

PEMODELAN SENTIMEN ULASAN PENGGUNA APLIKASI KURURIO DENGAN REGRESI LOGISTIK MENGGUNAKAN PYSPARK DAN SASTRAWI

Imam Nuur Wahid¹, Arkananta Daniswara Handoyo², Kartika Maulida Hindrayani³, Shindi Shella May Wara⁴

^{1,2}Mahasiswa Prodi Sains Data, FIK – UPN “Veteran” Jawa Timur

^{3,4}Dosen Prodi Sains Data, FIK – UPN “Veteran” Jawa Timur

¹23083010004@student.upnjatim.ac.id, ²23083010059@student.upnjatim.ac.id,

³kartika.maulida.ds@upnjatim.ac.id, ⁴shindi.shella.fasilkom@upnjatim.ac.id

Abstrak

Sebagai platform transportasi daring lokal, Kururio menghadapi tantangan kompetisi pasar yang ketat, sehingga analisis terhadap persepsi pengguna menjadi krusial untuk pengembangan layanan. Penelitian ini bertujuan menganalisis persepsi pengguna terhadap aplikasi Kururio, sebuah platform transportasi daring lokal, melalui analisis sentimen ulasan di Google Play Store. Metodologi yang digunakan meliputi scraping 1.020 ulasan, preprocessing menggunakan library Sastrawi, pembobotan TF-IDF, serta evaluasi model dengan k-fold cross validation. Berdasarkan perbandingan antara algoritma Regresi Logistik, Naive Bayes, Decision Tree, dan Random Forest, ditemukan bahwa Regresi Logistik pada PySpark memberikan performa terbaik dengan pembagian data 70:30. Hasil pengujian menunjukkan tingkat akurasi sebesar 87,18%, presisi 0,8747, dan F1-score 0,8693. Secara umum, mayoritas pengguna memberikan penilaian positif terhadap aplikasi ini, yang mengindikasikan bahwa rendahnya jumlah pengguna aktif dibandingkan kompetitor kemungkinan besar dipengaruhi oleh faktor eksternal di luar aspek teknis aplikasi. Temuan ini diharapkan menjadi masukan strategis bagi pengembang untuk meningkatkan kualitas layanan dan citra merek Kururio.

Kata kunci : Aplikasi, Ulasan, Sentimen, Pyspark, Regresi Logistik

1. Pendahuluan

Di tengah gelombang transformasi digital, memberikan dukungan kepada pelaku Usaha Mikro, Kecil, dan Menengah (UMKM) agar mampu beradaptasi menjadi bagian penting dalam strategi inklusi digital nasional. Kururio, platform digital karya anak bangsa, hadir sebagai wujud nyata dukungan tersebut melalui penyediaan layanan transportasi, ekspedisi, *marketplace*, dan layanan digital lainnya. Dengan mengedepankan nilai Aman, Nyaman, dan Terjangkau, Kururio telah berkembang sejak peluncurannya pada 25 Mei 2019 di Bau-Bau dan Malang, dan kini telah beroperasi di lebih dari 110 kota di seluruh Indonesia, didukung oleh ribuan *driver* dan mitra.

Meski menyajikan pelayanan yang komprehensif, Kururio masih menghadapi tantangan dalam meningkatkan jumlah pengguna aktif. Hal ini menandakan adanya gap antara nilai yang dijanjikan dan pengalaman nyata pengguna. Ulasan daring, khususnya di Google Play Store, menjadi tolok ukur reputasi aplikasi. Berdasarkan penelitian Rifa'i dkk. (2024), ulasan memuat elemen yang berkontribusi pada kepuasan pengguna, seperti kecepatan layanan, kemudahan navigasi, profesionalisme *driver*, keandalan sistem pembayaran, serta respons layanan pelanggan.

Sejumlah literatur mengenai analisis sentimen pada aplikasi populer di Indonesia, termasuk TIX ID dan DANA, mengonfirmasi bahwa pendekatan Regresi Logistik sangat kompeten dalam membedakan kategori sentimen pengguna secara tepat dan efisien (Febyanti dkk., 2026; Fitriani dkk., 2026; Rachmatullah dkk., 2014). Mawardi & Darmaja (2023), dalam studinya terhadap empat aplikasi berhasil mencapai akurasi ~81% menggunakan Regresi Logistik. Sementara itu penelitian yang dilakukan oleh Maulana dkk. (2023) terhadap ulasan aplikasi Gojek mengkomparasikan algoritma Regresi Logistik, SVM, dan KNN. Temuan mereka menunjukkan bahwa Regresi Logistik memiliki performa paling tinggi dengan tingkat akurasi sekitar 82,45%. Data tersebut memperkuat asumsi mengenai reliabilitas model Regresi Logistik dalam memproses opini pengguna pada aplikasi di Indonesia.

