

ANALISIS SENTIMEN APLIKASI SHOPEEPAY MENGUNAKAN *NAÏVE BAYES* DAN PEMODELAN TOPIK *LATENT DIRICHLET ALLOCATION*

Dinda Fatimah Sarah¹, Ulfa Khaira², Mutia Fadhila Putri³

1,2,3) Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Jambi, Indonesia

Article Info

Article history:

Received: 23 Mei 2025

Revised: 28 Mei 2025

Accepted: 01 Juni 2025

ABSTRACT

Abstrak

Gerakan Nasional Non-Tunai (GNNT) yang diluncurkan oleh Bank Indonesia telah mendorong pertumbuhan signifikan dalam penggunaan e-wallet sebagai alat pembayaran digital. ShopeePay menjadi salah satu platform dominan dengan penetrasi pasar mencapai 68%. Penelitian ini bertujuan menganalisis sentimen pengguna terhadap aplikasi ShopeePay serta menginterpretasi topik-topik sentimen yang dominan dalam ulasan pengguna. Metode yang digunakan adalah analisis sentimen dengan algoritma Naïve Bayes dan pemodelan topik menggunakan Latent Dirichlet Allocation (LDA) berdasarkan data ulasan Google Play Store periode Januari-Desember 2024. Hasil analisis menunjukkan akurasi model sebesar 89,70% dengan precision 82%, recall 86%, dan F1-score 84%. Dari 2.811 ulasan hasil preprocessing, model memprediksi 2.183 ulasan positif, sedangkan 628 ulasan negatif. Analisis topik mengungkap bahwa pengguna puas dengan kemudahan transaksi, keandalan sistem, dan kualitas layanan dengan koherensi 0,5157 pada kelompok topik 7, sementara keluhan utama terkait masalah teknis akun dan layanan pinjaman dengan nilai koherensi 0,3453 pada kelompok topik 10. Temuan ini memberikan rekomendasi bagi pengembang untuk meningkatkan kualitas layanan terkait penanganan isu teknis dan fitur pinjaman

Kata Kunci: ShopeePay, Naïve Bayes, Latent Dirichlet Allocation, Analisis sentimen

Abstract

The National Non-Cash Movement launched by Bank Indonesia has driven significant growth in the use of e-wallets as a digital payment. ShopeePay is one of the dominant platforms with market penetration 68%. This research aims to analyze user sentiment the ShopeePay application and interpret the dominant sentiment topics in user reviews. The method used is sentiment analysis with the Naïve Bayes and topic modeling Latent Dirichlet Allocation (LDA) based on Google Play Store review data for the period January-December 2024. The analysis results show the model accuracy 89.70%, precision 82%, recall 86%, and F1-score 84%. Of the 2,811 preprocessed reviews, the model predicted 2,183 positive, while 628 reviews were negative. Topic analysis revealed that users were satisfied with the ease of transactions, system reliability, and service quality with a coherence of 0.5157 in topic group 7, while the main complaints were related to account technical issues and loan services with a coherence value of 0.3453 in topic group 10. These findings provide recommendations for developers to improve service quality to handling technical issues and loan features.

Keywords: ShopeePay, Naïve Bayes, Latent Dirichlet Allocation, Sentiment Analysis

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi Internasional Creative Commons Attribution NonCommercial ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



Corresponding Author:E-mail : dhindajambi1047@gmail.com

1. PENDAHULUAN

Perkembangan sistem pembayaran digital di Indonesia telah mengalami transformasi signifikan sejak diluncurkannya Gerakan Non Tunai Nasional Bank Indonesia tahun 2014 [1]. Saat ini, terdapat 42 dompet digital terdaftar, dengan ShopeePay menempati posisi dominan (68% penetrasi pasar) berdasarkan riset NeuroSensum (2021). Fenomena ini didukung oleh tingginya adopsi internet yaitu 221,56 juta pengguna [2] dan transaksi digital 97% responden menggunakan e-wallet [3]. Salah satu aplikasi e-wallet yang banyak digunakan pengguna adalah ShopeePay. ShopeePay merupakan bagian dari SeaMoney, divisi layanan keuangan digital milik Sea Group yang menjadi salah satu layanan pembayaran digital yang mudah, aman, dan memuaskan. Untuk mengetahui kepuasan pengguna terhadap aplikasi e-wallet ShopeePay, penelitian ini akan menerapkan text mining dan pemodelan topik untuk mengetahui topik-topik yang teridentifikasi positif maupun negatif.

Text mining sebagai proses memperoleh pengetahuan dengan menganalisis kumpulan dokumen menggunakan berbagai alat, termasuk analisis sentimen yang meneliti opini individu dalam tulisan untuk memahami sentimen di baliknya dalam klasifikasi analisis sentimen terdapat beberapa metode [4], salah satunya adalah metode Naïve Bayes yang mengasumsikan bahwa setiap kejadian dalam sebuah kelas independen satu sama lain meskipun diberikan label yang sama [5], di mana cara kerjanya menggunakan probabilitas untuk menentukan kelas berdasarkan bagaimana kata-kata didistribusikan dalam dokumen, sehingga Naïve Bayes dipilih pada penelitian ini karena kemampuannya memberikan hasil yang baik dengan asumsi independensi fitur dan data latih yang relatif kecil [6].

