïve Bayes	91,96%
SVM	92,81%
Logistic Regression	92,56%
XGBoost	92,52%
SVM-XGBoost	93,05%



3.2 Pembahasan

Dari Berdasarkan hasil klasifikasi yang ditampilkan pada Tabel 1 memperlihatkan bahwa masing-masing algoritma menunjukkan performa yang bervariasi ketika diterapkan pada dataset ulasan pengguna. Perbedaan performa ini mencerminkan karakteristik unik dari masing-masing metode, baik dari segi keunggulan maupun keterbatasan dalam mengolah data teks. Dengan demikian, pemilihan algoritma yang paling sesuai sangat ditentukan oleh pola data serta kebutuhan analisis yang ingin dicapai. Pada algoritma berbasis probabilistik, yaitu Naïve Bayes, diperoleh akurasi sebesar 91,96%. Angka ini menunjukkan bahwa metode tersebut cukup kompetitif dalam menyelesaikan tugas klasifikasi sentimen. Salah satu kekuatan utama Naïve Bayes terletak pada efisiensinya; proses perhitungannya bersifat sederhana dan cepat, sehingga sangat sesuai untuk dataset berukuran besar maupun untuk kebutuhan analisis dengan keterbatasan sumber daya komputasi. Namun demikian, performa Naïve Bayes dapat mengalami penurunan apabila distribusi kata pada data bersifat kompleks atau tidak memenuhi asumsi dasar algoritma, yaitu independensi antar fitur. Dalam konteks data teks nyata, kondisi tersebut sering terjadi karena kata-kata dalam sebuah kalimat umumnya saling berkaitan secara semantik. Temuan ini didukung oleh hasil pada Tabel 2, yang menampilkan confusion matrix dari model Naïve Bayes. Melalui matriks tersebut, terlihat bagaimana model membagi prediksi ke dalam empat kategori: TP, TN, FP, dan FN. Tidak seperti akurasi yang hanya memberikan gambaran umum mengenai tingkat keberhasilan model, confusion matrix menawarkan perspektif evaluasi yang lebih mendetail. Dengan melihat distribusi prediksi benar dan salah pada masing-masing kelas, peneliti dapat memahami pola kesalahan yang muncul secara berulang. Jumlah False Positive (FP) dan False Negative (FN) menjadi indikator penting untuk mengidentifikasi jenis kesalahan yang paling sering dilakukan model. Misalnya, FN yang tinggi menunjukkan bahwa model sering gagal mengenali ulasan positif, sedangkan FP yang tinggi mengindikasikan kecenderungan model untuk salah menandai ulasan negatif sebagai positif. Analisis mendalam terhadap pola kesalahan ini sangat membantu dalam menilai kelemahan spesifik Naïve Bayes, terutama ketika digunakan untuk tugas klasifikasi sentimen yang memiliki dinamika bahasa relatif kompleks. Dengan demikian, evaluasi berdasarkan confusion matrix memberikan wawasan yang lebih kaya dan membantu dalam menentukan apakah Naïve Bayes merupakan metode yang tepat untuk dataset tertentu atau perlu dilakukan pengembangan lebih lanjut, seperti penyesuaian fitur, penambahan teknik pra-pemrosesan, atau penggunaan model alternatif.

