

A Comparative Analysis Of User Sentiment And Review Patterns On The Dana And Seabank Apps Using The Naive Bayes, Support Vector Machine And Logistic Regression Algorithms

Analisis Komparatif Sentimen Dan Pola Ulasan Pengguna Aplikasi Dana Dan Seabank Menggunakan Algoritma Naive Bayes, Support Vector Machine, Dan Logistic Regression

Nur Ayu Siti Hardianti ¹⁾; Dedy Abdullah ²⁾

¹⁾Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Bengkulu

²⁾ Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Bengkulu

Email: ¹⁾(hardiantiayu538@gmail.com ,²⁾ dedy_abdullah@umb.ac.id

How to Cite :

Hardianti, N, A, S., Abdullah, D. (2026). A Comparative Analysis of User Sentiment and Review Patterns on The Dana and Seabank Apps Using The Naive Bayes, Support Vector Machine and Logistic Regression Algorithms. Jurnal Media Computer Science, 5(3).

ARTICLE HISTORY

Received [19 Juni 2026]

Revised [20 Juli 2026]

Accepted [23 Juli 2026]

KEYWORDS

Sentiment Analysis, DANA, SeaBank, Naive Bayes, Support Vector Machine, Logistic Regression, Fintech, Machine Learning.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license



ABSTRAK

Perkembangan teknologi finansial (fintech) di Indonesia telah mendorong peningkatan signifikan penggunaan aplikasi keuangan digital, terutama e-wallet dan bank digital. Aplikasi DANA sebagai representasi layanan e-wallet dan SeaBank sebagai representasi layanan bank digital telah menarik jutaan pengguna dengan karakteristik layanan yang berbeda. Perbedaan karakteristik layanan tersebut berpotensi menghasilkan pola sentimen dan ulasan pengguna yang berbeda pula. Penelitian ini difokuskan pada analisis dan perbandingan sentimen serta karakteristik ulasan pengguna aplikasi DANA dan SeaBank dengan menerapkan tiga algoritma *machine learning*, yaitu *Naive Bayes*, *Support Vector Machine (SVM)*, dan *Logistic Regression*. Data penelitian berupa ulasan pengguna diperoleh dari Google Play Store, kemudian melalui serangkaian tahapan *text preprocessing* yang mencakup *case folding*, tokenisasi, *stopword removal*, dan *stemming*. Selanjutnya, representasi fitur teks dibangun menggunakan metode *Term Frequency-Inverse Document Frequency (TF-IDF)* sebelum proses klasifikasi dilakukan ke dalam tiga kategori sentimen, yaitu positif, negatif, dan netral. Kinerja masing-masing model dievaluasi berdasarkan metrik akurasi, presisi, *recall*, dan *F1-score* untuk mengukur efektivitas klasifikasi. Melalui analisis komparatif tersebut, penelitian ini diharapkan mampu menyajikan gambaran yang komprehensif mengenai perbedaan kecenderungan sentimen pengguna pada kedua jenis layanan *fintech*, sekaligus menentukan algoritma *machine learning* yang memiliki performa paling optimal dalam analisis sentimen ulasan aplikasi keuangan digital. Selain memberikan kontribusi akademis pada bidang analisis sentimen berbasis *machine learning*, hasil penelitian ini juga diharapkan dapat dimanfaatkan sebagai bahan evaluasi bagi pengembang aplikasi serta menjadi sumber informasi yang bermanfaat bagi pengguna.

ABSTRACT

The development of financial technology (fintech) in Indonesia has driven a significant increase in the use of digital financial applications, particularly e-wallets and digital banks. The DANA application as a representative of e-wallet services and SeaBank as a representative of digital banking services have attracted millions of users with different service characteristics. These differences in service characteristics potentially generate different patterns of user sentiment and reviews. This study aims to analyze and compare user sentiment and review patterns of the DANA and SeaBank applications using three machine learning algorithms: Naive Bayes, Support Vector Machine (SVM), and Logistic Regression. User review data were collected from the Google Play Store and processed through text preprocessing stages including case folding, tokenization, stopword removal, and stemming. Text features were extracted using the TF-IDF method before being classified into positive, negative, and neutral sentiment categories. Model performance evaluation was conducted using accuracy, precision, recall, and F1-score metrics. The comparative analysis results are expected to provide a comprehensive overview of differences in user sentiment based on the type of fintech service, while also identifying the most optimal machine learning algorithm for sentiment analysis of digital financial application reviews.

PENDAHULUAN

Kemajuan teknologi digital telah membawa transformasi besar dalam sektor keuangan global, termasuk di Indonesia. Hadirnya financial technology (fintech) secara signifikan mengubah cara masyarakat mengakses dan memanfaatkan berbagai layanan keuangan. Fintech menawarkan solusi inovatif yang mengintegrasikan teknologi informasi ke dalam layanan keuangan, sehingga memungkinkan transaksi dilakukan dengan lebih praktis, efisien, dan cepat melalui perangkat mobile. Sebagai salah satu negara dengan pertumbuhan ekonomi digital tercepat di Asia Tenggara, Indonesia memiliki potensi pasar yang sangat besar bagi industri fintech.

Di antara berbagai platform fintech yang berkembang pesat di Indonesia, aplikasi DANA dan SeaBank telah berhasil menarik perhatian jutaan pengguna. DANA hadir sebagai layanan e-wallet atau dompet digital yang menekankan kemudahan dalam pembayaran digital dan transfer dana. Sementara itu, SeaBank merupakan representasi dari layanan bank digital yang menawarkan produk perbankan lengkap melalui platform digital tanpa kehadiran fisik kantor cabang. Keduanya mewakili dua model bisnis fintech yang berbeda, sehingga perbandingan pengalaman dan kepuasan pengguna berdasarkan karakteristik masing-masing layanan menjadi sangat relevan untuk dikaji.

Ulasan pengguna pada platform distribusi aplikasi seperti Google Play Store merupakan sumber data yang kaya dan representatif untuk memahami persepsi, pengalaman, serta kepuasan pengguna terhadap suatu aplikasi. Besarnya volume ulasan pada kedua aplikasi tersebut menjadikannya sumber data yang ideal untuk analisis sentimen berbasis machine learning. Namun demikian, analisis ulasan secara manual dalam jumlah besar merupakan pekerjaan yang tidak efisien dan membutuhkan waktu yang sangat lama. Oleh karena itu, pendekatan otomatis yang mampu mengklasifikasikan sentimen dari ulasan pengguna secara efisien dan akurat sangat diperlukan.

Analisis sentimen merupakan salah satu cabang dari Natural Language Processing (NLP) yang bertujuan mengidentifikasi dan mengekstraksi opini subjektif dari teks, yang kemudian diklasifikasikan ke dalam kategori sentimen seperti positif, negatif, atau netral. Teknik analisis sentimen telah banyak diimplementasikan pada berbagai domain, mulai dari analisis ulasan produk, analisis opini di media sosial, hingga penilaian kepuasan pengguna aplikasi mobile. Perkembangan algoritma machine learning membuka peluang baru untuk analisis sentimen yang lebih akurat dan skalabel dibandingkan metode berbasis leksikon.

