



Perbandingan Naïve Bayes dan SVM untuk Analisis Sentimen Ulasan Kompas.id pada Data Tidak Seimbang

Muhammad Ardana, Rini Mayasari, Iqbal Maulana*

Fakultas Ilmu Komputer, Program Studi Informatika, Universitas Singaperbangsa Karawang, Karawang, Indonesia
Email: ¹1910631170103@student.unsika.ac.id, ²rini.mayasari@staff.unsika.ac.id, ^{3,*}iqbal.maulana@staff.unsika.ac.id
Email Penulis Korespondensi: iqbal.maulana@staff.unsika.ac.id

Abstrak—Perkembangan teknologi digital dan meningkatnya penggunaan perangkat mobile mendorong tingginya pemanfaatan aplikasi berita digital, termasuk Kompas.id. Ulasan pengguna pada Google Play Store menjadi sumber data penting untuk memahami tingkat kepuasan dan berbagai permasalahan yang dialami pengguna. Namun, jumlah ulasan yang besar menyulitkan analisis secara manual. Oleh karena itu, penelitian ini bertujuan untuk membandingkan kinerja algoritma Naïve Bayes dan Support Vector Machine (SVM) dalam mengklasifikasikan sentimen ulasan pengguna Kompas.id ke dalam kategori positif, netral, dan negatif. Metode penelitian menggunakan kerangka Knowledge Discovery in Databases (KDD) yang meliputi tahapan web scraping, preprocessing teks, pelabelan sentimen berbasis leksikon, ekstraksi fitur menggunakan Term Frequency–Inverse Document Frequency (TF-IDF), serta proses klasifikasi dan evaluasi. Dataset yang digunakan terdiri dari 1.023 ulasan bersih setelah proses pembersihan data. Evaluasi performa model dilakukan menggunakan confusion matrix dengan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa algoritma Naïve Bayes memperoleh tingkat akurasi sebesar 72%, sedangkan SVM menunjukkan performa yang lebih baik dengan akurasi sebesar 80%, yang mencerminkan kemampuannya yang lebih baik dalam menangani ruang fitur teks yang berdimensi tinggi dan bersifat jarang (sparse). Visualisasi word cloud mengindikasikan bahwa sentimen positif didominasi oleh aspek kualitas konten, sementara sentimen negatif banyak berkaitan dengan sistem berlangganan dan kendala teknis aplikasi. Berdasarkan hasil tersebut, algoritma SVM direkomendasikan sebagai metode yang lebih efektif untuk analisis sentimen ulasan aplikasi berita Kompas.id.

Kata Kunci: Analisis Sentimen; Naïve Bayes; Support Vector Machine; Knowledge Discovery in Databases; Kompas.id

Abstract—The rapid advancement of digital technology and the increasing use of mobile devices have driven the widespread adoption of digital news applications, including Kompas.id. User reviews on the Google Play Store represent an important data source for understanding user satisfaction and emerging issues; however, the large volume of reviews makes manual analysis inefficient. Therefore, this study aims to compare the performance of Naïve Bayes and Support Vector Machine (SVM) algorithms in classifying Kompas.id user reviews into positive, neutral, and negative sentiments. The research employs the Knowledge Discovery in Databases (KDD) framework, which includes web scraping, text preprocessing, lexicon-based sentiment labeling, feature extraction using Term Frequency–Inverse Document Frequency (TF-IDF), and classification and evaluation stages. The dataset consists of 1,023 cleaned reviews after data preprocessing. Model performance is evaluated using a confusion matrix with accuracy, precision, recall, and F1-score metrics. The results indicate that Naïve Bayes achieves an accuracy of 72%, while SVM outperforms it with an accuracy of 80%, reflecting its stronger ability to handle high-dimensional and sparse textual feature spaces. Word cloud visualization reveals that positive sentiments are mainly associated with content quality, whereas negative sentiments are dominated by subscription-related issues and technical problems. Based on these findings, SVM is recommended as a more effective algorithm for sentiment analysis of digital news application reviews.

Keywords: Sentiment Analysis; Naïve Bayes; Support Vector Machine; TF-IDF; Kompas.id

1. PENDAHULUAN

Perkembangan teknologi digital telah mengubah secara signifikan cara masyarakat dalam mengakses, mengonsumsi, dan mendistribusikan informasi. Transformasi ini ditandai dengan meningkatnya dominasi perangkat mobile sebagai medium utama dalam aktivitas digital sehari-hari. Laporan Digital 2025 Global Overview Report menunjukkan bahwa Indonesia berada pada jajaran tiga besar negara dengan tingkat penggunaan internet melalui perangkat mobile tertinggi di dunia, dengan rata-rata durasi penggunaan lebih dari empat jam per hari [1]. Kondisi tersebut mencerminkan pergeseran perilaku konsumsi informasi dari media konvensional menuju platform digital berbasis aplikasi.

Perubahan pola konsumsi informasi ini turut mendorong berkembangnya aplikasi berita digital sebagai kanal utama distribusi informasi. Salah satu aplikasi berita digital yang memiliki posisi strategis di Indonesia adalah Kompas.id. Berbeda dengan portal berita daring gratis, Kompas.id mengusung model bisnis berbasis langganan (subscription-based) yang menitikberatkan pada kualitas konten, kedalaman analisis, serta independensi jurnalistik. Model ini menempatkan pengalaman pengguna (user experience) dan kepuasan pelanggan sebagai faktor kunci keberlanjutan layanan.

Seiring dengan meningkatnya jumlah pengguna aplikasi Kompas.id, interaksi pengguna juga semakin intens, salah satunya melalui fitur ulasan (review) pada platform Google Play Store. Ulasan pengguna memuat beragam opini, mulai dari apresiasi terhadap kualitas konten hingga kritik terkait performa aplikasi, antarmuka pengguna, serta sistem berlangganan. Informasi yang terkandung dalam ulasan tersebut memiliki nilai strategis karena mencerminkan persepsi, ekspektasi, dan tingkat kepuasan pengguna secara langsung.

Namun demikian, volume ulasan yang besar menimbulkan tantangan tersendiri bagi pengelola aplikasi. Proses evaluasi ulasan secara manual menjadi tidak efisien dan berpotensi bias, terutama ketika jumlah ulasan terus bertambah dari waktu ke waktu. Ulasan negatif yang tidak dianalisis secara sistematis dapat berdampak pada penurunan citra aplikasi dan kepercayaan pengguna. Medhat et al. [2] menegaskan bahwa opini negatif yang tersebar luas di platform digital dapat memengaruhi persepsi konsumen serta keputusan penggunaan suatu produk atau layanan.