Tabel 2. Matrixs Naïve bayes

	Actual-pos	Actual-neg
Pred-pos	4513	328
Pred-neg	117	580

Performa SVM yang mencapai 92,56% menggambarkan bahwa metode ini mampu bersaing secara efektif dalam menjalankan tugas klasifikasi sentimen. Tingginya akurasi tersebut tidak terlepas dari mekanisme kerja SVM yang berfokus pada pencarian hyperplane paling optimal untuk memisahkan dua kelas secara tegas. Dengan margin pemisah yang maksimal, SVM mampu meminimalkan kesalahan klasifikasi pada data baru, sehingga menjadikannya salah satu metode yang konsisten dalam menghadapi berbagai jenis pola data. Selain itu, SVM dikenal sangat mampu bekerja secara optimal pada data yang memiliki jumlah fitur sangat besar, kondisi yang sering ditemui pada pemrosesan teks setelah melalui tahap ekstraksi fitur seperti TF-IDF. Pada representasi fitur semacam ini, jumlah dimensi dapat mencapai ribuan, namun SVM tetap mampu bekerja secara stabil karena sifatnya yang memanfaatkan titik-titik data yang paling berpengaruh dalam proses pemisahan kelas. Keunggulan ini menjadikan SVM sangat relevan dalam konteks analisis sentimen yang mengandalkan representasi tekstual kompleks. Walaupun demikian, salah satu kelemahan yang sering muncul pada penggunaan SVM adalah durasi pelatihan yang cenderung lebih lama, terutama ketika dataset berukuran besar. Hal ini disebabkan oleh proses optimisasi yang dilakukan untuk menemukan hyperplane terbaik, yang bisa menjadi semakin rumit ketika jumlah dimensi dan data meningkat secara signifikan. Dengan demikian, efisiensi waktu menjadi pertimbangan penting ketika SVM diterapkan pada dataset berskala besar. Untuk memperoleh pemahaman yang lebih rinci mengenai kualitas prediksi yang dihasilkan SVM, analisis tambahan dilakukan melalui matriks konfusi yang disajikan dalam Tabel 3. Matriks tersebut memperlihatkan bagaimana model membagi data ke dalam kelas positif maupun negatif, lengkap dengan rincian prediksi yang tepat serta keliru pada tiap kategori. Informasi ini memberikan wawasan yang lebih spesifik tentang jenis kesalahan yang dilakukan SVM, sehingga peneliti dapat mengidentifikasi apakah algoritma tersebut lebih sering gagal mengenali kelas tertentu atau sebaliknya. Dengan demikian, evaluasi berbasis confusion matrix menjadi bagian penting dalam menilai keandalan dan batasan yang dimiliki SVM dalam konteks klasifikasi sentimen.

Tabel 3. Matrixs SVM

	Actual-pos	Actual-neg
Pred-pos	4484	252
Pred-neg	146	656

Algoritma Logistic Regression turut menghasilkan performa yang cukup baik dengan akurasi mencapai 92,81%. Capaian ini menunjukkan bahwa model tersebut masih relevan sebagai salah satu pendekatan yang kompetitif dalam analisis sentimen. Logistic Regression memang dikenal sebagai metode yang efektif dalam memodelkan



hubungan linier antara variabel input dan output, sehingga sering dijadikan baseline pada berbagai penelitian terkait klasifikasi teks. Keandalan model ini terutama terletak pada kesederhanaan struktur matematisnya, yang membuat proses pelatihan berlangsung relatif cepat dan hasilnya mudah dipahami, baik dari sisi kontribusi fitur maupun interpretasi keputusan model. Kelebihan tersebut membuat Logistic Regression sering dipilih untuk menjadi model pembandingan awal sebelum menerapkan algoritma yang lebih kompleks. Namun demikian, model ini memiliki keterbatasan ketika dihadapkan pada data dengan pola non-linier yang lebih rumit. Dalam konteks analisis teks, hubungan antar fitur tidak selalu bersifat linier karena adanya konteks semantik dan hubungan antar kata yang subtil, sehingga Logistic Regression dapat mengalami penurunan performa dalam kondisi tertentu. Ketika pola data menjadi semakin kompleks, algoritma yang mampu menangani pemetaan non-linier seperti SVM atau XGBoost biasanya tampil lebih unggul. Untuk memahami lebih jauh bagaimana Logistic Regression melakukan klasifikasi, Tabel 4 menampilkan confusion matrix yang memuat distribusi prediksi model secara lebih mendetail. Melalui matriks tersebut, dapat diamati data yang berhasil diprediksi dengan benar untuk masing-masing kelas serta kesalahan yang muncul dalam bentuk false positive maupun false negative. Informasi ini memberikan evaluasi yang lebih kaya dibandingkan sekadar melihat nilai akurasi, karena mampu menunjukkan kecenderungan model dalam salah mengklasifikasikan jenis data tertentu. Dengan demikian, confusion matrix menjadi alat penting untuk mengidentifikasi pola kesalahan model dan menilai sejauh mana Logistic Regression mampu menangani karakteristik data sentimen yang dianalisis.