Analisis ulasan berbasis teks berbahasa Indonesia memerlukan tahap pemrosesan seperti tokenisasi, *stopword*

Available at:

<https://journal.unj.ac.id/unj/index.php/pinter/article/view/56764>

removal, dan *stemming* di mana *library* Sastrawi telah terbukti optimal dalam pengelolaan Bahasa Indonesia. Selain itu, karena data yang diperoleh dari Play Store memiliki skala yang besar, pemanfaatan *Apache* PySpark menjadi penting untuk mengelola dan mengolah data secara efisien dalam jumlah besar (*big data*). PySpark mendukung distribusi tugas *preprocessing* dan pelatihan model secara paralel, memungkinkan eksperimen kuantitatif eksploratif dengan kecepatan tinggi dan akurasi tinggi. *Preprocessing* teks Indonesia dengan Sastrawi dan PySpark efektif untuk *big data* ulasan, mirip dengan pendekatan pada analisis Twitter Indonesia (Fahrurrozi & Hadianti, 2025).

Penelitian ini dirancang untuk mendeteksi kecenderungan opini pelanggan terhadap performa Kururio dengan menganalisis data ulasan secara sistematis. Dengan mengandalkan teknik Regresi Logistik dan pendekatan eksploratif, studi ini menargetkan perolehan wawasan yang representatif, sehingga pengembang dapat memahami pandangan pengguna secara lebih mendalam dan berbasis data. Temuan ini diharapkan menjadi masukan strategis bagi pengembang dan pemangku kebijakan untuk terus meningkatkan kualitas layanan Kururio, sekaligus memajukan transformasi digital sektor UMKM di Indonesia.

2. Dasar Teori

2.1. UMKM dan Transformasi Digital

Sektor Usaha Mikro, Kecil, dan Menengah (UMKM) memegang peranan krusial sebagai pilar utama ekonomi nasional, namun saat ini dituntut untuk menyesuaikan diri dengan arus digitalisasi. Transformasi digital itu sendiri didefinisikan sebagai integrasi teknologi informasi guna merevolusi model operasional organisasi serta meningkatkan kualitas nilai yang ditawarkan kepada konsumen. Platform digital menjadi sarana penting untuk memperluas jangkauan layanan UMKM, baik dalam hal pemasaran, logistik, maupun interaksi pelanggan. Salah satu bentuk dukungan terhadap UMKM adalah pengembangan aplikasi layanan berbasis digital yang dapat digunakan oleh konsumen secara langsung melalui perangkat *mobile*.

2.2. Aplikasi Digital dan Ulasan Pengguna

Aplikasi digital adalah perangkat lunak berbasis *mobile* atau *web* yang dirancang untuk memudahkan pengguna dalam melakukan aktivitas tertentu seperti belanja daring, pemesanan transportasi, atau layanan ekspedisi, dan *marketplace* yang berperan penting dalam ekosistem digital UMKM. Ulasan pengguna merupakan pendapat atau tanggapan yang diberikan oleh konsumen setelah menggunakan sebuah aplikasi atau layanan digital. Ulasan tersebut mencakup beragam ekspresi pengguna, mulai dari apresiasi positif dan saran konstruktif hingga keluhan serta kritik tajam mengenai fungsionalitas aplikasi dan kualitas layanan. Data mentah ini merupakan aset informasi krusial yang dapat dibedah untuk meninjau efektivitas sistem sekaligus memperkuat mutu layanan digital yang ditawarkan.

2.3. Analisis Sentimen

Sebagai bagian dari bidang *Natural Language Processing* (NLP), analisis sentimen difungsikan untuk mengekstraksi dan mengenali opini yang terkandung dalam teks ulasan pengguna. Pendekatan ini telah diimplementasikan dalam berbagai studi, seperti pada evaluasi aplikasi PLN Mobile yang memanfaatkan metode regresi logistik (Bawazir dkk., 2025; Cahyani & Prasetyaningrum, 2026). Secara umum, sentimen tersebut dipilah ke dalam kelompok positif, negatif, serta netral (Liu, 2020). Bagi penyedia layanan digital, teknik ini sangat krusial dalam memetakan pandangan publik secara metodologis dan faktual.

2.4. Regresi Logistik

Regresi Logistik ialah suatu kerangka statistik yang difungsikan guna mengestimasi besarnya peluang terjadinya sebuah peristiwa biner (dua kemungkinan) dengan memanfaatkan sekumpulan variabel masukan yang ada. Dalam konteks *machine learning*, model ini tergolong sederhana namun efektif, terutama pada masalah klasifikasi dua kelas seperti positif dan negatif. Keunggulan Regresi Logistik adalah kemampuannya menangani data dimensi tinggi pada ulasan app, seperti terlihat pada klasifikasi sentimen ulasan Qpon dan e-commerce (Fahrurrozi & Hadianti, 2025; Febyanti dkk., 2026; Jurafsky, D. & Martin, 2024).