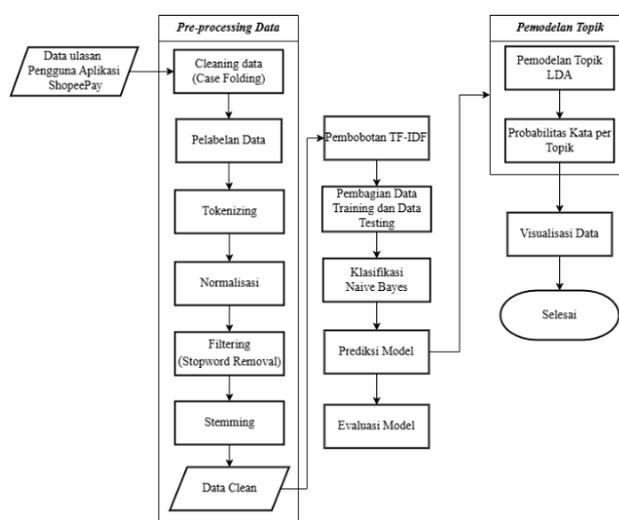
Latent Dirichlet Allocation (LDA) mengidentifikasi topik tersembunyi dalam dokumen ulasan, di mana setiap topik direpresentasikan sebagai distribusi kata-kata khas [7]. Pendekatan ini memungkinkan interpretasi topik baik pada ulasan positif maupun negatif. Berdasarkan jurnal yang dipublikasikan oleh [8], model probabilistik generatif yang dikenal sebagai Latent Dirichlet Allocation (LDA) menghasilkan topik dengan tingkat probabilitas tertentu.

Pada penelitian [7], menunjukkan bahwa Naïve Bayes memprediksi model mencapai akurasi 92% dan hasil analisis topik menggunakan LDA menunjukkan bahwa nilai koherensi yang lebih tinggi memudahkan interpretasi topik oleh manusia. Pada kelas positif, nilai koherensi tertinggi mencapai 0,613 pada topik optimal 8, sedangkan kelas negatif memperoleh 0,528 pada topik optimal 12.

Penelitian oleh [9], Naïve Bayes mampu mencapai akurasi sebesar 80% setelah resampling, dan metode LDA berhasil mengidentifikasi 17 topik utama termasuk administrasi, infrastruktur, dan informasi publik. penelitian berhasil memetakan prioritas perbaikan layanan. Penelitian ini akan menggunakan algoritma Naive Bayes untuk klasifikasi sentimen dan LDA untuk pemodelan topik kelas positif dan negatif. Hasil penelitian sebelumnya menunjukkan bahwa kombinasi kedua metode tersebut terbukti efektif dalam analisis sentimen.

Dari latar belakang diatas, peneliti merasa perlu melakukan analisis lebih lanjut terhadap ulasan pengguna ShopeePay di Google Play untuk mengetahui bagaimana opini pengguna terhadap aplikasi ShopeePay.

2. METODE PENELITIAN



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Pengumpulan data dilakukan dengan melakukan scraping data ulasan pengguna aplikasi ShopeePay. Package python yang digunakan untuk scraping data dari google play store adalah play scraper. Package ini memungkinkan untuk mengambil informasi

seperti nama aplikasi, peringkat, jumlah unduhan, ulasan pengguna, dan informasi lainnya tentang aplikasi yang terdaftar di google play store melalui Google Colab.

2.2. Preprocessing Data dan Pelabelan Data

2.2.1. Cleaning

Adapun proses yang dilakukan pada Cleaning menggunakan library Regular Expression (Regex) yang disingkat re. Cleaning data meliputi beberapa tahap, yaitu case folding, yang mengubah semua huruf dalam data menjadi huruf kecil. Menghapus single char atau karakter tunggal, digit atau nomor, mention, url. Remove punctuation, yang melibatkan penghapusan tanda baca hanya karakter huruf yang dipertahankan, menghapus karakter khusus atau emoji kemudian menghapus spasi berlebih.

Tabel 1. Hasil *Cleaning* Data

| No | <i>Dataset Mentah</i> | <i>Hasil Cleaning</i> |
|----|---|--|
| 1 | Aplikasi cacat, ga jelas. Masa gua gabisa verifikasi !! | aplikasi cacat ga jelas masa gua gabisa verifikasi |
| 3 | Mantappppp..... 👍👍👍👍👍 | mantappppp |

2.2.2. Pelabelan Data

Proses pelabelan data dilakukan secara manual oleh tim ahli dari Balai Bahasa Provinsi Jambi untuk memastikan validitas dan reliabilitas dalam analisis sentimen. Tujuan pelabelan adalah untuk membagi ulasan pengguna ShopeePay ke dalam dua kategori yaitu positif dan negatif.

2.2.3. Tokenizing

Tokenisasi adalah proses memotong kalimat dalam dokumen menjadi kata yang disebut "Token" yang dimasukkan ke dalam indeks untuk menangani kueri frasa, kedekatan, dan frekuensi munculnya [10]. Tahap ini membagi urutan karakter menjadi kalimat dan kemudian memecah kalimat tersebut menjadi token atau kata-kata.