Tabel 4. Matrixs Logistic Regression

	Actual-pos	Actual-neg
Pred-pos	4518	300
Pred-neg	112	608

Sementara itu, algoritma XGBoost memperlihatkan kinerja yang tergolong kuat dengan tingkat akurasi sebesar 92,52%. Angka tersebut menunjukkan bahwa pendekatan berbasis boosting ini mampu memberikan hasil yang konsisten dan kompetitif dalam tugas klasifikasi sentimen. Berbeda dari metode klasifikasi tradisional, XGBoost bekerja dengan membangun serangkaian serangkaian pohon keputusan dibangun secara berurutan, dan tiap pohon yang ditambahkan diarahkan untuk mengoreksi kesalahan prediksi yang terjadi pada tahap sebelumnya. Mekanisme ini memungkinkan XGBoost menghasilkan model akhir yang lebih akurat karena proses pembelajaran berlangsung secara berulang dan terarah. Salah satu kelebihan utama XGBoost adalah kemampuannya dalam menghadapi kompleksitas data, baik dari sisi jumlah fitur, struktur pola, maupun variasi distribusi. Hal ini menjadikan algoritma tersebut sangat sesuai digunakan pada dataset teks yang umumnya memiliki dimensi tinggi dan hubungan antarfitur yang tidak selalu linear. Selain itu, XGBoost dilengkapi dengan teknik regularisasi yang memungkinkan model mengontrol kompleksitasnya secara efektif. Regularisasi ini berfungsi guna menghindari munculnya overfitting, yakni keadaan ketika model menunjukkan kinerja sangat baik pada data pelatihan namun gagal mempertahankan performanya pada data baru. Dengan adanya mekanisme tersebut, XGBoost tidak hanya mengejar akurasi yang tinggi, tetapi juga menjaga agar model tetap stabil serta tetap mampu melakukan generalisasi secara optimal. Kajian yang lebih rinci terkait performa XGBoost dapat diamati melalui confusion matrix yang ditampilkan pada Tabel 5. Melalui matriks tersebut, distribusi prediksi untuk setiap kelas dapat dianalisis secara detail, sehingga peneliti dapat melihat pola keberhasilan maupun kesalahan yang dilakukan model. Informasi ini memungkinkan dilakukannya evaluasi yang lebih mendalam, sistematis, dan terstruktur terhadap kualitas prediksi yang dihasilkan oleh model XGBoost. Melalui analisis tersebut, peneliti dapat memperoleh pemahaman yang lebih komprehensif mengenai bagian-bagian model yang telah menunjukkan kinerja optimal, sekaligus mengidentifikasi aspek-aspek tertentu yang masih memiliki keterbatasan. Dengan demikian, informasi ini berperan penting dalam menentukan area yang memerlukan perhatian dan pengembangan lebih lanjut guna meningkatkan akurasi serta keandalan model dalam konteks klasifikasi sentimen.

Tabel 5. Matrixs XGBoost

	Actual-pos	Actual-neg
Pred-pos	4511	295
Pred-neg	119	613


Terakhir, model gabungan SVM-XGBoost memperlihatkan performa yang paling unggul dibandingkan seluruh algoritma tunggal lainnya, dengan akurasi mencapai 93,05%. Capaian ini menunjukkan bahwa pendekatan hybrid mampu mengatasi keterbatasan masing-masing metode ketika berdiri sendiri. Integrasi kedua algoritma ini memanfaatkan kelebihan SVM dalam menemukan decision boundary atau batas pemisah kelas yang optimal melalui margin yang maksimal, sehingga model dapat dengan jelas membedakan antara sentimen positif dan negatif. Di sisi lain, mekanisme boosting pada XGBoost dimanfaatkan untuk secara bertahap meningkatkan kualitas prediksi dengan memperbaiki kesalahan yang dilakukan pada tahap-tahap sebelumnya. Sinergi antara kedua mekanisme tersebut menghasilkan model yang tidak hanya memberikan akurasi yang tinggi, tetapi juga menunjukkan tingkat stabilitas prediksi yang lebih baik. Hasil yang diperoleh mengindikasikan bahwa pendekatan hybrid ini mampu menyeimbangkan antara ketepatan prediksi, kemampuan generalisasi terhadap data baru, dan ketahanan dalam