2.5. Pyspark

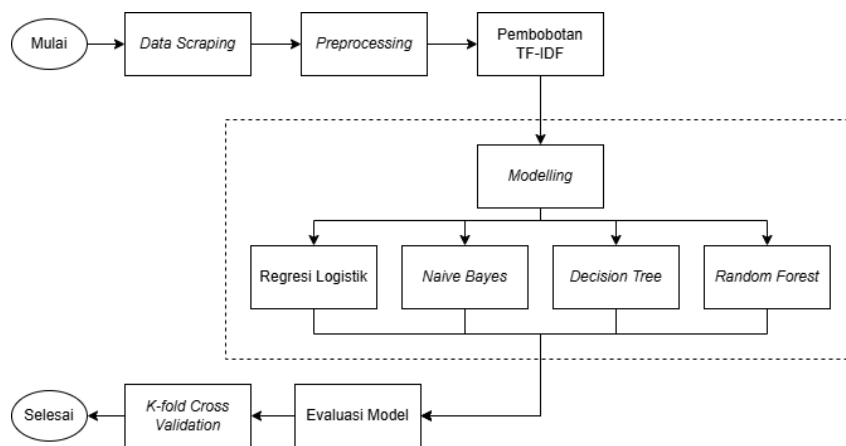
PySpark merupakan antarmuka Python untuk Apache Spark, yang merupakan sistem komputasi terdistribusi berskala besar. PySpark memungkinkan pemrosesan paralel data dalam jumlah besar secara efisien, sehingga sangat cocok digunakan dalam pengolahan *big data* yang berasal dari platform daring. (Zaharia dkk., 2016). Pemanfaatan PySpark dalam riset ini mencakup tahap konversi teks menjadi token (tokenisasi), ekstraksi fitur berbasis *Term Frequency–Inverse Document Frequency* (TF-IDF), hingga fase komputasi model. Algoritma seperti *Naive Bayes*, Regresi Logistik, dan *Decision Tree* diterapkan untuk menemukan model klasifikasi sentimen yang paling optimal

2.6. Sastrawi

Dalam mengolah teks berbahasa Indonesia, *library Sastrawi* digunakan sebagai instrumen utama untuk melakukan standarisasi data melalui teknik *stemming* dan *stopword removal*. Proses *stemming* berperan dalam mereduksi kata berimbuhan menjadi bentuk akarnya, sementara *stopword removal* berfungsi mengeliminasi kata-kata fungsional yang minim makna informatif (seperti "dan", "yang", atau "di"). Langkah-langkah ini krusial untuk meminimalisir gangguan (*noise*) serta mengonsolidasikan beragam variasi kata ke dalam satu konsep yang seragam. Merujuk pada penelitian Wati dkk. (2023) integrasi antara pembersihan teks berbasis *Sastrawi* dan pembobotan TF-IDF terbukti mampu mendongkrak performa akurasi model klasifikasi sentimen secara signifikan.

3. Metodologi

Rangkaian penelitian ini disusun melalui sejumlah tahapan terstruktur guna membedah sentimen para pengguna aplikasi mobile. Analisis tersebut dilakukan dengan memanfaatkan data ulasan yang dihimpun secara langsung dari platform Google Play Store. Metodologi terdiri atas enam tahap utama yaitu *data scraping*, *preprocessing*, pembobotan TF-IDF, *modelling*, evaluasi model, dan *k-fold cross validation*. Berikut penjelasan setiap tahap, yang dapat dilihat pada gambar 3.1:



Gambar 3.1. Diagram Alir Proses Penelitian

3.1. Data Scraping

Penelitian ini menggunakan ulasan aplikasi Kururio sebagai *dataset* utama yang diperoleh melalui teknik *scraping* pada platform Google Play Store. Dengan menyesuaikan parameter bahasa dan wilayah untuk pasar Indonesia, sekitar 1.020 ulasan berhasil dihimpun. Pada waktu pengambilan data (Mei 2025), aplikasi ini memiliki reputasi rating 3,3 dari total lebih dari 50 ribu instalasi. Seluruh informasi yang didapat kemudian disimpan dalam format tabel CSV untuk memfasilitasi tahapan *preprocessing*.