Tabel 2. Hasil *Tokenizing*

| No | <i>Sebelum Tokenizing</i> | <i>Sesudah Tokenizing</i> |
|----|--|---|
| 1 | aplikasi cacat ga jelas masa gua gabisa verifikasi | ['aplikasi', 'cacat', 'ga', 'jelas', 'masa', 'gua', 'gabisa', 'verifikasi'] |
| 2 | Mantappppp | ['mantappppp'] |

2.2.4. Normalization

Pada tahap ini dilakukan *spelling normalization* (normalisasi ejaan) yang berguna untuk menyesuaikan kata-kata yang tidak sesuai dengan kata baku dengan standar bahasa yang berlaku, dan juga memperbaiki kata-kata yang salah ketik. Sebagai contoh, kata "buat" merupakan salah satu kata tidak baku yang akan dinormalisasikan menjadi kata "untuk". Pada penelitian ini menggunakan list data normalisasi yang telah dibuat dan dibahas oleh peneliti sebelumnya dengan dosen Bahasa Indonesia di salah satu Universitas Negeri di Indonesia [11], dan penulis menambahkan beberapa kata salah ketik menyesuaikan data penelitian ini.

Tabel 3. Hasil Normalisasi

| No | Sebelum Normalization | Sesudah Normalization |
|----|---|--|
| 1 | ['aplikasi', 'cacat', 'ga', 'jelas', 'masa', 'gua', 'gabisa', 'verifikasi'] | ['aplikasi', 'cacat', 'tidak', 'jelas', 'masa', 'aku', 'gabisa', 'verifikasi'] |
| 2 | ['mantappppp'] | ['mantap'] |

2.2.5. Stopword

Setelah tahap normalisasi, dilakukan penyaringan dengan menghapus kata-kata umum yang disebut *stopword*. Kamus yang digunakan dalam proses *filtering* ini menggunakan kamus *sastrawi* dan *stoplist* yang didapatkan dari penelitian sebelumnya [12]. Contoh *stopword* dalam bahasa Indonesia adalah "yang", "untuk", "pada", "ke", "namun", "menurut", "antara", "dia", dan lainnya. Menghapus *stopword* membantu meningkatkan efisiensi analisis teks dengan fokus pada kata yang lebih relevan.

Tabel 4. Hasil Stopword

| No | Sebelum Stopword | Sesudah Stopword |
|----|--|---|
| 1 | ['aplikasi', 'cacat', 'tidak', 'jelas', 'masa', 'aku', 'gabisa', 'verifikasi'] | ['aplikasi', 'cacat', 'gabisa', 'verifikasi'] |
| 2 | ['mantap'] | ['mantap'] |

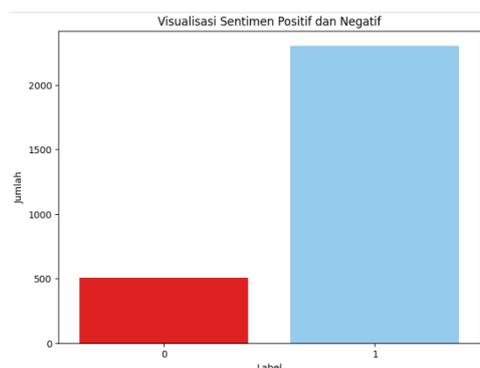
2.2.6. Stemming

Stemming merupakan tahap penghapusan imbuhan seperti awalan dan akhiran sehingga hanya tersisa inti dari kata tersebut, sehingga hanya kata dasar yang tersisa. Misalnya, "berguna" menjadi "guna" setelah *stemming*. *Library* yang digunakan yaitu kamus *sastrawi* yang merupakan kamus yang populer digunakan di lingkungan bahasa Indonesia.

Tabel 5. Hasil Stemming

| No | Sebelum Stemming | Sesudah Stemming |
|----|--|---|
| 1 | ['aplikasi', 'cacat', 'tidak', 'jelas', 'masa', 'aku', 'gabisa', 'verifikasi'] | ['aplikasi', 'cacat', 'gabisa', 'verifikasi'] |
| 2 | ['mantap'] | ['mantap'] |

Setelah proses *stemming* selesai, dilakukan pemeriksaan data kosong pada kolom yang akan digunakan untuk langkah selanjutnya yaitu kolom *stemming*. Tidak terdapat data kosong atau *NaN* pada data *stemming*, namun terdapat 189 baris data yang hanya berisi *string* kosong. Peneliti melakukan pergantian *string* kosong tersebut menjadi *NaN* agar memudahkan untuk menghapus baris data tersebut.



Gambar 2. Visualisasi Sentimen Setelah *Preprocessing*

2.3. TF-IDF

Metode Term Frequency-Inverse Document Frequency (TF-IDF) digunakan dalam penelitian ini untuk transformasi teks menjadi representasi numerik [13]. TF-IDF bekerja dengan menghitung bobot kata melalui dua komponen yaitu frekuensi relatif kata dalam dokumen diukur oleh Term Frequency (TF) dan Frekuensi Inverse Dokumen (IDF). Keunggulan TF-IDF pada kemampuannya menekan bobot kata umum sekaligus memperkuat kata kunci informatif, sehingga meningkatkan akurasi analisis sentimen. Dalam implementasinya, TF-IDF digunakan sebagai tahap ekstraksi fitur sebelum klasifikasi dengan Naïve Bayes, di mana vektor TF-IDF menjadi input untuk mengidentifikasi pola sentimen positif dan negatif.