menghadapi variasi distribusi data yang beragam. Karakteristik tersebut sangat penting dalam analisis sentimen, mengingat data teks sering kali mengandung pola yang tidak linier dan hubungan antarfitur yang kompleks. Evaluasi rinci terhadap performa model SVM-XGBoost dapat diamati pada Tabel 6, yang menyajikan distribusi prediksi melalui confusion matrix. Melalui tabel tersebut, pola keberhasilan dan kesalahan model dapat dianalisis lebih mendalam, sehingga memberikan gambaran yang lebih jelas mengenai efektivitas pendekatan hybrid ini dalam mengklasifikasikan sentimen secara konsisten. Temuan ini menegaskan bahwa kombinasi SVM-XGBoost merupakan salah satu solusi paling kuat untuk tugas klasifikasi sentimen berbasis ulasan pengguna, khususnya pada dataset yang memiliki variabilitas tinggi.

Tabel 6. Matrixs SVM-XGBoost

	Actual-pos	Actual-neg
Pred-pos	4507	262
Pred-neg	123	646

Hasil klasifikasi yang dihasilkan oleh kelima algoritma tersebut menyajikan pemahaman lebih luas dan terperinci mengenai seberapa efektif setiap metode dalam memproses dan memahami data ulasan pengguna. Masing-masing algoritma memiliki karakteristik performa yang berbeda, sehingga evaluasi tidak dapat dilakukan hanya berdasarkan satu indikator seperti akurasi. Perbedaan perilaku algoritma saat menghadapi data tertentu menjadikan penggunaan beberapa metrik evaluasi sebagai langkah penting agar penilaian yang dilakukan bersifat lebih seimbang dan tidak bias terhadap satu aspek saja. Analisis terhadap ukuran performa tambahan seperti precision, recall, dan F1-score menjadi sangat penting dalam konteks ini. Ketiga metrik tersebut mampu menggambarkan kemampuan model secara lebih mendalam, terutama dalam membedakan prediksi yang tepat untuk kelas positif maupun negatif. Precision mengukur seberapa akurat model dalam menghasilkan prediksi positif yang benar-benar relevan, sehingga metrik ini sangat penting ketika kesalahan prediksi positif memiliki konsekuensi besar. Di sisi lain, recall menunjukkan sejauh mana model dapat menangkap seluruh data yang seharusnya masuk dalam kelas positif, menjadikannya relevan dalam situasi yang membutuhkan deteksi maksimal terhadap suatu kategori. F1-score berperan sebagai metrik harmonisasi yang menggabungkan precision dan recall, memberikan penilaian yang lebih seimbang ketika kedua aspek tersebut sama pentingnya untuk diperhatikan. Dengan mempertimbangkan seluruh metrik ini, pemahaman mengenai kelebihan dan keterbatasan dari setiap algoritma menjadi lebih utuh. Selain itu, evaluasi yang menggunakan berbagai ukuran performa memungkinkan peneliti untuk memilih algoritma yang dianggap paling cocok untuk kebutuhan analisis sentimen, disesuaikan dengan pola data yang digunakan serta sasaran penelitian yang ingin dicapai. Kombinasi antara akurasi, precision, recall, dan F1-score menghasilkan perspektif evaluasi yang lebih objektif serta menyeluruh, sehingga keputusan pemilihan model menjadi lebih tepat. Visualisasi perbandingan metrik dari masing-masing algoritma ditampilkan pada Gambar 4. Grafik yang disajikan berfungsi sebagai media visual yang menggambarkan perbandingan performa antar berbagai metode klasifikasi secara sistematis dan terstruktur. Penyajian data dalam bentuk grafik memungkinkan informasi hasil pengujian ditampilkan secara lebih jelas dan informatif dibandingkan dengan penyajian deskriptif semata. Melalui visualisasi ini, peneliti dapat melakukan interpretasi terhadap hasil evaluasi model dengan tingkat ketelitian yang lebih tinggi, karena setiap perbedaan kinerja antar algoritma dapat diamati secara langsung. Selain itu, grafik tersebut memudahkan peneliti dalam mengidentifikasi pola kinerja yang dihasilkan oleh masing-masing metode klasifikasi, baik dari segi konsistensi maupun variasi nilai performa yang ditunjukkan. Perbedaan tingkat efektivitas antar algoritma dapat dianalisis secara komparatif, sehingga memberikan gambaran yang lebih objektif mengenai metode mana yang menunjukkan performa terbaik pada skenario pengujian tertentu. Visualisasi ini juga membantu dalam mendeteksi adanya anomali atau penurunan kinerja yang mungkin tidak terlihat secara jelas apabila hanya disajikan dalam bentuk tabel atau uraian teks. Lebih lanjut, keberadaan grafik memungkinkan peneliti untuk mengevaluasi keunggulan dan keterbatasan setiap algoritma secara lebih komprehensif. Aspek-aspek performa yang masih memerlukan peningkatan dapat diidentifikasi dengan lebih cepat, sehingga menjadi dasar yang kuat untuk pengembangan metode lanjutan atau optimasi model di masa mendatang. Dengan demikian, grafik ini tidak hanya berperan sebagai alat bantu visual, tetapi juga sebagai komponen penting dalam mendukung proses analisis yang mendalam dan sistematis terhadap kinerja model klasifikasi yang digunakan dalam penelitian.