3.2. Preprocessing

Langkah *preprocessing* dilakukan guna memurnikan serta melakukan normalisasi pada teks ulasan sebelum memasuki fase pemodelan. Rangkaian proses ini mencakup eliminasi berbagai elemen yang tidak relevan, seperti tautan URL, angka, simbol tanda baca, serta emoji. Selain itu, karakter non-ASCII dan spasi yang tidak beraturan juga dibersihkan untuk memastikan data teks yang dihasilkan lebih konsisten. Setelah itu dilakukan normalisasi teks dan tokenisasi, serta *stop word removal* dan *stemming* yang dapat membantu menyederhanakan data dan menghilangkan *noise* sebelum pemodelan (Munna & Zuliarso, 2024). Proses pelabelan dilakukan dengan merujuk pada angka penilaian pengguna, di mana skor ≥ 4 diidentifikasi sebagai sentimen positif. Sebaliknya, ulasan yang memperoleh penilaian kurang dari 4 dikategorikan sebagai sentimen negatif untuk kebutuhan pemodelan.

3.3. Pembobotan TF-IDF

Pada penelitian ini, metode TF-IDF digunakan untuk menentukan bobot kata pada *dataset* ulasan pengguna. Melalui pendekatan ini, kata-kata yang muncul dalam ulasan dikonversi menjadi fitur numerik yang lebih bermakna, yang pada akhirnya membantu model dalam mengenali pola sentimen secara lebih efektif. TF-IDF efektif untuk vektorisasi ulasan app Indonesia, sebagaimana dievaluasi pada *review marketplace* dengan regresi

logistik (Fitriani dkk., 2026; Lestari & Hutagalung, 2025). Metode ini menentukan bobot dengan membandingkan frekuensi kata dalam dokumen terhadap prevalensinya di seluruh korpus. Tujuannya adalah untuk memperkuat peran kata-kata unik yang membawa makna sentimen kuat dan mengesampingkan kata-kata fungsional yang muncul secara masif. Vektor fitur yang diperoleh dari tahapan ini selanjutnya menjadi variabel prediktor dalam pemodelan Regresi Logistik (Yutika dkk., 2021).

3.4. Modelling

Proses pemodelan melibatkan perbandingan antara Regresi Logistik, *Naive Bayes*, *Decision Tree*, dan *Random Forest*. Algoritma-algoritma ini dipilih karena rekam jejaknya yang solid dalam literatur analisis sentimen, di mana setiap metode menawarkan keunggulan spesifik dalam hal akurasi prediksi serta kejelasan logika hasil klasifikasinya.

3.4.1. Regresi Logistik

Regresi Logistik didefinisikan sebagai pendekatan statistik yang bertujuan menelaah korelasi antara variabel dependen biner—yang mencakup dua kemungkinan kategori seperti "positif" atau "negatif"—dengan berbagai variabel independen. Inti dari metode ini terletak pada pemanfaatan fungsi distribusi logistik guna mentransformasi data menjadi nilai peluang dalam rentang 0 hingga 1. Skor probabilitas inilah yang menjadi dasar utama dalam menetapkan kategori atau klasifikasi akhir dari suatu data.

$$f(x) = \frac{\exp(\beta_0 + \beta_1 x_1 + \dots + \beta_i x_i)}{1 + \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_i x_i)} \quad (1)$$

$f(x)$: Proporsi terjadinya suatu kejadian
 β_0 : *Intercept*
 β_i : Koefisien regresi
 x_i : Nilai fitur ke- i

Regresi logistik cocok digunakan dalam klasifikasi karena mampu menangani data kategori maupun kontinu pada variabel *input*. Di samping itu, algoritma ini kerap diandalkan sebagai model acuan (*baseline*) dalam beragam riset analisis sentimen. Hal ini disebabkan oleh strukturnya yang tidak kompleks serta kapasitasnya dalam menyajikan penjelasan yang transparan mengenai kontribusi setiap fitur terhadap keputusan klasifikasi yang dihasilkan (Muntiari dkk., 2023).

3.4.2. Naive Bayes

Naive Bayes adalah algoritma *machine learning* yang berakar pada *teorema* probabilitas *Bayes*. Karakteristik utama dari metode ini adalah penggunaan asumsi "naif", di mana setiap fitur dalam *dataset* dianggap saling bebas atau tidak memiliki keterkaitan satu sama lain secara kondisional. Dalam praktiknya, model ini mengestimasi peluang keanggotaan suatu kelas dengan menganalisis distribusi fitur yang ditemukan pada data pengujian.

$$P(C_i|X) = \frac{P(X|C_i) \cdot P(C_i)}{P(X)} \quad (2)$$

$P(C_i|X)$: probabilitas posterior dari kelas C_i terhadap data fitur X_i
 $P(X|C_i)$: *likelihood* dari fitur X diberikan kelas C
 $P(C_i)$: probabilitas *prior* dari kelas C
 $P(X)$: probabilitas *prior* dari fitur X