Tabel 6. Rata-rata Kemunculan Kata Menggunakan TF-IDF

| Kata | Nilai TF-IDF |
|----------|--------------|
| mantap | 0.130274 |
| oke | 0.095864 |
| bagus | 0.088791 |
| bantu | 0.081414 |
| mudah | 0.049114 |
| aplikasi | 0.038202 |
| cepat | 0.020421 |
| baik | 0.019349 |
| keren | 0.019212 |
| bayar | 0.018332 |

2.4. Klasifikasi Naïve Bayes

Berdasarkan buku ajar tentang data mining oleh [5], keuntungan penggunaan algoritma Naïve Bayes karena variabel dianggap independen dan hanya membutuhkan varians suatu variabel dalam kelas, bukan matriks kovarians secara keseluruhan, estimasi parameter data latih relatif kecil untuk dilakukan selama proses klasifikasi. Selain itu, Naïve Bayes memungkinkan personalisasi pengklasifikasian dokumen dan dapat digunakan dalam masalah biner atau multiclass dengan kode yang sederhana. Kekurangan Naïve Bayes termasuk ketergantungan pada asumsi independensi antar variabel yang dapat menurunkan akurasi, serta potensi nilai probabilitas prediksi menjadi nol jika probabilitas kondisionalnya nol [14]. Keakuratan algoritma ini memerlukan pengujian lebih lanjut dan pengetahuan awal untuk keputusan yang akurat.

Pada penelitian ini setelah dilakukan TF-IDF, dataset dibagi menjadi rasio 80:20, 80% sebagai data latih dan 20% sebagai data uji. Mengatasi masalah tidak seimbang kelas antar ulasan positif dan negatif, penelitian ini menerapkan metode SMOTE (Synthetic Minority Over-sampling Technique) pada data latih untuk menghasilkan sampel sintetis pada kelas minoritas, sehingga mencegah terjadinya kebocoran data [15] [16]. Teknik ini mengatasi ketidakseimbangan data dengan menghasilkan data sintetis baru untuk kelas minoritas, sehingga dapat meningkatkan performa algoritma klasifikasi [17]. Model Naïve Bayes dibangun dengan mempelajari distribusi probabilitas kata-kata dalam setiap kelas sentimen terhadap data latih yang sudah diseimbangkan. Kemudian dilakukan pengujian model menggunakan data uji, dimana model akan memprediksi sentimen setiap ulasan berdasarkan perhitungan probabilitas kata-kata yang terkandung, kemudian memberikan label positif atau negatif sesuai hasil prediksi.

2.5. Evaluasi Model

Evaluasi kinerja model klasifikasi menggunakan confusion matrix yang membandingkan hasil prediksi model dengan nilai aktual [18]. Matrik ini mengukur empat parameter yaitu True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN) [19]. Berdasarkan matriks tersebut, dihitung empat metrik evaluasi yaitu accuracy untuk mengukur rasio prediksi benar secara keseluruhan, precision untuk menilai ketepatan prediksi positif, recall yang mengukur kemampuan menemukan semua kasus positif, serta f1-score sebagai harmonisasi precision dan recall. Berikut persamaan keempat metrik dibawah ini:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (4)$$

2.6. Pemodelan Topik *Latent Dirichlet Allocation*

LDA merupakan salah satu metode pemodelan topik yang mengidentifikasi topik dalam sebuah dokumen berdasarkan kata-kata di dalamnya. Kata-kata yang mewakili topik yang berbeda dapat ditemukan, sebagaimana ditunjukkan dalam tabel di mana setiap baris mewakili topik dan setiap kolom mewakili kata dalam korpus, dengan sel berisi probabilitas kata tersebut termasuk dalam topik tertentu. Untuk menemukan kata-kata yang mewakili sebuah topik, kata-kata dapat diurutkan berdasarkan nilai probabilitasnya. Kata-kata dengan nilai tertinggi dipilih untuk mewakili topik tersebut, misalnya dengan memilih 10 kata teratas. Jika korpus kecil, semua kata dalam urutan nilainya bisa disimpan. Sebagai alternatif, ambang batas pada skor dapat ditetapkan, dan semua kata yang memiliki nilai di atas ambang batas dapat disimpan sebagai representasi topik tersebut sesuai urutan nilainya [20].

Pada penelitian ini data yang telah melalui tahap preprocessing serta memiliki label prediksi dari model Naïve Bayes digunakan sebagai input. Untuk menilai kualitas setiap topik yang dihasilkan, digunakan perhitungan coherence score sebagai alat evaluasi objektif. Coherence score berfungsi untuk membedakan topik yang memiliki makna jelas dari topik yang kurang bermakna. Dalam implementasinya, proses komputasi dipercepat dengan menggunakan library Python seperti Gensim atau Scikit-learn. Hasil pemodelan LDA ini kemudian dianalisis untuk diinterpretasi topik-topik yang ditemukan untuk kelas positif dan negatif.