Beberapa algoritma machine learning terbukti efektif dalam tugas klasifikasi teks, termasuk analisis sentimen. Naive Bayes merupakan algoritma probabilistik yang sederhana namun efektif, banyak digunakan dalam analisis sentimen ulasan aplikasi karena kemudahan implementasi dan kecepatan komputasinya. Support Vector Machine (SVM) bekerja dengan mencari hyperplane optimal untuk memisahkan kelas-kelas data dan menunjukkan performa unggul dalam berbagai tugas klasifikasi teks. Sementara itu, Logistic Regression merupakan algoritma klasifikasi yang menggunakan fungsi logistik untuk memodelkan probabilitas kelas dan terbukti kompetitif dalam tugas analisis sentimen. Perbandingan ketiga algoritma ini diharapkan menghasilkan gambaran komprehensif mengenai pendekatan terbaik untuk analisis sentimen ulasan aplikasi fintech.

Beberapa penelitian terdahulu telah mengkaji analisis sentimen pada berbagai aplikasi fintech maupun digital. Saputro et al. menerapkan metode SVM untuk analisis sentimen pengguna dompet digital DANA dan memperoleh hasil yang cukup memuaskan. Rifa et al. [18] membandingkan sentimen pengguna e-wallet DANA dan GoPay menggunakan SVM melalui data Twitter. Hondro menganalisis sentimen pengguna aplikasi e-wallet DANA melalui media sosial Twitter dengan metode Naive Bayes. Sementara itu, Putri et al. melakukan analisis sentimen khusus pada aplikasi SeaBank menggunakan Naive Bayes untuk tujuan optimalisasi pelayanan. Meskipun demikian, penelitian yang secara khusus membandingkan sentimen pengguna antara e-wallet DANA dan bank digital SeaBank secara bersamaan menggunakan tiga algoritma machine learning masih belum banyak dilakukan, sehingga penelitian ini hadir untuk mengisi celah tersebut.

Penelitian ini bertujuan menganalisis dan membandingkan sentimen serta pola ulasan pengguna aplikasi DANA dan SeaBank menggunakan algoritma Naive Bayes, Support Vector Machine, dan Logistic Regression, serta mengidentifikasi algoritma yang memberikan performa terbaik untuk kasus analisis sentimen aplikasi fintech. Pemilihan kedua aplikasi ini didasarkan pada fakta bahwa DANA dan SeaBank mewakili dua jenis layanan fintech yang berbeda, yaitu e-wallet dan bank digital, sehingga memungkinkan analisis komparatif terhadap perbedaan sentimen dan pola ulasan berdasarkan karakteristik layanan. Selain itu, kedua aplikasi ini memiliki jumlah pengguna dan ulasan yang besar di Google Play Store, sehingga data yang diperoleh cukup representatif untuk analisis sentimen berbasis machine learning.

LANDASAN TEORI

Financial Technology (Fintech)

Financial technology atau fintech adalah inovasi di bidang layanan keuangan yang memanfaatkan teknologi digital untuk memberikan kemudahan, kecepatan, dan efisiensi dalam transaksi keuangan. Fintech mencakup berbagai layanan mulai dari pembayaran digital, pinjaman online, investasi, asuransi, hingga perbankan digital. Di Indonesia, perkembangan fintech didorong oleh tingginya penetrasi smartphone dan meningkatnya akses internet di seluruh wilayah. Otoritas Jasa Keuangan (OJK) sebagai regulator telah menetapkan berbagai kerangka regulasi untuk mendukung ekosistem fintech yang sehat dan terpercaya.

Dua kategori utama fintech yang menjadi fokus penelitian ini adalah e-wallet dan bank digital. E-wallet atau dompet digital adalah platform penyimpanan uang elektronik yang memungkinkan pengguna melakukan pembayaran, transfer uang, dan berbagai transaksi keuangan secara digital melalui aplikasi mobile [3]. Bank digital, di sisi lain, adalah lembaga perbankan yang beroperasi sepenuhnya melalui platform digital tanpa kehadiran fisik kantor cabang konvensional, namun tetap menawarkan layanan perbankan lengkap seperti tabungan, pinjaman, dan investasi.

Aplikasi DANA

Financial technology atau fintech merupakan inovasi di bidang layanan keuangan yang memanfaatkan teknologi digital untuk memberikan kemudahan, kecepatan, dan efisiensi dalam transaksi keuangan. Fintech mencakup berbagai layanan mulai dari pembayaran digital, pinjaman online, investasi, asuransi, hingga perbankan digital. Di Indonesia, pertumbuhan fintech didorong

oleh tingginya penetrasi smartphone dan meningkatnya aksesibilitas internet di seluruh wilayah. Otoritas Jasa Keuangan (OJK) selaku regulator telah menetapkan berbagai kerangka regulasi guna mendukung ekosistem fintech yang sehat dan terpercaya.

Dua kategori utama fintech yang menjadi fokus dalam penelitian ini adalah e-wallet dan bank digital. E-wallet atau dompet digital adalah platform penyimpanan uang elektronik yang memungkinkan penggunanya melakukan berbagai transaksi keuangan secara digital melalui aplikasi mobile, termasuk pembayaran dan transfer uang. Di sisi lain, bank digital adalah lembaga perbankan yang beroperasi sepenuhnya melalui platform digital tanpa memerlukan kantor cabang fisik, namun tetap menyediakan layanan perbankan lengkap seperti tabungan, pinjaman, dan investasi.

Aplikasi DANA

DANA merupakan aplikasi dompet digital yang resmi diluncurkan di Indonesia pada tahun 2018, sebagai hasil kolaborasi antara Emtek Group dan Ant Financial (Alibaba Group). DANA menyediakan beragam layanan keuangan digital, di antaranya pembayaran merchant, transfer dana antara pengguna, pembayaran tagihan, pembelian pulsa dan data, serta berbagai layanan keuangan lainnya. Sebagai salah satu e-wallet dengan pengguna aktif terbesar di Indonesia, DANA tersedia secara luas di Google Play Store maupun App Store. Keunggulan utama DANA terletak pada antarmuka yang ramah pengguna, jaringan merchant yang luas, serta fitur DANA Bisnis yang mendukung kebutuhan transaksi pelaku usaha.

Aplikasi SeaBank

SeaBank Indonesia adalah bank digital yang bernaung di bawah Sea Group, sebuah perusahaan teknologi asal Singapura yang juga mengelola platform e-commerce Shopee dan platform game Garena. SeaBank beroperasi sebagai bank umum berbasis teknologi yang menawarkan layanan tabungan dengan bunga kompetitif, pinjaman, serta berbagai produk perbankan digital lainnya. Keunggulan kompetitif SeaBank terletak pada integrasinya dengan ekosistem Sea Group, khususnya Shopee, sehingga memberikan nilai tambah bagi pengguna yang aktif dalam ekosistem tersebut. Berdasarkan model bisnis yang diterapkan, SeaBank menghadirkan pendekatan perbankan yang lebih terjangkau dan mudah diakses dibandingkan bank konvensional.