3.4.3. Decision Tree

Dalam pengolahannya, *Decision Tree* menggunakan teknik partisi dataset ke dalam sejumlah subset. Algoritma ini mencari atribut yang paling signifikan untuk dijadikan titik percabangan, sehingga menghasilkan pemisahan kelas yang memiliki tingkat akurasi terbaik bagi model. Model ini membentuk struktur pohon, di mana setiap *node* internal merepresentasikan fitur, cabang merepresentasikan nilai dari fitur tersebut, dan *leaf node* (daun) mewakili kelas atau nilai prediksi.

$$Entropy(S) = - \sum_{i=1}^k p_i \log_2(p_i) \quad (3)$$

$Entropy(S)$: *Entropy* himpunan S
 S : Himpunan atau subset data
 k : Jumlah target kelas unik dalam himpunan S

p_i : Probabilitas contoh dari kelas ke- i dalam himpunan S

$$Gain(S, A) = Entropy(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} \cdot Entropy(S_v) \quad (4)$$

$Gain(S, A)$: Nilai Informasi Gain dari atribut A untuk himpunan S

$Values(A)$: Himpunan semua nilai unik dari atribut A

$Entropy(S)$: $Entropy$ himpunan S

$|S_v|$: Jumlah contoh dalam subset S_v

$|S|$: Jumlah total contoh dalam himpunan S

S_v : Subset dari S di mana S atribut A memiliki nilai v

3.4.4. Random Forest

Random Forest diimplementasikan sebagai algoritma *ensemble learning* yang mengandalkan teknik bagging (*Bootstrap Aggregating*). Metode ini mengonstruksi sekumpulan pohon keputusan secara acak, lalu mengintegrasikan hasil prediksinya melalui sistem voting mayoritas untuk menentukan kelas akhir. Pada setiap percabangan (node), atribut dipilih berdasarkan tingkat ketidakmurnian yang diukur melalui Indeks Gini guna memastikan setiap pohon memiliki struktur yang optimal.

$$Gini(S) = 1 - \sum_{i=1}^k p_i^2 \quad (5)$$

S : Himpunan data

k : Jumlah target kelas unik dalam himpunan S

p_i : Probabilitas contoh dari kelas ke- i dalam himpunan S

3.5. Evaluasi Model

Evaluasi terhadap hasil klasifikasi dilakukan melalui pendekatan *confusion matrix*, sebuah tabel evaluasi yang menyajikan frekuensi prediksi yang akurat maupun yang menyimpang. Elemen penyusunnya meliputi TP, TN, FP, dan FN, yang secara kolektif menggambarkan bagaimana model merespons setiap kategori sentimen. Data ini sangat krusial untuk mengevaluasi apakah model cenderung mengalami galat pada kelas tertentu. Penjelasan detail mengenai pembagian kelas ini dirangkum dalam Tabel 3.1.

Tabel 3.1. *Confusion Matrix* Evaluasi Output Data

	Predicted Negative	Predicted Positive
Actual Negative	True Positive (TP)	False Positive (FP)
Actual Positive	False Negative (FN)	True Negative (TN)

Tahap berikutnya melibatkan peninjauan mendalam melalui parameter akurasi, *precision*, *recall*, dan *F1-score*, yang secara kolektif berfungsi mengukur reliabilitas prediksi (Fernando dkk., 2024). Akurasi memberikan gambaran mengenai totalitas prediksi yang tepat. Di sisi lain, *precision* menitikberatkan pada validitas klasifikasi positif, sedangkan *recall* merepresentasikan efektivitas model dalam menjangkau seluruh data yang benar-benar positif. Sebagai penyeimbang, *F1-score* hadir sebagai rata-rata harmonik antara *precision* dan *recall*. Integrasi keempat metrik ini menjadi standar dalam studi sentimen untuk memastikan evaluasi performa model dilakukan secara menyeluruh (Andriyani dkk., 2025).

3.6. K-fold Cross Validation

Metode *K-Fold Cross-Validation* digunakan sebagai instrumen untuk memvalidasi keandalan model klasifikasi. Dalam prosedurnya, *dataset* dipecah menjadi beberapa *fold* berukuran sama, di mana setiap sub-bagian akan berperan sebagai data uji dalam iterasi yang berbeda. Proses ini memastikan bahwa setiap data memiliki kesempatan yang sama untuk diuji dan dilatih. Hasil akhir dari metode ini adalah perolehan rata-rata skor akurasi, *precision*, *recall*, dan *F1-score* yang lebih kokoh, meminimalisir bias yang mungkin muncul pada satu kali pembagian data (Irawan dkk., 2024).