3. HASIL DAN PEMBAHASAN

3.1. Dataset

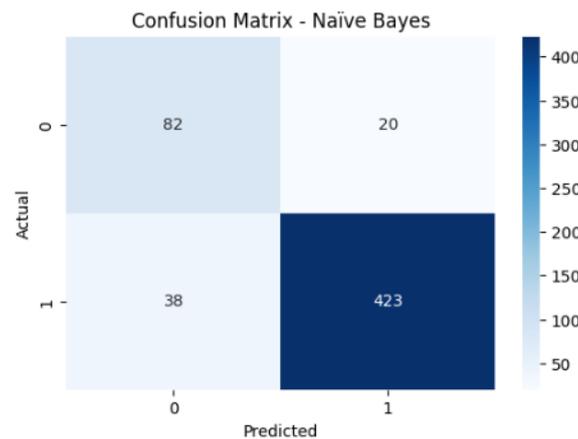
Sebanyak 45.743 baris data berhasil dikumpulkan, mencakup informasi seperti konten ulasan, rating, dan tanggal ulasan. Populasi penelitian ini adalah seluruh ulasan ShopeePay tahun 2024, dengan sampel sebanyak 3.000 ulasan berbahasa Indonesia yang dipilih melalui simple random sampling untuk memastikan keterwakilan data. Tahap pembersihan data meliputi seleksi periode Januari-Desember 2024, penghapusan data

duplikat dan missing value, serta penyaringan kolom yang relevan seperti content, at, dan score. Data kemudian dipersiapkan untuk tahap preprocessing yaitu cleaning data dahulu. Data yang sudah bersih digunakan untuk pelabelan data secara manual oleh tim ahli dari Balai Bahasa Provinsi Jambi. Setelah pelabelan selesai dilakukan tokenization, normalisasi, stopword removal, dan stemming. Hasil preprocessing menunjukkan bahwa hanya sebagian ulasan yang memenuhi syarat untuk analisis lebih lanjut. Dari seluruh data yang diolah, hanya 2.811 ulasan teridentifikasi memenuhi kriteria penelitian, dengan komposisi 2.303 ulasan (81.9%) bersentimen positif dan 508 ulasan (18.1%) bersentimen negatif. Langkah selanjutnya melakukan ekstraksi fitur dari data teks dengan TF-IDF dan dilanjutkan dengan membagi data dengan rasio 80:20, didapatkanlah 2.248 data latih dan 563 data uji. Data sentimen positif dan negatif memiliki jumlah data yang tidak seimbang di mana data kelas positif lebih banyak daripada data kelas negatif. Dikarenakan data latih lebih dominan pada satu kelas saja, imbalance data akan mempengaruhi hasil prediksi dari model yang dibuat. Untuk mengatasi masalah ini, teknik SMOTE atau menambah jumlah data pada kelas minoritas hingga jumlah data menjadi sama dengan kelas mayoritas[21] . Pembagian data setelah diterapkan hanya pada data latih adalah 1.842 kelas positif dan 1.842 kelas negative.

3.2. Klasifikasi Naïve Bayes

Model dibangun dengan algoritma Multinomial Naïve Bayes menggunakan data latih yang telah melalui SMOTE, sedangkan evaluasi performa dilakukan pada data uji asli tanpa penyeimbangan. Proses pelatihan model diawali dengan menghitung probabilitas awal masing-masing kelas sentimen, dilanjutkan dengan menghitung distribusi probabilitas setiap fitur kata dalam dokumen.

Setelah prediksi model didapatkan, perlu adanya proses mengevaluasi performa model. Pengujian model menggunakan confusion matrix untuk mengetahui performa model yang telah dilatih, terdapat 563 ulasan akan di uji berdasarkan accuracy, precision, recall, serta F1-score yang memberikan gambaran seimbang antara kedua metrik tersebut. Berdasarkan hasil evaluasi, model berhasil mengklasifikasikan dengan benar sebanyak 423 ulasan sebagai prediksi positif dan 82 ulasan sebagai prediksi negatif. Namun, terdapat kesalahan prediksi di mana 20 ulasan yang seharusnya positif terprediksi sebagai negatif (false positive), serta 38 data yang seharusnya negatif terprediksi sebagai positif (false negative).

Gambar 3. *Confusion Matrix*

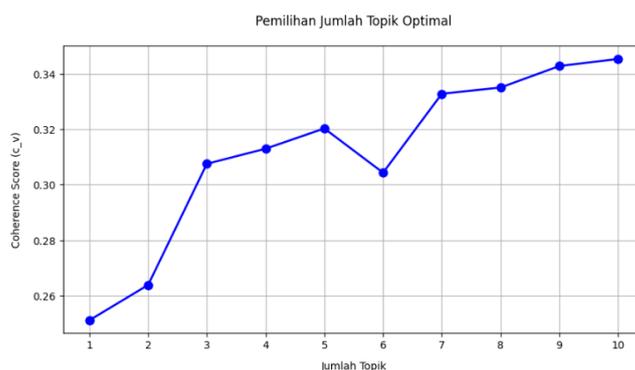
Hasil evaluasi model menunjukkan bahwa performa klasifikasi diukur menggunakan matriks confusion menghasilkan akurasi sebesar 89,70%, dengan presisi 82%, recall 86%, dan f1-Score 84%. Nilai-nilai matrik ini mengindikasikan bahwa untuk menganalisis sentimen ulasan aplikasi, algoritma Naïve Bayes menunjukkan kemampuan klasifikasi yang baik untuk aplikasi ShopeePay.