Gambar 4. Visualisasi algoritma

3.3 Implementasi Sistem Prediksi

Pelaksanaan implementasi sistem dilakukan dengan melakukan proses deployment menggunakan platform Streamlit. Pemilihan Streamlit bukan hanya karena kemampuannya menampilkan antarmuka yang interaktif dan responsif, tetapi juga karena platform ini memungkinkan proses pengembangan aplikasi berbasis web dilakukan dengan lebih sederhana tanpa memerlukan konfigurasi backend yang kompleks. Kelebihan tersebut menjadikan Streamlit sangat sesuai untuk membangun prototipe maupun aplikasi berbasis pembelajaran mesin yang membutuhkan kemudahan integrasi antara model dan antarmuka pengguna. Model klasifikasi yang telah selesai melalui tahap pelatihan kemudian disematkan ke dalam aplikasi Streamlit, sehingga pengguna dapat memberikan input data secara langsung melalui antarmuka yang tersedia. Setiap input yang diberikan akan diproses secara real-time, dan hasil prediksi ditampilkan secara instan tanpa memerlukan proses manual tambahan. Integrasi ini memastikan bahwa pengguna dapat merasakan pengalaman penggunaan sistem secara intuitif dan mudah, bahkan tanpa latar belakang teknis terkait machine learning. Tahap deployment sendiri melibatkan beberapa langkah penting, mulai dari konfigurasi lingkungan kerja yang mencakup instalasi paket dan dependensi yang dibutuhkan, proses pemanggilan model terlatih ke dalam aplikasi, hingga perancangan antarmuka web yang informatif dan mudah digunakan. Seluruh rangkaian tahapan tersebut dirancang untuk memastikan bahwa sistem dapat dijalankan dan diakses dengan baik melalui browser. Visualisasi yang berkaitan dengan implementasi antarmuka aplikasi disajikan pada Gambar 4, yang menampilkan struktur dan tata letak tampilan aplikasi setelah seluruh proses *deployment* berhasil diselesaikan. Gambar tersebut memberikan gambaran mengenai hasil akhir dari pengembangan antarmuka, sekaligus menunjukkan bagaimana komponen-komponen utama aplikasi ditampilkan dan dapat diakses oleh pengguna.