4. Hasil dan Analisis

Pada tanggal 10 Juni 2025, dilakukan *scraping* data ulasan dari *Google Play Store* menggunakan *library google-play-scraper*. Parameter pengambilan data dikonfigurasi secara khusus untuk menjangkau komentar dalam

Bahasa Indonesia dengan pengaturan regional Indonesia. Dengan demikian, dataset yang diperoleh benar-benar merepresentasikan umpan balik dari pengguna lokal.. Setelah melakukan *scraping*, dilakukan *preprocessing* seperti penghapusan kolom yang tidak digunakan, penghapusan tanda baca, emoji, spasi berlebih, penghapusan *stopwords*, normalisasi teks, pelabelan sentimen 4 ke atas untuk sentimen positif dan 3 ke bawah untuk negatif, tokenisasi dan *stemming* dengan *library* sastrawi. *Output* dari *preprocessing* yang berupa data sentimen yang telah dibersihkan yang kemudian diubah menjadi *Data Frame* PySpark.

Penelitian ini membandingkan efektivitas empat model, yaitu Regresi Logistik, *Naive Bayes*, *Decision Tree*, dan *Random Forest*. Evaluasi ini difokuskan pada perolehan akurasi tertinggi dengan mempertahankan parameter bawaan (*default*) pada seluruh algoritma, sehingga dapat diketahui performa murni dari tiap model dalam menangani *dataset* ulasan aplikasi.. Berdasarkan hasil evaluasi akurasi, Regresi Logistik adalah model dengan akurasi yang tertinggi yaitu 0.8462.

Tabel 4.1. Tabel Perbandingan Performa Model-Model Berdasarkan Evaluasi Akurasi tanpa *Cross Validation*

Regresi Logistik	<i>Naive Bayes</i>	<i>Decision Tree</i>	<i>Random Forest</i>
0.8462	0.8333	0.6538	0.6090

Penelitian ini juga mencoba membandingkan 4 macam pembagian data pelatihan dan uji, yaitu 60:40, 70:30, 80:20, dan 90:10 menggunakan validasi silang *K-Fold* dengan *folds* berjumlah 5. Hasil yang didapatkan adalah perbandingan 70:30 adalah yang terbaik dengan akurasi yang paling tinggi yaitu 0.8269.

Tabel 4.2. Tabel Perbandingan Performa Regresi Logistik Pada berdasarkan Evaluasi Akurasi tanpa *Cross Validation*

60:40	70:30	80:20	90:10
0.7352	0.8269	0.7957	0.7447


Dari hasil percobaan perbandingan beberapa model dan beberapa pembagian data *train* dan *test*, penelitian ini menggunakan model Regresi Logistik dengan perbandingan 70:30 untuk hasil yang terbaik dengan *tuning hyperparameter* dan menggunakan validasi silang *K-Fold* dengan *folds* 3. Kombinasi *hyperparameter* untuk *HashingTF* (*numFeatures*) dan Regresi Logistik (*regParam*, *elasticNetParam*, *fitIntercept*, *standardization*) diuji menggunakan validasi silang *K-Fold* sebesar 3. Hasil evaluasi menunjukkan hasil paling baik dengan peningkatan akurasi dan hasil evaluasi seperti pada berikut:

Tabel 4.3. Tabel Hasil Evaluasi

Akurasi	F1-Score	<i>Precision</i>	<i>Recall</i>	ROC-AUC
0.8718	0.8693	0.8747	0.8718	0.9379

Kata-kata yang muncul dalam ulasan positif antara lain "bantu", "bagus", dan "mantap" sedangkan pada ulasan negatif muncul kata-kata seperti "gagal" dan "jelek". Visualisasi berupa *word cloud* dan bar *chart* frekuensi kata digunakan untuk mempermudah mengidentifikasi kata-kata positif dan negatif. Regresi Logistik dipilih sebagai model utama karena performanya yang paling baik di antara model-model lainnya saat dibandingkan berdasarkan evaluasi akurasi. Pemilihan *train* dan *test split* 70:30 dikarenakan evaluasi model dengan ditambahkan validasi silang menunjukkan performa terbaiknya dibandingkan 80:20 dan 90:10.

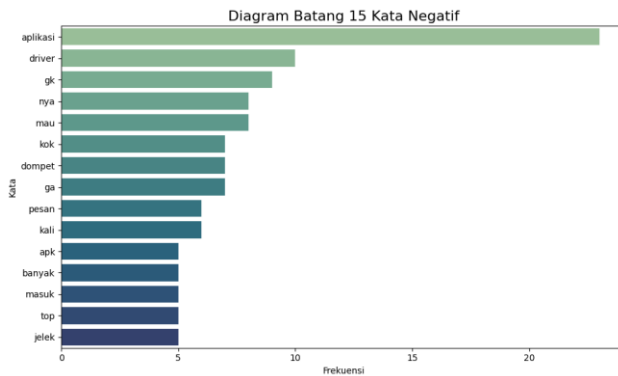
Analisis sentimen terhadap ulasan pengguna merupakan langkah awal dalam memahami kepuasan pelanggan, yang selanjutnya dapat ditindaklanjuti dengan integrasi layanan cerdas. Pemanfaatan teknologi berbasis *Natural Language Processing* (NLP) seperti *chatbot* terbukti mampu meningkatkan kualitas interaksi dan responsivitas layanan terhadap kebutuhan pengguna secara *real-time* (Satrio dkk., 2023).