Analisis Sentimen

Analisis sentimen atau opinion mining adalah proses komputasional untuk mengidentifikasi, mengekstraksi, dan menganalisis opini, sentimen, evaluasi, sikap, serta emosi seseorang terhadap suatu entitas tertentu, seperti produk, layanan, organisasi, ataupun individu, yang diungkapkan melalui teks. Analisis sentimen umumnya mengklasifikasikan teks ke dalam kategori sentimen positif, negatif, atau netral. Dalam konteks ulasan aplikasi mobile, analisis sentimen dapat membantu pengembang memahami persepsi pengguna secara otomatis dari data ulasan yang tersedia di platform distribusi aplikasi. Proses analisis sentimen umumnya melibatkan beberapa tahapan utama, yaitu pengumpulan data, preprocessing teks, ekstraksi fitur, pelatihan model klasifikasi, dan evaluasi model. Tahapan preprocessing teks pada bahasa Indonesia mencakup case folding (pengubahan huruf menjadi huruf kecil), tokenisasi (pemecahan kalimat menjadi token kata), normalisasi kata tidak baku, stopword removal (penghapusan kata yang tidak bermakna), dan stemming (pengubahan kata ke bentuk dasarnya) menggunakan algoritma seperti Sastrawi.

Term Frequency-Inverse Document Frequency (TF-IDF)

TF-IDF adalah metode pembobotan kata yang umum digunakan dalam pengolahan teks untuk merepresentasikan dokumen sebagai vektor numerik. TF (Term Frequency) mengukur seberapa sering suatu kata muncul dalam sebuah dokumen, sementara IDF (Inverse Document Frequency) mengukur seberapa jarang suatu kata muncul di seluruh koleksi dokumen. Kombinasi TF dan IDF menghasilkan bobot tinggi untuk kata-kata yang sering muncul dalam dokumen tertentu

namun jarang ditemukan di dokumen lainnya, sehingga kata-kata tersebut dianggap lebih informatif dan khas untuk dokumen tersebut. TF-IDF telah banyak digunakan sebagai metode ekstraksi fitur dalam berbagai tugas klasifikasi teks, termasuk analisis sentimen.

Algoritma Naive Bayes

Naive Bayes adalah algoritma klasifikasi yang berlandaskan teorema Bayes dengan asumsi independensi antar fitur (naive assumption). Meskipun asumsi ini jarang terpenuhi dalam praktik, algoritma Naive Bayes tetap menunjukkan performa yang baik dalam berbagai tugas klasifikasi teks karena kemampuannya menangani data berdimensi tinggi secara efisien [7, 8]. Untuk klasifikasi teks, varian Multinomial Naive Bayes umumnya digunakan karena sesuai dengan karakteristik data frekuensi kata. Algoritma ini bekerja dengan menghitung probabilitas posterior setiap kelas berdasarkan fitur-fitur yang ada, lalu mengklasifikasikan dokumen ke kelas dengan probabilitas posterior tertinggi. Keunggulan Naive Bayes adalah waktu pelatihan yang cepat, kebutuhan data pelatihan yang relatif sedikit, dan kemampuannya menangani fitur yang sangat banyak. Berbagai penelitian terdahulu telah membuktikan efektivitas Naive Bayes dalam analisis sentimen ulasan aplikasi mobile, termasuk untuk aplikasi fintech.

Algoritma Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang bekerja dengan mencari hyperplane optimal yang memisahkan data dari dua kelas berbeda dengan margin terbesar. Dalam ruang fitur berdimensi tinggi seperti representasi teks, SVM sering menunjukkan performa yang unggul dibandingkan algoritma lainnya karena kemampuannya menangani data yang tidak dapat dipisahkan secara linear melalui penggunaan kernel trick.

Untuk klasifikasi multi-kelas, SVM menggunakan strategi One-vs-Rest (OvR) atau One-vs-One (OVO). Kernel yang umum digunakan dalam klasifikasi teks adalah kernel linear, karena data teks yang direpresentasikan dengan TF-IDF biasanya sudah dapat dipisahkan dengan baik secara linear di ruang fitur berdimensi tinggi [14]. Berbagai penelitian telah mengkonfirmasi efektivitas SVM untuk analisis sentimen ulasan aplikasi, termasuk untuk aplikasi DANA dan berbagai aplikasi digital lainnya.

Algoritma Logistic Regression

Logistic Regression adalah algoritma klasifikasi yang menggunakan fungsi sigmoid (logistik) untuk memodelkan probabilitas suatu data termasuk ke dalam kelas tertentu. Meskipun namanya mengandung kata 'regression', Logistic Regression pada dasarnya adalah algoritma klasifikasi yang banyak digunakan untuk tugas klasifikasi biner maupun multi-kelas. Dalam konteks analisis sentimen, Logistic Regression memodelkan hubungan antara fitur teks (bobot TF-IDF) dengan label sentimen melalui estimasi parameter menggunakan metode Maximum Likelihood Estimation.

Keunggulan Logistic Regression terletak pada interpretabilitas modelnya, karena bobot parameter yang dihasilkan dapat menunjukkan kontribusi masing-masing fitur (kata) terhadap prediksi sentimen. Selain itu, Logistic Regression memiliki kompleksitas komputasi yang relatif rendah dan performa yang kompetitif untuk klasifikasi teks [16]. Beberapa penelitian menunjukkan bahwa Logistic Regression mampu bersaing bahkan mengungguli SVM dan Naive Bayes dalam tugas analisis sentimen tertentu.

METODE PENELITIAN

Penelitian ini dilakukan melalui delapan tahapan, yaitu pengumpulan data, eksplorasi dataset, preprocessing, pelabelan sentimen, ekstraksi fitur menggunakan TF-IDF, pembagian data latih dan data uji, pemodelan machine learning, serta evaluasi dan perbandingan performa model. Seluruh proses diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan pustaka pandas, numpy, scikit-learn, dan Sastrawi.

Data penelitian berupa ulasan pengguna aplikasi DANA dan SeaBank yang diperoleh melalui proses scraping dari Google Play Store. Data yang dikumpulkan meliputi teks ulasan dan nilai rating, kemudian disimpan dalam format .xlsx dan diolah menggunakan pandas untuk proses analisis lebih lanjut.

