

Perbandingan Algoritma Klasifikasi Terhadap Review Aplikasi Maxim Menggunakan Teknik Klasifikasi Machine learning

Comparison of Classification Algorithms Against Maxim Application Review Using Machine Learning Classification Techniques

Nova Tri Romadloni^{*1}, Pamela Hana Mulia², Wiwit Supriyanti³

^{1,2}Informatika, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Karanganyar

³Teknik Komputer, Fakultas Sains dan Teknologi, Universitas Muhammadiyah Karanganyar

*Penulis Korespondensi

Email: novatrir@umuka.ac.id

Abstrak. Perkembangan teknologi telah membawa dampak besar terhadap sistem transportasi publik, salah satunya dengan munculnya layanan ojek online yang memungkinkan pemesanan melalui aplikasi digital. Salah satu layanan transportasi daring yang cukup populer adalah Maxim, yang telah diunduh lebih dari 50 juta kali. Ulasan pengguna terhadap aplikasi ini menjadi sumber informasi penting untuk menilai pengalaman mereka serta sebagai dasar dalam upaya peningkatan kualitas layanan. Penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja beberapa algoritma machine learning dalam mengklasifikasikan sentimen dari ulasan pengguna Maxim. Data dikumpulkan menggunakan metode web scraping dan dikelompokkan berdasarkan rating bintang. Tahapan pra-pemrosesan mencakup pembersihan teks, tokenisasi, stemming, dan pembobotan menggunakan metode TF-IDF. Algoritma yang digunakan meliputi Logistic Regression, Naive Bayes, Support Vector Machine (SVM), Decision Tree, K-Nearest Neighbors (KNN), dan Random Forest (RF). Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Berdasarkan hasil analisis, algoritma Random Forest menunjukkan kinerja terbaik dengan akurasi mencapai 95%. Secara umum, hasil penelitian ini menegaskan bahwa Random Forest unggul dibandingkan algoritma lain dalam menganalisis sentimen ulasan pengguna aplikasi Maxim.

Kata kunci: Analisis Sentimen, Machine learning, Maxim, Klasifikasi, Transportasi Online

Abstract. Technological advancements have significantly impacted public transportation systems, particularly through the emergence of online motorcycle taxi services that enable bookings via digital applications. One of the well-known ride-hailing platforms is Maxim, which has been downloaded over 50 million times. User reviews on this application serve as valuable data to assess user experiences and serve as a reference for improving service quality. This study aims to evaluate and compare the performance of several machine learning algorithms in classifying sentiment from Maxim user reviews. The dataset was collected using web scraping techniques and categorized based on star ratings. The preprocessing stages included text cleaning, tokenization, stemming, and weighting using the TF-IDF method. The algorithms assessed include Logistic Regression, Naive Bayes, Support Vector Machine (SVM), Decision Tree, K-Nearest Neighbors (KNN), and Random Forest (RF). Performance was measured using accuracy, precision, recall, and F1-score metrics. The analysis results indicate that Random Forest delivered the best performance, achieving an accuracy of 95%. Overall, the study's findings demonstrate that Random Forest outperforms the other algorithms in analyzing user sentiment within the Maxim application reviews.

Keywords: Classification, Machine Learning, Maxim, Online Transportation, Sentiment Analysis

1. Pendahuluan

Di era globalisasi ini, segala aktivitas dapat dilakukan dengan cepat dan efisien melalui pemanfaatan teknologi. Salah satu dampak nyata dari perkembangan teknologi adalah meningkatnya popularitas transportasi online yang berbasis internet dan aplikasi digital (Akbar et al. 2022) Kehadiran teknologi memungkinkan masyarakat mengakses layanan secara real-time dan fleksibel, yang sangat membantu dalam menjalankan aktivitas sehari-hari yang semakin dinamis.

Kebutuhan masyarakat terhadap sarana transportasi mendorong pergeseran preferensi dari moda konvensional ke layanan digital. Di era modern ini, masyarakat memiliki beragam aktivitas yang membutuhkan sarana transportasi cepat dan fleksibel (Rokhman, Berlilana, and Arsi 2021). Bukti nyata pergeseran ini terlihat dari pengakuan anggota pangkalan ojek konvensional di Jambi yang menyatakan bahwa hampir seluruh konsumennya telah beralih menggunakan ojek online (Ferdila, Kasful, and Us 2021). Aplikasi transportasi online seperti Gojek, Grab, dan Maxim kini mendominasi pasar Indonesia. Aplikasi ini memungkinkan pemesanan kendaraan dengan cepat dan mudah melalui perangkat mobile. Inovasi ini tidak hanya mengubah pola mobilitas masyarakat, tetapi juga menciptakan persaingan baru dalam industri transportasi berbasis teknologi digital (Aida Sapitri and Fikry 2023) Kompetisi ini mendorong penyedia layanan untuk terus meningkatkan kualitas dan efisiensi layanannya.

Berdasarkan data yang dipublikasikan oleh Statista (www.statista.com) pada Juli 2024, tercatat bahwa jumlah pengguna layanan transportasi online di tahun tersebut mencapai 88,3 juta orang, menunjukkan tren peningkatan dibandingkan tahun-tahun sebelumnya. Proyeksi Statista juga memperkirakan bahwa jumlah pengguna transportasi online di Indonesia akan terus bertumbuh antara tahun 2024 hingga 2029, dengan penambahan sekitar 23,6 juta pengguna atau mengalami kenaikan sebesar 26,73%. Setelah mengalami pertumbuhan selama sembilan tahun berturut-turut, jumlah pengguna diperkirakan akan mencapai 111,89 juta orang pada tahun 2029 dan menjadi titik tertinggi berdasarkan hasil survei tersebut.

Di Indonesia, terdapat berbagai layanan transportasi online seperti Gojek, Grab, Maxim, Anterin, InDriver, Ojekjek, dan OjekBro. Di antara aplikasi tersebut, Maxim menjadi salah satu platform yang cukup dikenal oleh masyarakat. Maxim merupakan penyedia layanan transportasi berbasis aplikasi yang dapat diakses melalui perangkat dengan sistem operasi iOS, Android, dan HarmonyOS (Tambunan, Sihotang, & Mambu, 2021). Didirikan oleh Maxim Belonogov pada tahun 2003 di Chardinsk, Rusia, perusahaan ini kini telah berkembang secara internasional. Di Indonesia, Maxim mulai aktif memberikan layanan sejak tahun 2018 di bawah naungan PT Teknologi Perdana Indonesia. Aplikasi ini menawarkan beragam layanan transportasi yang dikembangkan untuk menjawab kebutuhan pengguna secara efisien dan tepat sasaran (Abdulkhalik & Darwesh, 2020).

Hasil survei pada 19 Desember 2024 melalui Google Play menunjukkan bahwa aplikasi Maxim telah diunduh lebih dari 50 juta kali, menjadikannya salah satu aplikasi transportasi yang populer saat ini. Seiring dengan bertambahnya jumlah pengguna, ulasan pengguna menjadi sumber informasi penting dalam mengevaluasi pengalaman mereka sekaligus sebagai masukan untuk meningkatkan mutu layanan (Farahsalsabil Yudhiane Cantika & R. Yuniardi Rusdianto, 2023).

Analisis sentimen bertujuan untuk mengelompokkan pendapat pengguna ke dalam kategori positif, negatif, atau netral berdasarkan teks ulasan (Santosa, Purnamasari, and Mayasari Rini 2022). Mengingat volume data yang besar dan tidak terstruktur, metode manual akan sangat tidak

efisien. Oleh karena itu, pendekatan berbasis machine learning digunakan karena mampu mengenali pola data dan melakukan klasifikasi secara otomatis (Romadloni and Supriyanti 2023). Dalam ulasan pengguna terdiri dari data teks dalam jumlah besar, maka diperlukan metode yang efisien dan akurat untuk melakukan klasifikasi sentimen secara otomatis (Syafrizal, Afdal, and Novita 2023). Salah satu pendekatan yang umum digunakan adalah machine learning, yang mampu mempelajari pola dari data historis dan melakukan klasifikasi berdasarkan pola tersebut (Romadloni et al. 2024).