Untuk mengatasi permasalahan tersebut, diperlukan pendekatan analitis berbasis data yang mampu mengolah opini pengguna dalam skala besar secara otomatis. Salah satu pendekatan yang banyak digunakan adalah analisis sentimen, yaitu proses pengelompokan opini atau pendapat dalam bentuk teks ke dalam kategori sentimen positif, negatif, atau netral [3]. Analisis sentimen memungkinkan organisasi memahami kecenderungan emosi dan sikap pengguna terhadap suatu produk secara lebih objektif dan terukur.

Dalam implementasinya, analisis sentimen umumnya merupakan bagian dari text mining yang melibatkan beberapa tahapan penting, antara lain pengumpulan data, pra-pemrosesan teks, ekstraksi fitur, proses klasifikasi, dan evaluasi hasil [4]. Analisis sentimen telah banyak diterapkan dalam berbagai konteks data teks, termasuk opini daring dan ulasan pengguna, dengan pendekatan machine learning yang beragam [5]. Keberhasilan analisis sentimen sangat dipengaruhi oleh pemilihan algoritma klasifikasi yang tepat, khususnya ketika berhadapan dengan data teks berdimensi tinggi seperti ulasan pengguna aplikasi.

Berbagai algoritma machine learning telah digunakan dalam penelitian analisis sentimen, di antaranya Naïve Bayes dan Support Vector Machine (SVM). Naïve Bayes merupakan algoritma klasifikasi probabilistik yang sederhana dan efisien, serta banyak digunakan pada data teks berukuran besar karena membutuhkan sumber daya komputasi yang relatif rendah [6]. Meskipun mengasumsikan independensi antar fitur, Naïve Bayes tetap mampu memberikan performa yang kompetitif pada berbagai kasus analisis sentimen.

Di sisi lain, Support Vector Machine (SVM) dikenal memiliki kemampuan generalisasi yang baik dan efektif dalam menangani data berdimensi tinggi. SVM bekerja dengan membangun hyperplane optimal yang memisahkan kelas-kelas data dengan margin maksimum, sehingga sering menghasilkan akurasi yang lebih tinggi dibandingkan algoritma probabilistik sederhana [7]. Selain itu, SVM sangat efektif untuk data teks karena karakteristik data teks yang umumnya bersifat jarang (sparse) dan memiliki dimensi fitur yang tinggi. Karakteristik ini menjadikan SVM sebagai salah satu algoritma unggulan dalam klasifikasi teks berbasis representasi TF-IDF.


Penelitian analisis sentimen terus berkembang dan banyak diterapkan pada ulasan aplikasi serta opini pengguna di berbagai platform digital [8]. Sejumlah penelitian terdahulu telah membandingkan performa kedua algoritma tersebut dalam konteks analisis sentiment. Syahputra et al. [9] menunjukkan bahwa algoritma Support Vector Machine memiliki performa yang lebih stabil dibandingkan Naïve Bayes dalam klasifikasi sentimen pada data Twitter. Penelitian lain yang membandingkan performa Naïve Bayes dan SVM pada data ulasan aplikasi adalah studi oleh Apriyani et al., yang menemukan bahwa SVM umumnya menunjukkan akurasi dan presisi yang lebih tinggi dibandingkan Naïve Bayes dalam klasifikasi sentimen ulasan aplikasi Mobile JKN [10]. Hasil serupa juga dilaporkan oleh Wiguna et al. [11] pada analisis sentimen ulasan aplikasi transportasi daring, di mana SVM menunjukkan performa klasifikasi yang lebih baik. Penelitian oleh Iskandar dan Nataliani [12] pada data analisis sentimen berbasis aspek juga menunjukkan bahwa SVM unggul dibandingkan Naïve Bayes dan k-NN. Selain itu, Mola et al. [13] yang meneliti ulasan aplikasi perbankan digital menemukan bahwa SVM memiliki kinerja yang kompetitif dan konsisten dibandingkan metode lain, termasuk Naïve Bayes. Penelitian oleh Fikri et al. [14] menegaskan bahwa perbedaan performa antara Naïve Bayes dan Support Vector Machine sangat dipengaruhi oleh karakteristik data serta konteks domain analisis sentimen yang digunakan.

Berdasarkan hasil-hasil tersebut, dapat disimpulkan bahwa tidak terdapat satu algoritma yang selalu unggul pada semua kondisi, karena performa metode klasifikasi sentimen sangat dipengaruhi oleh karakteristik data dan domain aplikasi yang digunakan. Meskipun penelitian terkait analisis sentimen telah banyak dilakukan, sebagian besar studi masih berfokus pada media sosial, aplikasi layanan publik, e-commerce, atau layanan transportasi daring. Penelitian yang secara khusus mengkaji ulasan aplikasi berita digital berbasis langganan seperti Kompas.id masih relatif terbatas. Padahal, ulasan aplikasi berita memiliki karakteristik yang berbeda karena sentimen pengguna tidak hanya dipengaruhi oleh aspek teknis aplikasi, tetapi juga kualitas konten jurnalistik serta kebijakan akses berbayar.

Berdasarkan celah penelitian tersebut, penelitian ini bertujuan untuk membandingkan kinerja algoritma Naïve Bayes dan Support Vector Machine dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Kompas.id. Penelitian ini diharapkan dapat memberikan kontribusi ilmiah dalam bentuk evaluasi komparatif algoritma klasifikasi sentimen pada domain media berita digital, serta memberikan rekomendasi praktis bagi pengembang aplikasi dalam meningkatkan kualitas layanan berbasis opini pengguna.

2. METODOLOGI PENELITIAN

Penelitian ini dirancang untuk menganalisis dan membandingkan performa algoritma Naïve Bayes dan Support Vector Machine (SVM) dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Kompas.id. Metodologi yang digunakan mengacu pada kerangka Knowledge Discovery in Databases (KDD), yang merupakan pendekatan sistematis untuk mengekstraksi pengetahuan bernilai dari kumpulan data berukuran besar. Kerangka KDD dipilih karena mampu mengakomodasi seluruh tahapan pengolahan data teks secara terstruktur, mulai dari pengumpulan data mentah hingga evaluasi hasil klasifikasi. Pendekatan ini juga memastikan bahwa setiap tahapan analisis dilakukan secara konsisten dan dapat direproduksi, sehingga meningkatkan validitas dan keterlacakan proses penelitian. Dengan demikian, penggunaan kerangka KDD memberikan fondasi metodologis yang jelas dalam memastikan kualitas data, ketepatan model, serta interpretabilitas hasil yang diperoleh. Selain itu, kerangka ini memudahkan integrasi antara proses pengolahan data, pemodelan, dan evaluasi dalam satu alur kerja yang sistematis dan terkontrol. Alur penelitian yang dilakukan bisa dilihat pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Tahapan Penelitian

Kerangka KDD yang digunakan dalam penelitian ini terdiri dari lima tahapan utama, yaitu data selection, preprocessing, transformation, data mining, dan evaluation. Setiap tahapan memiliki peran penting dalam memastikan bahwa data yang diolah memiliki kualitas yang baik serta model klasifikasi yang dibangun mampu menghasilkan prediksi yang akurat dan reliabel.