HASIL DAN PEMBAHASAN

Gambaran Umum Hasil Penelitian

Penelitian ini berhasil mengimplementasikan analisis sentimen komparatif terhadap ulasan pengguna aplikasi DANA dan SeaBank menggunakan tiga algoritma machine learning, yaitu Naive Bayes, Support Vector Machine (SVM), dan Logistic Regression. Proses penelitian dilaksanakan melalui beberapa tahapan sistematis yang dimulai dari pengumpulan data, preprocessing, ekstraksi fitur, pemodelan, hingga evaluasi performa model.

Dataset yang digunakan dalam penelitian ini terdiri dari 3.997 ulasan pengguna yang valid setelah melalui proses pembersihan data anomali. Data tersebut kemudian dibagi menjadi dua subset, yaitu data latih (training set) sebanyak 3.197 sampel (80%) dan data uji (testing set) sebanyak 800 sampel (20%). Pembagian data dilakukan dengan teknik stratified sampling untuk memastikan distribusi kelas sentimen yang proporsional pada kedua subset data.

Distribusi Sentimen Ulasan Pengguna

Distribusi Sentimen Keseluruhan. Berdasarkan hasil pelabelan sentimen yang dilakukan berdasarkan rating pengguna, diperoleh distribusi sentimen seperti yang ditunjukkan pada Tabel 1.

Tabel 1. Distribusi Sentimen Ulasan Pengguna

Label Sentimen	Jumlah Ulasan	Persentase
Positif	3.270	81,81%
Negatif	599	14,99%
Netral	128	3,20%
Total	3.997	100%

Dari Tabel 1 dapat dilihat bahwa sebagian besar ulasan pengguna (81,81%) bernilai sentimen positif, yang mengindikasikan bahwa mayoritas pengguna merasa puas dengan layanan aplikasi DANA dan SeaBank. Ulasan negatif mencapai 14,99% dari total data, sementara ulasan netral hanya 3,20%. Tingginya proporsi sentimen positif menunjukkan bahwa secara umum, kedua aplikasi fintech ini telah memberikan pengalaman yang memuaskan bagi penggunanya.

Distribusi Sentimen Per Aplikasi

Untuk mendapatkan pemahaman yang lebih mendalam, dilakukan analisis distribusi sentimen secara terpisah untuk masing-masing aplikasi. Hasilnya disajikan pada Tabel 4.2.


Tabel 2 Distribusi Sentimen Berdasarkan Aplikasi

Aplikasi	Negatif	Netral	Positif	Total
DANA	477	78	1.444	1.999
SeaBank	122	50	1.826	1.998
Total	599	128	3.270	3.997

Dari Tabel 2 terlihat perbedaan pola sentimen yang menarik antara kedua aplikasi. Aplikasi SeaBank menunjukkan proporsi sentimen positif yang lebih tinggi (91,39%) dibandingkan DANA

(72,24%). Sebaliknya, DANA memiliki proporsi ulasan negatif yang lebih tinggi (23,86%) dibandingkan SeaBank (6,11%). Perbedaan ini dapat dijelaskan oleh beberapa faktor:

1. Karakteristik Layanan: DANA sebagai e-wallet memiliki kompleksitas transaksi yang lebih tinggi dengan berbagai fitur pembayaran, transfer, dan top-up yang dapat menimbulkan lebih banyak masalah teknis. Sementara SeaBank sebagai bank digital memiliki fokus yang lebih sempit pada layanan tabungan dan transfer.
2. Ekspektasi Pengguna: Pengguna e-wallet seperti DANA cenderung memiliki ekspektasi yang lebih tinggi terhadap kecepatan dan ketersediaan layanan, sehingga lebih mudah kecewa ketika mengalami kendala.
3. Integrasi Ekosistem: SeaBank yang terintegrasi dengan ekosistem Shopee mungkin memberikan pengalaman yang lebih seamless bagi pengguna yang aktif dalam ekosistem tersebut.



Gambar Gambar 1 Distribusi Sentimen Ulasan Pengguna per Aplikasi

Gambar 1 menunjukkan perbandingan jumlah ulasan berdasarkan kategori sentimen (negatif, netral, dan positif) untuk masing-masing aplikasi, yaitu DANA dan SeaBank. Berdasarkan diagram batang tersebut, dapat dianalisis bahwa:

1. Aplikasi DANA didominasi oleh ulasan positif sebanyak 1.444 ulasan, diikuti oleh ulasan negatif sebanyak 477 ulasan, dan ulasan netral sebanyak 78 ulasan.
2. Aplikasi SeaBank juga didominasi oleh ulasan positif, namun dengan jumlah yang jauh lebih besar yaitu 1.826 ulasan. Ulasan negatifnya hanya berjumlah 122 ulasan, dan ulasan netral sebanyak 50 ulasan.

Secara visual terlihat bahwa proporsi ulasan negatif pada DANA jauh lebih mendominasi dibandingkan pada SeaBank. Hal ini mengindikasikan bahwa secara keseluruhan, pengguna SeaBank memiliki tingkat kepuasan yang lebih tinggi. Besarnya jumlah ulasan negatif pada DANA menunjukkan bahwa aplikasi *e-wallet* ini masih memiliki lebih banyak keluhan atau kendala teknis yang dialami oleh penggunanya dibandingkan dengan aplikasi bank digital SeaBank.

Ekstraksi Fitur TF-IDF

Proses ekstraksi fitur menggunakan metode TF-IDF menghasilkan representasi vector numerik dari teks ulasan yang telah melalui preprocessing. Dari 3.997 dokumen ulasan, diekstraksi sebanyak 2.935 fitur unik yang merepresentasikan kata-kata informatif dari korpus dokumen.

Fitur-fitur dengan bobot TF-IDF tertinggi umumnya merupakan kata-kata yang sering muncul dalam konteks tertentu namun tidak terlalu umum di seluruh dokumen. Contoh kata-kata dengan bobot tinggi antara lain: "mantap", "lancar", "mudah", "cepat", "error", "gagal", "lemot", yang masing-masing merefleksikan sentimen positif maupun negatif.

Penggunaan TF-IDF sebagai metode ekstraksi fitur dinilai tepat karena mampu memberikan penekanan lebih pada kata-kata yang khas dan informatif untuk setiap dokumen, sambil mengurangi bobot kata-kata yang terlalu umum.

Evaluasi Performa Model


Hasil Evaluasi Secara Keseluruhan. Evaluasi performa ketiga model machine learning dilakukan menggunakan empat metrik utama, yaitu akurasi, presisi, recall, dan F1-score. Hasil evaluasi pada data uji (800 sampel) disajikan pada Tabel 4.3.