3.3. Pemodelan *Latent Dirichlet Allocation*

Pemodelan topik diterapkan secara terpisah untuk dua kelas, yaitu kelas positif dan negatif. Proses diawali dengan penyusunan dictionary dan corpus menggunakan dataset hasil random sampling yang telah melalui tahap preprocessing dan dilabeli oleh model klasifikasi Naïve Bayes, terdapat 2.183 ulasan positif dan 628 ulasan negatif. Pemodelan topik melalui pendekatan koherensi menunjukkan variasi kualitas interpretasi antar topik. Seperti terlihat pada **Gambar 4-5**, kelas positif mencapai nilai koherensi optimal pada kelompok ke-7 bernilai 0,5157, sementara kelas negatif mencapai nilai koherensi optimal kelompok ke-10 dengan nilai 0,3453. Tingginya nilai koherensi tertentu mengindikasikan bahwa kata-kata penyusun topik tersebut memiliki hubungan semantik yang kuat, sehingga lebih mudah diinterpretasikan.



Gambar 4. Uji Koherensi Kelas Positif



Gambar 5. Uji Koherensi Kelas Negatif

Dapat dilihat pada **Tabel 7**, terdapat 7 topik yang dapat diinterpretasikan untuk kelas positif yaitu topik “0” mengandung informasi terhadap aplikasi yang dinilai bagus, praktis, simpel, dan andal. Topik “1” mengandung informasi harapan pengguna agar aplikasi memberikan manfaat, kelancaran, dan kesuksesan, serta harapan dan dukungan. Topik “2” mengandung informasi mengenai kepuasan terhadap kemudahan penggunaan, terutama dalam pembayaran dan transaksi. Topik “3” mengandung informasi kepuasan pengguna secara umum terhadap aplikasi ShopeePay, terutama dalam hal kecepatan dan kemudahan pembayaran, dan pengalaman transaksi yang memuaskan. Topik “4” mengandung informasi bahwa aplikasi ShopeePay membantu dan menunjukkan keandalan aplikasi. Topik “5” mengandung informasi kepuasan pengguna terhadap kecepatan dan layanan, meskipun ada sedikit keluhan. Topik “6” mengandung informasi kemudahan bertransaksi, belanja, dan transfer uang. Secara umum, sentimen positif pengguna berpusat pada pengalaman mereka dalam hal kemudahan transaksi, keandalan sistem, kecepatan layanan, serta kepuasan menyeluruh terhadap fitur yang ditawarkan aplikasi

Tabel 7. Topik Kelas Positif

| Topik 0 | Topik 1 | Topik 2 | Topik 3 |
|----------|---------|---------|-------------|
| bagus | baik | mudah | oke |
| aplikasi | manfaat | keren | terimakasih |
| suka | moga | bayar | bantu |
| praktis | pokok | cepat | transaksi |
| simpel | ringan | kasih | mudah |
| andal | lancar | terima | pakai |
| khusus | sukses | aman | lumayan |
| senang | poin | rumah | hidup |
| tahan | cepat | kerja | cepat |
| perlu | serba | biar | beli |

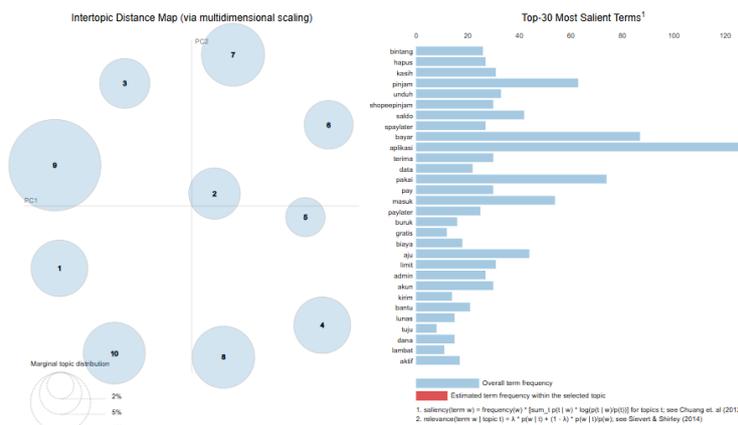
| Topik 4 | Topik 5 | Topik 6 |
|----------|---------|----------|
| mantap | puas | mudah |
| bantu | cepat | belanja |
| aplikasi | guna | aplikasi |

| | | |
|---------|----------|---------------|
| butuh | layan | transfer |
| amin | ribet | terimakasih |
| darurat | apa | layan |
| nyaman | aplikasi | alhamdulillah |
| masalah | moga | pay |
| akurat | amanah | usaha |
| takut | tingkat | uang |