Tahap data selection bertujuan untuk mengumpulkan data yang relevan dengan tujuan penelitian. Tahap preprocessing berfungsi untuk membersihkan dan menormalkan data teks agar siap dianalisis. Selanjutnya, tahap transformation dilakukan untuk mengubah data teks ke dalam bentuk numerik yang dapat diproses oleh algoritma machine learning. Tahap data mining mencakup proses pelatihan dan pengujian model klasifikasi menggunakan algoritma yang dipilih. Tahap terakhir, evaluation, dilakukan untuk menilai kinerja model berdasarkan metrik evaluasi tertentu.

2.2 Data Selection

Data yang digunakan dalam penelitian ini berupa ulasan pengguna aplikasi Kompas.id yang diperoleh dari platform Google Play Store. Pengambilan data dilakukan menggunakan teknik web scraping dengan bahasa pemrograman Python. Teknik ini dipilih karena mampu mengumpulkan data secara otomatis dan efisien dalam jumlah besar. Data ulasan yang dikumpulkan mencakup teks ulasan, tanggal ulasan, dan identitas pengguna.

Rentang waktu pengambilan data ditetapkan dari September 2020 hingga September 2025 dengan tujuan memperoleh representasi opini pengguna dalam jangka waktu yang cukup panjang. Dari proses pengumpulan data, diperoleh sebanyak 1.303 ulasan mentah. Namun, tidak seluruh data tersebut dapat langsung digunakan karena adanya duplikasi dan entri kosong. Oleh karena itu, dilakukan proses seleksi awal untuk memastikan bahwa hanya data yang relevan dan valid yang diproses pada tahap selanjutnya.

2.3 Preprocessing

Tahap preprocessing merupakan tahap krusial dalam analisis sentimen karena kualitas data teks sangat memengaruhi performa model klasifikasi [15], [16]. Preprocessing dilakukan untuk menghilangkan noise, menyamakan format teks, serta mengurangi kompleksitas data. Dalam penelitian ini, preprocessing meliputi beberapa langkah utama, yaitu cleaning, casefolding, tokenizing, stopword removal, dan stemming.

Proses cleaning dilakukan untuk menghapus elemen-elemen yang tidak memiliki makna analitis, seperti URL, angka, simbol, tanda baca, dan karakter non-ASCII. Selain itu, data duplikat dan entri kosong juga dihapus untuk mencegah bias dalam distribusi data. Tahap ini bertujuan memastikan bahwa teks yang dianalisis hanya mengandung informasi yang relevan dengan sentimen pengguna.

Tahap casefolding dilakukan dengan mengubah seluruh huruf dalam teks menjadi huruf kecil (lowercase). Langkah ini penting untuk menyeragamkan representasi kata, sehingga perbedaan penulisan huruf besar dan kecil tidak dianggap sebagai fitur yang berbeda oleh model.

Selanjutnya, tokenizing dilakukan untuk memecah teks menjadi unit-unit kata atau token. Proses ini memungkinkan setiap kata dianalisis secara individual pada tahap ekstraksi fitur. Setelah tokenisasi, dilakukan stopword removal untuk menghapus kata-kata umum dalam bahasa Indonesia yang memiliki frekuensi tinggi tetapi kontribusi maknanya rendah, seperti kata sambung dan kata bantu. Pada penelitian ini, daftar stopwords Bahasa Indonesia diperoleh dari pustaka NLTK dan diperluas dengan beberapa kata tambahan yang sering muncul dalam ulasan.

Tahap terakhir preprocessing adalah stemming, yaitu proses mengembalikan kata berimbuhan ke bentuk dasarnya. Proses stemming dilakukan menggunakan pustaka Sastrawi. Tujuan stemming adalah untuk menyatukan berbagai variasi kata ke dalam satu representasi dasar sehingga dapat mengurangi redundansi fitur dan meningkatkan generalisasi model. Meskipun Sastrawi cukup efektif untuk dataset berukuran sedang seperti dalam penelitian ini, pustaka ini dikenal memiliki keterbatasan performa pada skala data yang sangat besar; oleh karena itu, untuk penelitian berskala lebih besar di masa mendatang dapat dipertimbangkan penggunaan pendekatan dictionary-based atau versi pustaka stemming yang lebih dioptimalkan seperti PySastrawi.

2.4 Transformation

Setelah melalui tahap preprocessing, data teks kemudian ditransformasikan ke dalam bentuk yang dapat diproses oleh algoritma machine learning. Tahap transformation pada penelitian ini meliputi proses pelabelan sentimen dan ekstraksi fitur.



Pelabelan sentimen dilakukan menggunakan pendekatan lexicon-based, yaitu dengan mencocokkan kata-kata dalam ulasan terhadap kamus kata positif dan negatif Bahasa Indonesia. Pendekatan ini dipilih karena efisien untuk pelabelan otomatis pada data berukuran besar serta sesuai dengan karakteristik penelitian yang bersifat komparatif. Ulasan dengan dominasi kata positif diberi label positif, ulasan dengan dominasi kata negatif diberi label negatif, sedangkan ulasan yang tidak menunjukkan kecenderungan dominan diberi label netral. Pendekatan ini efisien untuk data berukuran besar, namun memiliki keterbatasan dalam menangkap sarkasme, konteks implisit, dan istilah teknis, sehingga validasi manual atau keterlibatan pakar menjadi penting untuk meningkatkan keandalan pelabelan pada penelitian selanjutnya.

Setelah pelabelan, data teks diubah menjadi representasi numerik menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF). Metode TF-IDF digunakan untuk merepresentasikan bobot kata dalam dokumen berdasarkan tingkat kepentingannya pada keseluruhan korpus [17]. Dalam penelitian ini, jumlah fitur dibatasi hingga 5.000 kata untuk menghindari dimensi fitur yang terlalu besar dan mengurangi risiko overfitting. Representasi fitur yang digunakan terbatas pada unigram, sehingga meskipun jumlah fitur relatif besar dibandingkan ukuran dataset, pendekatan ini dipilih untuk menjaga kelengkapan informasi leksikal tanpa menambahkan kompleksitas struktur n-gram yang lebih tinggi.

2.5 Data Mining

Tahap data mining merupakan inti dari penelitian ini, yaitu proses pembangunan model klasifikasi sentimen. Dua algoritma yang digunakan adalah Naïve Bayes dan Support Vector Machine (SVM). Algoritma Naïve Bayes merupakan metode probabilistik yang efektif dan efisien dalam klasifikasi teks, khususnya pada data berukuran besar [18], sedangkan Support Vector Machine banyak digunakan dalam klasifikasi teks karena kemampuannya dalam menangani data berdimensi tinggi [19].