Dengan memanfaatkan komentar pengguna di ulasan Google Play Store, peneliti dapat memahami sentimen di balik ulasan para pengguna (Darwis, Siskawati, and Abidin 2021). Diperlukan analisis lebih lanjut salah satunya dengan melakukan analisis sentimen. Analisis sentimen adalah langkah penting dalam mengungkapkan apakah ulasan tersebut bersifat positif atau negative (Prakoso and Hermawan 2023). Peneliti menggunakan beberapa metode untuk mengklasifikasikan ulasan tersebut dengan machine learning. Dalam hal ini machine learning bagian dari bidang *artificial intelligence* yang berfokus pada implementasi algoritma dan metode khusus untuk memperkirakan, mengenali pola dan mengelompokan (Angkasa and Pangaribuan 2022).

Analisis ulasan pengguna pada aplikasi Maxim ini telah dilakukan sebelumnya dengan menggunakan metode Naïve Bayes. Cara pengambilan data yang dilakukan menggunakan cara scrapping pada Google Play Store dengan mengambil ulasan sebanyak 1000 ulasan. Tahapan klasifikasi dimulai dari data selection sampai dengan evaluasi. Berdasarkan hasil yang telah dilakukan menghasilkan beberapa hasil yakni akurasi, presisi, recall dan f1-score sebesar 84%, 83%, 93%, dan 88% (Hasanah and Sari 2024).

Penelitian sebelumnya menggunakan metode Support Vector Machine (SVM). Analisis dilakukan terhadap 1200 ulasan pengguna dan memperoleh akurasi sebesar 79% (Lestari, Akbar, and Intan 2023). Selanjutnya, penelitian sebelumnya membahas mengenai analisis sentiment dengan menggunakan algoritma random forest. Metode penelitian yang dilakukan adalah Research and Development. Teknik analisis sentiment menggunakan metode Random Forest dan mendapatkan nilai akurasi sebesar 0.636 atau 64%. Pada skenario pengujian ini jumlah data yang digunakan adalah 2000 data. Data dibagi menjadi dua bagian yaitu data training dan data testing dengan perbandingan 1.175 : 825 dimana data yang digunakan tersebut sudah diberi label oleh algoritma Random Forest (Saripah and Sibarani 2024).

Perbedaan dari penelitian ini dibandingkan dengan studi-studi sebelumnya terletak pada pendekatan komparatif terhadap enam algoritma klasifikasi, sementara sebagian besar penelitian terdahulu hanya berfokus pada penggunaan satu algoritma saja. Diharapkan, temuan dari studi ini dapat memberikan kontribusi nyata bagi pengembang aplikasi Maxim dalam mengevaluasi serta meningkatkan kualitas layanan secara lebih optimal, dengan mengadopsi algoritma yang terbukti paling akurat dalam mengklasifikasikan sentimen pengguna. Selain itu, penelitian ini juga dapat menjadi rujukan ilmiah bagi peneliti lain yang ingin melakukan kajian serupa dengan pendekatan perbandingan terhadap berbagai model machine learning.

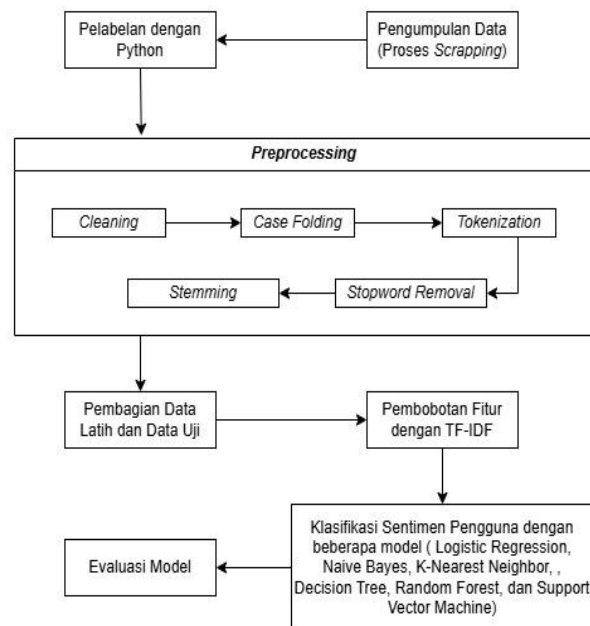
2. Bahan dan Metode

Dalam tahapan ini dilakukan analisis sentimen terhadap ulasan pengguna aplikasi Maxim dengan memanfaatkan metode klasifikasi berbasis machine learning. Proses penelitian dilakukan

dengan langkah sistematis, mulai dari tahapan pengumpulan data, pra-pemrosesan teks, pembobotan fitur, pemisahan dataset, pelatihan model klasifikasi, hingga pengujian dan evaluasi performa model. Penjabaran detail dari masing-masing tahap tersebut akan dijelaskan secara terstruktur pada subbab berikutnya.

2.1. Metode Penelitian

Penelitian ini mengadopsi pendekatan data-driven dengan sejumlah tahapan utama yang mencakup proses pengumpulan data, pemberian label, pra-pemrosesan data, pemberian bobot pada fitur, pemisahan dataset, penerapan berbagai algoritma klasifikasi machine learning, serta evaluasi performa model. Gambar 1 menyajikan gambaran menyeluruh dari alur proses dalam penelitian ini.



Gambar 1. Metode Penelitian

2.2.1 Pengumpulan Data

Tahapan awal dalam penelitian ini adalah pengumpulan data, yang difokuskan pada ulasan pengguna aplikasi Maxim yang tersedia melalui platform Google Play Store. Untuk proses ini, digunakan alat bantu bernama Google Play Scraper, yang dikembangkan menggunakan bahasa pemrograman Python dan dijalankan di lingkungan Google Colaboratory. Setelah melakukan instalasi library Google Scraper, peneliti dapat mengakses dan mengekstrak data secara langsung dari Google Play Store. Dalam penelitian ini, telah diambil sebanyak 1.000 data ulasan, dengan menggunakan ID aplikasi Maxim, yaitu com.taxsee.taxsee.

Data ulasan yang dikumpulkan memuat sejumlah informasi penting, seperti isi ulasan, tanggal publikasi, serta nilai rating yang diberikan oleh pengguna, dengan rentang nilai antara 1 hingga 5. Seluruh data tersebut diunduh dalam format CSV (comma-separated values). Setelah proses pengumpulan selesai, tahap berikutnya adalah melakukan penyaringan data dengan menerapkan filter berdasarkan tahun, yaitu hanya mempertahankan ulasan yang dipublikasikan pada tahun 2024. Langkah ini bertujuan untuk memastikan bahwa dataset yang digunakan merepresentasikan opini pengguna terkini dan relevan dengan kondisi terbaru penggunaan aplikasi Maxim.

2.2.2 Labeling Data

Langkah berikutnya adalah labeling data; setiap ulasan yang dikumpulkan diberi label sentimen. Label ini membagi perasaan pengguna ke dalam tiga kelompok utama: positif, netral, dan negatif. Ini dilakukan menggunakan aturan dan bintang rating ulasan. Penilaian 1 dan 2 adalah sentimen negatif, karena biasanya menunjukkan ketidakpuasan pengguna; rating 3 adalah sentimen netral, karena menunjukkan opini yang tidak terlalu positif atau negatif; dan rating 4 dan 5 adalah sentimen positif, karena biasanya menunjukkan kepuasan dan pengalaman yang baik. Script Python melakukan proses pelabelan secara otomatis.