Sentiment Analisis Pengguna Aplikasi Tunaiku



Gambar 5. Implementasi Sistem

4. KESIMPULAN

Penelitian ini melakukan perbandingan terhadap lima algoritma klasifikasi yang digunakan guna mengidentifikasi sentimen yang terkandung dalam ulasan para pengguna aplikasi Tunaiku, yakni Naïve Bayes, Logistic Regression, SVM, XGBoost, dan SVM-XGBoost. Temuan pengujian memperlihatkan bahwa semua algoritma mampu menghasilkan akurasi yang cukup tinggi dengan perbedaan yang tidak terlalu signifikan. Naïve Bayes memperoleh akurasi sebesar 91,96%, Logistic Regression mencapai 92,81%, SVM menghasilkan 92,56%, dan XGBoost mencatat 92,52%. Di antara seluruh metode yang diuji, kombinasi SVM-XGBoost memberikan hasil terbaik dengan akurasi tertinggi sebesar 93,05%. Hal ini membuktikan bahwa metode hybrid lebih unggul dibandingkan algoritma tunggal karena mampu memanfaatkan kelebihan masing-masing model, di mana SVM efektif dalam membedakan kelas dengan data berdimensi tinggi, sedangkan XGBoost memperbaiki kesalahan prediksi melalui mekanisme boosting. Oleh karena itu, SVM-XGBoost direkomendasikan sebagai algoritma yang paling efektif untuk analisis sentimen ulasan pengguna aplikasi Tunaiku. Hasil penelitian ini memiliki implikasi praktis bagi pengembang dan manajemen aplikasi Tunaiku. Penerapan algoritma terbaik, seperti SVM-XGBoost, memungkinkan perusahaan mengidentifikasi pola kepuasan maupun ketidakpuasan pengguna dengan lebih akurat, mendeteksi keluhan dan masalah pelanggan lebih cepat, serta memfasilitasi proses penentuan keputusan yang bertumpu pada data dalam pengembangan fitur maupun strategi pemasaran. Selain itu, penerapan model yang tepat dapat membantu meningkatkan kualitas layanan secara berkelanjutan dan pada akhirnya memperkuat loyalitas pengguna terhadap aplikasi Tunaiku. Untuk penelitian mendatang, disarankan menggunakan kumpulan data yang ukurannya lebih luas serta memiliki variasi yang lebih besar sehingga temuan yang dihasilkan dapat merepresentasikan kondisi secara lebih akurat, serta mempertimbangkan penerapan algoritma berbasis metode berbasis deep learning, misalnya LSTM maupun BERT sebagai pembanding dengan metode klasik. Optimalisasi tahap pra-proses, misalnya melalui teknik word embedding atau feature

engineering lanjutan, juga dapat meningkatkan representasi data dan memperbaiki hasil klasifikasi. Penelitian di masa mendatang juga dapat diperluas ke analisis sentimen multibahasa, sehingga model dapat diuji tingkat generalisasinya pada konteks yang lebih luas. Selain itu, pengembangan metode hybrid lain atau pendekatan ensemble yang berbeda berpotensi mendorong terbentuknya model yang memiliki akurasi lebih baik serta performa yang stabil. Dengan adanya pengembangan ini, penelitian analisis sentimen diharapkan dapat memberikan dampak yang lebih besar, baik dalam akademis maupun implementasi nyata pada sektor layanan keuangan digital seperti aplikasi Tunaiku.