Sebelum proses pelatihan model, dilakukan pembagian data menjadi data latih dan data uji dengan rasio 80:20. Pembagian ini bertujuan untuk menguji kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Mengingat adanya ketidakseimbangan distribusi kelas pada data latih, diterapkan teknik Random Oversampling untuk menyeimbangkan jumlah sampel pada setiap kelas sentimen.

Model Naïve Bayes dan SVM kemudian dilatih menggunakan data latih hasil oversampling. Setelah proses pelatihan, masing-masing model digunakan untuk memprediksi kelas sentimen pada data uji. Hasil prediksi ini menjadi dasar untuk melakukan evaluasi performa model.

2.6 Evaluation

Tahap evaluation dilakukan untuk menilai kinerja model klasifikasi yang telah dibangun menggunakan confusion matrix dan metrik evaluasi standar. Evaluasi dilakukan menggunakan confusion matrix yang menghasilkan metrik akurasi, presisi, recall, dan F1-score. Penggunaan beberapa metrik evaluasi bertujuan untuk memberikan gambaran performa model secara komprehensif, terutama dalam konteks klasifikasi multikelas.

Melalui tahapan evaluasi ini, dapat diketahui algoritma mana yang memiliki performa lebih baik dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Kompas.id. Hasil evaluasi tersebut selanjutnya dianalisis dan dibahas pada bagian hasil dan pembahasan.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil implementasi metode serta pembahasan mendalam terhadap performa algoritma Naïve Bayes dan Support Vector Machine (SVM) dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Kompas.id.

3.1 Hasil Penelitian

Pembahasan dilakukan secara sistematis mengikuti tahapan dalam kerangka Knowledge Discovery in Databases (KDD), mulai dari hasil seleksi data hingga evaluasi model klasifikasi. Pendekatan ini bertujuan untuk memberikan pemahaman yang komprehensif mengenai pengaruh setiap tahapan terhadap kinerja akhir model.

3.1.1 Hasil Data Selection

Tahap data selection dilakukan untuk memperoleh dataset ulasan pengguna aplikasi Kompas.id dari Google Play Store. Pengumpulan data menggunakan teknik web scraping dengan bahasa pemrograman Python menghasilkan total 1.303 ulasan mentah dalam rentang waktu September 2020 hingga September 2025. Ulasan tersebut mencerminkan berbagai bentuk opini pengguna terhadap aplikasi, baik yang bersifat positif, netral, maupun negatif. Contoh hasil pengumpulan data ulasan pengguna ditampilkan pada Tabel 1.

Tabel 1. Hasil Data Scraping

Reviewid	Username	Userimage	Content	Score	At
60d72bbb-bcda-44e5-aaee-b48d99afe04b	Nur Widi	https://play-lh.googleusercontent.com/a/ACg8ocJYD9z\ _MsNFB0u7Vh6Fzu\ _uz5Jw	Kompas is the best	5	2025-09-27 01:23:47



Reviewid	Username	Userimage	Content	Score	At
a62a4b88-94e2-47ad-851b-489d0b767897	Ikhwan Hrrn02	JEdj4W7dv2mews8M9a HqhQ=mo https://play-lh.googleusercontent.com/a-/ALV-UjVV6VNXmxEbzq-4TGO9qpiyaYgGdqYBe2ZgNL93kB5-9TPj3bM	Lets me laugh	4	2025-09-23 03:54:17
cf96d18b-cea9-48a3-804b-888ef67bab81	Emil Putri Nur Dewanti	https://play-lh.googleusercontent.com/a-/ALV-UjXSze5WALyg3PBanKXCqNs8zcw6KIMi b9LJC7au4HPGdjLV4eeQ	Beritanya lengkap sih. tpi gimana sih caranya liat berita-berita di bulan sebelumnya? atau 2-3 bulan yang lalu?? masa harus ngescroll?? capek bgt dong. Padahal udh bayar	4	2025-09-19 02:02:41
0e2d5b19-e6c8-423d-a737-96873ea49eae	Didin Samsudin	https://play-lh.googleusercontent.com/a-/ALV-UjVnacDXoPluBZE_JRL3Rl61GSRs6h-_70GAoePrPEoXT9x-9Ob_ZA	Nyari berita bola terbaru yg muncul berita tahun 2023 ga update	1	2025-09-16 00:30:33
c17a434a-077c-4b93-8332-c8a7cc35902b	Purwanto Sumarto	https://play-lh.googleusercontent.com/a-/ALV-UjV7BUWqeeaq_CVlcrHm83V-YIUbQbzILXp0KWuOTrwh9q3TR05m	Berbayar untuk baca berita	4	2025-09-11 06:46:58

Dari keseluruhan data yang dikumpulkan, hanya atribut teks ulasan (kolom content) yang digunakan dalam penelitian ini karena mengandung informasi utama terkait sentimen pengguna. Atribut lain seperti nama pengguna dan tanggal ulasan tidak dilibatkan dalam proses klasifikasi sentimen. Proses seleksi ini bertujuan untuk memfokuskan analisis pada konten opini yang relevan dengan tujuan penelitian. Pendekatan ini juga membantu mengurangi kompleksitas data serta meminimalkan potensi gangguan dari atribut non-teks yang tidak berkontribusi langsung terhadap proses analisis sentimen.

3.1.2 Hasil Preprocessing

Data mentah yang diperoleh dari Google Play Store mengandung berbagai elemen yang berpotensi menurunkan kualitas analisis, seperti karakter non-alfanumerik, simbol, duplikasi data, serta variasi penulisan kata. Oleh karena itu, tahap preprocessing menjadi langkah krusial dalam memastikan kualitas data sebelum diproses lebih lanjut.

a. Cleaning

Proses cleaning menghapus URL, angka, simbol, tanda baca, serta karakter non-ASCII yang tidak relevan. Selain itu, data duplikat dan entri kosong dihapus untuk menghindari bias distribusi kelas. Setelah tahap ini, jumlah data berkurang dari 1.303 menjadi 1.023 ulasan bersih. Pengurangan ini menunjukkan bahwa sebagian data awal tidak layak digunakan karena mengandung duplikasi atau informasi yang tidak lengkap. Contoh hasil proses cleaning ditampilkan pada Tabel 2.