Berdasarkan Tabel 8 dibawah, terdapat 10 topik yang dapat diinterpretasikan untuk kelas negatif yaitu topik “0” mengandung informasi keluhan terkait transaksi (pembayaran, saldo, paket) dan potensi masalah keamanan data atau ketidakjujuran. Topik “1” mengandung informasi mengenai biaya admin, penggunaan ShopeePayLater, dan masalah transfer dana. Topik “2” mengandung keluhan terkait saldo tidak masuk, pembayaran gagal, akun dibekukan, dan iklan yang mengganggu. Topik “3” mengandung informasi pengalaman buruk dengan layanan ShopeePayLater, termasuk transfer yang bermasalah dan biaya tak terduga. Topik “4” mengandung informasi mengenai keluhan terkait unduhan aplikasi, layanan ShopeePinjam, Topik “5” mengandung informasi keluhan terkait rating buruk, biaya tersembunyi, dan masalah pencairan dana. Topik “6” mengandung informasi keluhan seputar akun tidak aktif, masalah kuota, dan layanan ShopeePayLater dan ShopeePinjam. Topik “7” mengandung informasi keluhan akun dibekukan, masalah verifikasi, dan kesulitan dalam pengajuan layanan. Topik “8” mengandung informasi keluhan tentang keterlambatan pembayaran, limit pinjaman, dan penolakan transaksi. Topik “9” mengandung informasi keluhan kinerja aplikasi yang lambat, penghapusan akun, dan masalah transfer uang. Secara umum, sentimen negatif pengguna berkaitan dengan masalah transaksi seperti pembayaran gagal, saldo tidak masuk, dan akun dibekukan, serta layanan pinjaman yang rumit atau bermasalah.

Tabel 8. Topik Kelas Negatif

| Topik 0 | Topik 1 | Topik 2 | Topik 3 | Topik 4 |
|-----------|-----------|----------|----------|--------------|
| aplikasi | pakai | saldo | terima | unduh |
| saldo | admin | masuk | kasih | shopeepinjam |
| pay | spaylater | ribu | buruk | gratis |
| data | terima | lunas | transfer | spaylater |
| ribu | aplikasi | iklan | paylater | saldo |
| paket | biaya | aplikasi | kali | aju |
| kasih | aju | tagih | bayar | aplikasi |
| bayar | tau | beku | pulsa | tujuan |
| transaksi | transfer | gagal | pakai | pay |
| bohong | kali | tolak | uang | mantap |
| Topik 5 | Topik 6 | Topik 7 | Topik 8 | Topik 9 |
| bintang | aplikasi | aplikasi | bayar | aplikasi |



Gambar 9. Visualisasi Topik Kelas Positif

4. SIMPULAN

Berdasarkan hasil penelitian analisis sentimen menggunakan metode Naïve Bayes serta pemodelan topik dengan metode LDA pada aplikasi ShopeePay. Berdasarkan hasil analisis diperoleh 2.811 ulasan setelah di preprocessing dengan pembagian label berdasarkan prediksi model 2.183 kelas positif dan 628 kelas negatif. Sehingga dapat disimpulkan bahwa lebih banyak pengguna aplikasi ShopeePay memberikan ulasan positif dibandingkan negatif. Hasil pengujian Naïve Bayes menunjukkan performa yang baik dengan akurasi mencapai 89,70%, didukung oleh nilai precision 82%, recall 86%, dan f1-Score 84%. Sedangkan hasil pemodelan topik dengan LDA mengungkapkan bahwa ulasan positif terutama terkait dengan kemudahan transaksi, keandalan sistem, dan kualitas dengan nilai koherensi 0,5157 pada topik kelompok ke-7. Sementara itu, ulasan negatif membahas masalah teknis seperti kendala akun, limit pinjaman, dan masalah pada fitur ShopeePayLater dan ShopeePinjam dengan nilai koherensi 0,3453 pada topik kelompok ke-10.

REFERENCES

- [1] Bank Indonesia, "Elektronifikasi," BankIndonesia. Accessed: Nov. 19, 2024. [Online]. Available: <https://www.bi.go.id/id/fungsi-utama/sistem-pembayaran/ritel/elektronifikasi/default.aspx>
- [2] Asosiasi Penyelenggara Jasa Internet Indonesia, "Survei Penetrasi Internet Indonesia 2024," Feb. 2024. Accessed: Oct. 17, 2024. [Online]. Available: <https://apjii.or.id/berita/d/apjii-jumlah-pengguna-internet-indonesia-tembus-221-juta-orang>
- [3] Jakmin, "Metode Pembayaran Mana yang Paling Populer untuk Membeli Makanan?," <https://jakpat.net/info/metode-pembayaran-mana-yang-paling-populer-untuk-membeli-makanan/>. Accessed: Oct. 18, 2024. [Online]. Available: <https://jakpat.net/info/metode-pembayaran-mana-yang-paling-populer-untuk-membeli-makanan/>
- [4] B. Liu, "Sentiment Analysis and Opinion Mining," Morgan & Claypool Publishers, 2012.
- [5] A. Wanto *et al.*, *Data Mining : Algoritma dan Implementasi*. YayasanKitaMenulis, 2020.
- [6] M. I. Fikri, T. S. Sabrila, and Y. Azhar, "Perbandingan Metode Naïve Bayes dan Support Vector Machine pada Analisis Sentimen Twitter," *SMATIKA JURNAL*, vol. 10, no. 02, pp. 71–76, Dec. 2020, doi: 10.32664/smatika.v10i02.455.