Tabel 3. Hasil Evaluasi Performa Model

Model	Accuracy	Precision	Recall	F1-Score
Naive Bayes	0,8588	0,8203	0,8588	0,8275
SVM	0,8775	0,8413	0,8775	0,8556
Logistic Regression	0,8775	0,8412	0,8775	0,8551

Dari Tabel 3 dapat dilihat bahwa:

1. Support Vector Machine (SVM) dan Logistic Regression menunjukkan performa yang sangat kompetitif dengan nilai akurasi yang identik (0,8775 atau 87,75%). Kedua algoritma ini berhasil mengklasifikasikan sentimen dengan benar pada 702 dari 800 data uji.
2. Naive Bayes menunjukkan performa yang sedikit lebih rendah dengan akurasi 0,8588 (85,88%), yang masih tergolong baik untuk tugas klasifikasi sentimen.
3. Dari segi presisi, SVM unggul tipis dengan nilai 0,8413 dibandingkan Logistic Regression (0,8412) dan Naive Bayes (0,8203). Presisi yang tinggi menunjukkan bahwa ketika model memprediksi suatu kelas, prediksi tersebut memiliki kemungkinan besar untuk benar.
4. Nilai recall yang identik antara SVM dan Logistic Regression (0,8775) menunjukkan kemampuan yang sama dalam mengidentifikasi semua instance dari setiap kelas sentimen.
5. F1-Score, yang merupakan harmonic mean dari presisi dan recall, menunjukkan bahwa SVM memiliki performa yang paling seimbang dengan nilai 0,8556, diikuti Logistic Regression (0,8551) dan Naive Bayes (0,8275).



Gambar 1. Perbandingan Performa Model

Gambar 2 memvisualisasikan perbandingan performa ketiga algoritma *machine learning* (Naive Bayes, SVM, dan Logistic Regression) berdasarkan empat metrik evaluasi: *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Dari diagram batang tersebut, dapat dilihat bahwa:

1. SVM dan Logistic Regression menunjukkan performa yang hampir identik dan merupakan yang terbaik. Keduanya berhasil mencapai nilai *Accuracy* dan *Recall* tertinggi sebesar 0,8775 (87,75%), serta nilai *F1-Score* yang sangat kompetitif yaitu 0,8556 untuk SVM dan 0,8551 untuk Logistic Regression.
2. Naive Bayes berada di posisi ketiga dengan nilai yang sedikit lebih rendah, yaitu *Accuracy* sebesar 0,8587 (85,87%) dan *F1-Score* sebesar 0,8275.

- Secara visual, batang untuk SVM dan Logistic Regression terlihat lebih tinggi dan sejajar pada hampir semua metrik. Hal ini mengonfirmasi bahwa kedua algoritma ini lebih optimal dalam menangani dataset ulasan aplikasi *fintech* dibandingkan Naive Bayes. Meskipun demikian, selisih performa antar ketiga model tidak terlalu signifikan (hanya berselisih sekitar 2% pada akurasi), yang menunjukkan bahwa ketiganya tetap layak digunakan untuk kasus ini.

Evaluasi Per Kelas Sentimen

Untuk mendapatkan pemahaman yang lebih mendalam, dilakukan evaluasi performa model untuk setiap kelas sentimen secara terpisah. Hasil lengkapnya disajikan pada Tabel 4.4, 4.5, dan 4.6.

Tabel 4. Classification Report - Naive Bayes

Kelas	Precision	Recall	F1-Score	Support
Negatif	0,73	0,37	0,49	120
Netral	0,00	0,00	0,00	26
Positif	0,87	0,98	0,92	654
Kelas	Precision	Recall	F1-Score	Support
Negatif	0,73	0,37	0,49	120
Netral	0,00	0,00	0,00	26
Positif	0,87	0,98	0,92	654
Accuracy				0,86
Macro Avg	0,53	0,45	0,47	800
Weighted Avg	0,82	0,86	0,83	800

Tabel 5. Classification Report - SVM

Kelas	Precision	Recall	F1-Score	Support
Negatif	0,72	0,53	0,61	120
Netral	0,00	0,00	0,00	26
Positif	0,90	0,98	0,93	654
Accuracy				0,88
Macro Avg	0,54	0,5	0,51	800
Weighted Avg	0,84	0,88	0,86	800

Tabel 6. Classification Report - Logistic Regression

Kelas	Precision	Recall	F1-Score	Support
Negatif	0,73	0,52	0,60	120
Netral	0,00	0,00	0,00	26
Positif	0,90	0,98	0,93	654
Accuracy				0,88
Macro Avg	0,54	0,5	0,51	800
Weighted Avg	0,84	0,88	0,86	800

Dari ketiga classification report di atas, dapat dianalisis beberapa temuan penting:

- Kelas Positif: Ketiga model menunjukkan performa yang sangat baik dalam mengklasifikasikan sentimen positif, dengan recall mencapai 0,98 (98%). Ini berarti hampir semua ulasan positif berhasil diidentifikasi dengan benar. Precision untuk kelas positif juga tinggi (0,87-0,90), menunjukkan bahwa prediksi positif yang dihasilkan model sangat akurat.

2. Kelas Negatif: Performa untuk kelas negatif lebih bervariasi. SVM menunjukkan recall terbaik (0,53) diikuti Logistic Regression (0,52) dan Naive Bayes (0,37). Precision untuk kelas negatif berkisar antara 0,72-0,73, yang menunjukkan bahwa ketika model memprediksi negatif, prediksi tersebut cukup akurat. Namun, rendahnya recall (terutama pada Naive Bayes) menunjukkan bahwa masih banyak ulasan negatif yang terlewat dan terklasifikasi sebagai kelas lain.
3. Kelas Netral: Ketiga model gagal mengklasifikasikan kelas netral dengan baik, ditunjukkan oleh precision, recall, dan F1-score yang bernilai 0,00. Hal ini disebabkan oleh beberapa faktor:
 - a. Jumlah data netral yang sangat sedikit (hanya 26 sampel atau 3,25% dari data uji)
 - b. Karakteristik teks ulasan netral yang seringkali ambigu dan sulit dibedakan dari ulasan positif atau negatif
 - c. Kemungkinan ketidakseimbangan kelas (class imbalance) yang ekstrem
4. Weighted Average: Metrik weighted average yang memperhitungkan proporsi setiap kelas menunjukkan bahwa SVM dan Logistic Regression memiliki performa yang identik (0,84 precision, 0,88 recall, 0,86 F1-score), mengungguli Naive Bayes (0,82 precision, 0,86 recall, 0,83 F1-score).

Analisis Confusion Matrix

Confusion matrix memberikan gambaran detail tentang pola kesalahan klasifikasi yang dilakukan oleh masing-masing model. Berikut adalah analisis confusion matrix untuk ketiga model.