Tabel 2. Hasil Cleaning

Text	Cleaned
kompas is the best lets me laugh	kompas is the best lets me laugh
beritanya lengkap sih. tpi gimana sih caranya liat berita-berita di bulan sebelumnya? atau 2-3 bulan yang lalu?? masa harus ngescroll?? capek bgt dong. padahal udh bayar	beritanya lengkap sih tpi gimana sih caranya liat beritaberita di bulan sebelumnya atau bulan yang lalu masa harus ngescroll capek bgt dong padahal udh bayar
nyari berita bola terbaru yg muncul berita tahun 2023 ga update	nyari berita bola terbaru yg muncul berita tahun ga update
berbayar untuk baca berita	berbayar untuk baca berita



b. Casefolding

Tahap casefolding dilakukan dengan mengonversi seluruh teks menjadi huruf kecil untuk menyeragamkan representasi kata. Selanjutnya, proses tokenizing memecah teks ulasan menjadi unit kata sehingga setiap kata dapat dianalisis sebagai fitur individual. Pada tahap stopword removal, kata-kata umum yang tidak memiliki kontribusi makna signifikan terhadap sentimen, seperti kata sambung, dihapus dari dataset. Proses ini menyebabkan jumlah data berkurang menjadi 1.011 ulasan karena beberapa ulasan hanya terdiri dari stopword sehingga tidak lagi memiliki token bermakna. Contoh hasil proses casefolding ditampilkan pada Tabel 3.

Tabel 3. Contoh Hasil Casefolding

Cleaned	Casefolded
Mantap dan keren Mantap	Mantap dan keren Mantap
Saya sebenarnya suka sama aplikasi ini jadi bisa membaca artikel baru dengan mudah tapi saya tidak bisa membaca artikel lain lagi karna SAYA SUDAH MEMBACA ARTIKEL DI BULAN INI dan saya disuruh berlangganan yang awalnya rb tapi jadi rb setelah pembayaran pertama aku akui aplikasi ini emang bagus banget jadi aku bakal coba aplikasi ini lagi di lain waktu karna sekarang aku gapunya uang nya p	Saya sebenarnya suka sama aplikasi ini jadi bisa membaca artikel baru dengan mudah tapi saya tidak bisa membaca artikel lain lagi karna saya sudah membaca artikel di bulan ini dan saya disuruh berlangganan yang awalnya rb tapi jadi rb setelah pembayaran pertama aku akui aplikasi ini emang bagus banget jadi aku bakal coba aplikasi ini lagi di lain waktu karna sekarang aku gapunya uang nya p
Bagus	Bagus
Mantap banget ya berita Kompas lagi	Mantap banget ya berita Kompas lagi

c. Tokenizing

Tokenize bertujuan memecah kalimat menjadi unit kata. Proses ini dilakukan menggunakan pemisahan kata berdasarkan spasi. Tokenize penting agar setiap kata dapat diolah sebagai fitur individual dalam tahap selanjutnya. Contoh hasil tokenize bisa dilihat pada Tabel 4.

Tabel 4. Contoh Hasil Tokenizing

Casefolded	Tokenized
Kompas is the best lets me laugh	[kompas] [is] [the] [best] [lets] [me] [laugh]
beritanya lengkap sih tpi gimana sih caranya liat beritaberita di bulan sebelumnya atau bulan yang lalu masa harus ngescroll capek bgt dong padahal udh bayar	[beritanya] [lengkap] [sih] [tpi] [gimana] [sih] [caranya] [liat] [beritaberita] [di] [bulan] [sebelumnya] [atau] [bulan] [yang] [lalu] [masa] [harus] [ngescroll] [capek] [bgt] [dong] [padahal] [udh] [bayar]
nyari berita bola terbaru yg muncul berita tahun ga update	[nyari] [berita] [bola] [terbaru] [yg] [muncul] [berita] [tahun] [ga] [update]
berbayar untuk baca berita	[berbayar] [untuk] [baca] [berita]

d. Stopword Removal

Stopword removal dilakukan menggunakan daftar stopwords Bahasa Indonesia yang kemudian diperluas dengan beberapa kata tambahan seperti “ya”, “sih”, dan “yg”. Kata-kata yang dianggap tidak memberikan informasi penting bagi analisis sentimen dihapus dari setiap ulasan. Pada proses ini terjadi penurunan jumlah data dari 1023 menjadi 1011 ulasan, karena beberapa ulasan seluruh kata di dalamnya teridentifikasi sebagai stopwords sehingga menghasilkan token kosong. Baris dengan hasil kosong tersebut dihapus agar tidak mengganggu tahap stemming dan pemodelan. Contoh Hasil stopwords removal dapat dilihat pada Tabel 5.

Tabel 5. Contoh Hasil Stopword Removal

Tokenized	Stop Removed
[kompas] [is] [the] [best] [lets] [me] [laugh]	[kompas] [is] [the] [best] [lets] [me] [laugh]
[beritanya] [lengkap] [sih] [tpi] [gimana] [sih] [caranya] [liat] [beritaberita] [di] [bulan] [sebelumnya] [atau] [bulan] [yang] [lalu] [masa] [harus] [ngescroll] [capek] [bgt] [dong] [padahal] [udh] [bayar]	[beritanya] [lengkap] [tpi] [gimana] [liat] [beritaberita] [ngescroll] [capek] [bgt] [udh] [bayar]
[nyari] [berita] [bola] [terbaru] [yg] [muncul] [berita] [tahun] [ga] [update]	[nyari] [berita] [bola] [terbaru] [muncul] [berita] [ga] [update]
[berbayar] [untuk] [baca] [berita]	[berbayar] [baca] [berita]



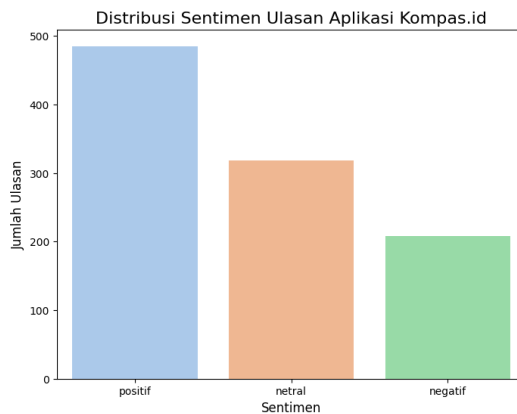
e. Stemming

Tahap stemming dilakukan menggunakan pustaka Sastrawi untuk mengembalikan kata ke bentuk dasarnya. Proses ini bertujuan untuk mengurangi variasi kata akibat imbuhan sehingga model dapat mengenali kata dengan makna yang sama sebagai satu fitur. Secara keseluruhan, preprocessing berhasil meningkatkan kualitas data dengan mengurangi noise dan redundansi, sehingga data lebih siap untuk tahap transformasi dan klasifikasi. Contoh hasil proses stemming ditampilkan pada Tabel 6.