2.2.3 Preprocessing Data

Preprocessing dilakukan untuk menyiapkan kumpulan data mentah, yaitu data teks, yang dapat digunakan untuk analisis pembelajaran mesin (Setyorini & Mustakim, 2021). Pada tahap pertama, data dibersihkan. Ini berarti menghapus elemen yang tidak relevan, seperti angka, simbol, tanda baca, dan ulasan duplikat, serta ulasan yang kosong atau hanya berisi karakter non-alfabet. Selanjutnya, case folding digunakan untuk normalisasi teks. Ini mengubah semua huruf menjadi lebih kecil untuk membuat format teks seragam dan memudahkan analisis berbasis kata.

Setelah itu, teks ulasan dibagi menjadi unit kata yang lebih kecil melalui proses tokenisasi. Teknik penghapusan stopword menghapus kata-kata umum yang tidak signifikan, seperti "dan", "atau", dan sebagainya. Selain itu, teknik stemming menyederhanakan kata-kata ke bentuk aslinya, seperti mengubah "berjalan" menjadi "jalan". Ini menggunakan library Python seperti NLTK atau Sastrawi untuk Bahasa Indonesia untuk menjalankan proses ini. Hasilnya adalah dataset teks yang bersih, terstruktur, dan siap dikonversi ke bentuk numerik seperti TF-IDF sebelum digunakan dalam model pembelajaran mesin. Preprocessing yang tepat memastikan bahwa model dapat memahami data teks dengan lebih baik.

2.2.4 Pembagian Data Latih dan Data Uji

Data uji dan data latih adalah nama dua kelompok yang dibentuk oleh dataset yang digunakan dalam penelitian ini setelah melewati tahap preprocessing. Model pembelajaran mesin menggunakan data latih untuk mempelajari pola dalam data. Ini melakukan ini dengan mempelajari hubungan antara fitur teks ulasan (seperti TF-IDF) dan label sentimen (positif, netral, atau negatif). Ini memungkinkan model untuk memahami bagaimana pola kata tertentu berhubungan dengan perasaan pengguna. Tujuan utama data latih adalah membantu model mencapai kemampuan prediksi yang akurat.

Untuk saat ini, data uji digunakan untuk mengevaluasi kinerja model setelah pelatihan. Data ini tidak digunakan selama proses pelatihan, jadi evaluasinya menunjukkan kemampuan model untuk mengidentifikasi pola pada data baru. Dataset biasanya dibagi dalam proporsi tertentu, seperti 80 : 20 atau 90 : 10 yang sebagian besar data digunakan untuk pelatihan dan sisanya untuk pengujian.

2.2.4 Pembobotan TF-IDF

(*Term Frequency-Inverse Document Frequency* atau biasa disebut TF-IDF merupakan teknik untuk merepresentasikan teks dalam bentuk numerik agar dapat diolah oleh algoritma *machine learning*. Metode ini menentukan bobot setiap kata berdasarkan seberapa sering kata tersebut muncul dalam satu dokumen (*Term Frequency*) dan seberapa jarang kata tersebut muncul di keseluruhan dokumen (*Inverse Document Frequency*).

Tahapan TF-IDF melibatkan perhitungan *Term Frequency (TF)*, yang menunjukkan frekuensi kemunculan kata dalam dokumen, diikuti dengan perhitungan *Inverse Document Frequency (IDF)*, yaitu logaritma rasio total dokumen terhadap jumlah dokumen yang memuat kata tersebut. Kombinasi keduanya menghasilkan nilai TF-IDF yang mencerminkan relevansi kata dalam dokumen tertentu. Proses ini dapat dilakukan secara otomatis menggunakan library seperti *Scikit-learn*, yang mengonversi teks menjadi matriks fitur numerik. Matriks ini kemudian digunakan sebagai input untuk melatih model *machine learning*, membantu model fokus pada kata-kata relevan dan meningkatkan performa prediksi sentimen. Perhitungan TF-IDF menggunakan rumus di berikut ini.

$$TF\ IDF_{t,d} = 1 + \log(FT_{t,d}) * \log\left(\frac{N}{DF_t}\right)$$

2.2.5 Visualisasi Data

Word cloud dan *bar chart* digunakan untuk memberikan gambaran tentang kata-kata dan sentimen yang sering digunakan dalam penelitian ini. *Word cloud* menampilkan kata-kata yang paling umum dalam dataset, dengan ukuran teks menunjukkan frekuensi kata. Misalnya, kata-kata yang menunjukkan emosi positif, seperti "bagus" atau "mudah", akan tampak lebih besar, sedangkan kata-kata yang menunjukkan emosi negatif, seperti "error" atau "lambat", akan lebih menonjol jika emosi negatif mendominasi. Visualisasi ini memberikan perspektif yang sangat informatif dan mudah dipahami dalam satu pandang.

Selain itu, *bar chart* menunjukkan jumlah ulasan untuk setiap kategori sentimen, yang terdiri dari positif, netral, dan negatif. Diagram batang ini memudahkan analisis distribusi sentimen, misalnya untuk menentukan apakah sentimen tertentu mendominasi ulasan atau apakah ada ketidakseimbangan dalam dataset yang dapat memengaruhi kinerja model. Data disajikan dengan jelas dan menarik dengan alat seperti *Matplotlib*, *Seaborn*, dan *Plotly*.

2.2.6 Pengujian Algoritma

Dalam penelitian ini, menggunakan pengujian algoritma *machine learning* beberapa diantaranya sebagai berikut, *Regression (LR)*, *Naive Bayes (NB)*, *Support Vector Machine (SVM)*, *Decision Tree (DT)*, *K-Nearest Neighbors (KNN)* dan *Random Forest (RF)*.

Logistic Regression merupakan algoritma pembelajaran mesin yang digunakan untuk mengklasifikasikan data dengan variabel target yang bersifat kategoris. Algoritma ini memodelkan probabilitas kejadian suatu kelas berdasarkan satu atau lebih variabel prediktor. Rumus dasar *Logistic Regression* adalah:

$$P = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}}$$

Keterangan :

P = Probabilitas dari kejadian suatu peristiwa $Y = 1$ (output bernilai 1)

β_0 = intercept atau bias, yaitu nilai konstanta yang tidak tergantung pada x

β_1 = Koefisien regresi untuk variabel x , yang menunjukkan pengaruh x terhadap logit P .

x = Nilai dari variabel independen (fitur).

e = Basis logaritma natural (bilangan eksponensial, sekitar 2.718).

Kelebihan LR adalah kemudahan interpretasi, efisiensi komputasi, dan kemampuan menangani variabel prediktor yang banyak. Namun, LR memiliki kelemahan dalam menangani

data yang tidak linier dan tidak dapat menangani interaksi kompleks antar fitur. Kemudian, Naïve Bayes merupakan algoritma pembelajaran mesin yang menggunakan teorema Bayes untuk membuat prediksi. Algoritma ini mengasumsikan bahwa fitur-fitur dalam data saling independen. Rumus dasar Naive Bayes adalah:

$$P(A|B) = \frac{P(B|A) * P(A)}{P(B)}$$

Keterangan :

$P(A|B)$ = Probabilitas bersyarat A yang diberikan oleh B

$P(B|A)$ = Probabilitas bersyarat B yang diberikan oleh A

$P(A)$ = Probabilitas kejadian A

$P(B)$ = probabilitas kejadian B

Kelebihan NB adalah kemudahan implementasi, kemampuan menangani data yang berdimensi tinggi, dan kemampuan menghasilkan probabilitas prediksi. Namun, NB memiliki kelemahan dalam menangani fitur yang saling terkait dan tidak dapat melakukan pembelajaran kompleks. Sedangkan, Support Vector Machine (SVM) merupakan algoritma pembelajaran mesin yang mengklasifikasikan data dengan memaksimalkan margin pemisah antara kelas-kelas. Algoritma ini mencari *hyperplane* optimal yang memisahkan kelas-kelas dengan jarak maksimum. Rumus dasar SVM adalah:

$$f(x) = \omega \cdot x + b$$

Keterangan :

ω = Vektor bobot (normal *hyperplane*)

x = Titik data (vektor fitur input)

b = Bias (intersep)

Kelebihan SVM adalah kemampuan menangani data yang tidak linier, kinerja yang baik pada data berdimensi tinggi, dan ketahanannya terhadap *overfitting*. Namun, SVM memiliki kelemahan dalam menangani data yang besar, interpretasi model yang sulit, dan parameter yang harus disetel dengan tepat. Kemudian algoritma selanjutnya Decision Tree pembelajaran mesin yang menghasilkan model berbentuk pohon keputusan. Algoritma ini secara rekursif memilih fitur yang paling informatif untuk membagi data menjadi subkelompok yang lebih kecil. Rumus dasar DT adalah:

$$H(S) = - \sum_{i=1}^n P_i \log_2(P_i)$$

Keterangan :

$H(S)$ = Entropy dari dataset S

$\sum_{i=1}^n$ = Penjumlahan dilakukan untuk semua kelas (n adalah jumlah kelas)

$P_i \log_2$ = Logaritma basis 2 dari p_i untuk Mengukur kontribusi probabilitas p_i terhadap ketidakpastian.