Tabel 7. Confusion Matrix - Naive Bayes

Actual \ Predicted	Negatif	Netral	Positif
Negatif	44	0	76
Netral	3	0	23
Positif	13	0	641

Tabel 8. Confusion Matrix - SVM

Actual \ Predicted	Negatif	Netral	Positif
Negatif	64	0	56
Netral	15	0	11
Positif	10	0	644


Tabel 9. Confusion Matrix - Logistic Regression

Actual \ Predicted	Negatif	Netral	Positif
Negatif	62	0	58
Netral	10	0	16
Positif	13	0	641

Dari confusion matrix di atas, dapat dianalisis beberapa pola:

1. True Positives (Diagonal Utama):
 - a. SVM berhasil mengklasifikasikan 64 ulasan negatif dan 644 ulasan positif dengan benar
 - b. Logistic Regression mengklasifikasikan 62 negatif dan 641 positif dengan benar
 - c. Naive Bayes mengklasifikasikan 44 negatif dan 641 positif dengan benar
 - d. Tidak ada satupun model yang berhasil mengklasifikasikan ulasan netral dengan benar
2. False Negatives (Ulasan Negatif yang Terprediksi Positif):
 - a. Naive Bayes memiliki false negative tertinggi (76 ulasan negatif terprediksi sebagai positif)
 - b. SVM memiliki false negative terendah (56 ulasan)
 - c. Logistic Regression berada di tengah (58 ulasan)
 - d. Pola ini menunjukkan kecenderungan model untuk memprediksi ulasan sebagai positif

3. False Positives (Ulasan Positif yang Terprediksi Negatif):
 - a. Ketiga model menunjukkan false positive yang relatif rendah (10-13 ulasan)
 - b. Ini menunjukkan bahwa model cukup konservatif dalam memprediksi kelas negatif
4. Kelas Netral: Tidak ada satupun model yang berhasil mengklasifikasikan ulasan netral dengan benar (ditunjukkan oleh nilai 0 pada diagonal kelas netral). Namun, kesalahan prediksinya terbagi dua: sebagian besar ulasan netral salah diprediksi sebagai kelas Positif, namun ada sebagian kecil yang salah diprediksi sebagai kelas Negatif (3 data pada Naive Bayes, 15 data pada SVM, dan 10 data pada Logistic Regression). Fenomena ini mengindikasikan bahwa model tidak mampu membedakan karakteristik teks netral dan cenderung melemparnya ke kelas mayoritas (positif) atau kelas minoritas lainnya (negatif).
- 5.



Gambar 3 Confusion Matrix Ketiga Model

Gambar 3 menampilkan *confusion matrix* dari ketiga model yang diuji pada 800 data uji. *Confusion matrix* ini merinci berapa banyak data yang berhasil diprediksi dengan benar (nilai pada diagonal utama) dan berapa banyak yang salah prediksi (nilai di luar diagonal). Berdasarkan gambar tersebut, terlihat pola yang konsisten pada ketiga model sebagai berikut:

1. Kelas Positif: Ketiga model berhasil memprediksi kelas positif dengan sangat baik. Dari total 654 data uji kelas positif, masing-masing model berhasil memprediksi dengan benar sekitar 98% dari data tersebut (*Recall* 0,98). Hal ini terlihat dari nilai yang paling besar pada kotak diagonal kelas positif di ketiga matriks.
2. Kelas Negatif: SVM menjadi model yang terbaik dalam mendeteksi kelas negatif, yaitu berhasil memprediksi dengan benar 53% dari 120 data uji negatif (sekitar 64 data). Diikuti oleh Logistic Regression yang berhasil mendeteksi 52% (sekitar 62 data), dan Naive Bayes yang hanya berhasil mendeteksi 37% (sekitar 44 data). Banyak data negatif pada Naive Bayes yang salah diprediksi sebagai positif (*False Negatives*).
3. Kelas Netral (Anomali): Terlihat jelas pada ketiga matriks bahwa tidak ada satupun data netral yang berhasil diprediksi dengan benar (ditunjukkan dengan nilai 0 pada diagonal kelas netral). Seluruh 26 data uji untuk kelas netral salah diprediksi ke dalam kelas positif. Fenomena ini terjadi karena ketidakseimbangan kelas (*class imbalance*) yang ekstrem, di mana data netral hanya berjumlah sangat sedikit (3,2% dari total data). Akibatnya, model *machine learning* cenderung mengabaikan kelas minoritas ini dan memprediksi semua data yang ambigu ke kelas mayoritas (positif).

Pembahasan

Perbandingan Performa Algoritma

Berdasarkan hasil evaluasi yang telah dipaparkan, dapat disimpulkan bahwa Support Vector Machine (SVM) dan Logistic Regression menunjukkan performa yang sangat kompetitif dan hampir identik dalam tugas klasifikasi sentimen ulasan aplikasi fintech. Kedua algoritma ini mengungguli Naive Bayes pada hampir semua metrik evaluasi.

Keunggulan SVM dan Logistic Regression dapat dijelaskan oleh beberapa faktor:

1. Kemampuan Menangani Fitur Kompleks: SVM dengan kernel yang tepat dan Logistic Regression mampu memodelkan hubungan non-linear yang kompleks antara fitur TF-IDF dan label sentimen. Sementara Naive Bayes membuat asumsi independensi yang kuat antar fitur yang jarang terpenuhi dalam data teks nyata.
2. Robustness terhadap Noise: SVM dikenal robust terhadap noise dan outliers dalam data, yang merupakan karakteristik umum dari ulasan pengguna di Google Play Store.
3. Optimisasi Margin: SVM bekerja dengan memaksimalkan margin antara kelas-kelas yang berbeda, yang menghasilkan generalisasi yang lebih baik pada data uji.

Namun, perbedaan performa antara ketiga algoritma tidak terlalu signifikan (perbedaan akurasi hanya sekitar 2%). Hal ini menunjukkan bahwa untuk dataset dengan karakteristik seperti ini, ketiga algoritma dapat dipertimbangkan dengan trade-off yang berbeda:

- Naive Bayes: Kecepatan pelatihan dan inferensi yang sangat tinggi, cocok untuk aplikasi real-time
- SVM: Performa terbaik secara keseluruhan, namun waktu pelatihan lebih lama
- Logistic Regression: Performa yang hampir sama dengan SVM dengan interpretabilitas model yang lebih baik

Analisis Sentimen DANA vs SeaBank

Temuan menarik dari penelitian ini adalah perbedaan pola sentimen yang signifikan antara DANA dan SeaBank. SeaBank menunjukkan tingkat kepuasan pengguna yang jauh lebih tinggi dengan 91,39% ulasan positif, dibandingkan DANA yang hanya 72,24%.

Beberapa faktor yang mungkin menjelaskan perbedaan ini:

1. Kompleksitas Layanan: DANA sebagai e-wallet menawarkan beragam fitur yang kompleks (pembayaran merchant, transfer, top-up, pembayaran tagihan, dll), yang meningkatkan kemungkinan terjadinya masalah teknis atau kebingungan pengguna. SeaBank memiliki fokus yang lebih sempit pada layanan tabungan dan transfer.
2. Ekspektasi Pengguna: Pengguna e-wallet cenderung memiliki ekspektasi yang lebih tinggi terhadap kecepatan dan ketersediaan layanan 24/7. Ketika terjadi gangguan, pengguna lebih mudah kecewa dan memberikan ulasan negatif.
3. Maturitas Produk: DANA yang telah beroperasi lebih lama mungkin menghadapi masalah teknis yang lebih kompleks seiring dengan penambahan fitur dan peningkatan jumlah pengguna. SeaBank yang relatif lebih baru mungkin masih dalam tahap pertumbuhan yang lebih terkontrol.
4. Integrasi Ekosistem: SeaBank yang terintegrasi dengan ekosistem Shopee memberikan nilai tambah bagi pengguna yang aktif berbelanja online, sehingga meningkatkan kepuasan secara keseluruhan.
5. Customer Support: Perbedaan kualitas layanan pelanggan dan respons terhadap keluhan pengguna juga dapat berkontribusi pada perbedaan sentimen.