Tabel 6. Contoh Hasil Stemming

Stop Removed	Stemmed
[kompas] [is] [the] [best]	[kompas] [is] [the] [best]
[lets] [me] [laugh]	[lets] [me] [laugh]
[beritanya] [lengkap] [tpi] [gimana] [liat] [beritaberita]	[berita] [lengkap] [tpi] [gimana] [liat] [beritaberita]
[ngescroll] [capek] [bgt] [udh] [bayar]	[ngescroll] [capek] [bgt] [udh] [bayar]
[nyari] [berita] [bola] [terbaru] [muncul] [berita] [ga]	[nyari] [berita] [bola] [baru] [muncul] [berita] [ga]
[update]	[update]
[berbayar] [baca] [berita]	[bayar] [baca] [berita]

Setelah melalui tahap preprocessing, dilakukan analisis terhadap distribusi kelas sentimen untuk mengetahui proporsi data pada masing-masing kategori sentimen. Analisis ini bertujuan untuk mengidentifikasi apakah terdapat ketidakseimbangan jumlah data antar kelas sentimen yang berpotensi memengaruhi proses pelatihan dan evaluasi model klasifikasi. Informasi mengenai distribusi kelas menjadi penting karena ketidakseimbangan data dapat menyebabkan model cenderung bias terhadap kelas dengan jumlah data yang lebih dominan. Oleh karena itu, pemahaman terhadap distribusi kelas digunakan sebagai dasar dalam menentukan strategi penanganan data, seperti penerapan teknik oversampling pada kelas minoritas. Dengan demikian, analisis distribusi kelas tidak hanya berfungsi sebagai deskripsi awal data, tetapi juga sebagai landasan dalam pengambilan keputusan pada tahap pemodelan selanjutnya.



Gambar 2. Distribusi Sentimen

Gambar 2 menunjukkan bahwa distribusi kelas sentimen belum seimbang, di mana kelas sentimen positif memiliki jumlah data yang lebih dominan dibandingkan kelas lainnya. Kondisi ini berpotensi memengaruhi kinerja model klasifikasi sehingga diperlukan penanganan lebih lanjut pada tahap selanjutnya.

3.1.3 Hasil Transformation

Tahap transformasi meliputi proses pelabelan sentimen dan ekstraksi fitur. Pelabelan sentimen dilakukan secara otomatis menggunakan pendekatan lexicon-based dengan kamus kata positif dan negatif Bahasa Indonesia. Setiap ulasan diberi label positif, negatif, atau netral berdasarkan dominasi skor sentimen kata-kata yang terkandung di dalamnya.

Pendekatan lexicon-based dipilih karena efisien dan mampu memberikan label awal secara konsisten pada dataset berukuran besar, meskipun memiliki keterbatasan dalam memahami konteks semantik yang kompleks [20]. Meskipun pendekatan ini memiliki keterbatasan dalam menangkap konteks kalimat yang kompleks, metode ini dinilai cukup representatif untuk tujuan komparasi performa algoritma klasifikasi.

Setelah pelabelan, data teks diubah menjadi representasi numerik menggunakan metode Term Frequency–Inverse Document Frequency (TF-IDF). TF-IDF memberikan bobot lebih tinggi pada kata-kata yang sering muncul dalam satu dokumen tetapi jarang muncul dalam keseluruhan korpus. Dalam penelitian ini, jumlah fitur dibatasi hingga 5.000 kata paling informatif untuk menjaga keseimbangan antara kelengkapan informasi dan efisiensi komputasi.

Pembagian data dilakukan dengan rasio 80% data latih dan 20% data uji. Dari total 1.011 data valid, sebanyak 808 data digunakan sebagai data latih dan 203 data sebagai data uji. Analisis distribusi kelas menunjukkan adanya ketidakseimbangan jumlah data pada masing-masing kelas sentimen, di mana kelas positif lebih dominan dibandingkan kelas negatif.



Untuk mengatasi permasalahan tersebut, diterapkan teknik Random Oversampling pada data latih. Teknik ini menyeimbangkan jumlah sampel pada setiap kelas dengan cara menggandakan data pada kelas minoritas. Hasil oversampling menunjukkan bahwa setiap kelas sentimen pada data latih memiliki jumlah yang sama, sehingga potensi bias model terhadap kelas mayoritas dapat diminimalkan.

3.1.4 Hasil Data Minig

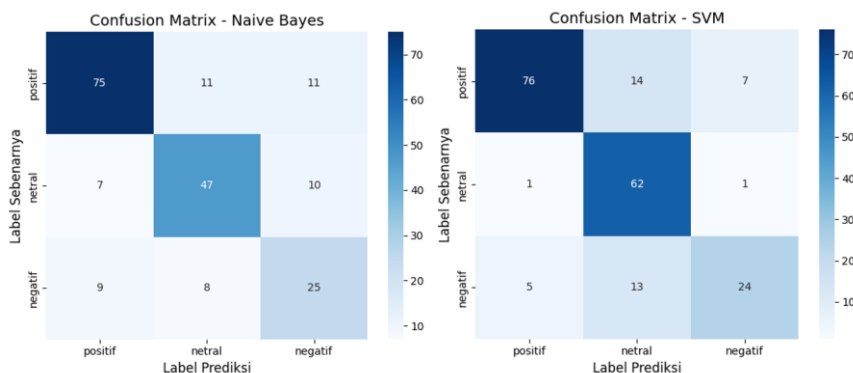
Tahap data mining melibatkan proses pelatihan dan pengujian model klasifikasi sentimen menggunakan algoritma Naïve Bayes dan Support Vector Machine (SVM). Kedua algoritma dilatih menggunakan data latih hasil oversampling yang telah direpresentasikan dalam bentuk matriks TF-IDF.

Model Naïve Bayes diimplementasikan menggunakan pendekatan Multinomial Naïve Bayes. Algoritma ini mempelajari distribusi probabilitas kemunculan kata pada masing-masing kelas sentimen. Keunggulan utama Naïve Bayes terletak pada kesederhanaan dan efisiensi komputasi, sehingga cocok digunakan pada data teks berukuran besar.

Sementara itu, model Support Vector Machine menggunakan kernel linear untuk menemukan hyperplane optimal yang memisahkan kelas-kelas sentimen pada ruang fitur berdimensi tinggi. Pemilihan kernel linear didasarkan pada karakteristik data teks TF-IDF yang umumnya bersifat sparse dan memiliki dimensi tinggi.

3.1.5 Hasil Evaluation

Evaluasi performa kedua model dilakukan menggunakan confusion matrix yang menghasilkan metrik akurasi, presisi, recall, dan F1-score. Metrik-metrik ini digunakan untuk menilai tidak hanya ketepatan prediksi secara keseluruhan, tetapi juga kemampuan model dalam mengenali masing-masing kelas sentimen, khususnya pada kelas dengan jumlah data yang tidak seimbang. Evaluasi ini menjadi penting untuk mengidentifikasi potensi bias model terhadap kelas mayoritas serta keterbatasan model dalam mendeteksi kelas minoritas. Selain itu, hasil evaluasi menjadi dasar dalam menentukan model yang paling sesuai untuk tujuan analisis sentimen pada konteks aplikasi berita digital. Dengan demikian, proses evaluasi tidak hanya berfungsi sebagai alat ukur performa, tetapi juga sebagai landasan dalam interpretasi dan pemanfaatan hasil penelitian. Hasil confusion matrix bisa dilihat pada Gambar 3.