- [7] N. L. P. Merawati, A. Z. Amrullah, and Ismarmiaty, "Analisis Sentimen dan Pemodelan Topik Pariwisata Lombok Menggunakan Algoritma Naive Bayes dan Latent Dirichlet Allocation," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 1, pp. 123–131, Feb. 2021, doi: 10.29207/resti.v5i1.2587.
- [8] E. S. Asyhar, S. H. Wijoyo, and N. Y. Setiawan, "Analisis Sentimen dan Pemodelan Topik Terhadap Ulasan Aplikasi Jenius Menggunakan Metode Support Vector Machine dan Latent Dirichlet Allocation," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 1, no. 1, pp. 1–10, Jan. 2017, Accessed: Nov. 17, 2024. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/download/14100/6294/100083>
- [9] F. Atmaja, Agussalim, and E. Dyar Wahyuni, "Analisis Sentimen Berbasis Aspek Pada Sistem Layanan Pengaduan Masyarakat Di Kota Surabaya Menggunakan Metode Latent Dirichlet Allocation Dan Naïve Bayes," *Jurnal Mahasiswa Teknik Informatika*, vol. 9, no. 1, pp. 527–534, Feb. 2025, Accessed: Oct. 18, 2024. [Online]. Available: <https://ejournal.itn.ac.id/index.php/jati/article/view/12438>
- [10] C. D. Manning, P. Raghavan, and H. Schütze, *An Introduction to Information Retrieval*. England, 2009. Accessed: Mar. 06, 2025. [Online]. Available: <https://nlp.stanford.edu/IR-book/pdf/irbookonlinereading.pdf>
- [11] A. A. Putri, "Text Preprocessing," GitHub. Accessed: Mar. 07, 2025. [Online]. Available: <https://github.com/adeariniputri/text-preprocesing/blob/master/kamus.txt>
- [12] F. Z. Tala, "A Study of Stemming Effects on Information Retrieval in Bahasa Indonesia," Amsterdam. Accessed: May 04, 2025. [Online]. Available: <https://eprints.illc.uva.nl/id/eprint/740/1/MoL-2003-02.text.pdf>
- [13] P. W. Rahayu *et al.*, *Buku Ajar Data Mining*. PT. Sonpedia Publishing Indonesia, 2024. [Online]. Available: <https://www.researchgate.net/publication/377415198>
- [14] M. H. Widiyanto, "Algoritma Naive Bayes," BinusUniversity.
- [15] M. P. Pulungan, A. Purnomo, and A. Kurniasih, "Penerapan SMOTE untuk Mengatasi Imbalance Class dalam Klasifikasi Kepribadian MBTI Menggunakan Naive Bayes Classifier," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 5, pp. 1033–1042, Oct. 2024, doi: 10.25126/jtiik.2024117989.
- [16] A. F. Anjani, D. Anggraeni, and I. M. Tirta, "Implementasi Random Forest Menggunakan SMOTE untuk Analisis Sentimen Ulasan Aplikasi Sister for Students UNEJ," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 9, no. 2, pp. 163–172, Sep. 2023, doi: 10.25077/teknosi.v9i2.2023.163-172.
- [17] C. Cahyaningtyas, Y. Nataliani, and I. R. Widiyari, "Analisis sentimen pada rating aplikasi Shopee menggunakan metode Decision Tree berbasis SMOTE," *AITI: Jurnal Teknologi Informasi*, vol. 18, pp. 173–184, Aug. 2021, Accessed: Apr. 13, 2025. [Online]. Available: <https://ejournal.uksw.edu/aiti/article/view/5151/2000>
- [18] K. S. Nugroho, "Confusion Matrix untuk Evaluasi Model pada Supervised Learning," Medium. Accessed: Nov. 18, 2024. [Online]. Available: <https://ksnugroho.medium.com/confusion-matrix-untuk-evaluasi-model-pada-unsupervised-machine-learning-bc4b1ae9ae3f>
- [19] K. Anam, A. R. Rinaldi, and Fathurrohman, "Komparasi Algoritma Machine Learning Dalam Klasifikasi Loyalitas Nasabah Bank Berbasis Particle Swarm Optimization," *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 4, pp. 8212–8218, Aug. 2024, Accessed: May 22, 2025. [Online]. Available: <https://ejournal.itn.ac.id/index.php/jati/article/download/10941/6105/>
- [20] R. Kulshrestha, "A Beginner's Guide to Latent Dirichlet Allocation(LDA)," *TowardDataScience*. Accessed: Nov. 17, 2024. [Online]. Available: <https://towardsdatascience.com/latent-dirichlet-allocation-lda-9d1cd064ffa2>
- [21] F. Destiyanti, A. I. Hadiana, and F. R. Umbara, "Penerapan Metode Support Vector Machine dan SMOTE untuk Klasifikasi Sentimen Publik Terhadap Polisi Republik Indonesia," *JUMANJI*, vol. 8, no. 1, pp. 1–15, Apr. 2024, Accessed: May 22, 2025. [Online]. Available: <https://jumanji.unjani.ac.id/index.php/jumanji/article/view/336>