(P_i) = Proporsi data dalam kelas ke- i

– = Menjadikan hasil positif karena $\log_2(P_i)$ bernilai negatif untuk $0 < p_i < 1$

Kelebihan DT adalah kemudahan interpretasi, kemampuan menangani data kategoris dan numerik, serta ketahanannya terhadap fitur yang tidak relevan. Namun, DT memiliki kelemahan

dalam menangani data yang banyak dan kompleks, serta rentan terhadap *overfitting*. Kemudian, *K-Nearest Neighbors (KNN)* merupakan algoritma pembelajaran mesin yang mengklasifikasikan data berdasarkan kedekatan dengan tetangga terdekatnya. Algoritma ini memprediksi kelas suatu data berdasarkan kelas dari k tetangga terdekatnya. Rumus dasar KNN adalah:

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ij})^2}$$

Keterangan :

x = Titik data baru

x_i = Titik data ke- i dalam dataset

n = jumlah fitur

x_j = Nilai fitur ke- j dari data baru

x_{ij} = Nilai fitur ke- j dari data x_i

Kelebihan KNN adalah kemudahan implementasi, kemampuan menangani data non-linier, dan tidak memerlukan asumsi distribusi data. Namun, KNN memiliki kelemahan dalam menangani data berdimensi tinggi, sensitif terhadap pemilihan nilai k, dan rentan terhadap keberadaan fitur yang tidak relevan. Selanjutnya, Random Forest merupakan algoritma pembelajaran mesin yang menggabungkan banyak decision tree untuk membuat prediksi. Algoritma ini membangun hutan acak yang terdiri dari banyak *decision tree*, dan menggunakan suara mayoritas dari *tree-tree* tersebut untuk membuat prediksi. Rumus dasar RF adalah:

$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2$$

Keterangan :

MSE = Mean Squared Error (MSE) yaitu rata-rata kuadrat dari selisih antara nilai aktual (f_i) dan nilai prediksi (y_i)

N = Jumlah total data dalam node yang sedang dipertimbangkan

f_i = Nilai target aktual (ground truth) untuk data ke- i dalam node.

y_i = Nilai prediksi rata-rata dari seluruh nilai target dalam node

$(f_i - y_i)^2$ = Selisih antara nilai aktual (f_i) dan nilai prediksi rata-rata (y_i) dikuadratkan.

$\frac{1}{N} \sum_{i=1}^N$ = Rata-rata dari total nilai kuadrat selisih untuk seluruh data dalam node.

Kelebihan RF adalah kemampuan menangani data yang kompleks, ketahanan terhadap *overfitting*, dan kemampuan menangani fitur yang tidak relevan. Namun, RF memiliki kelemahan dalam interpretasi model yang sulit, penggunaan memori yang besar, dan waktu pelatihan yang lebih lama dibandingkan algoritma lainnya.

3. Hasil dan Pembahasan

Hasil dari penerapan dan evaluasi model klasifikasi sentimen terhadap ulasan pengguna aplikasi Maxim disajikan dalam bab ini. Data yang telah melalui tahapan preprocessing dan pembobotan TF-IDF kemudian diklasifikasikan menggunakan enam algoritma pembelajaran mesin. Selanjutnya, evaluasi terhadap kinerja masing-masing model dilakukan berdasarkan metrik

akurasi, presisi, recall, dan skor F1. Hasil yang diperoleh kemudian dianalisis untuk menentukan model yang paling ideal. Selain itu, ini memberikan interpretasi tentang bagaimana masing-masing algoritma berfungsi dalam analisis sentimen.

3.1. Hasil Olah Data

Proses scraping menghasilkan 1.000 ulasan pengguna untuk aplikasi Maxim dari Google Play Store. Selanjutnya, ulasan ini dilabeli secara otomatis berdasarkan nilai bintang: nilai 4 dan 5 menunjukkan perasaan positif, dan nilai 1 dan 2 menunjukkan perasaan negatif. Setelah itu, data berlabel diproses melalui tahap persiapan, yang mencakup pembersihan teks, tokenisasi, penghapusan stopword, dan stemming. Selanjutnya, metode TF-IDF digunakan untuk membatasi fitur teks untuk menunjukkan kepentingan setiap kata dalam ulasan. Hasil contoh pembobotan TF-IDF berikut: 800 data sebagai data latih dan 200 data sebagai data uji. Hasil olah data menunjukkan bahwa data telah siap digunakan dalam proses pelatihan dan pengujian model klasifikasi.

| | content | processed_content | aa | \ |
|---|--------------------------------------|------------------------------|-----|---|
| 0 | bagus rekomend | bagu rekomend | 0.0 | |
| 1 | mntap | mntap | 0.0 | |
| 2 | driver ramah | driver ramah | 0.0 | |
| 3 | sangat baik dan ramah | sangat ramah | 0.0 | |
| 4 | good | good | 0.0 | |
| 5 | semoga lancar rezeki nya dek | semoga lancar rezeki nya dek | 0.0 | |
| 6 | sangat baik dan kang ojek nya ramahh | kang ojek nya ramahh | 0.0 | |
| 7 | good job....., pak | good job | 0.0 | |
| 8 | Mantap | mantap | 0.0 | |
| 9 | tepat waktu dan nyaman | nyaman | 0.0 | |

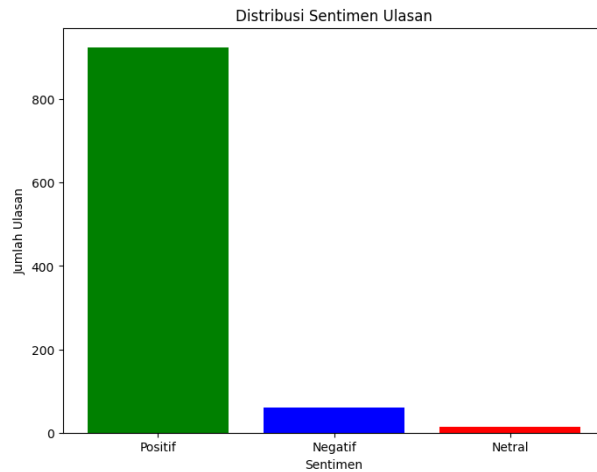
| | abang | abangni | abangnya | abg | adaain | adab | adanyajujur | ... | wlpn | wmail | \ |
|---|-------|---------|----------|-----|--------|------|-------------|-----|------|-------|---|
| 0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 1 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 2 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 3 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 4 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 5 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 6 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 7 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 8 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |
| 9 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | 0.0 | ... | 0.0 | 0.0 | |

Gambar 2. Hasil Pembobotan TF-IDF

Nilai TF-IDF yang muncul menunjukkan seberapa penting suatu kata dalam satu ulasan dibandingkan dengan dokumen secara keseluruhan. Kata-kata yang lebih jarang muncul tetapi memiliki banyak informasi akan menerima skor yang lebih tinggi. Sebaliknya, kata-kata umum yang sering muncul di banyak ulasan akan menerima skor yang lebih rendah. Dalam membedakan emosi antar ulasan, proses ini bertujuan untuk menekankan kata-kata yang benar-benar relevan. Selanjutnya, hasil pembobotan ini digunakan sebagai input fitur pada model klasifikasi.