Gambar 3. Perbandingan Confusion Matrix NB dan SVM

Untuk memberikan gambaran kuantitatif yang lebih terukur terhadap performa kedua model, hasil evaluasi klasifikasi sentimen menggunakan metrik akurasi, precision, dan recall untuk algoritma Naïve Bayes dan Support Vector Machine disajikan pada Tabel 7.

Tabel 7. Perbandingan Hasil Evaluasi NB dan SVM

Metrik / Kelas	Naïve Bayes	SVM
Akurasi	0.72	0.80
Precision Negatif	0.54	0.75
Precision Netral	0.71	0.70
Precision Positif	0.82	0.93
Recall Negatif	0.60	0.57
Recall Netral	0.73	0.97
Recall Positif	0.77	0.78
F1-score Negatif	0.57	0.65
F1-score Netral	0.72	0.81
F1-score Positif	0.80	0.85
Macro Average F1	0.70	0.77
Weighted Average F1	0.73	0.80

Hasil evaluasi menunjukkan bahwa algoritma SVM memiliki performa yang lebih unggul dibandingkan Naïve Bayes secara keseluruhan. Algoritma Naïve Bayes memperoleh akurasi sebesar 72%, sedangkan SVM mencapai akurasi sebesar 80%. Perbedaan ini menunjukkan bahwa SVM lebih mampu memisahkan kelas sentimen secara akurat pada data

ulasan aplikasi Kompas.id. Selain itu, nilai weighted F1-score pada SVM juga lebih tinggi, yang mengindikasikan keseimbangan yang lebih baik antara presisi dan recall.

Analisis lebih lanjut terhadap confusion matrix menunjukkan bahwa SVM memiliki performa yang sangat baik pada kelas sentimen netral, dengan tingkat recall yang tinggi. Hal ini mengindikasikan bahwa SVM mampu mengenali ulasan yang bersifat informatif atau deskriptif tanpa muatan emosi yang kuat. Pada kelas sentimen positif, SVM juga menunjukkan performa yang stabil dengan tingkat presisi dan recall yang relatif seimbang.

Di sisi lain, Naïve Bayes menunjukkan sensitivitas yang relatif lebih baik pada kelas sentimen negatif, meskipun dengan tingkat presisi yang lebih rendah. Hal ini berarti bahwa Naïve Bayes cenderung lebih sering memprediksi ulasan sebagai negatif, namun sebagian prediksi tersebut tidak selalu tepat. Fenomena ini dapat dijelaskan oleh asumsi independensi antar fitur pada Naïve Bayes, yang kurang mampu menangkap konteks kalimat secara utuh.


Meskipun algoritma SVM menunjukkan nilai akurasi tertinggi (80%), hasil evaluasi juga memperlihatkan bahwa nilai recall pada kelas sentimen negatif relatif rendah (0,57). Hal ini menunjukkan adanya fenomena accuracy trap, di mana performa model tampak tinggi secara agregat, tetapi kurang optimal dalam mendeteksi kelas yang justru paling penting secara praktis, yaitu ulasan negatif. Rendahnya recall negatif mengindikasikan bahwa hampir separuh ulasan negatif tidak berhasil terdeteksi oleh model, sehingga berpotensi menyebabkan pengelola aplikasi kehilangan informasi penting terkait keluhan dan permasalahan pengguna. Dalam konteks aplikasi Kompas.id, di mana ulasan negatif merupakan sumber utama untuk identifikasi masalah dan perbaikan layanan, keterbatasan ini menjadi krusial. Oleh karena itu, meskipun SVM unggul secara akurasi, hasil ini menegaskan bahwa evaluasi model klasifikasi sentimen tidak seharusnya hanya berfokus pada akurasi, tetapi juga perlu mempertimbangkan metrik lain seperti recall pada kelas negatif sesuai dengan tujuan analisis.

3.2 Pembahasan

Keunggulan performa SVM dalam penelitian ini sejalan dengan temuan sejumlah penelitian terdahulu yang menyatakan bahwa SVM lebih efektif dalam menangani data teks berdimensi tinggi. Kemampuan SVM dalam membangun hyperplane optimal memungkinkan algoritma ini memisahkan kelas sentimen dengan margin yang lebih jelas dibandingkan Naïve Bayes.

Namun demikian, performa Naïve Bayes yang relatif baik pada kelas negatif menunjukkan bahwa algoritma ini masih memiliki keunggulan dalam mendeteksi kata-kata bernuansa keluhan yang eksplisit. Ulasan negatif pada aplikasi Kompas.id banyak mengandung kata-kata teknis seperti “langganan”, “bayar”, dan “aplikasi”, yang sering muncul secara konsisten pada kelas negatif.

Visualisasi word cloud memperkuat temuan ini dengan menunjukkan bahwa sentimen positif didominasi oleh kata-kata yang berkaitan dengan kualitas konten dan manfaat informasi, sedangkan sentimen negatif lebih banyak berkaitan dengan sistem berlangganan dan kendala teknis. Hal ini menunjukkan bahwa persepsi pengguna terhadap aplikasi berita tidak hanya dipengaruhi oleh kualitas teknis, tetapi juga oleh kebijakan akses dan model bisnis yang diterapkan. Visualisasi word cloud bisa dilihat pada Gambar 4.



Gambar 4. Visualisasi Wordcloud

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa Support Vector Machine lebih unggul dalam mengklasifikasikan sentimen ulasan aplikasi berita digital. Namun, pemilihan algoritma tetap perlu disesuaikan dengan tujuan analisis dan karakteristik data. Kombinasi pendekatan lexicon-based dan machine learning dalam penelitian ini juga terbukti mampu memberikan gambaran sentimen pengguna secara komprehensif.

4. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan kinerja algoritma Naïve Bayes dan Support Vector Machine (SVM) dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Kompas.id pada platform Google Play Store dengan memanfaatkan kerangka Knowledge Discovery in Databases (KDD) yang mencakup tahapan data selection,