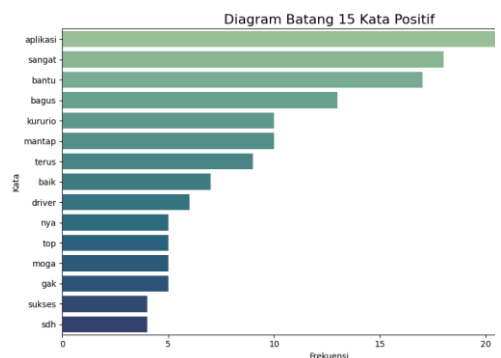
Gambar 4.1. Word Cloud Kata-kata Negatif



Gambar 4.2. Word Cloud Kata-kata Positif



Gambar 4.3. Diagram Batang Kata-kata Negatif



Gambar 4.4. Diagram Batang Kata-kata Positif

5. Kesimpulan dan Saran

Dari penelitian ini, dapat disimpulkan bahwa untuk mendapatkan model terbaik perlu menggunakan Regresi Logistik dengan perbandingan *train* dan *test* sebesar 70:30 dan menggunakan validasi silang untuk memastikan keakuratan yang optimal. Model berhasil melakukan klasifikasi sentimen positif (*rating* ≥ 4) dan negatif (*rating* < 4) dengan akurasi sebesar 87.18%, presisi sebesar 0.8747, F1-score sebesar 0.8693, *recall* dengan hasil 0.8718 yang secara kumulatif mengindikasikan efektivitas model yang sangat baik dalam diskriminasi sentimen biner.

Penelitian ini mencatat dominasi sentimen positif dalam ulasan Kururio, yang menandakan bahwa kepuasan pengguna terhadap aplikasi sebenarnya cukup tinggi. Dengan demikian, tertinggalnya popularitas Kururio dari para pesaingnya diduga kuat disebabkan oleh variabel luar, misalnya strategi penetapan pasar yang kurang masif atau pengalaman pengguna saat berinteraksi dengan mitra pengemudi. Oleh karena itu, disarankan agar tim pengembang Kururio tidak hanya fokus pada perbaikan teknis yang sering dikeluhkan, tetapi juga meningkatkan citra merek di luar aplikasi. Untuk studi mendatang, penggunaan pendekatan *deep learning* atau metode pemrosesan sentimen yang lebih canggih dapat dipertimbangkan untuk hasil yang lebih baik.

Daftar Pustaka:

- Andriyani, W., Astuti, Y., Wisesa, B. A., dan Hengki, H. (2025). Analisis sentimen pada ulasan produk dengan SVM dan Word2Vec. *JIKO (Jurnal Informatika dan Komputer)*, 9(1). <https://doi.org/10.26798/jiko.v9i1.1498>
- Bawazir, R. F., Purnamasari, R., dan Eliskar, Y. (2025). Analisis sentimen menggunakan algoritma Logistic Regression dan LDA (Latent Dirichlet Allocation) pada ulasan aplikasi PLN Mobile di Play Store. *Jurnal Teknik Informatika (JUTIF)*, 12(6), 8483.
- Cahyani, R. D., and Prasetyaningrum, P. T. (2026). Sentiment analysis of user reviews for AI applications: Evaluating SVM, Logistic Regression, and Random Forest. *Journal ISI: Implementasi Sistem Informasi dan Teknologi*, 8(1), 1–27. <https://doi.org/10.63158/journalisi.v8i1.1366>
- Christanti Mawardi, V., and Darmaja, E. (2023). Logistic Regression method for sentiment analysis application on Google Playstore. *International Journal of Application on Sciences, Technology and Engineering*, 1(1), 241–247. <https://doi.org/10.24912/ijaste.v1.i1.241-247>
- Fahrurrozi, N. A., dan Hadiani, S. (2025). Analisis sentiment ulasan produk e-commerce menggunakan metode