3.2. Visualisasi Data

Visualisasi distribusi sentimen ulasan pengguna aplikasi Maxim disajikan pada Gambar berikut. Grafik menunjukkan jumlah data dalam masing-masing kategori sentimen, yaitu positif, negatif, dan netral.



Gambar 3. Visualisasi Kategori Sentiment Ulasan

Berdasarkan visualisasi tersebut, terlihat bahwa sebagian besar ulasan berada dalam kategori positif, dengan lebih dari 850 ulasan. Sekitar 80 ulasan memiliki sentimen negatif, dan hanya 20 ulasan memiliki sentimen netral. Persepsi pengguna terhadap aplikasi Maxim cenderung positif, menurut ketimpangan distribusi ini. Namun demikian, ketidakseimbangan data seperti ini dapat berdampak pada kinerja model klasifikasi. Ini terutama berlaku untuk menentukan apakah kelas minoritas dianggap memiliki sentimen negatif. Oleh karena itu, untuk menjaga fokus pada dua kelas utama (positif dan negatif) dan menghindari bias yang tinggi, proses klasifikasi penelitian tidak menggunakan ulasan netral.



Gambar 4. Visualisasi Data Wordcloud

Selain menyajikan distribusi sentimen, dilakukan pula visualisasi data dalam bentuk *word cloud* untuk menampilkan kata-kata yang paling sering muncul dalam ulasan pengguna. *Word cloud* menyajikan representasi visual dari kata-kata dominan, di mana ukuran setiap kata mencerminkan frekuensi kemunculannya dalam dataset. Berdasarkan visualisasi tersebut, terlihat bahwa kata-kata seperti “bagus”, “ramah”, “mantap”, “nyaman”, “cepat”, dan “terimakasih” merupakan yang paling sering digunakan dalam ulasan terhadap aplikasi Maxim. Dominasi kata-kata dengan makna positif ini memperkuat hasil analisis distribusi sentimen sebelumnya, yang menunjukkan bahwa mayoritas ulasan memiliki sentimen positif.

Kemunculan kata seperti “driver” dan “layanan” juga mengindikasikan bahwa aspek pelayanan pengemudi menjadi salah satu faktor utama dalam persepsi pengguna terhadap kualitas

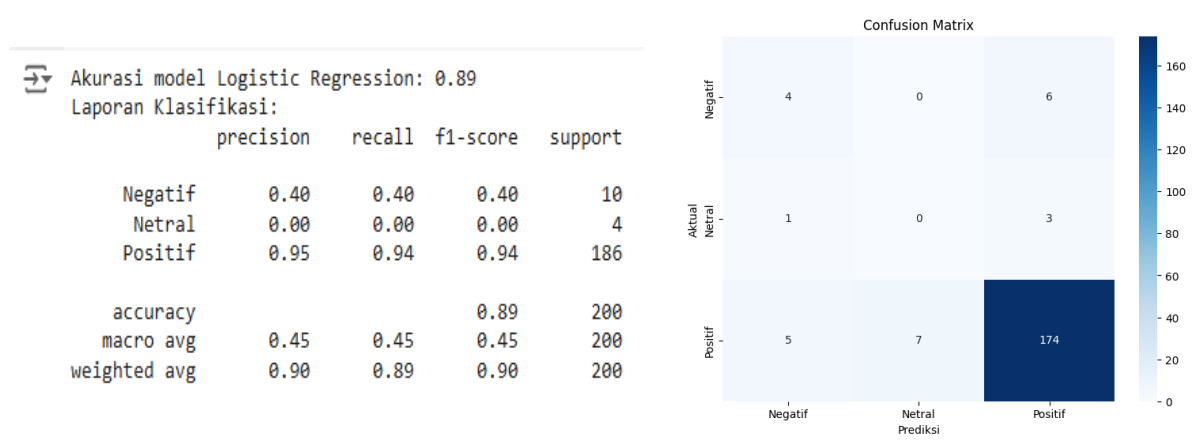
aplikasi. *Word cloud* ini memberikan gambaran umum mengenai fokus perhatian pengguna saat menyampaikan ulasan, yang pada gilirannya dapat menjadi masukan strategis bagi pengembang untuk menjaga dan meningkatkan aspek layanan yang dinilai penting oleh pengguna.

3.3. Pengujian Algoritma

Pengujian algoritma memproses dan membandingkan kinerja enam model machine learning dalam mengklasifikasikan sentimen ulasan pengguna aplikasi Maxim, yaitu Logistic Regression, Naïve Bayes, Support Vector Machine (SVM), Decision Tree, K-Nearest Neighbor (KNN), dan Random Forest. Setiap model dilatih menggunakan 800 data latih dan diuji pada 200 data uji, dengan evaluasi performa berdasarkan metrik.

3.3.1 Hasil Uji Algoritma Logistic Regression

Hasil pengujian performa model Logistic Regression terhadap data ulasan aplikasi Maxim disajikan pada Gambar berikut.



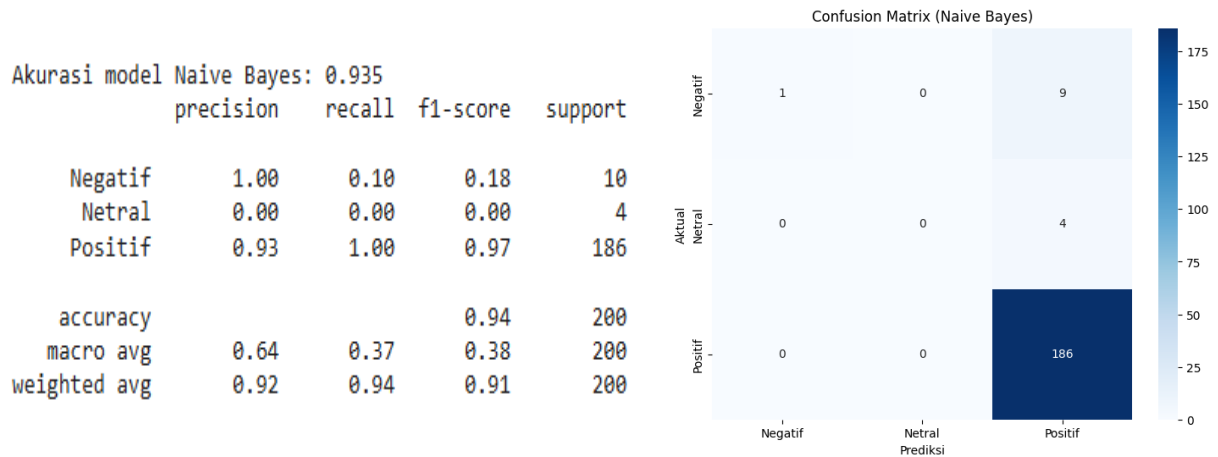
Gambar 5. Hasil Uji Algoritma Logistic Regression

Berdasarkan hasil klasifikasi yang ditampilkan pada Gambar 5, model Logistic Regression mampu mencapai tingkat akurasi sebesar 0,89 (89%). Pada kategori sentimen positif, model menunjukkan kinerja yang sangat baik dengan precision 0,95, recall 0,94, dan F1-score 0,94 dari total 186 data uji. Namun demikian, performa model pada kelas negatif masih tergolong rendah, dengan nilai precision, recall, dan F1-score masing-masing sebesar 0,40, yang didasarkan pada jumlah support sebanyak 10 data saja.

Sementara itu, kelas netral tidak terdeteksi oleh model, tercermin dari seluruh metrik evaluasi yang bernilai nol, menandakan bahwa model tidak berhasil mengenali ulasan yang termasuk dalam kategori tersebut. Nilai macro average yang hanya mencapai 0,45 menunjukkan adanya ketimpangan dalam performa model antar kelas. Sebaliknya, weighted average yang relatif tinggi sebesar 0,90 mencerminkan dominasi data pada kelas positif yang secara signifikan memengaruhi hasil keseluruhan.