preprocessing, transformation, data mining, dan evaluation, menggunakan dataset ulasan pengguna dalam rentang waktu September 2020 hingga September 2025 yang telah melalui proses pembersihan dan seleksi sehingga diperoleh data yang representatif untuk dianalisis. Berdasarkan hasil pengujian dan evaluasi model, diperoleh bahwa algoritma SVM menunjukkan performa yang lebih unggul dibandingkan Naïve Bayes dengan tingkat akurasi sebesar 80% dibandingkan 72% pada Naïve Bayes, serta nilai weighted F1-score yang lebih tinggi, yang mengindikasikan keseimbangan yang lebih baik antara presisi dan recall dalam mengklasifikasikan sentimen positif, netral, dan negatif, sekaligus menunjukkan efektivitas SVM dalam menangani data teks berdimensi tinggi yang direpresentasikan menggunakan TF-IDF. Namun demikian, nilai recall pada kelas sentimen negatif masih relatif rendah (0,57), yang mengindikasikan bahwa model belum sepenuhnya optimal dalam mendeteksi seluruh keluhan atau komplain pengguna secara akurat, meskipun Naïve Bayes menunjukkan keunggulan tertentu dalam mendeteksi sentimen negatif yang ditandai dengan kemunculan kata-kata keluhan yang eksplisit. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan, antara lain penggunaan pendekatan pelabelan sentimen berbasis leksikon yang belum sepenuhnya mampu menangkap konteks kalimat yang bersifat ambigu atau sarkastik, serta keterbatasan objek penelitian yang masih berfokus pada satu aplikasi berita digital sehingga generalisasi hasil perlu dilakukan secara hati-hati. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan pendekatan pelabelan berbasis supervised learning dengan data berlabel manual atau mengadopsi metode deep learning seperti Long Short-Term Memory (LSTM) atau Bidirectional Encoder Representations from Transformers (BERT), serta memperluas objek penelitian ke aplikasi berita digital lain guna memperoleh pemahaman yang lebih komprehensif mengenai perilaku dan sentimen pengguna media digital di Indonesia.

REFERENCES

- [1] S. Kemp, "Digital 2025: Global Overview Report." Diakses: 25 Oktober 2025. [Daring]. Tersedia pada: <https://datareportal.com/reports/digital-2025-global-overview-report>
- [2] W. Medhat, A. Hassan, dan H. Korashy, "Sentiment analysis algorithms and applications: A survey," *Ain Shams Engineering Journal*, vol. 5, no. 4, hlm. 1093–1113, Des 2014, doi: 10.1016/J.ASEJ.2014.04.011.
- [3] B. Liu, "Sentiment Analysis and Opinion Mining," Morgan & Claypool Publishers, 2012.
- [4] U. Fayyad, G. Piatetsky-Shapiro, dan P. Smyth, "From Data Mining to Knowledge Discovery in Databases," *AI Mag*, vol. 17, no. 3, hlm. 37–37, Mar 1996, doi: 10.1609/AIMAG.V17I3.1230.
- [5] K. Ravi dan V. Ravi, "A survey on opinion mining and sentiment analysis: Tasks, approaches and applications," *Knowl Based Syst*, vol. 89, hlm. 14–46, Nov 2015, doi: 10.1016/J.KNOSYS.2015.06.015.
- [6] C. M. Bishop, "Pattern Recognition and Machine Learning," 2006.
- [7] M. Mohri, A. Rostamizadeh, dan A. Talwalkar, "Foundations of Machine Learning," 2012.
- [8] M. V. Mäntylä, D. Graziotin, dan M. Kuutila, "The evolution of sentiment analysis—A review of research topics, venues, and top cited papers," *Comput Sci Rev*, vol. 27, hlm. 16–32, Feb 2018, doi: 10.1016/J.COSREV.2017.10.002.
- [9] R. Syahputra, G. J. Yanris, dan D. Irmayani, "SVM and Naïve Bayes Algorithm Comparison for User Sentiment Analysis on Twitter," *Sinkron*, vol. 7, no. 2, hlm. 671–678, Mei 2022, doi: 10.33395/sinkron.v7i2.11430.
- [10] M. E. Apriyani, A. F. Nur, dan E. S. Astuti, "Performance Comparison of Naïve Bayes and SVM Algorithms in Sentiment Analysis on JKN Application Data," *Knowbase : International Journal of Knowledge in Database*, vol. 4, no. 2, hlm. 180–188, Des 2024, doi: 10.30983/KNOWBASE.V4I2.8758.
- [11] B. F. Wiguna, H. Herlawati, dan A. Y. P. Yusuf, "Sentiment Analysis of On-Demand Ride-Hailing Systems using Support Vector Machine and Naïve Bayes," *PIKSEL : Penelitian Ilmu Komputer Sistem Embedded and Logic*, vol. 11, no. 2, hlm. 401–414, Sep 2023, doi: 10.33558/PIKSEL.V11I2.7384.
- [12] J. W. Iskandar dan Y. Nataliani, "Perbandingan Naïve Bayes, SVM, dan k-NN untuk Analisis Sentimen Gadget Berbasis Aspek," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 6, hlm. 1120–1126, Des 2021, doi: 10.29207/resti.v5i6.3588.
- [13] S. A. S. Mola, D. L. B. Baun, I. O. Nunes, dan M. M. A. R. Sani, "ANALISIS SENTIMEN APLIKASI HALO BCA DI GOOGLE PLAY STORE MENGGUNAKAN METODE NAIVE BAYES, SUPPORT VECTOR MACHINE DAN RANDOM FOREST," *HOAQ (High Education of Organization Archive Quality) : Jurnal Teknologi Informasi*, vol. 15, no. 2, hlm. 69–79, Des 2024, doi: 10.52972/hoaq.vol15no2.p69-79.
- [14] M. I. Fikri, T. S. Sabrila, Y. Azhar, dan U. M. Malang, "Perbandingan Metode Naïve Bayes dan Support Vector Machine pada Analisis Sentimen Twitter," *SMATIKA JURNAL*, vol. 10, no. 02, hlm. 71–76, Des 2020, doi: 10.32664/SMATIKA.V10I02.455.
- [15] S. Chohan, A. Nugroho, A. M. B. Aji, dan W. Gata, "Analisis Sentimen Pengguna Aplikasi Duolingo Menggunakan Metode Naïve Bayes dan Synthetic Minority Over Sampling Technique," *Paradigma - Jurnal Komputer dan Informatika*, vol. 22, no. 2, hlm. 139–144, Sep 2020, doi: 10.31294/p.v22i2.8251.
- [16] M. I. Ghozali, W. H. Sugiharto, dan A. F. Iskandar, "Analisis Sentimen Pinjaman Online Di Media Sosial Twitter Menggunakan Metode Naive Bayes," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 3, no. 6, hlm. 1340–1348, Jun 2023, doi: 10.30865/KLIK.V3I6.936.
- [17] G. Salton dan C. Buckley, "Term-weighting approaches in automatic text retrieval," *InfProcess Manag*, vol. 24, no. 5, hlm. 513–523, Jan 1988, doi: 10.1016/0306-4573(88)90021-0.
- [18] A. McCallum dan K. Nigam, "A comparison of event models for naive bayes text classification," *AAAI Conference on Artificial Intelligence*, 1998.
- [19] T. Joachims, "Text categorization with Support Vector Machines: Learning with many relevant features," hlm. 137–142, 1998, doi: 10.1007/BFB0026683.
- [20] G. A. Miller, "WordNet," *Commun ACM*, vol. 38, no. 11, hlm. 39–41, Nov 1995, doi: 10.1145/219717.219748.