REFERENCES

- [1] A. Daza, N. Saboya, J. I. Necochea-Chamorro, K. Zavaleta Ramos, and Y. D. R. Vásquez Valencia, “Systematic review of machine learning techniques to predict anxiety and stress in college students,” *Inform. Med. Unlocked*, vol. 43, p. 101391, 2023, doi: 10.1016/j.imu.2023.101391.
- [2] M. Mustaqim, A. Gunawan, Y. B. Pratama, and I. Zaliman, “Pengembangan Chatbot Layanan Publik Menggunakan Machine Learning Dan Natural Language Processing,” *J. Inf. Technol. Soc.*, vol. 1, no. 1, pp. 1–4, Jun. 2023, doi: 10.35438/jits.v1i1.16.
- [3] S. Yadav and N. Saleena, “Sentiment Analysis Of Reviews Using an Augmented Dictionary Approach,” in *2020 5th International Conference on Computing, Communication and Security (ICCCS)*, Patna, India: IEEE, Oct. 2020, pp. 1–5. doi: 10.1109/ICCCS49678.2020.9277094.
- [4] M. Melda, S. P. Cipta, N. Nurhaeni, M. Mambang, and M. H. Adini, “Analisis Sentimen pada Aplikasi Pinjaman Online Easycash Menggunakan Algoritma Naïve Bayes di Media Sosial Twitter,” *J. Nas. Komputasi Dan Teknol. Inf. JNKTI*, vol. 7, no. 4, pp. 981–988, Aug. 2024, doi: 10.32672/jnkti.v7i4.7918.
- [5] X. Wu, Y. Linghu, T. Wang, and Y. Fan, “Sentiment Analysis of Weak-RuleText Based on the Combination of Sentiment Lexicon and Neural Network,” in *2021 IEEE 6th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA)*, Chengdu, China: IEEE, Apr. 2021, pp. 205–209. doi: 10.1109/ICCCBDA51879.2021.9442593.
- [6] M. Iqbal, M. Afdal, and R. Novita, “Implementasi Algoritma Support Vector Machine Untuk Analisa Sentimen Data Ulasan Aplikasi Pinjaman Online di Google Play Store,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 4, pp. 1244–1252, Jul. 2024, doi: 10.57152/malcom.v4i4.1435.
- [7] Alfandi Safira and F. N. Hasan, “Analisis Sentimen Masyarakat terhadap Paylater Menggunakan Metode Naive Bayes Classifier,” *ZONasi J. Sist. Inf.*, vol. 5, no. 1, pp. 59–70, Jan. 2023, doi: 10.31849/zn.v5i1.12856.
- [8] B. Satya, M. H. S. J. M. Rahardi, and F. F. Abdulloh, “Sentiment Analysis of Review Sestyc Using Support Vector Machine, Naive Bayes, and Logistic Regression Algorithm,” in *2022 5th International Conference on Information and Communications Technology (ICOIACT)*, Yogyakarta, Indonesia: IEEE, Aug. 2022, pp. 188–193. doi: 10.1109/ICOIACT55506.2022.9972046.
- [9] J. Liu, X. Zhu, and Y. Zhang, “Application of DE-GWO-SVM Algorithm in Business Order Prediction Model,” in *2020 IEEE 11th International Conference on Software Engineering and Service Science (ICSESS)*, Beijing, China: IEEE, Oct. 2020, pp. 432–435. doi: 10.1109/ICSESS49938.2020.9237714.
- [10] M. R. Kurniawanda and F. A. T. Tobing, “Analysis Sentiment Cyberbullying In Instagram Comments with XGBoost Method,” *IJNMT Int. J. New Media Technol.*, vol. 9, no. 1, pp. 28–34, Jul. 2022, doi: 10.31937/ijnmt.v9i1.2670.
- [11] C. Shuran and L. Yian, “Breast cancer diagnosis and prediction model based on improved PSO-SVM based on gray relational analysis,” in *2020 19th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES)*, Xuzhou, China: IEEE, Oct. 2020, pp. 231–234. doi: 10.1109/DCABES50732.2020.00067.
- [12] S. Poria, D. Hazarika, N. Majumder, and R. Mihalcea, “Beneath the Tip of the Iceberg: Current Challenges and New Directions in Sentiment Analysis Research,” *IEEE Trans. Affect. Comput.*, vol. 14, no. 1, pp. 108–132, Jan. 2023, doi: 10.1109/TAFFC.2020.3038167.
- [13] M. Ladjal, M. A. Ouali, and M. D. Lass, “optimization of SVM parameters with hybrid PCA-PSO methods for water quality monitoring,” in *2020 International Conference on Electrical Engineering (ICEE)*, Istanbul, Turkey: IEEE, Sep. 2020, pp. 1–6. doi: 10.1109/ICEE49691.2020.9249881.
- [14] M. Kasri, M. Birjali, M. Nabil, A. Beni-Hssane, A. El-Ansari, and M. El Fissaoui, “Refining Word Embeddings with Sentiment Information for Sentiment Analysis,” *J. ICT Stand.*, Aug. 2022, doi: 10.13052/jicts2245-800X.1031.
- [15] Rizky Rizaldi, M. Ridho, Arraihan Tahta Ainullah, Lusiana Efrizoni, Rahmaddeni Rahmaddeni, and M. Fahrel Dea Putra, “Penerapan Algoritma Support Vector Machine dan XGBoost Dalam Mengklasifikasikan Sentimen Opini Publik Terhadap Aplikasi Uber,” *J. Inform. Dan Tekonologi Komput. JITEK*, vol. 5, no. 1, pp. 01–09, Apr. 2025, doi: 10.55606/jitek.v5i1.5735.
- [16] N. P. Husain and A. F. Syam, “Analisis Sentimen Ulasan Pengguna Tiktok pada Google Play Store Berbasis TF-IDF dan Support Vector Machine,” vol. 5, no. 1, 2024.
- [17] “Implementasi Machine Learning untuk Prediksi Harga Mobil Bekas dengan Algoritma Regresi Linear berbasis Web,” *J. Ilm. Komputasi*, vol. 21, no. 4, Dec. 2022, doi: 10.32409/jikstik.21.4.3327.
- [18] F. T. Saputra, S. H. Wijaya, Y. Nurhadryani, and Defina, “Lexicon Addition Effect on Lexicon-Based of Indonesian Sentiment Analysis on Twitter,” in *2020 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, Jakarta, Indonesia: IEEE, Nov. 2020, pp. 136–141. doi: 10.1109/ICIMCIS51567.2020.9354269.
- [19] H. Hermanto, R. Fahlapi, A. Y. Kuntoro, and T. Asra, “Perbandingan Algoritma Klasifikasi Analisis Sentimen Pengguna Aplikasi Getcontact Dalam Pencegahan Penipuan Online,” *J-INTECH*, vol. 12, no. 1, pp. 158–167, Jul. 2024, doi: 10.32664/j-intech.v12i1.1262.
- [20] R. Hassan and Md. R. Islam, “Impact of Sentiment Analysis in Fake Online Review Detection,” in *2021 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD)*, Dhaka, Bangladesh: IEEE, Feb. 2021, pp. 21–24. doi: 10.1109/ICICT4SD50815.2021.9396899.