3.3.2 Hasil Uji Algoritma Naïve Bayes

Hasil pengujian performa model Naïve Bayes terhadap data ulasan aplikasi Maxim disajikan pada Gambar berikut.



Gambar 6. Hasil Uji Algoritma Niave Bayes

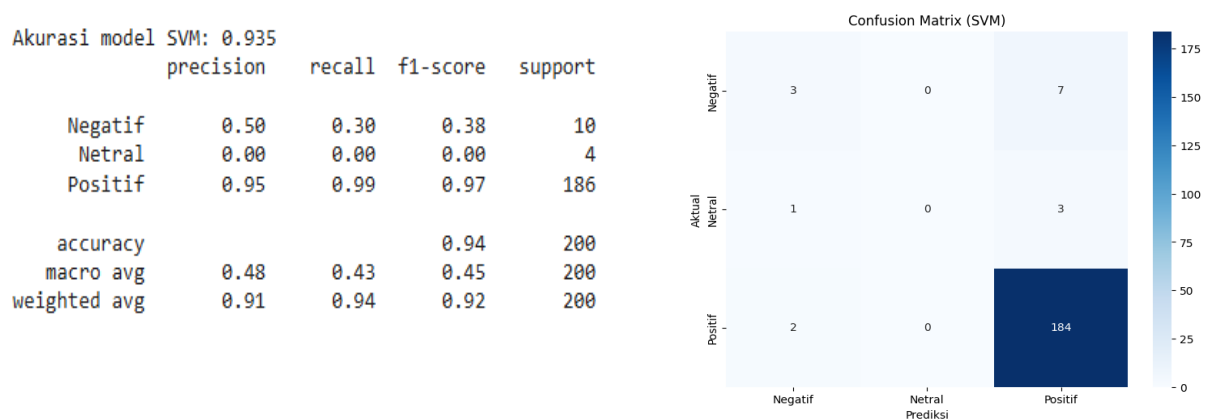
Hasil klasifikasi yang ditampilkan pada Gambar 6 menunjukkan bahwa model Naive Bayes berhasil meraih tingkat akurasi sebesar 0,935 (93,5%), yang mencerminkan performa umum yang sangat baik. Pada kategori sentimen positif, model bekerja sangat optimal, dengan nilai precision sebesar 0,93, recall mencapai 1,00, dan F1-score sebesar 0,97, dari total 186 data uji. Hal ini menunjukkan bahwa model memiliki kemampuan tinggi dalam mengidentifikasi ulasan yang bersifat positif.

Namun demikian, untuk kelas negatif, meskipun precision mencapai 1,00, recall hanya tercatat sebesar 0,10, dan F1-score sebesar 0,18, dari 10 data uji. Ini mengindikasikan bahwa meskipun prediksi terhadap ulasan negatif sangat akurat saat terdeteksi, namun model jarang mengklasifikasikan ulasan sebagai negatif. Sedangkan pada kelas netral, seluruh nilai evaluasi baik precision, recall, maupun F1-score bernilai nol, yang menunjukkan bahwa model sama sekali tidak mengenali kategori ini.

Performa yang tidak merata antar kelas tercermin dari nilai macro average, masing-masing sebesar 0,64 (precision), 0,37 (recall), dan 0,38 (F1-score). Di sisi lain, nilai weighted average yang tinggi, yaitu 0,92 untuk precision, 0,94 untuk recall, dan 0,91 untuk F1-score, menunjukkan bahwa hasil keseluruhan dipengaruhi secara dominan oleh banyaknya data pada kelas positif.

3.3.3 Hasil Uji Algoritma Support Vector Machine (SVM)

Hasil pengujian performa model Support Vector Machine (SVM) terhadap data ulasan aplikasi Maxim disajikan pada Gambar berikut.



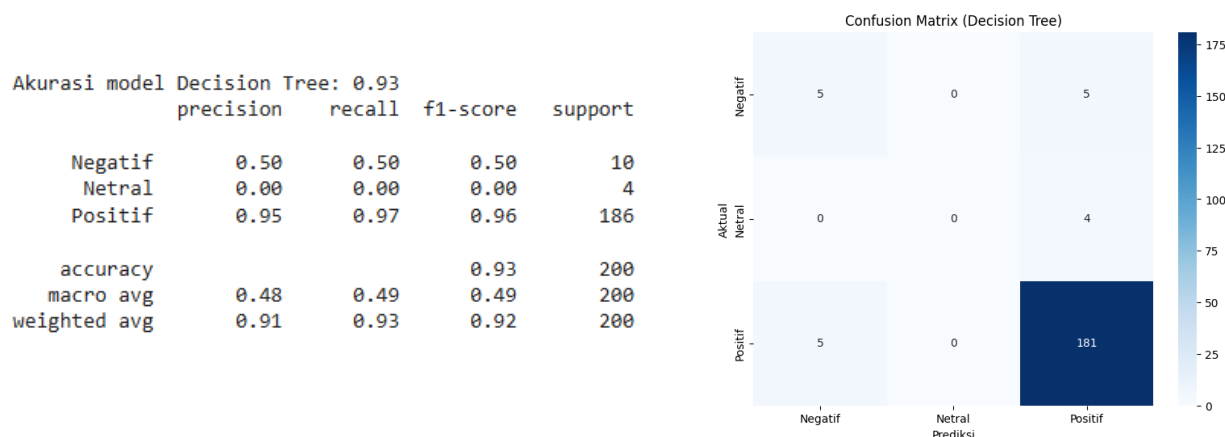
Gambar 7. Hasil Uji Algoritma Support Vector Machine (SVM)

Model Support Vector Machine (SVM) berhasil mencapai tingkat akurasi sebesar 0,935 (93,5%), yang mengindikasikan performa klasifikasi yang sangat baik secara keseluruhan. Pada kelas sentimen positif, model menunjukkan kinerja unggul dengan precision sebesar 0,95, recall 0,99, dan F1-score 0,97 dari 186 data uji. Capaian ini menunjukkan bahwa SVM sangat efektif dalam mengenali ulasan positif dari pengguna. Namun, performa model pada kelas negatif masih belum optimal. Dari 10 data uji, model hanya menghasilkan precision sebesar 0,50, recall 0,30, dan F1-score 0,38, yang mengindikasikan keterbatasan dalam mengidentifikasi ulasan bernuansa negatif. Untuk kelas netral, model tidak mampu melakukan klasifikasi sama sekali, terlihat dari seluruh nilai metrik evaluasi (precision, recall, F1-score) yang bernilai 0,00. Kondisi ini mirip dengan hasil yang diperoleh dari algoritma lain.

Nilai macro average menunjukkan adanya ketidakseimbangan performa antar kelas, dengan masing-masing nilai precision 0,48, recall 0,43, dan F1-score 0,45. Sementara itu, nilai weighted average tetap tinggi, yaitu precision 0,91, recall 0,94, dan F1-score 0,92, yang mencerminkan bahwa secara keseluruhan model menunjukkan kinerja baik berkat dominasi data ulasan positif dalam dataset.

3.3.4 Hasil Uji Algoritma Decision Tree

Hasil pengujian performa model Decision Tree terhadap data ulasan aplikasi Maxim disajikan pada Gambar berikut.