Tantangan Klasifikasi Sentimen Netral

Salah satu temuan penting dari penelitian ini adalah kesulitan model dalam mengklasifikasikan sentimen netral. Ketiga model gagal mengidentifikasi satupun ulasan netral dengan benar. Fenomena ini dapat dijelaskan oleh beberapa faktor:

1. Class Imbalance Ekstrem: Kelas netral hanya merepresentasikan 3,2% dari total data, yang menyebabkan model tidak memiliki cukup contoh untuk belajar pola karakteristik kelas ini.
2. Ambiguitas Bahasa: Ulasan netral seringkali menggunakan bahasa yang ambigu atau campuran antara aspek positif dan negatif, yang membuatnya sulit diklasifikasikan.
3. Kualitas Label: Pelabelan berdasarkan rating 3 bintang mungkin tidak sepenuhnya akurat merepresentasikan sentimen netral. Beberapa pengguna mungkin memberikan rating 3 untuk alasan yang berbeda-beda.
4. Fitur yang Tidak Membeda: Kata-kata dalam ulasan netral mungkin tidak memiliki daya pembeda yang kuat dibandingkan dengan ulasan positif atau negatif.

Untuk mengatasi masalah ini, beberapa strategi yang dapat dipertimbangkan:

- a. Pengumpulan data netral yang lebih banyak
- b. Penggunaan teknik oversampling (seperti SMOTE) atau undersampling
- c. Pendekatan klasifikasi hierarkis atau one-vs-rest yang lebih sophisticated
- d. Penggunaan deep learning yang mampu menangkap konteks lebih baik

Bab ini telah memaparkan hasil dan pembahasan dari penelitian analisis sentiment komparatif aplikasi DANA dan SeaBank. Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa dari 3.997 ulasan yang dianalisis, mayoritas (81,81%) bernilai sentimen positif, diikuti negatif (14,99%) dan netral (3,20%). SeaBank menunjukkan tingkat kepuasan pengguna yang lebih tinggi (91,39% positif) dibandingkan DANA (72,24% positif). SVM dan Logistic Regression menunjukkan performa terbaik dengan akurasi 87,75%, mengungguli Naive Bayes (85,88%). Ketiga model mengalami kesulitan dalam mengklasifikasikan sentimen netral akibat class imbalance yang ekstrem. SVM direkomendasikan sebagai algoritma terbaik untuk kasus ini, dengan pertimbangan performa dan robustness.

Hasil penelitian ini memberikan kontribusi dalam pemahaman tentang perbedaan sentimen pengguna antara layanan e-wallet dan bank digital, serta memberikan rekomendasi algoritma machine learning yang optimal untuk analisis sentimen aplikasi fintech di Indonesia.

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil penelitian dan pembahasan mengenai analisis komparatif sentimen dan pola ulasan pengguna aplikasi DANA dan SeaBank menggunakan algoritma *Naive Bayes*, *Support Vector Machine* (SVM), dan *Logistic Regression*, maka dapat ditarik beberapa kesimpulan utama sebagai berikut:

Pola Sentimen Pengguna Fintech Terdapat perbedaan pola sentimen yang signifikan antara aplikasi *e-wallet* (DANA) dan bank digital (SeaBank). SeaBank memiliki tingkat kepuasan pengguna yang jauh lebih tinggi dengan dominasi ulasan positif mencapai 91,39%, sedangkan DANA memiliki ulasan positif sebesar 72,24% namun dengan proporsi ulasan negatif yang lebih besar (23,86% dibandingkan SeaBank yang hanya 6,11%). Hal ini mengindikasikan bahwa kompleksitas fitur pada *e-wallet* berpotensi memunculkan lebih banyak kendala teknis atau keluhan pengguna dibandingkan layanan bank digital yang lebih terfokus. Performa Komparatif Algoritma *Machine Learning* Dari ketiga algoritma yang diuji, Support Vector Machine (SVM) dan Logistic Regression menunjukkan performa yang paling optimal dan hampir identik, dengan nilai akurasi tertinggi sebesar 87,75%. Namun, SVM unggul tipis dalam hal Presisi (84,13%) dan F1-Score (85,56%) dibandingkan Logistic Regression. Algoritma *Naive Bayes* berada di posisi ketiga dengan akurasi 85,88%. Dengan demikian, SVM dapat direkomendasikan sebagai algoritma terbaik untuk kasus klasifikasi sentimen pada dataset ulasan aplikasi *fintech* ini karena kemampuannya menangani fitur TF-IDF berdimensi tinggi secara robust.

Klasifikasi Per Kelas dan Anomali Kelas Netral Ketiga model terbukti sangat handal dalam mengklasifikasikan sentimen positif dengan nilai *Recall* mencapai 0,98 (98%). Namun, ditemukan anomali signifikan di mana ketiga model gagal total (0,00) dalam mengklasifikasikan kelas netral. Kegagalan ini disebabkan oleh ketidakseimbangan kelas (*class imbalance*) yang ekstrem, di mana data netral hanya merepresentasikan 3,20% dari total dataset (hanya 26 sampel pada data uji), serta adanya ambiguitas semantik pada teks ulasan yang memberikan rating bintang 3. Kemudian, Efektivitas Preprocessing dan TF-IDF Tahapan *preprocessing* teks menggunakan *Sastrawi* (meliputi *case folding*, *cleaning*, *stopword removal*, dan *stemming*) yang dikombinasikan dengan ekstraksi fitur TF-IDF terbukti efektif dalam mereduksi noise dan menghasilkan 2.935 fitur informatif yang mampu membedakan polaritas sentimen positif dan negatif dengan baik.

Saran

Berdasarkan hasil penelitian dan keterbatasan yang ditemukan, berikut beberapa saran untuk penelitian selanjutnya dan penerapan praktis.