- Logistic Regression. *JUTIK: Jurnal Teknologi Informasi dan Komputer*, 11(1), 1–6.
- Febiyanti, I., Devi, A. S., Wardah, S., Wara, S. M., dan Damaliana, A. T. (2026). Klasifikasi sentimen ulasan pengguna aplikasi Qpon dengan Support Vector Machine dan Logistic Regression. *Journal of Data Science and Management Information Systems*, 4(1), 1–10. <https://doi.org/10.54259/jdmis.v4i1.4663>
- Fernando, R., Wibowo, S., dan Nugroho, A. (2024). Analisis sentimen ulasan pengguna aplikasi mobile JKN menggunakan metode machine learning. *ESTIMASI: Journal of Statistics and Its Application*, 5(1), 11–20. <https://doi.org/10.20956/ejsa.v6i2.44943>
- Fitriani, D., Pajri, A. E., dan Ardianti, A. D. (2026). Studi komparatif algoritma Random Forest dan Logistic Regression dalam analisis sentimen ulasan aplikasi e-wallet Dana. *JURIKOM (Jurnal Riset Komputer)*, 13(1), 296–304. <https://doi.org/10.30865/jurikom.v13i1.9517>
- Irawan, R. N., Hindrayani, K. M., dan Idhom, M. (2024). Penerapan cross validation sebagai analisis sentimen pelayanan publik kereta api lokal daop 8 menggunakan metode Multinomial Naïve Bayes. *G-Tech: Jurnal Teknologi Terapan*, 8(2), 1–10. <https://doi.org/10.33379/gtech.v8i2.4117>
- Jurafsky, D., and Martin, J. H. (2024). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition with language models* (3rd ed. draft). Prentice Hall.
- Lestari, V. B., and Hutagalung, C. A. (2025). Evaluation of TF-IDF extraction techniques in sentiment analysis of Indonesian-language marketplaces using SVM, Logistic Regression, and Naive Bayes. *Journal of Computer Science and Applications*, 8(1), 22–35. <https://doi.org/10.21009/j-psh.v8i1>
- Liu, B. (2020). *Sentiment analysis: Mining opinions, sentiments, and emotions* (2nd ed.). Cambridge University Press. <https://doi.org/10.1017/9781108639286>
- Maulana, A., Afifah, I. A., Mubarrak, A., Fauzan, K. R., Dwintara, A., dan Zen, B. P. (2023). Comparison of Logistic Regression, MultinomialNB, SVM, and K-NN methods on sentiment analysis of Gojek app reviews on the Google Play Store. *Jurnal Informatika*, 4(1), 1–12.
- Munna, A., dan Zuliarso, E. (2024). Interpretasi model stacking ensemble untuk analisis sentimen ulasan aplikasi pinjaman online menggunakan LIME. *AITI: Jurnal Teknologi Informasi*, 21(2), 183–196. <https://doi.org/10.24246/aiti.v21i2.183-196>
- Muntiari, N. R., Hanif, K. H., dan Nisa, I. C. (2023). Perbandingan algoritma Regresi Logistik, Support Vector Machine, dan Gradient Boosting pada analisis sentimen data komentar siswa. *Jurnal Ilmu Komputer dan Teknologi (IKOMTI)*, 4(2), 1–10. <https://doi.org/10.35960/ikomti.v4i2.1286>
- Rachmatullah, M. M., Irawan, B., Faqih, A., Pratama, D., dan Kurnia, D. A. (2024). Analisis komparatif Multinomial Naïve Bayes dan Logistic Regression untuk klasifikasi sentimen ulasan pengguna aplikasi TIX ID. *Jurnal Sistem Informasi Universitas Suryadarma*, 13(1), 62–70. <https://doi.org/10.35968/jsi.v13i1.1723>
- Rifa'i, A., Ardhani, R., Pratama, D., dan Fatihanursari, F. (2024). Analisis sentimen terhadap layanan aplikasi grab indonesia menggunakan metode Naïve Bayes. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(1), 1–10.
- Satrio, B., Rochim, A. F., dan Nugraheni, D. M. K. (2023). Mental health consultation information system using natural language processing based on expert system with forward chaining method. *AIP Conference Proceedings*, 2865(1), 50004. <https://doi.org/10.1063/5.0163351>
- Wati, R., Ernawati, S., dan Rachmi, H. (2023). Pembobotan TF-IDF menggunakan Naïve Bayes pada sentimen masyarakat mengenai isu kenaikan BIPIH. *Jurnal Manajemen Informatika (JAMIKA)*, 13(1), 1–10. <https://doi.org/10.34010/jamika.v13i1.9424>
- Yutika, C. H., Adiwijaya, A., dan Faraby, S. A. (2021). Analisis sentimen berbasis aspek pada review female daily menggunakan TF-IDF dan Naïve Bayes. *Jurnal Media Informatika Budidarma*, 5(2), 1–10. <https://doi.org/10.30865/mib.v5i2.2845>
- Zaharia, M., Xin, R. S., Wendell, P., Das, T., Armbrust, M., Dave, A., Meng, X., Rosen, J., Venkataraman, S., Franklin, M. J., Ghodsi, A., Gonzalez, J., Shenker, S., and Stoica, I. (2016). *Apache Spark: A unified engine for big data processing*. *Communications of the ACM*, 59(11), 56–65. <https://doi.org/10.1145/2934664>