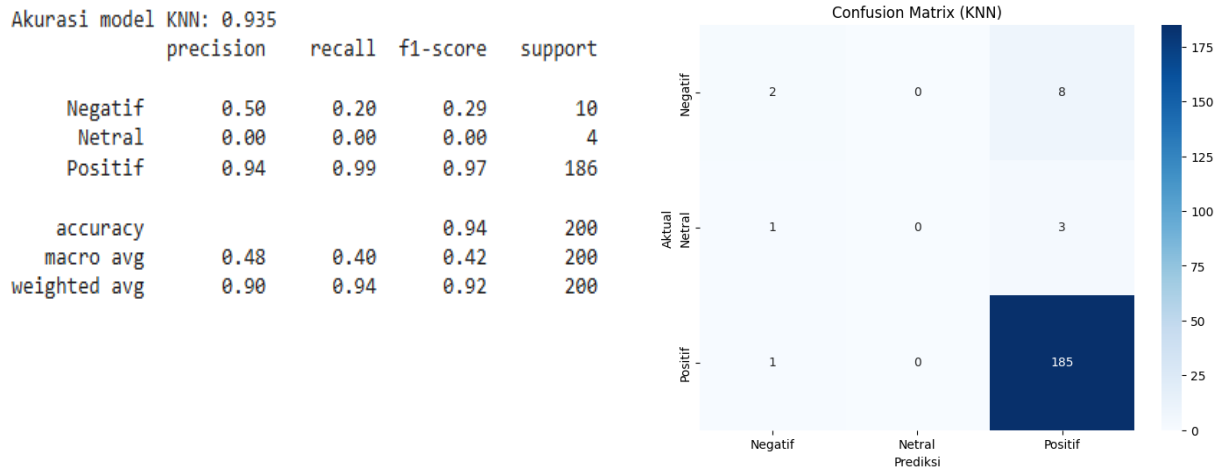
Gambar 8. Hasil Uji Algoritma Decision Tree

Merujuk pada hasil klasifikasi yang ditampilkan pada Gambar 8, model Decision Tree memperoleh tingkat akurasi sebesar 93%, yang menunjukkan kinerja cukup baik secara keseluruhan. Pada kelas positif, yang merupakan kelas dominan dalam data uji, model mencatatkan 0,95 untuk precision, 0,97 untuk recall, dan F1-score sebesar 0,96 dari 186 data uji. Hasil ini mengindikasikan bahwa model sangat andal dalam mendeteksi ulasan yang bernuansa positif. Untuk kelas negatif, model menghasilkan nilai yang sama pada ketiga metrik evaluasi, yaitu precision, recall, dan F1-score masing-masing 0,50 dari 10 data uji. Artinya, model berhasil mengklasifikasikan setengah dari total ulasan negatif secara tepat. Namun, seperti beberapa algoritma sebelumnya, kelas netral tidak berhasil dikenali oleh model, yang tercermin dari nilai precision, recall, dan F1-score yang seluruhnya bernilai 0. Nilai macro average berkisar antara 0,48 hingga 0,49 sedangkan weighted average berada pada rentang 0,91 hingga 0,93. Ini menunjukkan adanya ketimpangan kinerja antar kelas, di mana tingginya hasil evaluasi lebih

banyak dipengaruhi oleh keberhasilan model dalam mengklasifikasikan ulasan positif, yang jumlahnya memang dominan dalam dataset.

3.3.5 Hasil Uji Algoritma K-Nearest Neighbor (KNN)

Hasil pengujian performa model K-Nearest Neighbor (KNN) terhadap data ulasan aplikasi Maxim disajikan pada Gambar berikut.

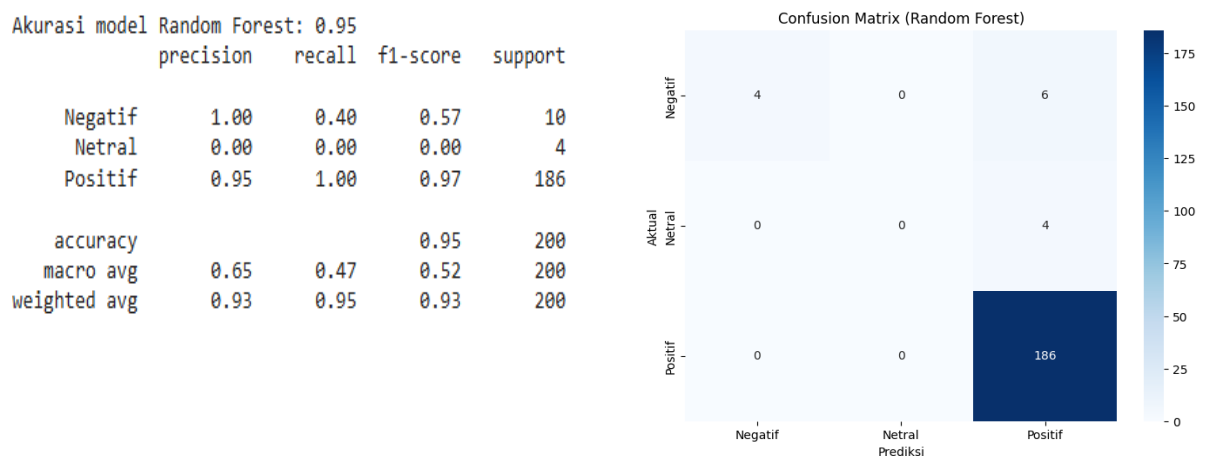


Gambar 9. Hasil Uji Algoritma K-Nearest Neighbor (KNN)

Model KNN menghasilkan akurasi sebesar 0,935 (93,5%), yang menunjukkan performa cukup tinggi secara umum. Hal ini menunjukkan bahwa model sangat andal dalam mengenali ulasan dengan sentimen positif. Namun, performa KNN dalam mengklasifikasikan kelas negatif masih kurang optimal. Untuk kelas netral, model kembali gagal memberikan prediksi yang akurat, dengan seluruh metrik bernilai 0,00 dari 4 data. Kegagalan dalam mendeteksi kelas netral ini juga ditemukan pada hampir semua algoritma lain dalam studi ini. Nilai macro average yang menunjukkan ketidakseimbangan kinerja antar kelas. Sementara itu, *weighted average* yang tinggi (precision 0,90, recall 0,94, F1-score 0,92) mengindikasikan bahwa performa keseluruhan model tetap baik karena didorong oleh dominasi data kelas positif.

3.3.6 Hasil Uji Algoritma Random Forest

Hasil pengujian performa model Random Forest terhadap data ulasan aplikasi Maxim disajikan pada Gambar berikut.



Gambar 9. Hasil Uji Algoritma K-Nearest Neighbor (KNN)

Berikut Tabel 1 perbandingan performa enam model klasifikasi yang mencakup metrik akurasi, serta precision, recall, dan F1-score untuk masing-masing kelas sentimen (positif dan negatif).

Tabel 1. Perbandingan Performa Model Klasifikasi

| Model | Akurasi | Precision (+) | Precision (-) | Recall (+) | Recall (-) | F1-Score (+) | F1-Score (-) |
|------------------------|---------|---------------|---------------|------------|------------|--------------|--------------|
| Logistic Regression | 89% | 95% | 40% | 94% | 40% | 94% | 40% |
| Naïve Bayes | 94% | 93% | 100% | 100% | 10% | 94% | 18% |
| Support Vector Machine | 94% | 95% | 50% | 99% | 30% | 97% | 38% |
| Decision Tree | 93% | 95% | 50% | 97% | 50% | 96% | 50% |
| K-Nearest Neighbor | 94% | 94% | 50% | 99% | 20% | 97% | 29% |
| Random Forest | 95% | 95% | 100% | 100% | 40% | 97% | 57% |

Secara umum, dari tabel perbandingan diatas Random Forest unggul dalam hal akurasi dan kestabilan prediksi, terutama dalam mengenali kelas minoritas (negatif) meskipun belum optimal. Model seperti SVM dan Naïve Bayes sangat baik untuk kelas mayoritas (positif), namun kurang seimbang untuk kelas lain. KNN dan Decision Tree menawarkan akurasi tinggi, namun mengalami penurunan pada recall kelas negatif dan netral. Logistic Regression cocok untuk baseline, namun kurang mampu menangkap kompleksitas data ulasan.