1. Saran untuk Penelitian Selanjutnya

- **Penanganan Ketidakseimbangan Kelas**
Penelitian selanjutnya disarankan menerapkan teknik oversampling (SMOTE atau ADASYN) maupun undersampling untuk mengatasi ketidakseimbangan kelas. Alternatif lainnya adalah menggunakan klasifikasi biner (positif dan negatif) dengan menghilangkan kelas netral yang cenderung ambigu.
- **Penerapan Deep Learning**
Penggunaan representasi teks berbasis Deep Learning, seperti Word2Vec, FastText, atau IndoBERT, disarankan untuk meningkatkan kemampuan model dalam memahami konteks dan ambiguitas pada ulasan, khususnya kelas netral.
- **Analisis Sentimen Berbasis Aspek**
Penelitian berikutnya dapat menerapkan Aspect-Based Sentiment Analysis (ABSA) agar sentimen terhadap aspek tertentu, seperti transaksi, UI/UX, layanan pelanggan, dan keamanan, dapat dianalisis secara lebih rinci.
- **Optimasi Hyperparameter**
Penelitian selanjutnya disarankan melakukan hyperparameter tuning menggunakan GridSearchCV atau RandomizedSearchCV untuk memperoleh konfigurasi model yang lebih optimal, termasuk pengujian kernel Linear pada SVM.

2. Saran Praktis bagi Pengembang Aplikasi

- **Pengembang DANA**
Tingginya ulasan negatif menunjukkan perlunya peningkatan stabilitas sistem, kelancaran transaksi, kemudahan antarmuka, serta responsivitas layanan pelanggan guna meningkatkan kepuasan pengguna.
- **Pengembang SeaBank**
SeaBank disarankan mempertahankan kualitas layanan yang telah memperoleh tingkat kepuasan tinggi serta terus mengoptimalkan integrasi dengan ekosistem Shopee sebagai keunggulan kompetitif.
- **Monitoring Sentimen Berkelanjutan**
DANA dan SeaBank disarankan mengimplementasikan model machine learning yang telah dibangun sebagai sistem pemantauan sentimen secara berkala agar perubahan persepsi pengguna dapat dideteksi dan ditindaklanjuti lebih cepat.

DAFTAR PUSTAKA

- Angin, P. W. P. (2025). Analisis model bisnis, produk dan layanan bank digital SeaBank. *Musyari: Jurnal Manajemen, Akuntansi, dan Ekonomi*, 19(9), 71–80.
- Hadna, N. M. S., Santosa, P. I., & Winarno, W. W. (2016). Studi literatur tentang perbandingan metode untuk proses analisis sentimen di Twitter. *Semin. Nas. Teknol. Inf. dan Komun*, 2016, 57–64.
- Hondro, O. (2023). Analisis sentimen pengguna aplikasi e-wallet Dana melalui postingan di media sosial Twitter menggunakan Naïve Bayes. *KETIK: Jurnal Informatika*, 1(01), 27–31.
- Nurian, A. (2023). Analisis sentimen ulasan pengguna aplikasi Google Play menggunakan Naïve Bayes. *Jurnal Informatika dan Teknik Elektro Terapan*, 11(3s1).
- Giovani, A. P., Ardiansyah, A., Haryanti, T., Kurniawati, L., & Gata, W. (2020). Analisis sentimen aplikasi Ruang Guru di Twitter menggunakan algoritma klasifikasi. *Jurnal Teknoinfo*, 14(2), 115.
- Gunawan, B., Sastypratiwi, H., & Pratama, E. E. (2018). Sistem analisis sentimen pada ulasan produk menggunakan metode Naive Bayes. *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, 4(2), 113–118.
- Kevin, K., Enjeli, M., & Wijaya, A. (2024). Analisis sentimen penggunaan aplikasi KineMaster menggunakan metode Naive Bayes. *Jurnal Ilmiah Computer Science*, 2(2), 89–98.
- Darwis, D., Siskawati, N., & Abidin, Z. (2021). Penerapan algoritma Naive Bayes untuk analisis sentimen review data Twitter BMKG Nasional. *Jurnal Tekno Kompak*, 15(1), 131.
- Tanggaraeni, A. I., & Sitokdana, M. N. (2022). Analisis sentimen aplikasi e-government pada Google Play menggunakan algoritma Naïve Bayes. *JATISI*, 9(2), 785–795.
- Nugroho, D. G., Chrisnanto, Y. H., & Wahana, A. (2016). Analisis sentimen pada jasa ojek online menggunakan metode Naive Bayes. *Prosiding Sains Nasional dan Teknologi*, 1(1).
- Insan, M. K. K., Hayati, U., & Nurdian, O. (2023). Analisis sentimen aplikasi BRImo pada ulasan pengguna di Google Play menggunakan algoritma Naive Bayes. *JATI*, 7(1), 478–483.
- Idris, I. S. K., Mustofa, Y. A., & Salihi, I. A. (2023). Analisis sentimen terhadap penggunaan aplikasi Shopee menggunakan algoritma Support Vector Machine (SVM). *Jambura Journal of Electrical and Electronics Engineering*, 5(1), 32–35.
- Gifari, O. I., Adha, M., Hendrawan, I. R., & Durrand, F. F. S. (2022). Analisis sentimen review film menggunakan TF-IDF dan Support Vector Machine. *Journal of Information Technology*, 2(1), 36–40.
- Novantika, A., & Sugiman, S. (2022). Analisis sentimen ulasan pengguna aplikasi video conference Google Meet menggunakan metode SVM dan Logistic Regression. *PRISMA, Prosiding Seminar Nasional Matematika*, 5, 808–813.
- Ramadhani, B., & Suryono, R. R. (2024). Komparasi algoritma Naïve Bayes dan Logistic Regression untuk analisis sentimen Metaverse. *Vol. 8*, 714–725.
- Saputro, W. E., Yuana, H., & Puspitasari, W. D. (2023). Analisis sentimen pengguna dompet digital Dana pada kolom komentar Google Play Store dengan metode klasifikasi Support Vector Machine. *JATI*, 7(2), 1151–1156.
- Rifa, M. K. R., Totohendarto, M. H., & Muttaqin, M. R. (2023). Analisis sentimen pengguna e-wallet Dana dan Gopay pada Twitter menggunakan metode Support Vector Machine (SVM). *TEKNIKA*, 17(2), 323.

- Putri, N. Z., Martanto, M., Dikananda, A. R., & Rifa'i, A. (2025). Analisis sentimen aplikasi SeaBank dengan algoritma Naive Bayes untuk optimalisasi pelayanan. *Jurnal Informatika Terpadu*, 11(1), 55–62.
- Ferdiana, R., Jatmiko, F., Purwanti, D. D., Ayu, A. S. T., & Dicka, W. F. (2019). Dataset Indonesia untuk analisis sentimen. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI)*, 8(4), 334–339.
- Lindinillah, E. R., Rohana, T., & Juwita, A. R. (2023). Analisis sentimen Twitter terhadap Steam menggunakan algoritma Logistic Regression dan Support Vector Machine. *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, 10(2), 154–164.
- Indriyani, F. A., Fauzi, A., & Faisal, S. (2023). Analisis sentimen aplikasi TikTok menggunakan algoritma Naïve Bayes dan Support Vector Machine. *TEKNOSAINS: Jurnal Sains, Teknologi dan Informatika*, 10(2), 176–184.