- [21] H. T. Phan, V. C. Tran, N. T. Nguyen, and D. Hwang, "Improving the Performance of Sentiment Analysis of Tweets Containing Fuzzy Sentiment Using the Feature Ensemble Model," *IEEE Access*, vol. 8, pp. 14630–14641, 2020, doi: 10.1109/ACCESS.2019.2963702.
- [22] B. Gunawan, H. S. Pratiwi, and E. E. Pratama, "Sistem Analisis Sentimen pada Ulasan Produk Menggunakan Metode Naive Bayes," *J. Edukasi Dan Penelit. Inform. JEPIN*, vol. 4, no. 2, p. 113, Dec. 2018, doi: 10.26418/jp.v4i2.27526.
- [23] M. Choirul Rahmadan, A. Nizar Hidayanto, D. Swadani Ekasari, B. Purwandari, and Theresiawati, "Sentiment Analysis and Topic Modelling Using the LDA Method related to the Flood Disaster in Jakarta on Twitter," in *2020 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, Jakarta, Indonesia: IEEE, Nov. 2020, pp. 126–130. doi: 10.1109/ICIMCIS51567.2020.9354320.
- [24] V. A. Riyanto and D. B. Santoso, "Penerapan Model Support Vector Machine Pada Klasifikasi Sentimen Ulasan Aplikasi Lazada," *J. Ris. Sist. Inf. Dan Tek. Inform. JURASIK*, vol. 9, pp. 178–184, 2024.