Kesimpulan

Berdasarkan evaluasi terhadap enam algoritma, disimpulkan bahwa Random Forest merupakan model klasifikasi yang paling unggul dalam menganalisis sentimen ulasan pengguna aplikasi Maxim. Algoritma ini tidak hanya menghasilkan akurasi tertinggi 95%, tetapi juga menunjukkan performa yang lebih seimbang dibandingkan model lainnya, khususnya dalam mengenali kelas minoritas seperti sentimen negatif. Meskipun beberapa algoritma lain seperti SVM, Naïve Bayes, dan KNN juga mencatat akurasi tinggi di atas 93%, performa mereka cenderung bias terhadap kelas mayoritas (positif) dan gagal mengidentifikasi kelas netral serta negatif secara konsisten. Logistic Regression memiliki keunggulan dalam kesederhanaan model, namun kurang efektif untuk data dengan distribusi tidak seimbang. Decision Tree menawarkan interpretabilitas tinggi, namun lebih rentan terhadap overfitting.

Dengan demikian, Random Forest direkomendasikan sebagai algoritma yang paling tepat untuk diterapkan dalam studi klasifikasi sentimen berbasis teks dengan distribusi kelas yang tidak seimbang, sebagaimana yang ditemukan pada ulasan aplikasi Maxim. Temuan ini juga dapat menjadi acuan bagi penelitian lanjutan dan pengembangan sistem klasifikasi opini pengguna berbasis machine learning. Penelitian selanjutnya, disarankan agar data yang digunakan lebih seimbang antara kelas positif dan negatif guna meningkatkan kemampuan model dalam mengenali semua jenis sentimen secara proporsional. Penggunaan teknik balancing seperti SMOTE atau

oversampling dapat menjadi solusi untuk mengatasi ketimpangan distribusi data. Selain itu, eksplorasi terhadap teknik klasifikasi berbasis deep learning seperti LSTM atau BERT juga dapat menjadi alternatif untuk meningkatkan performa model. Penelitian lanjutan juga dapat mempertimbangkan fitur tambahan seperti analisis emosi atau aspek-aspek layanan (*service aspect analysis*) guna memberikan wawasan yang lebih mendalam bagi pengembang aplikasi.

Daftar Pustaka

- Abdulkhaliq, Sasan Sarbast, and Aso Mohammad Darwesh. 2020. "Sentiment Analysis Using Hybrid Feature Selection Techniques." *UHD Journal of Science and Technology* 4(1):29–40. doi: 10.21928/uhdjst.v4n1y2020.pp29-40.
- Aida Sapitri, Indah, and Muhammad Fikry. 2023. "Pengklasifikasian Sentimen Ulasan Aplikasi Whatsapp Pada Google Play Store Menggunakan Support Vector Machine." *Jurnal TEKINKOM* 6(1):1–7. doi: 10.37600/tekinkom.v6i1.773.
- Akbar, M. Bahroni. 2019. "Tinjauan Yuridis Cybercrime Dalam Tindak Pidana Pencemaran Nama Baik." *Cybercrime*.
- Akbar, Muhammad Nur, Nur Hasanahmar'iyah Rusydi, M. Hasrul, and Shaumi Ramadhanti. 2022. "Sentiment Analysis Terhadap Review Aplikasi Maxim Di Google Play Store Menggunakan Support Vector Machine (SVM)." *JOURNAL of AGENTS* 2(2):1.
- Angkasa, Vincent, and Jefri Junifer Pangaribuan. 2022. "Information System Development Komparasi Tingkat Akurasi Random Forest Dan Knn Untuk Mendiagnosis Penyakit Kanker Payudara." *Journal Information System Development (ISD)* 7(1):37–38.
- Darwis, Dedi, Nery Siskawati, and Zaenal Abidin. 2021. "Penerapan Algoritma Naive Bayes Untuk Analisis Sentimen Review Data Twitter Bmkg Nasional." *Jurnal Tekno Kompak* 15(1):131. doi: 10.33365/jtk.v15i1.744.
- Farahsalsabil Yudhiane Cantika, and R. Yuniardi Rusdianto. 2023. "Mengoptimalkan Akurasi Navigasi Dan Fleksibilitas Pembayaran Pada Aplikasi Maxim: Tinjauan Terhadap Pengalaman Pengguna." *Jurnal Pelayanan Dan Pengabdian Masyarakat Indonesia* 2(2):84–95. doi: 10.55606/jppmi.v2i2.385.
- Ferdila, Merdiana, Dan Kasful, and Anwar Us. 2021. "Analisis Dampak Transportasi Ojek Online Terhadap Pendapatan Ojek Konvensional Di Kota Jambi." *IJIEB: Indonesian Journal of Islamic Economics and Business* 6(2):2021.
- Hasanah, Anisa Nur, and Betha Nurina Sari. 2024. "Analisis Sentimen Ulasan Pengguna Aplikasi Jasa Ojek Online Maxim Pada Google Play Dengan Metode Naive Bayes Classifier." *Jurnal Informatika Dan Teknik Elektro Terapan* 12(1):90–96. doi: 10.23960/jitet.v12i1.3628.
- Lestari, Indah, Muhamad Akbar, and Bunga Intan. 2023. "Perbandingan Algoritma Machine Learning Untuk Klasifikasi Amenorrhoea." *Journal of Computer and Information Systems Ampere* 4(1):32–43. doi: 10.51519/journalcisa.v4i1.371.
- Prakoso, Cahyo, and Arief Hermawan. 2023. "Perbandingan Model Machine Learning Dalam Analisis Sentimen Ulasan Pengunjung Keraton Yogyakarta Pada Google Maps." *Kajian Ilmiah Informatika Dan Komputer* 4(3):1292–1302. doi: 10.30865/klik.v4i3.1419.
- Rokhman, Khoirul Abbi, Berlilana Berlilana, and Primandani Arsi. 2021. "Perbandingan Metode Support Vector Machine Dan Decision Tree Untuk Analisis Sentimen Review Komentar

- Pada Aplikasi Transportasi Online.” *Journal of Information System Management (JOISM)* 3(1):1–7. doi: 10.24076/joism.2021v3i1.341.
- Romadloni, Nova Tri, Nisa Dwi Septiyanti, Cucut Hariz Pratomo, Wakhid Kurniawan, and Rauhulloh Ayatulloh Khomeini Noor Bintang. 2024. “Classification of Sms Spam With N-Gram and Pearson Correlation Based Using Machine Learning Techniques.” *SENTRI: Jurnal Riset Ilmiah* 3(2):967–77. doi: 10.55681/sentri.v3i2.2252.
- Romadloni, Nova Tri, and Wiwit Supriyanti. 2023. “Analisis Sentimen Penggunaan Teknologi Pada Pendidikan Anak Usia Dini.” *Jurnal Ilmiah SINUS* 21(2):101. doi: 10.30646/sinus.v21i2.759.
- Santosa, Agil, Intan Purnamasari, and Mayasari Rini. 2022. “Pengaruh Stopword Removal Dan Stemming Performa Klasifikasi Teks Komentar New Normal Menggunakan Algoritma.” *Jurnal Sains Komputer & Informatika (J-SAKTI)* 6:81–93.
- Saripah, Aini Pohan, and Fathiya Hasyifah Sibarani. 2024. “Analisis Sentimen Terhadap Aplikasi Maxim Menggunakan Algoritma Random Forest.” *Journal of Science and Social Research* 7(3):1201–8.
- Syafrizal, Syafrizal, M. Afdal, and Rice Novita. 2023. “Analisis Sentimen Ulasan Aplikasi PLN Mobile Menggunakan Algoritma Naïve Bayes Classifier Dan K-Nearest Neighbor.” *MALCOM: Indonesian Journal of Machine Learning and Computer Science* 4(1):10–19. doi: 10.57152/malcom.v4i1.983.
- Tambunan, Rianti Ruth Florenza, Jay Idoan Sihotang, and Joe Yuan Mambu. 2021. “Analisa Tingkat Kepuasan Kerja Driver Maxim Terhadap Sistem Layanan Maxim Dengan Pieces Framework.” *CogITo Smart Journal* 7(2):339–48. doi: 10.31154/cogito.v7i2.330.339-348.